



**Detección de Humedales con Imágenes Radar de Apertura Sintética (SAR) Aéreas y Satelitales. Caso de Estudio: Zona Central del Municipio de Popayán (Cauca).**

**John Fander Higidio Castro**

**Universidad del Cauca  
Programa de Maestría en Geomática  
Facultad de Ingeniería Civil  
Popayán  
2023**



**Detección de Humedales con Imágenes Radar de  
Apertura Sintética (SAR) Aéreas y Satelitales.  
Caso de Estudio: Zona Central del Municipio de  
Popayán (Cauca).**

**John Fander Higidio Castro**  
Ingeniero Ambiental

Tesis de grado presentado como requisito parcial para optar al título de:  
**Magister en Geomática**

Director:  
Ph.D. Nixon Alexander Correa Muñoz

Línea de Investigación:  
Percepción Remota

**Universidad del Cauca**  
**Programa de Maestría en Geomática**  
**Facultad de Ingeniería Civil**  
**Popayán**  
**2023**



# Aceptación

Documento final del trabajo de grado titulado Detección de Humedales con Imágenes Radar de Apertura Sintética (SAR) Aéreas y Satelitales. Caso de Estudio: Zona Central del Municipio de Popayán (Cauca).”; realizado por el estudiante John Fander Higidio Castro, se autoriza la sustentación del mismo para optar al título de de Magister en Geomática. Facultad de Ingeniería Civil de la Universidad del Cauca. Programa Maestría en Geomática.

---

PhD. Nixon alexander Correa Muñoz  
Director  
Universidad del Cauca

---

PhD. Sergio Andrés Córdoba Pareja  
Jurado  
Universidad del Cauca

---

MSc. Jorge Armando Alpala Aguilar  
Jurado  
Servicio Geológico Colombiano (SGC)



# Dedicatoria:

Toda la Gloria sea a Nuestro Dios, por darme la vida y fortaleza para conseguir este logro frente a los obstáculos que se presentaron. **A mis padres Guillermo Franco Higidio Garcia y Zenaida Castro y mis hermanas Johana y Andrea** que son una bendición y un regalo de Dios para mi vida.

”El hombre hace planes, pero es el SEÑOR el que dirige sus pasos”.

Proverbios 16:9 NBV



# Agradecimientos

Quiero expresar mis agradecimientos a todas las personas e instituciones que han hecho posible que este estudio haya llegado a feliz término:

Primeramente a Dios por sostenerme y darme las fuerzas para terminar este proyecto profesional y a mi familia por el apoyo y la confianza que depositaron en mí.

Al ingeniero Nixon Alexander Correa Muñoz, como director y amigo por su interés, tiempo, apoyo y valiosos aportes para que este estudio saliera adelante.

Al Biólogo Jaime Mauna de los Reyes por su tiempo, empeño y colaboración en el desarrollo de este estudio.

A la Universidad del Cauca y al programa de Mestría en Geomática y profesores por el conocimiento impartido.

A la Corporación Autónoma Regional del Cauca (CRC), especialmente a la dependencia de gestión ambiental del departamento del Cauca, por brindarme la oportunidad y facilitar la información para poder desarrollar este estudio.

y finalmente a todas mis amigos y colegas que me han apoyado en este proceso.



---

## Resumen

El propósito de esta investigación es detectar humedales en la zona central del Municipio de Popayán a escala semidetallada, evaluando el potencial de las imágenes satelitales SAR Sentinel-1 (SAR S1 Dual-pol) en banda C y aéreas UAVSAR en banda L (Quad-pol), analizando variables como el coeficiente de retrodispersión (Backscatter Coefficient) y descriptores polarimétricos derivados de las descomposiciones Cloude-Pottier y Freeman-Durden, así como el uso de información espacial complementaria derivada de datos ópticos y Modelo Digital de Elevaciones (DEM).

Se caracterizó la intensidad de retrodispersión de las imágenes GRD Sentinel-1 (SAR S1) en el período de octubre a diciembre del año 2014 y 2015, para los humedales del área de estudio (AE1) mediante la distribución de los datos obtenidos de los centroides y estadística zonal, complementando este análisis con la formación de clúster jerárquicos. Se utilizó la técnica multivariada no paramétrica de Análisis de Componentes Principales (ACP) para explorar la correlación y representación de las variables polarimétricas VV ascendentes (VVAS) y descendentes (VVDES) en el primer plano factorial y detectar multicolinealidad en la intensidad de retrodispersión de las imágenes SAR S1 del año 2014 y 2015.

Se evaluó el período anual 2015 en el modelo de detección, determinando nueve clases de coberturas, tres asociados a humedales AaArA (Espejos de agua), TpPaVeBj (Ciénegas y pantanos con vegetación baja) y TpPaVeSe (Ciénegas y pantanos con vegetación secundaria) obtenidas de las bases de datos de la Corporación Autónoma Regional del Cauca (CRC) y seis clases asociados a no humedales (Bosque, CT, ZU, Pastos, SD, Veg\_S) extraídas del mapa de coberturas del Servicio Geológico Colombiano (SGC) a escala 1:25.000 del año 2015. Se modelaron diferentes escenarios para los datos SAR S1 utilizando variables predictoras de entrada como: la intensidad de retrodispersión, ACP y variables auxiliares (Var\_Aux) determinando la pendiente de terreno, el Índice Topográfico de Humedad (ITW) derivados del DEM GeoSAR y variables de datos ópticos Sentinel-2A, como el Índice de Vegetación de Diferencia Normalizada (NDVI) y el Índice de Agua de Diferencia Normalizada (NDWI). Para los datos aéreos UAVSAR se modelaron dos escenarios, con variables predictoras derivadas de descomposiciones polarimétrica (Cloude-Pottier y Freeman-Durden) y variables auxiliares como la pendiente del terreno y el ITW.

La fusión y sinergia con variables auxiliares en los modelos de detección de humedales satelital SAR S1 y aéreos UAVSAR implementados con el algoritmo de aprendizaje automático (Machine Learning: ML) Random Forest (RF) para clasificación, obtuvieron los mejores rendimientos evaluados en la matriz de confusión, determinando los Errores de Omisión (EO), Comisión (EC), Exactitud del Usuario (UA) y del Productor (PA). Las métricas más sensibles de Exactitud General, índice Kappa y OOB (Error Fuera de Bolsa) las arrojó el modelo SAR\_S1\_2015 – Var\_Aux con 87.01 %, 84.55 % y 14.13 % y para el modelo UAVSAR\_2015 – Var\_Aux con 66.53 %, 61.42 % y 34.1 % respectivamente. Las variables con mayor aporte y relevancia determinados por la métrica MDA (Disminución Media de la Precisión) y el

índice de Gini en el modelo satelital SAR\_S1\_2015-Var\_Aux fueron la polarimetría VVDES, el NDVI, ITW y la pendiente del terreno y en el modelo con datos aéreos UAVSAR\_2015-Var\_Aux fueron la pendiente del terreno, ITW, descriptores polarimétricos como el ángulo Alpha, combination\_1mH1mA, entropía y Freeman\_Dbl.

**Palabras clave: Detección, Descomposición Polarimétrica, Exactitud, Humedales, SAR, UAVSAR, Sentinel-1, Retrodispersión, Polarización.**

---

## Abstract

The purpose of this research is to detect wetlands in the central area of the Municipality of Popayán at a semi-detailed scale, evaluating the potential of SAR Sentinel-1 (SAR S1 dual pol) satellite images in C band and aerial UAVSAR in L band (quad pol). , analyzing variables such as the backscatter coefficient and polarimetric descriptors derived from Cloude-Pottier and Freeman-Durden decompositions, as well as the use of complementary spatial information derived from optical data and Digital Elevation Model (DEM).

The backscatter intensity of the SAR S1 images in the period from October to December of 2014 and 2015, was analyzed for the wetlands of the study area (AE1) through the distribution of the data obtained from centroids and zonal statistics, complementing this analysis with the formation of hierarchical clusters. The non-parametric multivariate technique of principal component analysis (PCA) was used to analyze the correlation and representation polarimetric variables VV ascending (VVASC) and descending (VVDES) in the first factorial plane and detect collinearity in the backscatter intensity of the SAR S1 images of 2014 and 2015.

The 2015 annual period was evaluated in the detection model, determining nine cover classes, three belonging to wetlands AaArA (Water Mirrors), TpPaVeBj (Swamps and low vegetation swamps) and TpPaVeSe (Swamps and swamps with secondary vegetation) obtained from the databases of the Corporación Autónoma Regional del Cauca (CRC) and six classes belonging to non-wetlands (Forest, CT, ZU, Grass, SD, Veg\_S) extracted from Servicio Geológico Colombiano (SGC) coverages at scale of 1:25,000 of the year 2015. Ten scenarios were modeled for the SAR S1 data using input predictor variables such as: backscatter intensity, ACP and auxiliary variables (Var\_Aux) determining slope, the topographic moisture index (ITW) derived from the DEM GeoSAR and Sentinel-2A optical data variables such as Normalized Difference Vegetation Index (NDVI) and Normalized Difference Water Index (NDWI). For the UAVSAR aerial data, two scenarios were modeled, with predictor variables derived from polarimetric decompositions (Cloude-Pottier and Freeman-Durden) and auxiliary variables such as slope and ITW.

Fusion and synergy of backscatter intensity and Var\_Aux for SAR S1 and polarimetric descriptors and Var\_Aux for UAVSAR in the detection models that were implemented with the Machine Learning (ML) Random Forest (RF) classification algorithm, obtained the best performances evaluated in the confusion matrix, determining the Errors of Omission (EO), Commission (EC), User's Accuracy (UA) and Producer's Accuracy (PA). The most sensitive metrics of General Accuracy, Kappa index and OOB (Out of Bag Error) were obtained for the SAR\_S1\_2015 - Var\_Aux model with 87.01 %, 84.55 % and 14.13 % and for the UAVSAR\_2015 - Var\_Aux model with 66.53 %, 61.42 % and 34.1 % respectively. The variables with higher contribution and relevance determined by MDA (Mean Decrease in Accuracy) and the Gini index in the satellite model SAR\_S1\_2015 - Var\_Aux were the VVDES polarimetry, the NDVI, ITW and slope and in the model with aerial data UAVSAR\_2015 - Var\_Aux were

the slope, ITW, polarimetric descriptors such as the Alpha angle, combination\_1mH1mA, entropy and Freeman\_Dbl.

**Keywords: Detection, Polarimetric Decomposition, Accuracy, Wetlands, SAR, UAV-SAR, Sentinel-1, Backscattering, Polarization.**

# Contenido

	Pag.
<b>Resumen</b> . . . . .	x
<b>Lista de Tablas</b> . . . . .	xvii
<b>Lista de Figuras</b> . . . . .	xviii
<b>Lista de Abreviaturas</b> . . . . .	xviii
<b>1. Introducción</b> . . . . .	<b>1</b>
1.1. Definición del problema . . . . .	1
1.2. Justificación . . . . .	2
1.3. Hipótesis y preguntas de investigación . . . . .	3
1.4. Objetivos . . . . .	4
<b>2. Revisión de Literatura</b> . . . . .	<b>5</b>
2.1. Polarimetría de imágenes SAR . . . . .	5
2.2. Parámetros del Sensor . . . . .	6
2.2.1. Longitud de onda . . . . .	6
2.2.2. Polarización . . . . .	6
2.2.3. Ángulo de Incidencia . . . . .	7
2.3. Mecanismos de dispersión de la señal de radar . . . . .	8
2.4. Información derivada de imágenes SAR . . . . .	8
2.4.1. Intensidad de la señal de retrodispersión . . . . .	8
2.4.2. Parámetros Polarimétricos . . . . .	9
2.5. Fuentes auxiliares en detección de humedales . . . . .	11
2.6. Métodos de clasificación . . . . .	11
2.7. Evaluación del rendimiento . . . . .	12
<b>3. Materiales y métodos</b> . . . . .	<b>14</b>
3.1. Área de estudio . . . . .	14
3.2. Datos de Entrada . . . . .	15
3.2.1. Inventario de humedales . . . . .	15
3.2.2. Imágenes satelitales SAR Sentinel-1 . . . . .	16
3.2.3. Imágenes aéreas SAR UAVSAR . . . . .	17
3.2.4. Información Auxiliar . . . . .	19

3.2.5. Modelo de detección, selección de variables y validación . . . . .	20
<b>4. Resultados y Discusión . . . . .</b>	<b>23</b>
4.1. Caracterización del coeficiente de retrodispersión Sentinel-1A . . . . .	23
4.1.1. Análisis exploratorio Sentinel-1A . . . . .	23
4.2. Análisis de conglomerados Jerárquicos . . . . .	29
4.3. Análisis exploratorio información auxiliar . . . . .	34
4.4. Criterios para detectar humedales con imágenes SAR . . . . .	35
4.5. Modelo de Detección de Humedales Datos Satelitales Sentinel-1A . . . . .	37
4.5.1. Rendimiento del modelo . . . . .	37
4.5.2. Importancia de variables Modelo SAR_S1A_2015 - Var_Aux . . . . .	42
4.5.3. Mapa detección de humedales modelo SAR_S1A_2015 - Var_Aux . . . . .	43
4.6. Modelo de Detección de Humedales Datos Aéreos UAVSAR . . . . .	47
4.6.1. Rendimiento del modelo . . . . .	47
4.6.2. Importancia de variables Modelo UAVSAR_2015 - Var_Aux . . . . .	51
4.6.3. Mapa detección de humedales modelo UAVSAR_2015 - Var_Aux . . . . .	52
4.6.4. Prueba de las hipótesis planteadas . . . . .	56
<b>5. Conclusiones y recomendaciones . . . . .</b>	<b>57</b>
5.1. Conclusiones . . . . .	57
5.1.1. Importancia y aplicación a la Geomática . . . . .	59
5.1.2. Limitaciones . . . . .	59
5.2. Recomendaciones . . . . .	60
<b>Bibliografía . . . . .</b>	<b>61</b>
<b>Anexos . . . . .</b>	<b>69</b>
<b>Anexo A . . . . .</b>	<b>71</b>
<b>Anexo B . . . . .</b>	<b>77</b>
<b>Anexo C . . . . .</b>	<b>82</b>

# Lista de Tablas

Tabla 2-1. Intensidad de retrodispersión para cuerpos de agua . . . . .	9
Tabla 3-1. Clasificación de Humedales del Municipio de Popayán según la Convención Ramsar . . . . .	15
Tabla 3-2. Descripción de los humedales de estudio . . . . .	16
Tabla 3-3. Características de las Imágenes SAR Sentinel-1 . . . . .	16
Tabla 3-4. Datos Imágenes SAR Sentinel-1- Banda C, Año 2014 . . . . .	16
Tabla 3-5. Características imágenes SAR UAVSAR . . . . .	17
Tabla 3-6. Datos polarimétricos SAR UAVSAR . . . . .	18
Tabla 3-7. Características de la información espacial auxiliar . . . . .	19
Tabla 3-8. Coberturas seleccionadas del área de estudio - SGC . . . . .	19
Tabla 3-8. Coberturas seleccionadas del área de estudio - SGC . . . . .	20
Tabla 3-9. Variables utilizadas en el modelo de detección RF SAR S1 - UAVSAR . . . . .	20
Tabla 3-10. Muestras para entrenamiento y validación modelo RF . . . . .	22
Tabla 4-1. Descriptores estadísticos imágenes Sentinel-1A 2014 (AE1) . . . . .	23
Tabla 4-2. Descriptores estadísticos Sentinel-1A 2014 de los polígonos de humedales . . . . .	24
Tabla 4-3. Descriptores estadísticos Sentinel-1A 2015 (AE1) . . . . .	25
Tabla 4-4. Descriptores estadísticos imágenes Sentinel-1A 2015 de los polígonos de humedales . . . . .	25
Tabla 4-5. Medias de clase conglomerados jerárquicos Sentinel-1A 2014 . . . . .	30
Tabla 4-6. Medias de clase conglomerados jerárquicos Sentinel-1A 2015 . . . . .	31
Tabla 4-7. Descriptores estadísticos de variables auxiliares . . . . .	35
Tabla 4-8. Evaluación del rendimiento modelos SAR Sentinel-1A con RF . . . . .	37
Tabla 4-9. Matriz de confusión entrenamiento modelo SAR_S1A_2015 - Var_Aux . . . . .	38
Tabla 4-10. Matriz de confusión validación modelo SAR_S1A_2015 - Var_Aux . . . . .	39
Tabla 4-11. Exactitud del Usuario (UA) y del Productor (PA) . . . . .	40
Tabla 4-12. Sensibilidad - Especificidad SAR_S1A_2015 - Var_Aux . . . . .	41
Tabla 4-13. Evaluación del rendimiento de los modelos UAVSAR . . . . .	47
Tabla 4-14. Matriz confusión entrenamiento modelo UAVSAR_2015 - Var_Aux . . . . .	48
Tabla 4-15. Matriz de confusión validación modelo UAVSAR_2015 - Var_Aux . . . . .	48
Tabla 4-16. Exactitud del Usuario (UA) y del Productor (PA) . . . . .	50
Tabla 4-17. Sensibilidad - Especificidad UAVSAR_2015 - Var_Aux . . . . .	50
Tabla 4-18. Evaluación del rendimiento de los modelos SAR . . . . .	56

# Lista de Figuras

Figura 3.1.	Localización del área de estudio y distribución espacial de humedales	14
Figura 3.2.	Área de estudio SAR UAVSAR (AE2)	18
Figura 3.3.	Área de estudio SAR UAVSAR sobre Google Earth (AE2)	18
Figura 3.4.	Flujo de trabajo detección de humedales con S1 SAR - UAVSAR	22
Figura 4.1.	Imágenes Sentinel-1A 2014 (AE1)	24
Figura 4.2.	Imágenes Sentinel-1A 2015 (AE1)	26
Figura 4.3.	Centroides y estadística zonal de humedales con Sentinel-1A 2014	27
Figura 4.4.	Centroides y estadística zonal de humedales con Sentinel-1A 2015	28
Figura 4.5.	Cluster jerárquico primer plano factorial Sentinel-1A 2014	29
Figura 4.6.	Conglomerados jerárquicos Sentinel-1A 2015	30
Figura 4.7.	Segmentación de conglomerados jerárquicos Sentinel-1A 2014	31
Figura 4.8.	Conglomerados 2014 y 2015. Fuente : CRC- Google Earth	32
Figura 4.9.	Distribución espacial conglomerados jerárquicos Sentinel-1A 2014 y 2015	33
Figura 4.10.	Variables Auxiliares de área de estudio	34
Figura 4.11.	Círculo de correlaciones bandas Sentinel-1A 2014 y 2015	36
Figura 4.12.	Importancia de variables MDA SAR_S1A_2015 - Var_Aux	42
Figura 4.13.	Importancia Gini SAR_S1A_2015 - Var_Aux	43
Figura 4.14.	Mapa detección humedales SAR_S1A_2015 - Var_Aux AE1	44
Figura 4.15.	Mapa detección humedales SAR_S1A_2015 - Var_Aux C1	45
Figura 4.16.	Mapa detección humedales SAR_S1A_2015 - Var_Aux C2	46
Figura 4.17.	Importancia de variables MDA UAVSAR_2015 - Var_Aux	51
Figura 4.18.	Importancia Gini UAVSAR_2015 - Var_Aux	52
Figura 4.19.	Mapa detección humedales UAVSAR_2015 - Var_Aux (AE2)	53
Figura 4.20.	Mapa detección humedales UAVSAR_2015 - Var_Aux C1	54
Figura 4.21.	Mapa detección humedales UAVSAR_2015 - Var_Aux C2	55

## Lista de abreviaturas

<b>AaArA</b>	Humedal Lacustre, Áreas de Almacenamiento de Agua o Espejos de Agua.
<b>ACP</b>	Análisis de Componentes Principales.
<b>AE1</b>	Área de Estudio 1 Sentinel-1A.
<b>AE2</b>	Área de Estudio 2 UAVSAR.
<b>CRC</b>	Corporación Autónoma Regional del Cauca.
<b>CT</b>	Construcciones.
<b>Dual-pol</b>	Polarización Doble.
<b>EO</b>	Error de Omisión.
<b>EC</b>	Error de Comisión.
<b>ITW</b>	Índice Topográfico de Humedad.
<b>ML</b>	Machine Learning.
<b>MDA</b>	Disminución Media de la Precisión.
<b>MDG</b>	Disminución Media del Coeficiente de Gini.
<b>NDVI</b>	Índice de Vegetación de Diferencia Normalizada.
<b>NDWI</b>	Índice de Agua De Diferencia Normalizada.
<b>OOB</b>	Error Fuera de Bolsa (Out-Of-Bag).
<b>PA</b>	Exactitud del Productor.
<b>Quad-pol</b>	Polarización Cuádruple.
<b>RF</b>	Random Forest.
<b>SAR S1</b>	Imágenes GRD Sentinel-1.
<b>SD</b>	Suelos Desnudos.
<b>SGC</b>	Servicio Geológico Colombiano.
<b>SAR</b>	Radar de Apertura Sintética.
<b>TpPaVeBj</b>	Humedal Palustre, Asociado a Ciénegas con Vegetación Baja.
<b>TpPaVeSe</b>	Humedal Palustre, Asociado a Ciénegas con Vegetación Secundaria.

<b>UAVSAR</b>	Radar de Apertura Sintética para Vehículo Aéreo no Tripulado.
<b>UA</b>	Exactitud del Usuario.
<b>Veg_S</b>	Vegetacion Secundaria.
<b>VV</b>	Transmisión Vertical - Recepción Vertical.
<b>VH</b>	Transmisión Vertical - Recepción Horizontal.
<b>HH</b>	Transmisión Horizontal - Recepción Horizontal.
<b>VVASC</b>	Polarización VV Órbita Ascendente.
<b>VVDES</b>	Polarización VV Órbita Descendente.
<b>VHASC</b>	Polarización VH Órbita Ascendente.
<b>ZU</b>	Zona Urbana.
$\sigma$	Intensidad de Retrodispersión.

---

---

# 1. Introducción

---

---

## 1.1. Definición del problema

[Mahdavi et al. \(2018\)](#), describe la importancia y las ventajas de los humedales al ambiente y al ser humano, como ecosistemas que prestan servicios ambientales y como fuentes naturales importantes que ejercen influencia en el control de inundaciones, filtración de contaminantes, purificación del agua y hábitat para una variedad de especies de plantas y animales; que condicionan el clima y prestan beneficios estéticos y recreacionales.

Debido a la creciente influencia antropogénica y los efectos del cambio climático, los humedales son cada vez más amenazados y degradados ([Deenik, 2022](#)). Por ello se ha implementado el uso y aplicación de datos obtenidos con sensores remotos para el desarrollo de estudios en humedales ([Abdelmajeed et al., 2023](#); [Ottinger and Kuenzer, 2020](#)).

La percepción remota ha sido una herramienta importante para estudiar la superficie terrestre y sus cambios a largo del tiempo. Las imágenes obtenidas con tecnología SAR (Radar de Apertura Sintética) han sido ampliamente utilizadas por la comunidad científica para estudiar los ecosistemas de humedales desde principios de los años 70 ([Waite and MacDonald, 1971](#)). Un ejemplo son las imágenes SAR con polarización doble (Dual-pol) y cuádruple (Quad-pol) multifrecuencias, que han sido esenciales para obtener información de los objetos de la tierra, para así poder detectarlos, identificarlos y clasificarlos ([Tsyganskaya et al., 2018](#)).

Teóricamente, los datos SAR tienen un gran potencial para el estudio de humedales, ya que las longitudes de onda de las microondas pueden penetrar la cubierta vegetal y son sensibles a la humedad del suelo y la presencia de aguas abiertas bajo un dosel. La polarización de la banda C (longitud onda  $\sim 6$  cm), con buen potencial para detectar humedales herbáceos y el sensor de banda L (longitud onda  $\sim 24$  cm), para humedales con vegetación inundada y vegetación alta ([Henderson and Lewis, 2008](#); [Huang et al., 2018](#); [Catry et al., 2018](#); [Rico Cabrera, 2021](#)).

Esta investigación se llevó a cabo en la zona central del Municipio de Popayán, donde están distribuidos diversos ecosistemas de humedales, clasificados en diferentes usos, con el objetivo de estimar el potencial de la banda C para detectar humedales con atributos de vegetación baja, secundaria y espejos de agua; así como también, el uso y potencial de la banda L, para detectar y discriminar humedales con vegetación densa y humedales inundados ([Mahdavi et al., 2018](#); [Catry et al., 2018](#)). El alcance de este estudio tiene como objetivo general, la detección de ecosistemas de protección ambiental, que implica determinar la existencia de los humedales en el área de estudio ([Chuvieco, 2010](#)).

Este estudio pretende utilizar la intensidad del retorno derivada de las imágenes satelitales SAR S1 y sensibilizar la descomposición polarimétrica vectorial Cloude-Pottier y Freeman-Durden, con las polarizaciones de las imágenes aéreas UAVSAR (banda L), implementando técnicas de Machine Learning, como Random Forest (RF) (Mahdianpari et al., 2017).

## 1.2. Justificación

Los avances en la percepción remota y el surgimiento de nuevas plataformas Earth Observation (EO), como fuentes de datos potenciales, permiten obtener información de la superficie terrestre en diferentes períodos de tiempo y escalas. Dentro de estas tecnologías es importante resaltar las ventajas de los sistemas de satélites SAR (Radar de Apertura Sintética) que proporcionan información del espectro en el rango de las microondas sobre las propiedades físicas de los objetos de la tierra, información útil para inferir y deducir la dinámica de los sistemas naturales (Guo et al., 2017).

Los ecosistemas de humedales han sido estudiados utilizando la percepción remota, debido a las diferentes ventajas y recursos que proporcionan, especialmente, para áreas geográficas extensas. Sin embargo, se hace necesario refinar con más detalle los resultados de detección de estos ecosistemas con estudios locales y áreas geográficas más pequeñas para el caso de Colombia (Estupinan-Suarez et al., 2015), con el fin de extrapolar los modelos de detección, que permitan determinar el potencial de la bandas polarimétrica C (Dual-pol) y L (Quad-pol), en la detección de objetivos de interés como vegetación inundada, emergente y cuerpos de agua. (Ottinger and Kuenzer, 2020; LaRocque et al., 2020).

La combinación de SAR, en banda C y banda L, permite la cartografía precisa de los humedales (Bourgeau-Chavez et al., 2009). Con este estudio se pretende interactuar y aprovechar el potencial de la información capturada por estas bandas, para detectar humedales, con el uso de técnicas y métodos no paramétricos multivariados, que permitan generar modelos base, de interpretación y refinamiento de la información. Así mismo fusionar los datos SAR con datos ópticos y del terreno, con el fin de obtener sinergismos que mejoren la precisión y exactitud para concluir sobre las ventajas y limitaciones encaminadas hacia futuros estudios con esta tecnología que avanza muy rápidamente (Karlson et al., 2019; Ottinger and Kuenzer, 2020; Rico Cabrera, 2021; Deenik, 2022).

Al finalizar este estudio de detección de humedales en el Municipio de Popayán, se obtendrá un análisis de las variables utilizadas con mayor aporte en la detección, así como la evaluación cuantitativa del modelo implementado, con el fin de determinar el potencial de las bandas C y L. Estos resultados servirán como referencia para otras fases de investigaciones con respecto a la detección, identificación, clasificación, monitoreo y detección de cambios de estos sistemas de protección ambiental (Liu et al., 2022).

Actualmente se han realizado investigaciones del potencial de los satélites SAR de segunda generación utilizando Machine Learning (Li et al., 2020), y aún no hay estudios publicados de detección de humedales en Popayán, utilizando insumos de plataformas satelitales y aéreas.

### 1.3. Hipótesis y preguntas de investigación

Al finalizar esta investigación se responderán las siguientes preguntas:

#### Pregunta I:

¿ El modo orbital de adquisición de la retrodispersión por el sensor SAR Sentinel-1 influye en la información ?

#### Hipótesis I:

$$H_0 : \sigma_{VVASC} = \sigma_{VVDES}$$

$$\sigma_{VHASC} = \sigma_{VHDES}$$

#### Pregunta II:

¿La exactitud del modelo de detección de humedales con Dual- pol es menor que Quad-pol?

#### Hipótesis II:

$$H_0 : \text{Exactitud\_Dual} - \text{pol} < \text{Exactitud\_Quad} - \text{pol}$$

## 1.4. Objetivos

### General

- \* Detectar Humedales Usando Imágenes Radar (SAR) Aéreas y Satelitales en la Zona Central del Municipio de Popayán (Cauca).

### Específicos

- \* Caracterizar el coeficiente de retrodispersión para cada polarimetría usada en las imágenes SAR S1.
- \* Determinar las variables de retrodispersión, la geometría y los umbrales de las distribuciones SAR para detectar los humedales en el área de estudio.
- \* Diseñar e implementar un modelo de detección de humedales con los criterios y datos de Earth Observation recopilados.
- \* Evaluar las métricas de precisión y exactitud de los resultados obtenidos.

---

---

## 2. Revisión de Literatura

---

---

La presente revisión de literatura se enfocará en aspectos de la tecnología radar aplicados en estudios de humedales como: polarimetría de imágenes SAR, parámetros del sensor, mecanismos de dispersión de la señal de radar, información derivada de las imágenes SAR, fuentes auxiliares en detección de humedales, técnicas de clasificación y por último, evaluación de métricas de precisión y exactitud.

### 2.1. Polarimetría de imágenes SAR

Las plataformas de observación de la tierra (Earth Observation) han proporcionado una herramienta fundamental para recopilar información y ayudar en la detección, identificación, monitoreo y clasificación de los humedales. Diversos estudios se han realizado con sensores ópticos y esfuerzos considerables en el uso de imágenes de radar, debido a la información complementaria y suplementaria que se puede obtener de estos sensores que operan en el rango de las microondas, comparado con los que operan en las bandas ópticas y térmicas (Henderson and Lewis, 2008).

Para áreas de estudio cubiertas por nubes o con poca luz, las imágenes SAR son las únicas que pueden proporcionar datos periódicos y consistentes de manera confiable, ya que es capaz de atravesar las nubes, el dosel de la vegetación y en cierta medida, dar información sobre el subcanopy, es decir, sobre la capa de vegetación que se encuentra debajo del dosel principal de un bosque o una vegetación densa. Debido a lo anterior los sensores de radar proporcionan datos únicos, relacionados con los atributos de los ecosistemas de la superficie terrestre (Henderson and Lewis, 2008).

Los sistemas SAR polarimétricos emiten y reciben energía polarizada a través de ondas electromagnéticas y miden la amplitud y la fase de las reflexiones recibidas por los objetos (Tsyganskaya et al., 2018; Mahdavi et al., 2018). Diversos estudios de humedales se han realizado utilizando polarimetría de imágenes SAR, en las diferentes bandas y longitudes de onda de operación del radar (Mahdianpari et al., 2017; White et al., 2015; Mahdianpari et al., 2019; Henderson and Lewis, 2008).

Varios autores han aportado estudios donde describen las relaciones radar - humedal y los parámetros de detección que incluyen longitud de onda, polarización, ángulo incidente y las propiedades del entorno como son las propiedades dieléctricas (contenido de humedad del suelo y la vegetación) y atributos geométricos (rugosidad de la superficie) donde la retrodispersión del eco es sensible (Hess et al., 1990; Schmullius and Evans, 1998; Lunetta and Christopher, 1998).

Hay muchos tipos de humedales, sin embargo, todos poseen tres características principales en común: presencia de agua en la superficie, capas de tierra húmedas y poco profundas y vegetación adaptada a este tipo de condiciones. La presencia o ausencia de vegetación asociada a la superficie de agua es el objetivo perseguido (Costa et al., 2013; White et al., 2015).

## 2.2. Parámetros del Sensor

### 2.2.1. Longitud de onda

Una característica de la onda electromagnética es la longitud de onda ( $\lambda$ ). Los sensores SAR operan en varias bandas que incluyen las bandas P, L, S, C y X con longitudes de ondas aproximadas de 100, 25, 11, 6 y 3 cm respectivamente (Lee and Pottier, 2009).

La longitud de onda larga tiene alta capacidad para penetrar el dosel de la vegetación (Wang, 2002; Hess et al., 2003). Por ejemplo, la banda L es adecuada para detectar inundaciones bajo el dosel boscoso (Hess et al., 2003). En estudio de humedales ha sido utilizada para mapear humedales (Henderson and Lewis, 2008; Moser et al., 2016; Mahdavi et al., 2017b). Algunos estudios reportan que la banda L es parcialmente transparente a la vegetación herbácea (Silva et al., 2008; Evans and Costa, 2013).

Las bandas L y P son importantes en la identificación de humedales cubiertos por bosques o por vegetación herbácea densa debido a la alta profundidad de la penetración de la señal (Henderson and Lewis, 2008; Hong et al., 2015; Catry et al., 2018). Estas señales pueden atravesar el dosel de la vegetación y detectar agua bajo los árboles o vegetaciones densas.

En comparación con la banda L, las longitudes de ondas cortas como la banda C y la banda X, tienen limitaciones para penetrar el dosel de la vegetación (Costa et al., 2002; Hess et al., 2003). Las señales de las longitudes de onda corta como la banda C y X, han sido útiles en la detección de humedales herbáceos, vegetación densa con bajo crecimiento y agua bajo vegetación corta (Brisco et al., 2009; Henderson and Lewis, 2008; Dronova, 2015; Hong et al., 2015).

La combinación de SAR de banda C y banda L es una herramienta eficiente para la detección de agua debajo del dosel (Townsend, 2001), debido a que los sensores de banda L son débilmente sensibles a las superficies lisas, generalmente permiten la discriminación entre bosques inundados y áreas forestales no inundadas (Hess et al., 1990).

### 2.2.2. Polarización

Los radares polarimétricos consideran la polaridad de la señal electromagnética que emiten y las propiedades de la polarización de la señal que capta el retorno. La polarización es una propiedad de la radiación electromagnética donde la onda tiene una orientación que puede ser transmitida y recibida horizontal o verticalmente (Ouchi, 2013). Los sensores SAR pueden trabajar en polarización simple, doble o cuádruple.

La polarización simple ha sido efectiva para la detección de cuerpos de agua abierta en

calma (Moser et al., 2016). La polarización HH es la más usada para delineación de humedales (Bourgeau-Chavez et al., 2009). L-HH ha sido utilizada para la detección de humedales (Mahdianpari et al., 2017). Por otra parte, la polarización VV es sensitiva a la humedad del suelo, a las condiciones de inundación y aguas abiertas a la superficie (Bourgeau-Chavez et al., 2009; Mahdianpari et al., 2017; Townsend, 2001). La polarización cruzada HV es sensitiva a la biomasa y las propiedades del suelo (Han et al., 2017).

Las ondas Co-polarizadas (HH y VV) son más eficaces en la detección de humedales inundados y no inundados, debido a la respuesta de la señal en estas bandas, que ha sido mejor en condiciones de inundación (Henderson and Lewis, 2008). Las ondas polarizadas L-HH y C-HH son adecuadas para la detección de bosque inundado y más sensitivo a la inundación que la polarización vertical (Henderson and Lewis, 2008; Kasischke et al., 2009; Moser et al., 2016).

Kasischke et al. (1997), concluyó que los radares Co-polarizados son adecuados para la detección de vegetación inundada, que la onda Co-polarizadas L-HH fue preferida para la vegetación leñosa y se prefirió C-HH para detección de humedales herbáceos. Estas conclusiones coincidieron con la revisión de Hess et al. (1990). Adicionalmente Schullius and Evans (1998), aportaron recomendaciones en investigaciones de humedales herbáceos con parámetros óptimos SAR donde la polarización C-HH, C-VV y la polarización cruzada fueron contribuyentes importantes en estos estudios.

Estudios recientes de humedales y detección de cuerpos de agua y vegetación, se han reportado en la banda C con polarimetría doble en imágenes SAR (Mahdianpari et al., 2019; Pham-Duc et al., 2017; Catry et al., 2018). También se han reportado clasificaciones de humedales con polarimetría doble, y alta precisión en la clasificación, lo más cercana a la polarimetría cuádruple (Schmitt and Brisco, 2013; Dabboor et al., 2015). Aunque con la polarización doble se obtiene la mitad de la información que se puede obtener con un conjunto de datos totalmente polarimétricos, las primeras tienen un ancho de franja más amplio y, por lo tanto, cubren un área más grande (Ainsworth et al., 2009).

Moser et al. (2016), presentaron un enfoque recientemente desarrollado que permite la extracción de vegetación inundada mediante la descomposición de datos de polarización doble. Las técnicas para la descomposición de datos SAR con doble polarización son relativamente recientes; sin embargo, según los estudios mencionados anteriormente, produjeron resultados prometedores.

### 2.2.3. Ángulo de Incidencia

Estudios han reportado que ángulos inferiores a  $35^\circ$  son más apropiados para la detección de cuerpos de agua bajo vegetación (Li et al., 2007; Bourgeau-Chavez et al., 2009). Así mismo Hess et al. (1990), mostró que con ángulos inferiores a  $35^\circ$  se facilitan la detección de humedales ya que los ángulos pequeños tienen mayor profundidad de penetración. Según Henderson and Lewis (2008), los ángulos de incidencia moderados no parecen proporcionar mucha información útil para la detección de humedales, especialmente si la imagen tiene buena resolución.

Los ángulos de incidencia pequeños pueden atravesar en la vegetación y, por lo tanto, pueden detectar mejor la vegetación inundada (Adam et al., 1998; Töyrä et al., 2001). Pham-Duc et al. (2017), realiza histogramas de retrodispersión con polarizaciones VH y VV, para separar píxeles de agua con ángulos de incidencia entre 30° - 45°.

## 2.3. Mecanismos de dispersión de la señal de radar

Hay cuatro mecanismos de dispersión comunes: dispersión especular, dispersión áspera, dispersión por volumen y dispersión de doble rebote o diédrica.

La dispersión especular (sin retorno al SAR), que se produce a partir de superficies más lisas, como por ejemplo en aguas tranquilas o suelo desnudo, carreteras. La dispersión áspera, que se produce cuando hay un único retorno de rebote al SAR desde superficies tales como arbustos pequeños, agua agitada, áreas deforestadas, campos agrícolas. La dispersión por volumen, que se produce cuando la señal se retrodispersa en múltiples direcciones tales como cubiertas de vegetación y la dispersión de doble rebote o diédrica, que ocurre entre una superficie de agua que refleja especularmente y estructuras verticales de la vegetación, como troncos y tallos (Moser et al., 2016; Pulvirenti et al., 2013). Este último caso de dispersión ocurre típicamente cuando la vegetación emergente vertical está rodeada por una superficie de agua visible y lisa (Brisco et al., 2008; Hess et al., 2003; Wdowinski et al., 2008).

La vegetación inundada también puede tener una combinación de retrodispersión de doble rebote y volumen (Brisco et al., 2013; Wdowinski et al., 2008). Kasischke and Bourgeau-Chavez (1997), resume las posibles interacciones entre las microondas y áreas con vegetación para varios tipos de humedales donde se pueden observar los mecanismos de dispersión por superficie, doble rebote y por volumen.

Debido a su comportamiento como reflector especular y su alta constante dieléctrica, el agua retrodispersa baja energía al sensor, lo que resulta en tonos oscuros en las imágenes SAR. (Di Baldassarre et al., 2011). Los datos de la banda X se reflejan en la parte superior del dosel, la banda C se refleja en el dosel y las ramas (penetración a unos pocos metros dentro del dosel) y la banda L penetra a través de todo el dosel para reflejar en los troncos, la superficie del agua o superficie del suelo (Kasischke et al., 1997; Martinis et al., 2015; Li et al., 2012).

## 2.4. Información derivada de imágenes SAR

### 2.4.1. Intensidad de la señal de retrodispersión

La señal retrodispersada recibida por el sensor SAR de un humedal depende de las características del sensor (longitud de onda, polarización, ángulo de incidencia de la onda transmitida) y las condiciones del entorno del objetivo (forma, tamaño, orientación, contenido de humedad, rugosidad del suelo, biomasa de vegetación, propiedades dieléctricas del suelo y la vegetación así como la presencia o ausencia de aguas abiertas) (Catry et al., 2018).

Tsyganskaya et al. (2018), menciona diversos estudios relacionados con clasificación de vegetación inundada de humedales mediante intensidad de la retrodispersión, donde los valores de intensidad son frecuentemente convertidos a la sección transversal normalizada del radar o coeficiente de retrodispersión, que se mide en unidades de decibelios (dB) (Henderson and Lewis, 2008).

La combinación de imágenes SAR en bandas C y L son una herramienta eficiente para la detección de agua bajo dosel (Townsend, 2001). Para mapeos de agua se han utilizado métodos de umbral de intensidad en imágenes SAR en las bandas X, C y L (Catry et al., 2018).

En la literatura se reportan Intensidades de umbrales para clasificar cuerpos de agua en las bandas C y L. Pham-Duc et al. (2017), reportaron umbrales en banda C con polarización doble de -22 dB a -15 dB para las polarizaciones VH y VV respectivamente. Manjusree et al. (2012), reportaron en la banda C con polarización cuádruple, umbrales de diferentes capas de agua como se indica en la Tabla 2-1.

Capas de agua	Intensidad $\sigma$ (dB)			
	HH	HV	VH	VV
Agua de inundación	-8 a -12	-15 a -24	-15 a -24	-6 a -15
Agua de ríos	-6 a -30	-24 a -36	-24 a -36	-19 a -32
Agua de tanques	-13 a -26	-22 a -40	-22 a -40	-16 a -28
Lagos	-16 a -24	-21 a -32	-21 a -32	-24 a -32
Campos parcialmente sumergidos	-18 a -30	-24 a -34	-24 a -34	-8 a -18

**Tabla 2-1:** Intensidad de retrodispersión para cuerpos de agua

Tsyganskaya et al. (2018), reportan la mediana del coeficiente de retrodispersión obtenida para clases de agua en diferentes polarizaciones y longitudes de onda (X, C y L). En este estudio se incluyen aguas profundas y poco profundas, con los valores más bajos en las distribuciones. En aguas poco profundas, para una clase de humedal reportan una mediana de -20 dB para la polarización HH en las bandas X, C y L, así como en la banda C-HV y una mediana de -22 dB y -23 dB para las bandas C-VV y L-HV, respectivamente. En la clase de aguas profundas se presentaron los valores más bajos y la mayor variabilidad de las demás clases. Para todas las imágenes polarizadas en polarización HH independiente de la longitud de onda, así como en la banda C-VV obtuvieron una mediana aproximada de -21 dB. En las imágenes con polarización C-HV y L-HV reportaron una mediana de -25 dB.

### 2.4.2. Parámetros Polarimétricos

Los sistemas SAR multipolares (polarización Dual-pol y Quad-pol) tienen ventajas significativas en comparación con los datos SAR con polarización simple, proporcionando más información sobre la presencia de agua debajo del dosel de vegetación (Souza-Filho et al.,

2011). Estos sistemas también permiten la aplicación de descomposiciones polarimétricas, los cuales detectan diferentes mecanismos de dispersión en la señal del SAR de los objetivos terrestres.

[Mahdianpari et al. \(2017\)](#), describe las técnicas de descomposición polarimétricas incoherentes que analizan la matriz de coherencia obteniendo autovectores y autovalores, como Cloud-Pottier, Freeman-Durden, Kennaugh matriz, Touzi, Yamaguchi que han sido utilizadas para clasificaciones de humedales y vegetación inundada en función de varios clasificadores en años recientes ([White et al., 2015](#); [Freeman and Durden, 1998](#); [Montgomery et al., 2021](#)).

La descomposición de Freeman-Durden es un método de descomposición basado en tres componentes, y emplea dispersión por superficie, doble rebote y de volumen ([Freeman and Durden, 1998](#)). El enfoque Freeman-Durden ha tenido éxito en delinear los límites de los humedales a través de la utilidad de la dispersión de doble rebote para identificar la vegetación inundada y es muy adecuado para identificar vegetación emergente en humedales pantanosos ([Montgomery et al., 2021](#)).

La dispersión por superficie ocurre comúnmente en superficies de aguas abiertas, especialmente en aguas tranquilas donde se produce la dispersión especular (es decir, longitud de onda de radiación incidente mucho mayor que las características de rugosidad del agua), lo que resulta en una señal de retorno débil de la superficie de agua, ocasionando que esta aparezca más oscura que otras superficies terrestres. La dispersión difusa / rugosa ocurre en superficies perturbadas de un solo retorno de rebote generalmente por el viento, reduciendo efectivamente el contraste entre la tierra y el agua, lo que puede llevar a que las superficies del agua se identifiquen erróneamente. La dispersión de doble rebote ocurre sobre humedales con vegetación emergente, ya que la radiación incidente se refleja primero especularmente desde la superficie del agua y luego desde la vegetación cercana. La dispersión volumétrica es un mecanismo de dispersión difusa que ocurre cuando la radiación incidente interactúa con múltiples objetivos (mayor de 2), típicamente dentro de las copas de los bosques y la vegetación emergente alta con una superficie altamente heterogénea que dispersa la radiación incidente varias veces. La dispersión volumétrica ocurre en humedales con vegetación alta (copa de árboles) ([Sultana et al., 2016](#)).

[Sultana et al. \(2016\)](#), realizaron identificación de humedales con datos Quad-pol SAR UAVSAR, formando composiciones de falso color utilizando el canal del rojo (doble rebote), verde (volumen) y azul (superficie), identificando los mecanismos predominantes en los humedales.

Por otra parte, las descomposiciones permiten extraer información física (mecanismo de dispersión de la vegetación, por ejemplo aguas abiertas, etc.) pero no representan en sí un enfoque de clasificación por sí mismos, por lo que han sido complementadas con el uso de técnicas de Machine Learning (Random Forest, Maquinas Soportadas en Vectores y Redes neuronales artificiales), clasificación basada en distancias de (máxima verosimilitud, K-nearest-neighbour), árboles de clasificación, enfoques de umbrales automáticos y manuales, lógica difusa entre otros ([Tsyganskaya et al., 2018](#); [Mahdavi et al., 2018](#)).

## 2.5. Fuentes auxiliares en detección de humedales

En estudios de detección, clasificación y monitoreo de humedales se han utilizado la fusión de datos ópticos, modelos digitales de elevación y datos SAR. Esta combinación de fuentes múltiples auxiliares, en general, proporciona una precisión superior a la del uso de datos ópticos ó SAR de forma individual (Mahdavi et al., 2018; Amani et al., 2017; Franklin and Ahmed, 2017; Mahdianpari et al., 2019).

Las imágenes multiespectrales de sensores ópticos como MODIS, Landsat-8, Sentinel-2 se han utilizado en diferentes estudios de humedales (Amani et al., 2019; Mahdianpari et al., 2019; Estupinan-Suarez et al., 2015; LaRocque et al., 2020; Kaplan and Avdan, 2017), derivando variables como el Índice de Vegetación de Diferencia Normalizada (NDVI) y el Índice De Agua De Diferencia Normalizada (NDWI), los cuales contienen información del tipo de vegetación y la presencia de agua, donde es posible detectar un humedal (Amani et al., 2019; Bian et al., 2021).

NDWI se utiliza para delinear características de aguas abiertas y se calcula a partir del infrarrojo cercano (NIR) y las bandas verdes. Los valores positivos de NDWI indican la presencia de agua, mientras que los valores negativos indican áreas no acuáticas (Deenik, 2022; Bian et al., 2021).

El NDVI se utiliza como indicador de la presencia y condición de la vegetación y puede ser útil para la clasificación de humedales (Pettorelli, 2019). Se calcula a partir de las bandas roja y NIR. Los valores altos de NDVI indican vegetación saludable densa con altos niveles de clorofila, mientras que los valores bajos indican vegetación no saludable con baja clorofila. También permite la detección potencial de cuerpos de agua, con umbrales de NDVI cercanos a cero o ligeramente negativos (Pettorelli, 2019; Deenik, 2022).

VARIABLES del terreno se han derivado del Modelo Digital de Elevación (DEM) como la Pendiente, el Índice de Posición Topográfica (TPI) y el Índice Topográfico de Humedad (ITW) entre otras, se han considerado importantes en la predicción de humedales, para mejorar la precisión de la clasificación en estudios de humedales con diferentes niveles de éxito (Karlson et al., 2019; Deenik, 2022; Mahdavi et al., 2018; Guo et al., 2017; Hird et al., 2017).

La pendiente del terreno (tasa de cambio de elevación) es importante para entender la dinámica del flujo y morfología superficial (Franklin and Ahmed, 2017; Deenik, 2022). El índice de humedad (ITW) cuantifica y describe la tendencia o propensión de un sitio (píxel) a acumular agua, se basa en la pendiente y el área de contribución del flujo acumulado. Es probable que las áreas con valores de ITW más altos sean más húmedas en relación con las áreas con valores más bajos, por ello es un componente importante en la predicción de humedales. (Guo et al., 2017; Mahdavi et al., 2018; Deenik, 2022).

## 2.6. Métodos de clasificación

Como ya se mencionó se han aplicado diversas técnicas de clasificación para estudios de humedales. Para detección de superficie de aguas se ha utilizado los niveles de grises res-

pecto a umbrales. En este método, todos los píxeles con un coeficiente de retrodispersión inferior a un umbral especificado en una imagen de intensidad se asignan como agua (Hess et al., 1995; Henry et al., 2006). Esta técnica se utiliza para aguas abiertas tranquilas que poseen un mecanismo de dispersión especular (Pulvirenti et al., 2011). Enfoque de umbrales automáticos han sido reportados en diversas investigaciones basados en la forma o umbrales del histograma, empleados para separar vegetación inundada y cuerpos de agua de otras clases (Tsyganskaya et al., 2018; Pham-Duc et al., 2017; Twele et al., 2016; Duy, 2015).

Por otra parte, la literatura reporta buenas precisiones de clasificación con Random Forest (RF) en mapeo y monitoreo de humedales que oscilan entre 70 % a 99 % dependiendo del número de clases (Montgomery et al., 2021). Se identificaron coberturas con vegetación inundada y superficies de cuerpos de agua (Mahdianpari et al., 2019, 2017; Mahdavi et al., 2018; Tsyganskaya et al., 2018; Huang et al., 2018; Halabisky et al., 2018; Merchant et al., 2019). El modelo RF se utilizó con éxito para predecir la presencia de humedales (Filatow et al., 2020; Deenik, 2022; Karlson et al., 2019), ya que es un algoritmo de Machine Learning (ML) beneficioso porque no es afectado por valores atípicos, ni conjunto de datos con ruidos, tiene gran capacidad para trabajar con alta dimensionalidad y datos multifuente sin sobreajustarse y es computacionalmente eficiente. Debido a lo anterior estudios realizados concluyen que RF es superior a otros clasificadores por su capacidad de manejar eficientemente la alta dimensionalidad y no ser tan sensible al sobreajuste como otros modelos (Amani et al., 2017; Berhane et al., 2018; LaRocque et al., 2020; Merchant et al., 2019).

Los dos parámetros principales en modelo RF son el número de árboles de clasificación (ntree) y el número de predictores que deben considerarse en cada nodo de árbol (mtry). El valor óptimo de ntree se puede determinar observando los cambios en la estimación de precisión del bootstrapping interno hasta obtener su estabilización, mientras que mtry con el valor de la raíz cuadrada del número total de predictores (Karlson et al., 2019).

## 2.7. Evaluación del rendimiento

Investigaciones en estudios de humedales reportan métricas de evaluación de la precisión y la exactitud de los modelos de Machine Learning (ML) utilizando el error fuera de bolsa (OOB) como indicador de la precisión interna del modelo y una matriz de confusión donde se estiman los indicadores de precisión estándar incluida la precisión general (OA), el coeficiente Kappa y la precisión específica de la clase del usuario (UA:user's accuracy) y del productor (PA:producer's accuracy), correspondiente al error de comisión y omisión por cada clase (Congalton, 1991).Duy (2015), reporta las métricas de exactitud en detección de cuerpos de agua superficiales con verdaderos positivos (True positive), falsos positivos (False positive) y falsos negativos (False negative).

El coeficiente kappa, el cual determina el grado de coincidencia entre los datos de referencia y el mapa de clasificación (Congalton, 1991). El error OOB se calcula para cada árbol incluido en el bosque aleatorio y luego se promedia para proporcionar una precisión general de la clasificación. El OOB es utilizado para clasificar los predictores en función del criterio de disminución de la precisión de la media (MDA), que cuantifican el cambio relativo en la

---

precisión que resulta de incluir o excluir un predictor particular en la clasificación ([Deenik, 2022](#); [Karlson et al., 2019](#)).

La UA corresponde al error de comisión y revela la fiabilidad del modelo, es decir, con qué frecuencia la categoría clasificada en el mapa, estará realmente presente en el terreno. Por otra parte, PA corresponde al error de omisión y puede revelar, que humedales corren el riesgo de ser pasados por alto u omitidos de la clasificación, es decir, con qué frecuencia se clasifican correctamente las características reales sobre el terreno ([Deenik, 2022](#)).

---

---

## 3. Materiales y métodos

---

---

### 3.1. Área de estudio

El área de estudio se encuentra ubicada en la parte central del Municipio de Popayán, cuenta con un área aproximada de 20 km x 18 km ( $360 \text{ km}^2$ ) y coordenadas WGS84 de  $76^\circ 41' 46.87'' \text{ W}$ ,  $2^\circ 24' 6.11'' \text{ N}$  y  $76^\circ 30' 55.85'' \text{ W}$ ,  $2^\circ 33' 55.03'' \text{ N}$ . Los humedales de referencia para el estudio se encuentran en alturas que oscilan entre 1484 y 2445 m.s.n.m, como se muestra en la Figura 3.1.

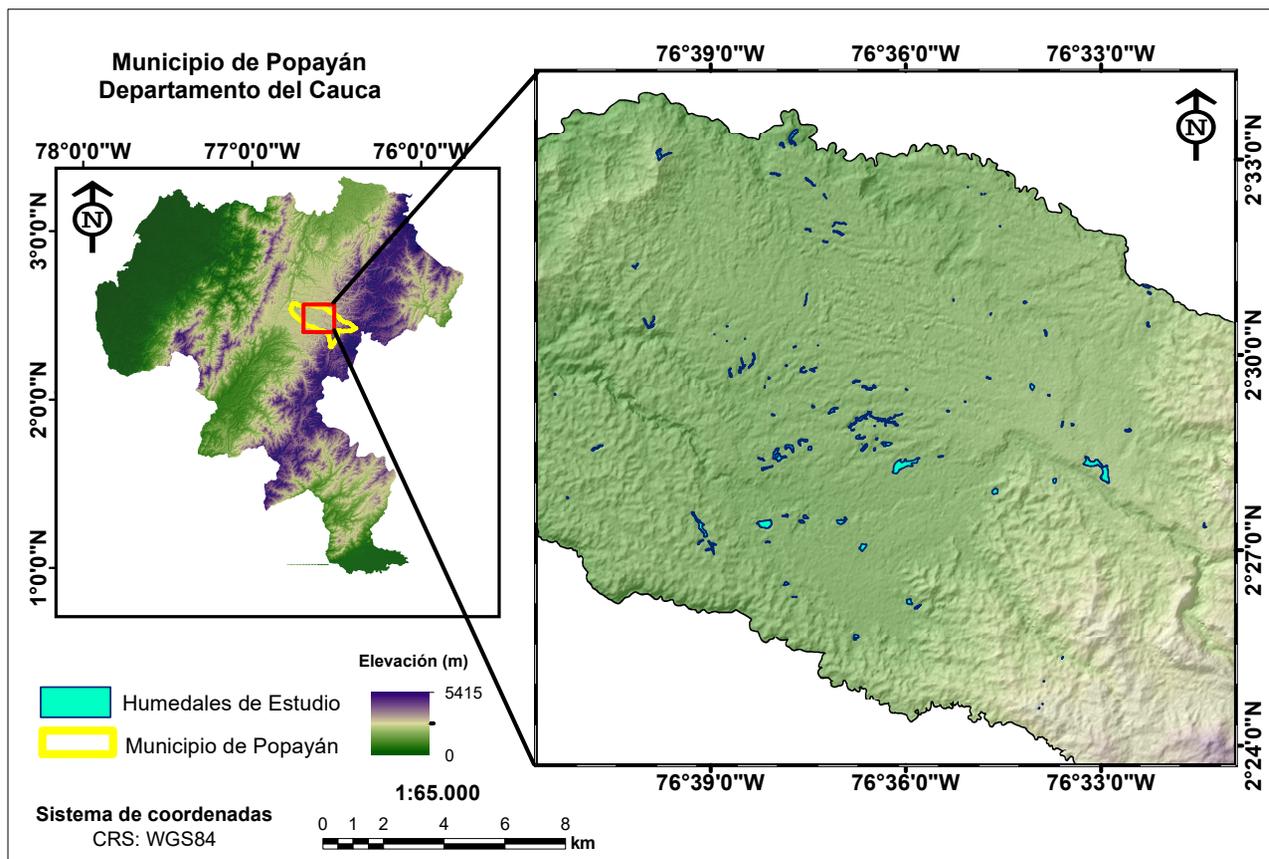


Figura 3.1: Localización del área de estudio y distribución espacial de humedales

En el Municipio de Popayán se han identificado 153 humedales<sup>1</sup>, de origen natural y artificial ubicados en la zona urbana y rural, con usos de reservorios, recreación, paisajísticos

<sup>1</sup><https://crc-siac.opendata.arcgis.com/datasets/humedales>

entre otros . El área que abarca los humedales en Popayán es de aproximadamente 162.28 ha.

La Convención Ramsar(1971)<sup>2</sup> adoptó un sistema de clasificación en niveles jerárquicos de tipos de humedales como se indica en la Tabla 3-1.

Ámbito	Sistema	Subsistema	Clase	Subclase
Interior	Lacustre	Permanente		Lagos dulces permanentes
	Palustre	Permanente	Emergente	Pantanos y ciénagas dulces Permanentes
				Ciénaga estacional dulce

**Tabla 3-1:** Clasificación de Humedales del Municipio de Popayán según la Convención Ramsar

La Resolución No.196 de 2006<sup>3</sup>, por la cual se adopta la guía técnica para la formulación de planes de manejo para humedales en Colombia toma los lineamientos del sistema de clasificación de la Convención Ramsar de tipos de humedales. Según la Resolución No.196 los humedales Palustres se definen dentro del tipo **Tp** que se refiere a Pantanos/ciénegas/esteros/charcas permanentes de agua dulce con vegetación emergente y los humedales Lacustres que son los humedales artificiales asociados a áreas de almacenamiento de agua.

## 3.2. Datos de Entrada

### 3.2.1. Inventario de humedales

Se seleccionaron 80 humedales de la base de datos de humedales de la Corporación Regional del Cauca (CRC) cuyas áreas se encuentran entre 0.20 y 12.90 ha, sumando un área total de 128.77 ha, en el área central del Municipio de Popayán. Se definieron 3 categorías de clasificación para los humedales basados en la Convención Ramsar (Tabla 3-1), estudios realizados por la CRC, fotografías de campo y el conocimiento de profesionales biólogos con gran experiencia en humedales. El 45 % pertenecen a humedales lacustres de clase AaArA (Áreas de Almacenamiento de Agua - Reservorios Artificiales) asociados a lagos y masas de agua estable, el 28.75 % a humedales de tipo palustre de la clase TpPaVeBj (Ciénegas o Pantanos con Vegetación Baja) y el 26.25 % a humedales de tipo palustre de la clase TpPaVeSe (Ciénegas o Pantanos con Vegetación Secundaria) como se indica en la Tabla 3-2.

<sup>2</sup><https://www.ramsar.org>

<sup>3</sup><https://www.minambiente.gov.co/documento-entidad/resolucion-0196-de-2006/>

Tipo	# Poligonos	%	Clase	Área (ha)
Lacustre	36	45	AaArA	37.99
Palustre	23	28.75	TpPaVeBj	48.33
	21	26.25	TpPaVeSe	42.45
<b>Total</b>	80	100	-	128.77

Tabla 3-2: Descripción de los humedales de estudio

### 3.2.2. Imágenes satelitales SAR Sentinel-1

Las imágenes SAR Sentinel-1 (S1 GRD: Ground Range Detected) con 10 m de resolución y revisitas de 6, 12 y 24 días, fueron obtenidas de Copernicus Open Access Hub <https://scihub.copernicus.eu/dhus/#/home>. En la Tabla 3-3, se describen sus características principales. Para el año 2014 se obtuvieron 6 imágenes Sentinel-1A, con polarización únicamente en VV (ausencia de polarización VH). Se obtuvieron 3 imágenes para cada modo de órbita, ascendente (ASC) y descendente (DES) en el período de octubre a diciembre, respectivamente (Tabla 3-4).

#	Programa	Tipo de dato	Banda	Resolución (m)	Angulo Inc (°)
1	Copernicus (ESA)	Dual- pol	$C(\lambda = 5.6 \text{ cm})$	10 m	30-46

Tabla 3-3: Características de las Imágenes SAR Sentinel-1

#	Imagen GRD	Fecha	Órbita	Polarimetría
1	S1A_IW_GRDH_1SSV_20141231T232118_20141231T232143_003970_004C77_5C27	31-12-14	Ascendente	VV
2	S1A_IW_GRDH_1SSV_20141214T105114_20141214T105139_003714_0046A2_D4D3	14-12-14	Descendente	VV
3	S1A_IW_GRDH_1SSV_20141207T232119_20141207T232144_003620_004485_1A4B	07-12-14	Ascendente	VV
4	S1A_IW_GRDH_1SSV_20141113T232119_20141113T232144_003270_003C8B_CA9E	13-11-14	Ascendente	VV
5	S1A_IW_GRDH_1SSV_20141027T105115_20141027T105140_003014_0036F9_BC1A	27-10-14	Descendente	VV
6	S1A_IW_GRDH_1SSV_20141003T105115_20141003T105140_002664_002F7B_A260	03-10-14	Descendente	VV

Tabla 3-4: Datos Imágenes SAR Sentinel-1- Banda C, Año 2014

Para el año 2015 se obtuvieron 25 imágenes, 24 con polarización VV y una imagen con polarización VH. Para VV en órbita ascendente (VVASc) se obtuvieron 10 imágenes y VV en órbita descendente (VVDES) 14 imágenes, mientras que solo se encontró una imagen VH en órbita ascendente (VHASc) (Ver [Anexo A](#)).

Se combina datos de entrada con procesamiento de las escenas SAR Sentinel-1A, en la Sentinel Application Platform (SNAP)<sup>4</sup>, software de acceso libre de la Agencia Espacial Europea (ESA). Se aplicaron las calibraciones radiométricas, geométricas, filtro speckle y la amplitud medida por el coeficiente de retrodispersión (backscatter coefficient), y se convirtió a unidades de decibeles (dB). Con el coeficiente de retrodispersión en las unidades requeridas se utilizó el software SAGA (System for Automated Geoscientific Analyses)<sup>5</sup> y R-project<sup>6</sup> para extraer información derivada de los datos SAR Sentinel-1A, realizar análisis exploratorio, estadística zonal y análisis de cluster jerárquico con la librería FactoClass<sup>7</sup> de R-CRAN.

### 3.2.3. Imágenes aéreas SAR UAVSAR

Los datos SAR polarimétricos UAVSAR (Radar de Apertura Sintética de Vehículos Aéreos No Tripulados) en banda L, para el área de estudio, fueron obtenidos de NASA/JPL (<https://uavsar.jpl.nasa.gov/cgi-bin/data.pl>). Las escenas SAR UAVSAR contienen polarización Quad-pol (Cuádruple), esto es, HHHH, HHHV, HHVV, HVHV, HVVV y VVVV (Tabla 3-5). Las características de la escena SAR UAVSAR, utilizada en este estudio se indican en la Tabla 3-6.

El área de estudio establecida con las imágenes Sentinel-1A (AE1) fue recortada basados en los humedales de referencia que cubrían la imagen SAR UAVSAR obteniendo un área de estudio (AE2) con una extensión de  $93.73 \text{ km}^2$  como se indica en las Figuras 3.2 y 3.3.

El procesamiento y análisis de la escena SAR UAVSAR polarimétrica en banda L, se realizó en el software open source PolSAR pro v.6.0 (Data Processing and Education Tool). La descomposición polarimétrica de Cloude-Pottier y Freeman-Durden, permitió obtener tres componentes que contribuyen a los mecanismos de dispersión de superficie (Freeman\_Odd), doble rebote (Freeman\_Dbl) y de volumen (Freeman\_Vol) (Correa Muñoz, 2020).

#	Programa	Tipo de dato	Banda	Resolución (m)	Angulo Inc (°)
1	NASA JPL	Quad - pol	$L(\lambda = 27 \text{ cm})$	6 m	25-60

**Tabla 3-5:** Características imágenes SAR UAVSAR

<sup>4</sup><http://step.esa.int/main/download/snap-download/>

<sup>5</sup><https://saga-gis.sourceforge.io/en/index.html>

<sup>6</sup><http://www.rproject.org/>

<sup>7</sup><https://cran.r-project.org/web/packages/FactoClass/index.html>

#	Flight Line ID	Producto	Fecha	Polarización Cuádruple
1	31800	ColVol.31800_15019_006 _150313_L090_CX_01.	13-03-15	HHHH, HHHV, HHVV, HVHV, HVVV, VVVV

Tabla 3-6: Datos polarimétricos SAR UAVSAR

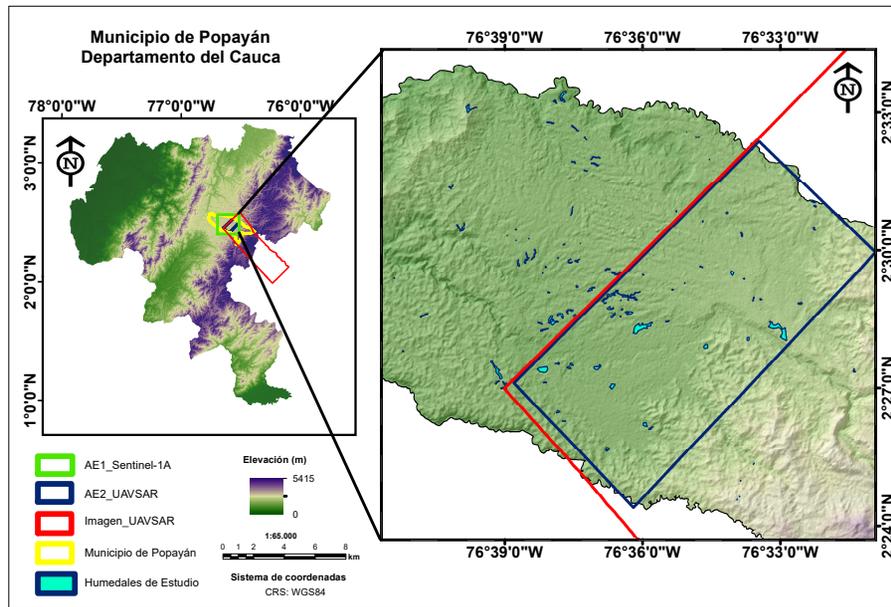


Figura 3.2: Área de estudio SAR UAVSAR (AE2)

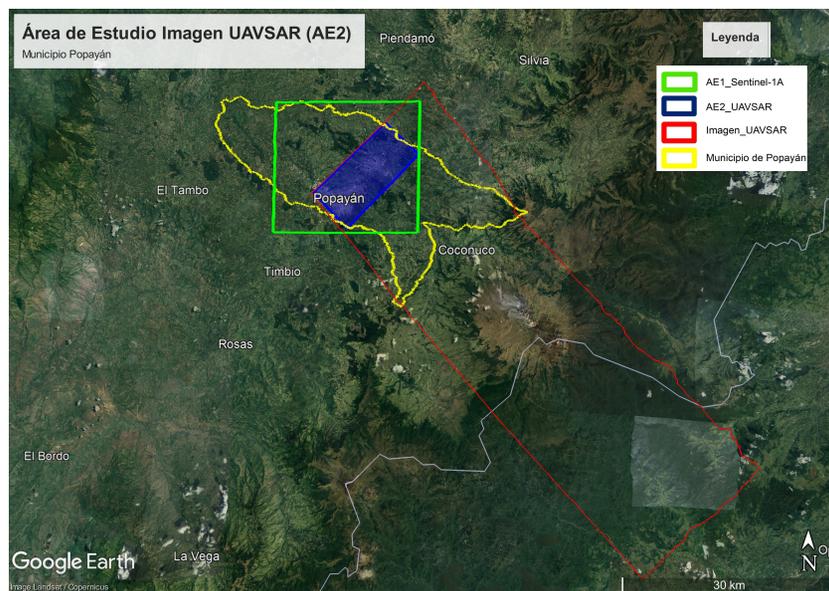


Figura 3.3: Área de estudio SAR UAVSAR sobre Google Earth (AE2)

### 3.2.4. Información Auxiliar

En el modelo de detección se implementaron variables auxiliares geomorfológicas provenientes del modelo digital (datos SAR) y de índices espectrales provenientes de sensores ópticos. El DEM procesado GeoSAR (2008) en banda P y resolución de 5 m, fue proporcionada por el IGAC y la imagen multispectral Sentinel 2A (24 de diciembre del 2015), con resolución de 10 m obtenida del programa Copernicus Open Access Hub ESA (<https://scihub.copernicus.eu/dhus/#/home>) (Tabla 3-7).

En el software SAGA se determinaron las variables auxiliares geomorfológicas y los índices espectrales denominadas en adelante Var\_Aux (Pendiente, Índice Topográfico de Humedad (ITW), Índice de Vegetación de Diferencia Normalizada (NDVI) y el Índice de Agua de Diferencia Normalizada (NDWI)). Se realizó el remuestreo del DEM GeoSAR a 10 m y se derivó la pendiente del terreno y el índice ITW, el cual es importante en la detección de humedales, ya que describe la tendencia de una zona a acumular agua y se basa en la pendiente y área contributiva específica (Mattivi et al., 2019). El preprocesamiento de Sentinel-2A se realizó con SCP (Semi-Automatic Classification Plugin)<sup>8</sup> de QGIS, derivando el índice espectral de vegetación de diferencia normalizada (NDVI) usado para la caracterización de la vegetación, calculado con la Banda 4 (Rojo) y la Banda 8 (VNIR) (Luo et al., 2015). También se calculó el índice NDWI, utilizado para identificar áreas húmedas a partir de las Banda 3 (Verde) y la Banda 8 (VNIR) (Hird et al., 2017; Matasci et al., 2018).

Adicionalmente se utilizó un mapa de coberturas de la tierra suministrado por el Servicio Geológico Colombiano<sup>9</sup> a escala 1:25.000, del cual se seleccionaron y extrajeron polígonos de clases de coberturas en el área de estudio para implementar el modelo de detección indicados en la Tabla 3-8, su distribución se ilustra en el mapa del Anexo A.

**Tabla 3-7:** Características de la información espacial auxiliar

#	Tipo	Producto	Resolución	Banda
1	Sentinel 2A	S2A_MSIL1C_20151224T153612_N0201_R068_T18NUH	10 m	Banda 2 (Azul), Banda 3 (Verde), Banda 4 (Rojo), Banda 8 (VNIR)
2	DEM	GeoSAR	5 m	P

**Tabla 3-8:** Coberturas seleccionadas del área de estudio - SGC

Tipo	# Polígonos	Clase	Área_ha
Zona Urbana	11	ZU	177.81
Vegetación Secundaria	29	Veg_S	69.16
Suelos Desnudos	34	SD	206.75
Pastos	51	Pastos	116.24

<sup>8</sup><https://plugins.qgis.org/plugins/SemiAutomaticClassificationPlugin/>

<sup>9</sup><https://miig.sgc.gov.co/Paginas/Resultados.aspx?k=deslizamientos%20popayan>

**Tabla 3-8:** Coberturas seleccionadas del área de estudio - SGC

Construcciones	42	CT	545.67
Bosques	18	Bosques	40

### 3.2.5. Modelo de detección, selección de variables y validación

El algoritmo de ML utilizado en este estudio fue Random Forest (RF) de clasificación desarrollado en la librería randomForest<sup>10</sup> de R, resistente al sobreajuste, valores atípicos y datos faltantes (LaRocque et al., 2020; Merchant et al., 2019; Berhane et al., 2018; Amani et al., 2017). Este método se usó para detectar la presencia de un humedal tipo palustre (vegetación baja y vegetación secundaria) o lacustre (espejos de agua). Se analizó el potencial de las imágenes SAR en banda C (coeficiente de retrodispersión) y L (descomposición polarimétrica), así como el aporte y comportamiento de las variables auxiliares derivadas del DEM (datos SAR) y Sentinel-2A (datos ópticos), en el modelo de detección.

Las variables utilizadas en los modelos de detección satelitales SAR Sentinel-1 (SAR S1) y aéreos UAVSAR, se muestran en la Tabla 3-9. Las imágenes Sentinel-1A con polarizaciones VV en órbita ascendente y descendente prevalecen debido a que la polarización VH en los años 2014 y 2015 estuvo limitada para el área de interés. El período de análisis de este estudio se centró en el año 2015 donde se presentó la mayor frecuencia de escenas SAR Sentinel-1A en el área de estudio (AE1). Adicionalmente la imagen UAVSAR perteneciente al año 2015 cubre la mayor proporción del área de estudio e intersección con el mayor número de humedales definiendo un área de trabajo (AE2).

#	Fuente	Variables
1	Sentinel-1 SAR Banda C	Coeficiente de retrodispersión (dB) VVASC- VVDES - VHASC
2	DEM GeoSAR	Pendiente ITW
3	Sentinel 2A	NDVI NDWI
4	UAVSAR SAR Banda L	Descomposición Cloude-Pottier (Alpha, Entropy (H), Anisotropy (A), Lambda, Combination_1mH1mA, Combination_1mHA, Combination_H1mA, Combination_HA). Freeman_Durden (Freeman_Odd, Freeman_Dbl, Freeman_Vol), SPAN.

**Tabla 3-9:** Variables utilizadas en los modelo de detección RF SAR S1 - UAVSAR

<sup>10</sup><https://cran.rproject.org/web/packages/randomForest/index.html>

Se utilizó un valor óptimo del parámetro `n`tree de 1000 (analizando los cambios de precisión del OOB hasta obtener su estabilización) y el `n`try con la raíz cuadrada del número total de predictores. El modelo fue entrenado con polígonos de humedales que cubrían cada área de estudio (ver [Anexo A](#)) para UAVSAR y SAR S1.

En la Tabla [3-10](#) se indican las clases y el número total de puntos de las muestras obtenidas de los polígonos de humedales, los cuales se dividieron en 70 % para entrenamiento y 30 % para validación ([Slagter, 2019](#)). Las muestras de entrenamiento y validación se determinaron sistemáticamente obteniendo 23035 (training) y 9872 (test) para SAR S1 y para UAVSAR 13061 (training) y 5597 (test) respectivamente.

El rendimiento de los modelos fue evaluado mediante la matriz de confusión de la cual se derivaron las métricas de Exactitud General, Índice Kappa, Exactitud del Usuario (UA) que corresponde al error de comisión y Exactitud del Productor (PA) que corresponde al error de omisión para cada clase. Posteriormente se analiza la importancia de las variables donde se identifican las variables de entrada más relevantes para la clasificación basadas en la Mean Decrease in Accuracy (MDA: Disminución Media de la Precisión) que cuantifican el cambio relativo en la precisión que resulta de incluir o excluir un predictor particular en la clasificación y Mean Decrease in Gini (MDG: evalúa la impureza de los datos de entrenamiento) ([Slagter, 2019](#); [Karlson et al., 2019](#)).

El rendimiento interno del modelo de RF se evaluó utilizando el Error Fuera de Bolsa (Out-Of-Bag, OOB), usado para evaluar la precisión del modelo. El OOB es una estimación de error interno de un bosque aleatorio a medida que se está construyendo ([Karlson et al., 2019](#); [Deenik, 2022](#)).

Se generaron escenarios a partir de las variables mencionadas en la Tabla [3-9](#) incorporando el Análisis de Componentes Principales (ACP) para reducir la dimensionalidad de las variables de entrada y obtener la mayor varianza de la información para utilizar los componentes como variables predictoras de entrada ([Crowson et al., 2019](#); [Chatziantoniou et al., 2017](#)).

El flujo de trabajo que se implementó en la detección de humedales se describe en la Figura [3.4](#), donde se realiza una evaluación cuantitativa del coeficiente de retrodispersión con Sentinel-1A (Dual-pol) y los descriptores polarimétricos de Freeman-Durden y Cloude-Pottier obtenidos con UAVSAR (Qual-pol). El coeficiente de retrodispersión de las 25 imágenes Sentinel-1A 2015 y las variables de las descomposiciones polarimétricas derivadas de UAVSAR, se implementaron como entradas en los modelos. Se determinaron los componentes principales de las imágenes Sentinel-1A 2015 haciendo parte de las variables de entrada. Las órbitas ascendente y descendente de la polarización VV (VVASC y VVDES) se modelaron por separado según lo concluido en el círculo de correlaciones del ACP. Posteriormente se realizó la fusión con las Var\_Aux (variables geomorfológicas - índices espectrales), obteniendo el aporte y el rendimiento del sinergismo de estas variables en los diferentes escenarios de detección.

Clase humedal	# Muestra S1 SAR	# Muestra UAVSAR
AaArA	3837	1580
TpPaVeBj	4890	3208
TpPaVeSe	4480	3259
ZU	1500	1363
Veg_S	3600	2706
SD	3600	1815
Pastos	4200	2241
CT	4000	1051
Bosques	2800	1435
<b>Total</b>	<b>32907</b>	<b>18658</b>

Tabla 3-10: Muestras para entrenamiento y validación modelo RF

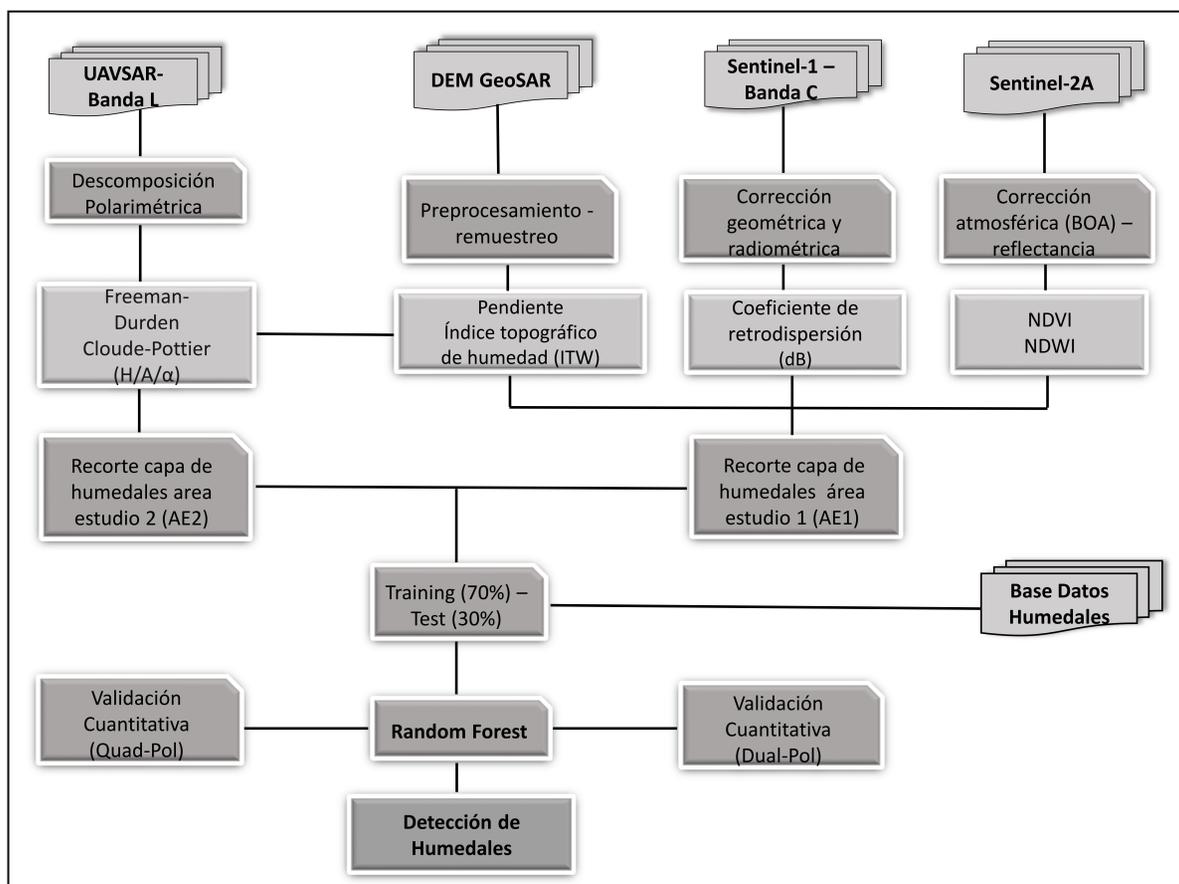


Figura 3.4: Flujo de trabajo detección de humedales con S1 SAR - UAVSAR

---

---

## 4. Resultados y Discusión

---

---

### 4.1. Caracterización del coeficiente de retrodispersión Sentinel-1A

#### 4.1.1. Análisis exploratorio Sentinel-1A

Se determinaron descriptores estadísticos para las escenas SAR Sentinel-1A 2014 en el período de octubre a diciembre indicados en la Tabla 4-1. Para la polarimetría VVASC (órbita ascendente) y VVDES (órbita descendente) en el área de estudio (AE1), se obtuvieron los valores más bajos (Mín) de retrodispersión de -21.22 dB (VVASC) y -22.85 dB (VVDES), característicos de agua de ríos y de cuerpos de agua abierta sin vegetación emergente o inundada (Pham-Duc et al., 2017; Manjusree et al., 2012). Los valores mínimos de la media fluctuaron entre -8.00 dB (VVASC) y -9.73 dB (VVDES) y valores mínimos de mediana de -8.14 dB (VVASC) y -9.90 dB (VVDES). La mayor variabilidad se presentó en la polarimetría VVASC, mientras que la polarización VVDES proporcionó los rangos de intensidad más bajos en el área de estudio (AE1), que permite detectar aguas abiertas en movimiento (ríos) o reposo (espejos de agua).

En la Figura 4.1 se muestran rangos de intensidad de retrodispersión obtenidos en el área de estudio (AE1) de octubre, noviembre y diciembre del año 2014. En la zona urbana se observan tonos brillantes (mayor energía devuelta al sensor) y diferentes tonalidades de grises en la zona rural (áreas que retrodispersan menor al sensor) (Rico Cabrera, 2021).

Estadísticos (dB)	Mín	Máx	Media	Mediana	Sd	Coef Variación
Variables						
VVASC_5C27_DIC_31	-21.22	20.11	-8.00	-8.14	2.40	30.00
VVDES_D4D3_DIC_14	-21.20	18.85	-8.53	-8.70	2.21	25.91
VVASC_1A4B_DIC_7	-20.78	19.38	-7.57	-7.75	2.37	31.31
VVASC_CA9E_NOV_13	-21.05	19.97	-7.37	-7.57	2.39	32.43
VVDES_BC1A_OCT_27	-20.72	19.23	-8.71	-8.91	2.25	25.83
VVDES_A260_OCT_3	-22.85	18.09	-9.73	-9.90	2.31	23.74

**Tabla 4-1:** Descriptores estadísticos imágenes Sentinel-1A 2014 (AE1)

En la Tabla 4-2, se describen los descriptores estadísticos de retrodispersión extraídos de los polígonos de humedales, donde se resalta la banda VVDES\_A260\_OCT\_3, con los valores más bajos de retrodispersión de -21.56 dB, media de -11.11 dB y mediana de -10.69 dB. La polarimetría VV en órbita descendente se caracterizó por presentar los valores de retrodispersión más bajos, sensibles a la humedad y cuerpos de agua. La mayor variabilidad de los datos se presentó en la polarimetría VVASC.

Variables	Estadísticos (dB)					
	Mín	Máx	Media	Mediana	Sd	Coef Variación
VVASC_5C27_DIC_31	-20.15	-0.91	-10.00	-9.59	2.44	24.37
VVDES_D4D3_DIC_14	-21.20	5.78	-9.31	-9.23	2.50	26.90
VVASC_1A4B_DIC_7	-20.16	-1.40	-9.47	-9.02	2.57	27.17
VVASC_CA9E_NOV_13	-19.08	1.60	-9.15	-8.78	2.45	26.79
VVDES_BC1A_OCT_27	-20.42	-0.86	-10.21	-9.82	2.43	23.77
VVDES_A260_OCT_3	-21.56	0.21	-11.11	-10.69	2.53	22.76

Tabla 4-2: Descriptores estadísticos Sentinel-1A 2014 de los polígonos de humedales

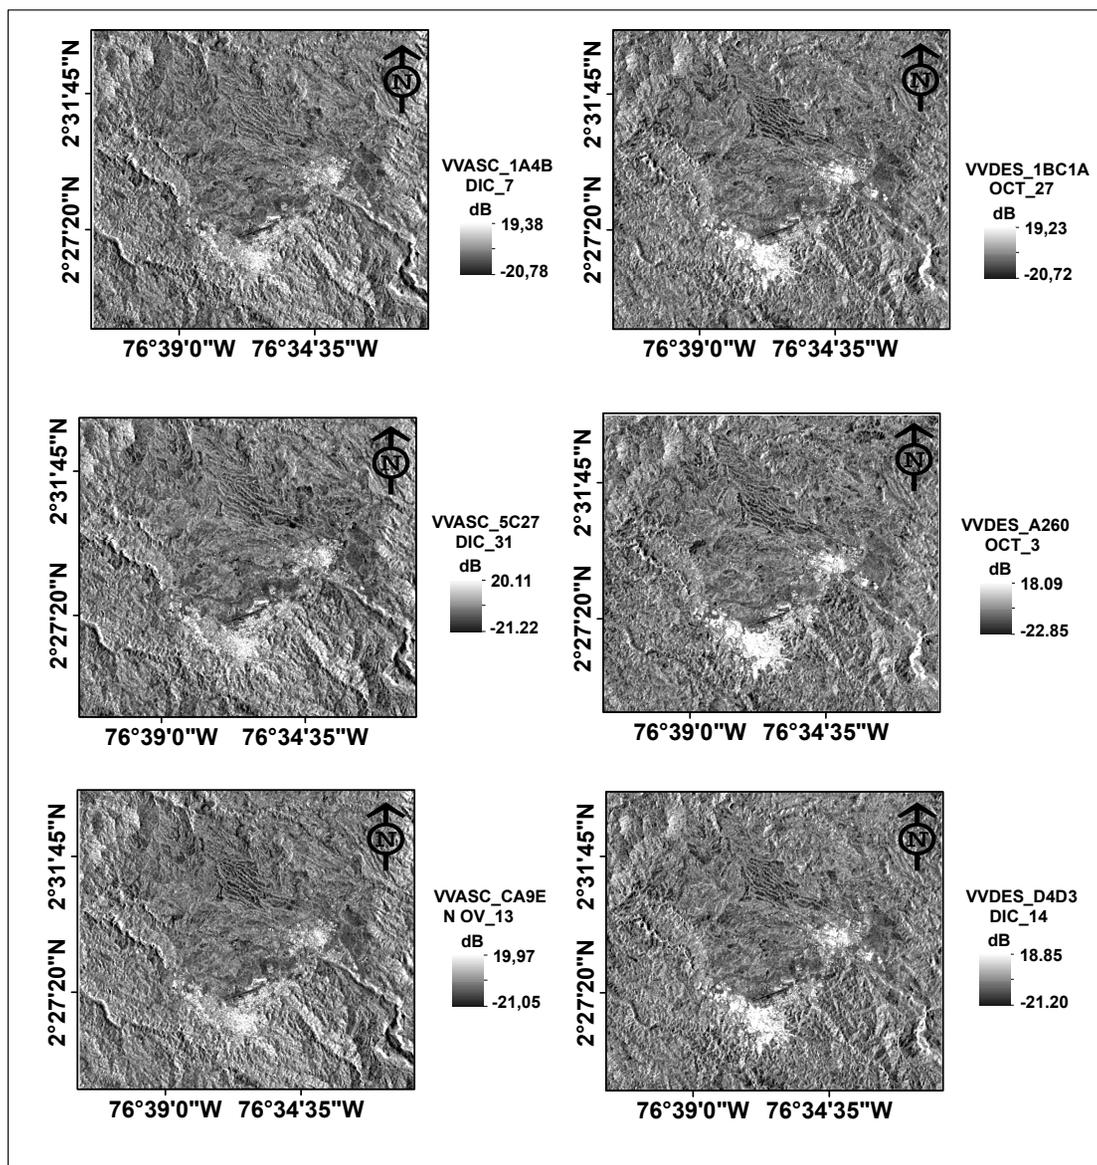


Figura 4.1: Imágenes Sentinel-1A 2014 (AE1)

Los valores Máx de retrodispersión aportan información de la existencia de humedales colonizados por vegetación.

En el año 2015 se analizaron los mismos períodos anteriores del área de estudio y los polígonos de humedales, descritos en la Tabla 4-3 y la Tabla 4-4 respectivamente. En ambos casos se presentaron los valores de retrodispersión más bajos en la banda VVDES\_3573.DIC\_09 de -20.93 dB, valores importantes en la detección de humedales con cuerpo de agua (Gulácsi and Kovács, 2020)

Los valores más bajos en la media y mediana de los humedales oscilan entre -9.97 dB y -9.60 dB. Tanto en el año 2014 y 2015 los valores más bajos del coeficiente de retrodispersión se obtuvieron en la polarimetría VVDES.

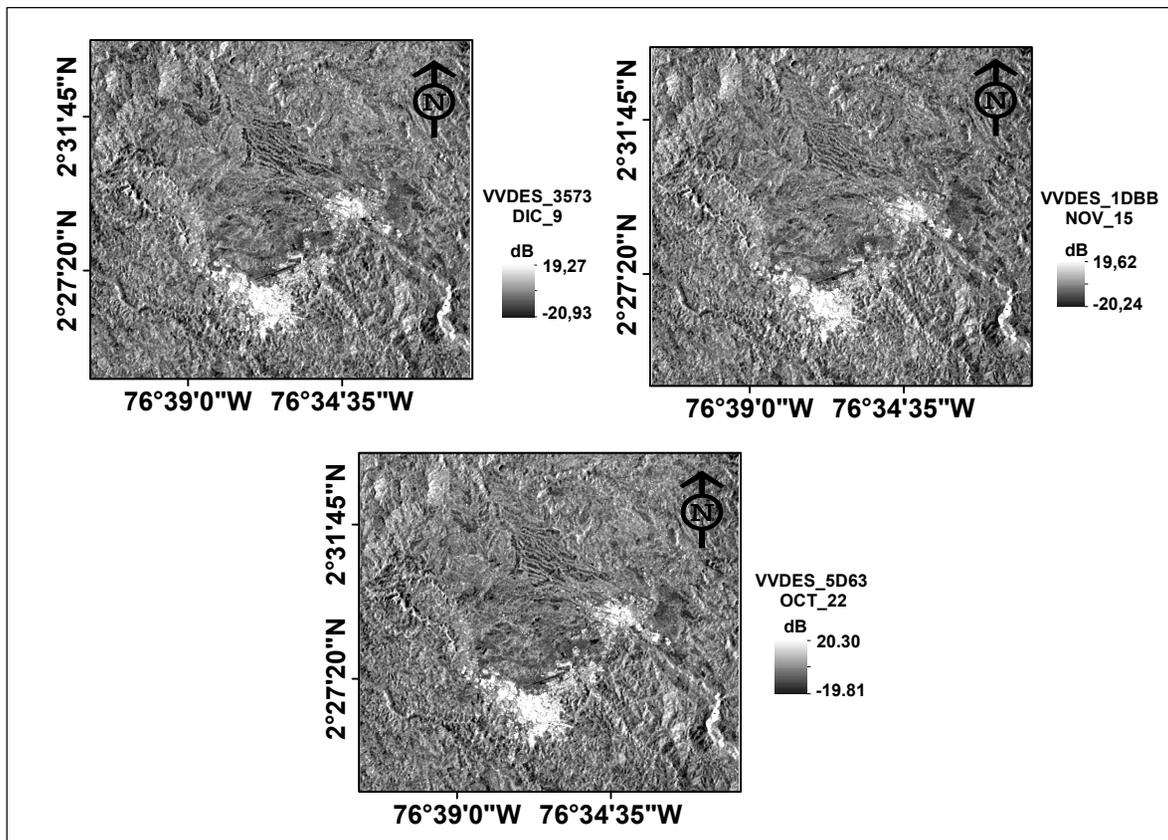
Estadísticos (dB)	Mín	Máx	Media	Mediana	Sd	Coef Variación
VVDES_3573.DIC_09	-20.93	19.27	-8.59	-8.74	2.29	26.63
VVDES_1DBB_NOV_15	-20.24	19.62	-7.97	-8.15	2.26	28.40
VVDES_5D63.OCT_22	-19.81	20.30	-8.16	-8.32	2.32	28.51

**Tabla 4-3:** Descriptores estadísticos Sentinel-1A 2015 (AE1)

Estadísticos (dB)	Mín	Máx	Media	Mediana	Sd	Coef Variación
VVDES_3573.DIC_09	-20.93	4.65	-9.97	-9.60	2.46	24.66
VVDES_1DBB_NOV_15	-18.78	2.42	-9.03	-8.79	2.15	23.85
VVDES_5D63.OCT_22	-18.52	3.43	-9.46	-9.25	2.19	23.17

**Tabla 4-4:** Descriptores estadísticos imágenes Sentinel-1A 2015 de los polígonos de humedales

En la Figura 4.2 se muestran los rangos de intensidad de retrodispersión en el área de estudio, perteneciente a los meses de octubre, noviembre y diciembre del 2015. Al contrastar los rangos de retrodispersión VVDES de las Tablas 4-2 y 4-4 en 2014 y 2015, en que oscilan los humedales, se puede observar que no hay una diferencia significativa en sus valores mínimos (Mín) y diferencias notables en sus valores máximos (Máx). Los rangos Mín en la polarimetría VVDES oscilaron entre -21.56 dB a -20.42 dB en 2014 y -20.93 dB a -18.52 dB en 2015 para los polígonos de humedales, umbrales importantes para detectar humedales lacustres en el área de estudio (Pham-Duc et al., 2017; Gulácsi and Kovács, 2020; Manjusree et al., 2012). De igual forma los rangos Mín y Máx de media y mediana de VVDES para los polígonos de humedales en 2014 oscilaron de -11.11 dB a -9.31 dB (media) y -10.69 dB a -9.23 dB (mediana) mientras que en 2015 fluctuaron de -9.97 dB a -9.03 dB (media) y -9.60 dB a -8.79 dB (mediana).

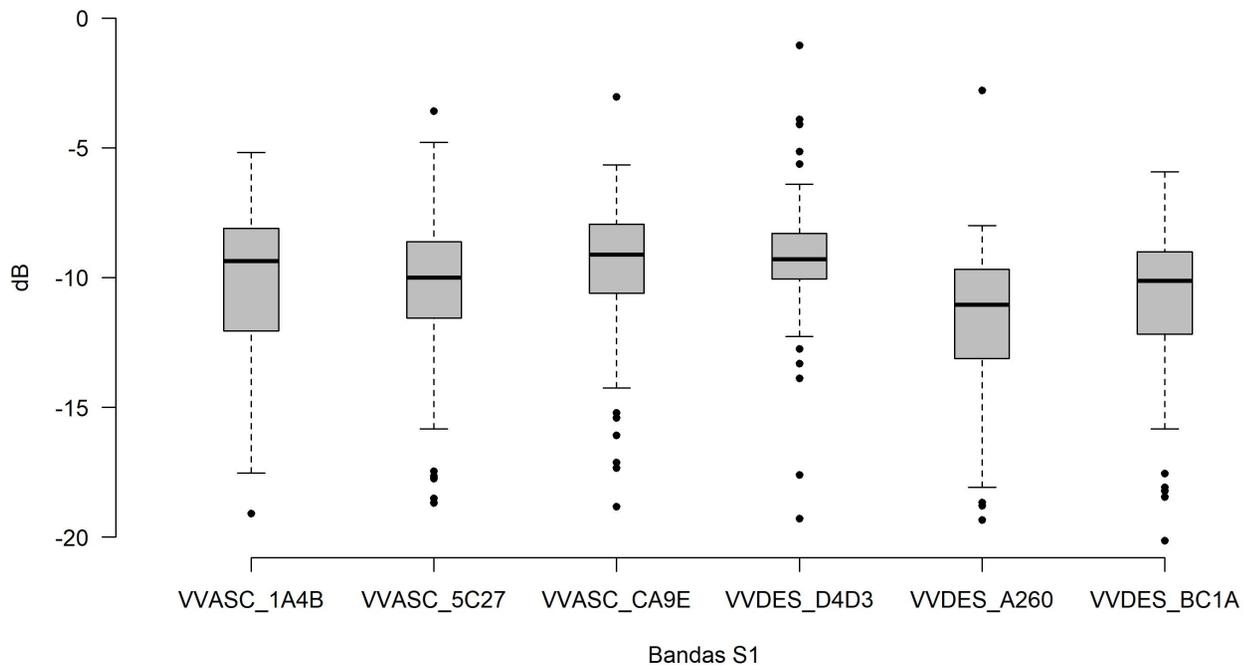


**Figura 4.2:** Imágenes Sentinel-1A 2015 (AE1)

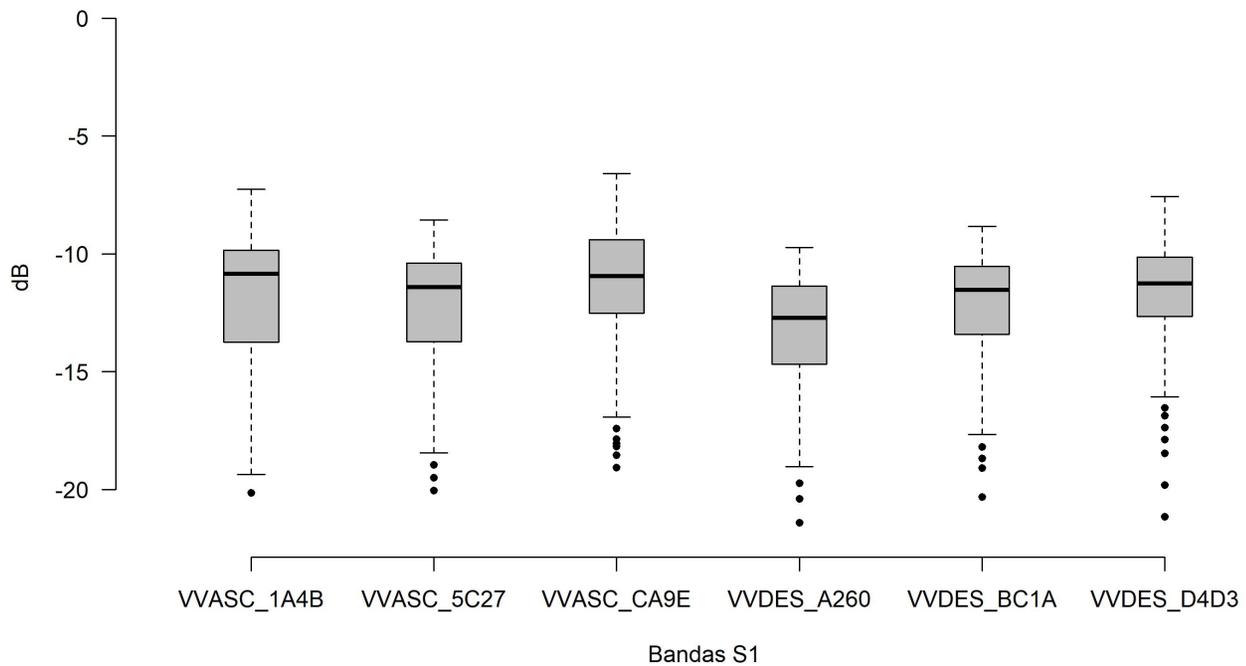
El análisis de la distribución de la intensidad de retrodispersión evaluados en los centroides y estadística zonal (mediana) de los humedales para 2014 y 2015, se indica en la Figura 4.3 y Figura 4.4.

Los diagramas de cajas para el año 2014 en la Figura 4.3a de centroides muestran una distribución de la retrodispersión con sesgo negativo y valores atípicos en ambos extremos de los datos SAR S1 en órbita ASC y DES. La mediana indicada en la Figura 4.3b es más sensible a valores atípicos hacia los valores bajos de la distribución, mostrando un potencial para la determinación de umbrales en humedales lacustres (Huang et al., 2018; Rico Cabrera, 2021). En los diagramas de cajas para el año 2015 en las Figuras 4.4a y 4.4b, se observa un comportamiento similar, con sesgos negativos en las distribuciones y valores atípicos hacia los valores bajos de retrodispersión de los datos SAR S1.

En el área de trabajo se puede inferir la existencia de humedales con espejos de agua (lacustres) valores bajos inusuales y humedales colonizados por vegetación (palustres) de pastos o arbustos debido a la presencia de valores altos inusuales en la distribución. El análisis estadístico se realizó en todos los humedales del área de estudio sin discriminar sus clases previamente, con el fin de realizar una clasificación no supervisada de conglomerados jerárquicos basados en la mediana de retrodispersión, que darán una idea del comportamiento y distribución espacial de los humedales.

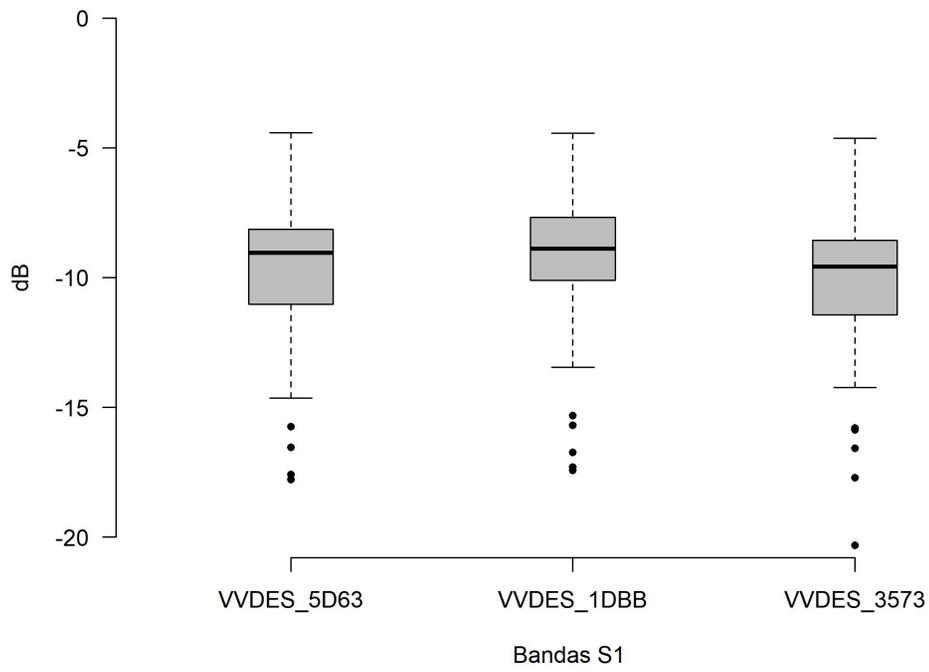


(a) Retrodispersión centroides de humedales

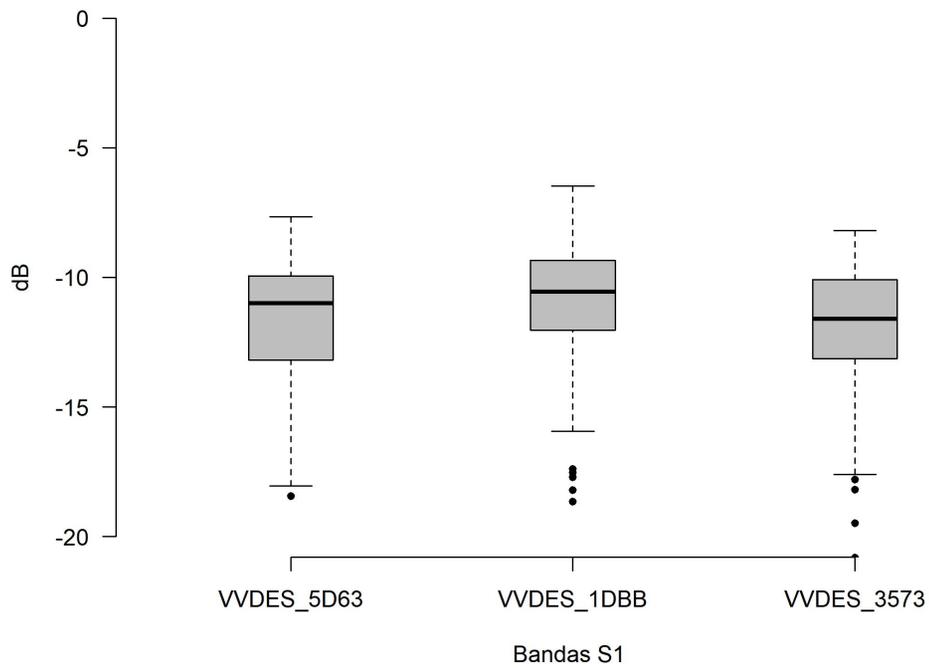


(b) Retrodispersión estadística zonal mediana

**Figura 4.3:** Centroides y estadística zonal de humedales con Sentinel-1A 2014



(a) Retrodispersión centroides de humedales



(b) Retrodispersión estadística zonal mediana

**Figura 4.4:** Centroides y estadística zonal de humedales con Sentinel-1A 2015

## 4.2. Análisis de conglomerados Jerárquicos

El análisis de conglomerados jerárquicos se realizó con la librería FactoClass de R-CRAN (Pardo and Del Campo, 2007), utilizando las medianas de retrodispersión en los humedales de estudio (Ver Anexo A) con las imágenes Sentinel-1A 2014 y 2015. Se determinaron 5 cluster basados en las distancias euclidianas mediante la técnica del codo (Ver Anexo B) (Elbow Method)(Jing et al., 2020) que se fundamenta en las minimización de la varianza intra-cluster y la maximización de la varianza inter-cluster, es decir, ubicar observaciones que se encuentren muy cerca a las de su mismo grupo y los grupos que estén lo más alejados posibles. Los métodos no supervisados de conglomerados han sido importantes en el estudio de de humedales con datos SAR ya que han ayudado en la segmentación y separabilidad de las clases para obtener patrones, que vislumbren los rangos de retrodispersión y mecanismo en que se mueven los humedales (Gulácsi and Kovács, 2020; Refice et al., 2020).

En la Figura 4.5 se muestran los conglomerados jerárquicos en el primer plano factorial y en la Tabla 4-5 extraída del Anexo B se indican los rangos medios de la clase. Con estos resultados se deduce que los conglomerados cl2 (13 humedales) y cl5 (9 humedales) pertenecen a humedales lacustres, retornos de retrodispersión más bajos que las obtenidas en otras clases de VVASC y VVDES, esto debido al mecanismo de reflexión de superficie especular que presentan. Los conglomerados cl1 (14 humedales), cl3 (24 humedales) y cl4 (20 humedales), pertenecen a humedales palustres, ecosistemas colonizados por vegetación secundaria y pastos, presentando los rangos más altos de retrodispersión media en el conglomerado cl4, debido al mecanismo de doble rebote y volumen (Rico Cabrera, 2021; Sultana et al., 2016).

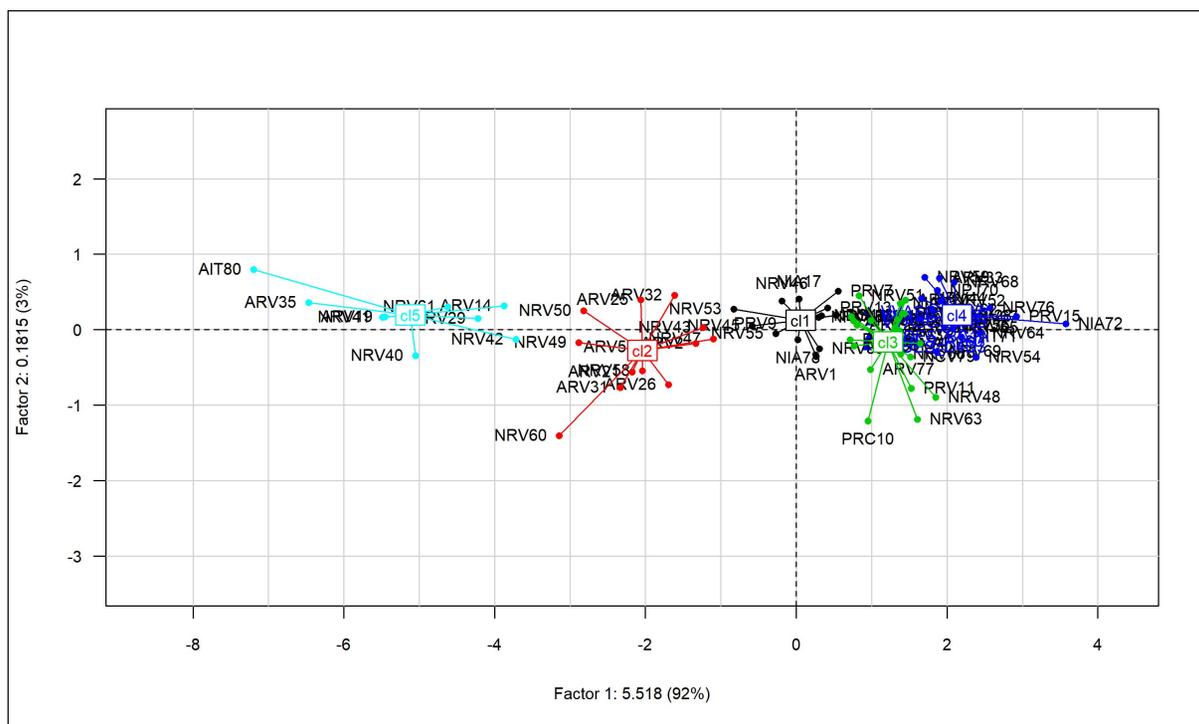
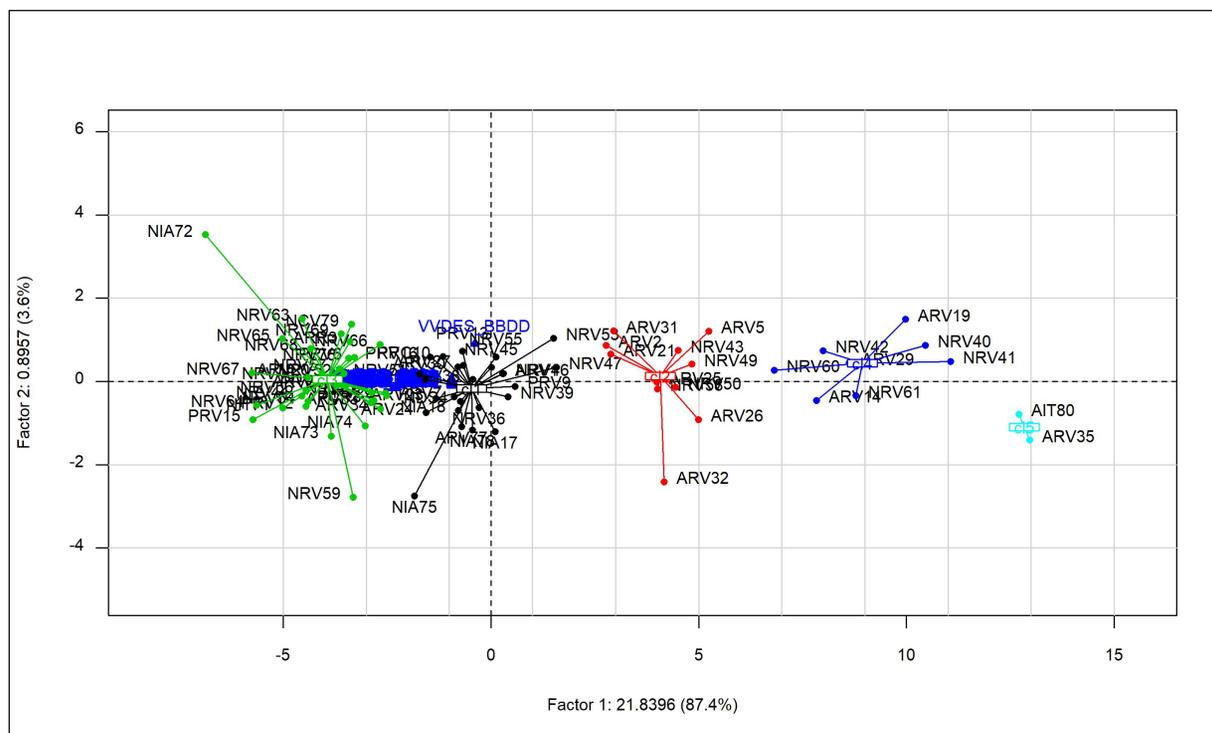


Figura 4.5: Cluster jerárquico primer plano factorial Sentinel-1A 2014

Conglomerado	Media_VVASC (dB)	Media_VVDES (dB)	#
cl1	-11.8 a -11.5	-13.7 a -11.5	14
cl2	-15.4 a -13.9	-15.2 a -13.6	13
cl3	-11.2 a -10.5	-11.6 a -10.5	24
cl4	-9.6 a -8.8	-11.2 a -9.8	20
cl5	-17.9 a -17.5	-18.9 a -17.6	9

**Tabla 4-5:** Medias de clase conglomerados jerárquicos Sentinel-1A 2014

En la Figura 4.6 y la Tabla 4-6 extraída del Anexo B, se observan los agrupamientos cl2 (11 humedales), cl4 (8 humedales) y cl5 (2 humedales) pertenecen a humedales lacustres, con los rangos de retrodispersión media más bajos observando una buena separabilidad y segmentación de umbrales en los espejos de agua, como por ejemplo, el conglomerado cl5 pertenece a los espejos de agua con mayor superficie en el área de estudio (3.69 ha y 3.58 ha). Las clases cl1 y cl3 pertenecen a humedales palustres, con la mayor cantidad de humedales en el conglomerado cl3 (33) donde se presentaron las intensidades de retrodispersión media más altas, debido a que estos ecosistemas están colonizados por vegetación.



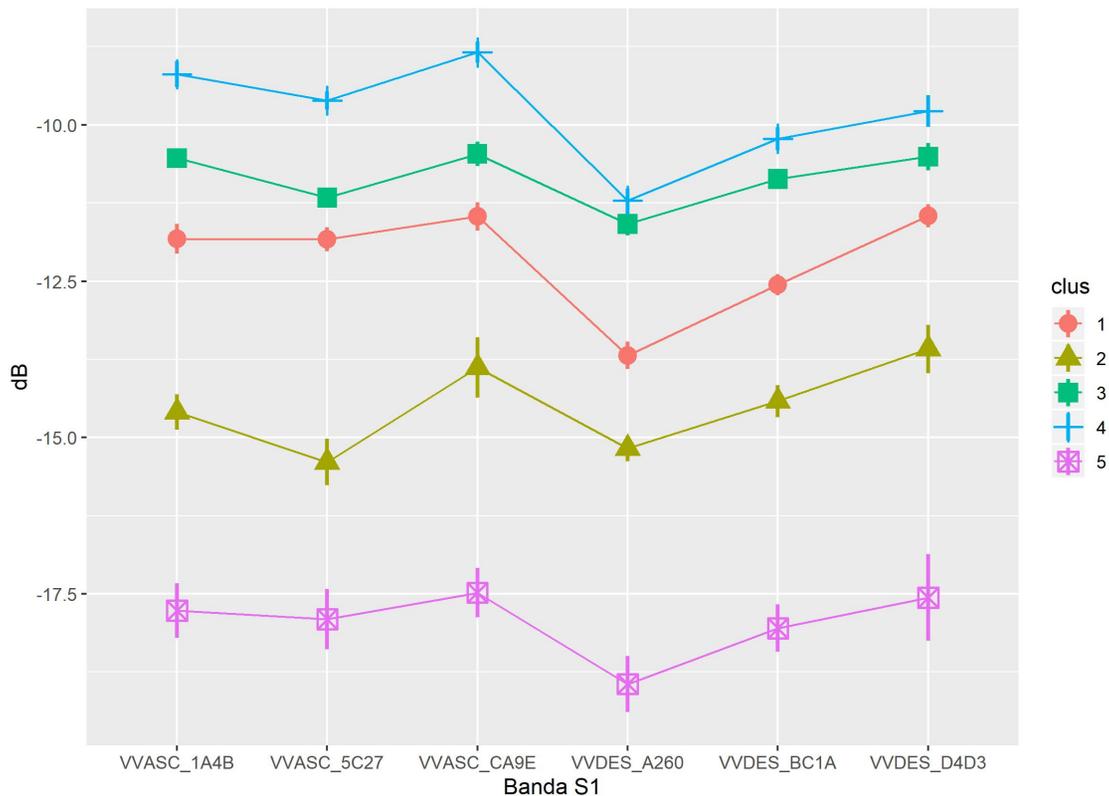
**Figura 4.6:** Conglomerados jerárquicos Sentinel-1A 2015

En la Figura 4.7, se muestra la conformación y separabilidad de los grupos formados por las bandas VVASC y VVDES del año 2014, esta clasificación no supervisada segmentan los humedales lacustres y palustres, donde las intensidades más bajas corresponden a los espejos

de agua y las intensidades más altas a las ciénegas.

Conglomerado	Media_VVASC (dB)	Media_VVDES (dB)	#
cl1	-12.4 a -11.0	-13.0 a -10.5	26
cl2	-15.4 a -13.4	-15.4 a -12.8	11
cl3	-10.5 a -9.2	-11.1 a -8.8	33
cl4	-18.3 a -15.6	-17.8 a -15.9	8
cl5	-20.2 a -18.8	-20.6 a -15.4	2

**Tabla 4-6:** Medias de clase conglomerados jerárquicos Sentinel-1A 2015



**Figura 4.7:** Segmentación de conglomerados jerárquicos Sentinel-1A 2014

En la Figura 4.8, se ilustran imágenes de algunos humedales que se clasificaron en diferentes conglomerados, donde se pueden observar las características de la vegetación y como están colonizados por esta. Los conglomerados cl3-2015 y cl4-2014 son ecosistemas que presentan vegetación secundaria con presencia de arbustos y los conglomerados cl1 2014 y 2015, son ecosistemas que presentan vegetación baja con presencia de pastos. Los conglomerados

cl5 son ecosistemas que presentan cuerpos de agua. Aunque geoméricamente hay una similitud en la intensidad de retrodispersión que retornan los humedales y que permite formar los conglomerados basada en la distancias euclidianas, no se observa un patrón en la distribución espacial donde se localice una clase específica, que permita sectorizar los humedales como se muestra en la la Figura 4.9.



(a) Las Chozas, cl1(2014 y 2015)



(b) Padua, cl1(2014 y 2015)



(c) Heroica, cl3-2015, cl4-2014



(d) La Carola, cl3-2015, cl4-2014

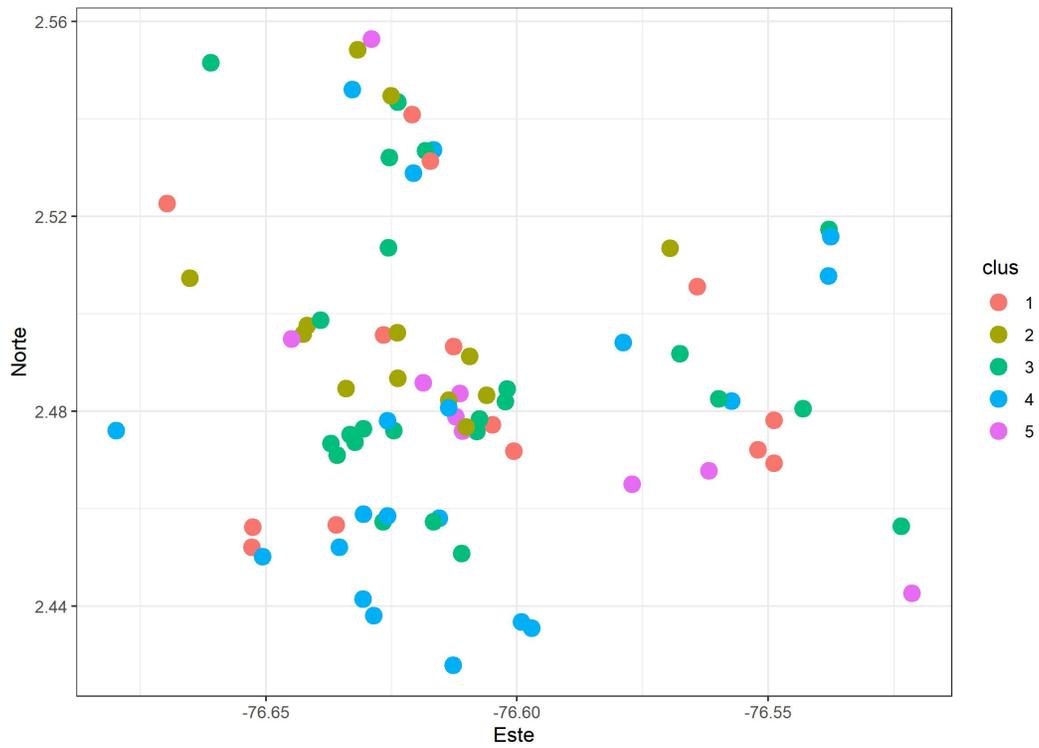


(e) Florida, cl5 (2014 y 2015)

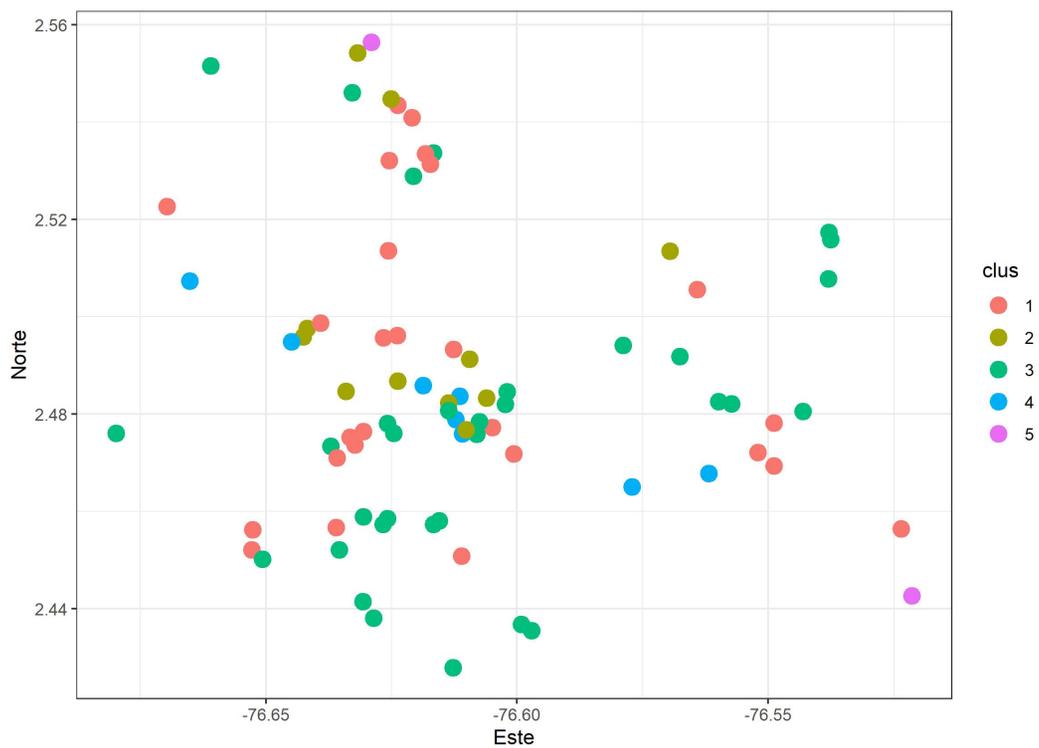


(f) Las Vegas, cl5 (2014 y 2015)

**Figura 4.8:** Conglomerados 2014 y 2015. Fuente : CRC- Google Earth



(a) Cluster jerárquico Sentinel-1A 2014



(b) Cluster jerárquico Sentinel-1A 2015

**Figura 4.9:** Distribución espacial conglomerados jerárquicos Sentinel-1A 2014 y 2015

### 4.3. Análisis exploratorio información auxiliar

En la Figura 4.10 se indican los rangos de cada variable en el área de estudio (AE1). La pendiente muestra que la mayor parte del terreno del AE1 presenta inclinaciones bajas en la zona urbana, con inclinaciones pronunciadas en la zona rural. Mientras que el ITW muestra que los valores más altos se encuentran en los canales de drenaje, áreas más húmedas y presenta una disminución hacia las divisorias de agua (Wilson and Gallant, 2000). Los índices espectral como el NDVI, nos muestra que en el área de estudio hay alta densidad de la vegetación y el NDWI detecta áreas potenciales donde hay presencia de agua.

En la Tabla 4-7, se indican los resultados de los descriptores estadísticos del área de interés de donde se deduce la presencia o contenido de agua (NDWI, valores positivos altos), áreas potenciales con alto contenido y acumulación de agua (ITW, valores altos), presencia y densidad de la vegetación (NDVI, valores bajos corresponden a áreas con escasa vegetación como superficies de agua y valores altos a vegetación densa y vigorosa), así como la importancia para entender la dinámica del flujo y la morfología superficial con la pendiente del terreno, que tiene la mayor variabilidad de los datos el área de trabajo (67.61%), seguido del ITW (35.43%) (Deenik, 2022; Pettorelli, 2019; Amani et al., 2019; Bian et al., 2021).

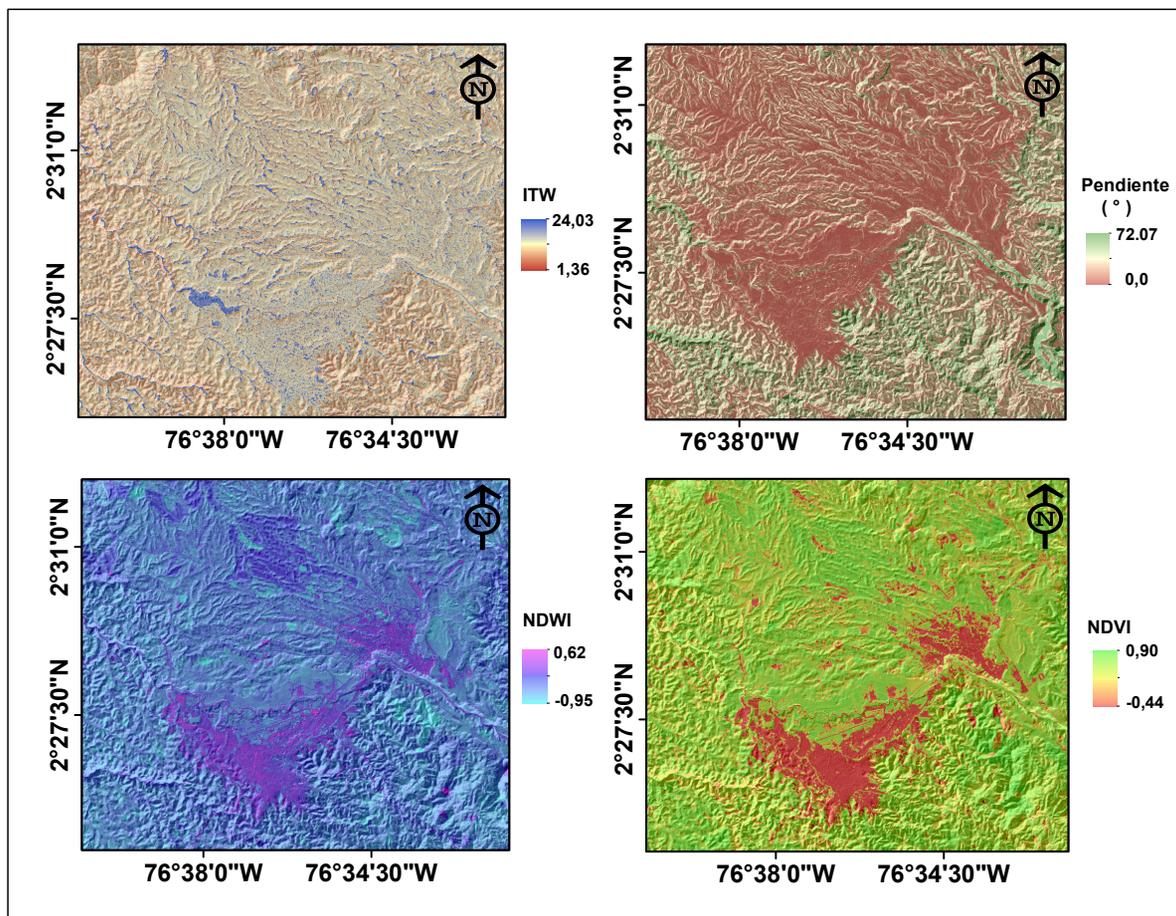


Figura 4.10: Variables Auxiliares de área de estudio

Estadísticos Variables	Mín	Máx	Media	Mediana	Sd	Coef Variación
NDVI	-0.44	0.90	0.66	0.71	0.17	25.76
NDWI	-0.95	0.62	-0.50	-0.51	0.08	16.00
ITW	1.36	24.03	5.87	5.37	2.08	35.43
Pendiente(°)	0.00	72.07	12.32	10.94	8.33	67.61

**Tabla 4-7:** Descriptores estadísticos de variables auxiliares

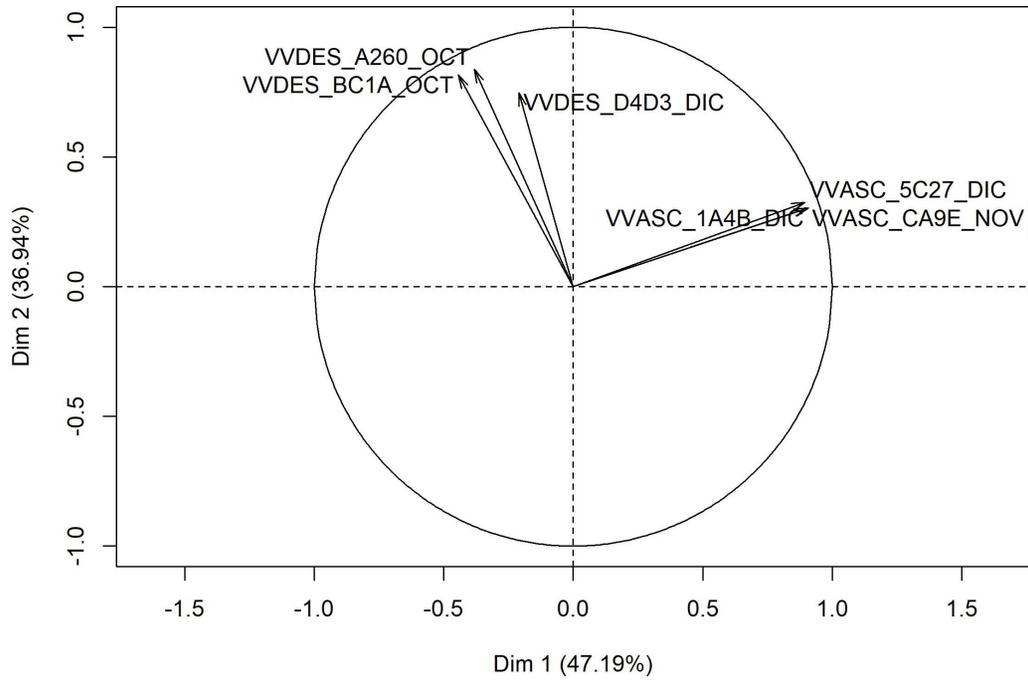
## 4.4. Criterios para detectar humedales con imágenes SAR

En la sección 4.1, se evaluó la intensidad de retrodispersión de las imágenes SAR S1 en los humedales, donde se encontraron rangos en los que fluctúan estos ecosistemas. Los rangos presentaron una variabilidad en la intensidad que hace complejo determinar rangos específicos para la clase de humedales palustres (ciénegas), debido a la densidad y tipo de vegetación que presentan mecanismos de doble rebote o volumen, esto hace que las coberturas u objetos terrestres retrodispersen las mismas intensidades de energía. Por otra parte, los humedales lacustres presentaron los rangos más bajos en la intensidad debido a la poca energía que retrodispersan por el mecanismo de reflexión especular (Sultana et al., 2016; Moser et al., 2016).

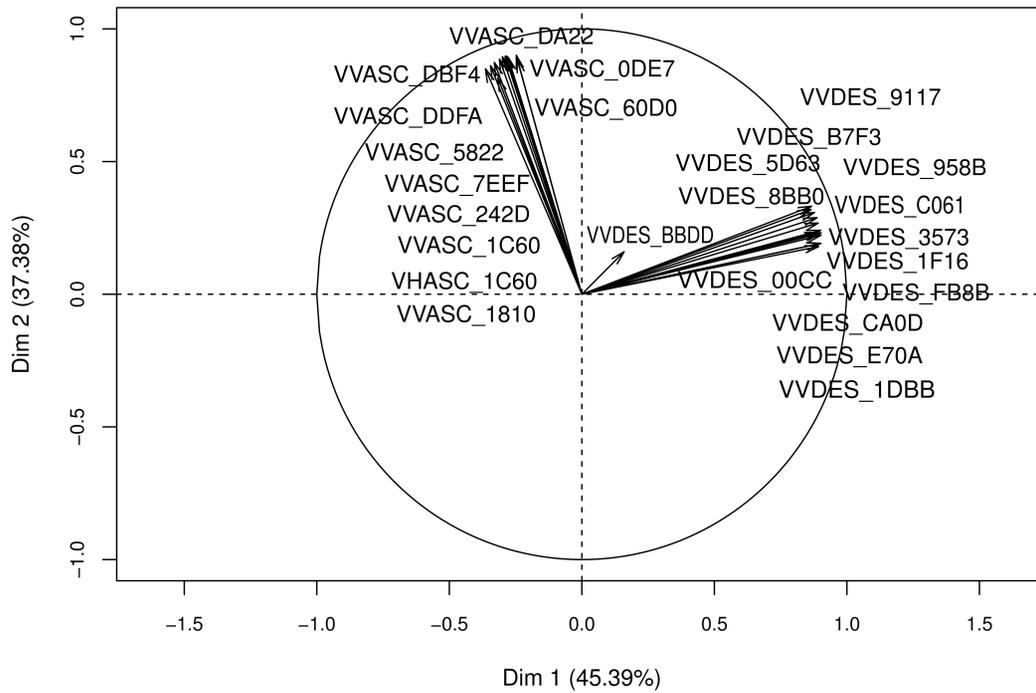
La información auxiliar del DEM y óptica son complementos importantes para la detección de humedales, por la capacidad que presentan para detectar propiedades y atributos como la vegetación, la morfología, presencia de humedad y agua (Deenik, 2022; Mahdianpari et al., 2019; Mahdavi et al., 2018).

El círculo de correlaciones obtenido del análisis de componentes principales (ACP) de las bandas polarimétricas 2014 y 2015 se indica en la Figura 4.11, donde se muestra buena representatividad de las bandas Sentinel-1A VVASC y VVDES en el primer plano factorial. Se observa alta correlación en las Figuras 4.11a y 4.11b de las bandas VVASC, lo que indica que presentan información intrínseca similar (multicolinealidad) así como en las bandas VVDES. Por otra parte, las bandas VVASC y VVDES forman un ángulo recto en ambos gráficos mostrando información diferente e independiente, útil en la detección de humedales, lo que significa que es importante un análisis por separado de las bandas polarimétricas VV en órbita ascendente y descendente. Se redujo la dimensionalidad de las imágenes SAR Sentinel-1A 2015, en tres componentes principales con una varianza del 86.59% que se utilizaron como variables predictoras en el modelo de detección de humedales (Montgomery et al., 2021).

El uso de imágenes aéreas UAVSAR (Qual-pol) PolSAR, han sido importantes por las capacidades para discriminar entre diferentes clases de coberturas terrestres y detectar diferentes mecanismos de dispersión (dispersión superficial, doble rebote y volumen), de objetos terrestres. Los humedales están dominados por varios blancos distribuidos que pueden caracterizarse por técnicas de descomposición polarimétrica incoherente, que han demostrado gran potencialidad para mapear humedales como la descomposición de Cloude-Pottier y Freeman-Durden (Mahdianpari et al., 2017; de Almeida Furtado et al., 2016).



(a) ACP 2014



(b) ACP 2015

**Figura 4.11:** Círculo de correlaciones bandas Sentinel-1A 2014 y 2015

## 4.5. Modelo de Detección de Humedales Datos Satelitales Sentinel-1A

### 4.5.1. Rendimiento del modelo

En este estudio se modelaron diferentes escenarios; con bandas SAR Sentinel-1A pertenecientes al año 2015, utilizando como variables predictoras el coeficiente de retrodispersión (SAR\_S1A\_2015), componentes principales (ACP\_SAR\_S1A\_2015), bandas en órbita ascendente (SAR\_S1A\_VVASC\_2015), bandas en órbita descendente (SAR\_S1A\_VVDES\_2015) y componentes principales con órbitas ASC y DES (ACP\_SAR\_S1A\_VVASC\_VVDES\_2015). Así mismo se modelaron cada uno de los escenarios anteriores fusionando variables auxiliares (Var\_Aux), provenientes del DEM y Sentinel-2A (óptica). Los resultados de exactitud general del modelo RF obtenidos, se indican en la Tabla 4-8, concerniente a las clases de humedales de referencia (pixeles) que se clasificaron correctamente. Los escenarios que tuvieron los mayores rendimientos generales fueron SAR\_S1A\_2015 - Var\_Aux con el 87.01%, SAR\_S1A\_2015 con 86.39% y SAR\_S1A\_VVDES\_2015 - Var\_Aux con el 81.77%, los cuales fueron concordantes con estudios de humedales que han utilizado RF (LaRocque et al., 2020; Montgomery et al., 2021).

Escenarios Modelados	Exactitud General (%)	Kappa (%)	OOB (%)
SAR_S1A_2015	<b>86.39</b>	<b>84.55</b>	<b>14.13</b>
SAR_S1A_2015 - Var_Aux	<b>87.01</b>	<b>85.27</b>	<b>14.05</b>
ACP_SAR_S1A_2015	68.16	63.85	33.50
ACP_SAR_S1A_2015 - Var_Aux	76.64	73.50	24.70
SAR_S1A_VVASC_2015	72.05	68.24	29.66
SAR_S1A_VVASC_2015 - Var_Aux	77.58	74.55	24.43
SAR_S1A_VVDES_2015	79.75	76.99	21.28
SAR_S1A_VVDES_2015 - Var_Aux	<b>81.77</b>	<b>79.3</b>	<b>19.04</b>
ACP_SAR_S1A_VVASC_VVDES_2015	72.42	68.68	29.27
ACP_SAR_S1A_VVASC_VVDES_2015 - Var_Aux	78.84	75.99	22.60

**Tabla 4-8:** Evaluación del rendimiento modelos SAR Sentinel-1A con RF

Los escenarios evaluados anteriormente revelaron los coeficientes Kappa y OOB más satisfactorios para evaluar la confiabilidad del modelo. En el respectivo orden obtuvimos los siguientes resultados: 85.27% - 14.05%, 84.55% - 14.13% y 79.30% - 19.04% (Munoz and Bangdiwala, 1997; Slagter et al., 2020). Estas métricas son importantes para determinar el grado de coincidencia entre los datos de referencia y el mapa clasificado (Kappa) (Mahdian-pari et al., 2017), así como la tasa de error porcentual (OOB) que indica cuántas muestras no utilizadas en el entrenamiento de los árboles de decisión se clasificaron incorrectamente.

En la Tabla 4-9, se reportan los errores de clase obtenidos en el entrenamiento del modelo SAR\_S1A\_2015 - Var\_Aux. Las categorías asociadas a humedales arrojaron los errores de clase más bajos (frecuencia de píxeles que fueron clasificados incorrectamente), humedales palustres asociados a ciénegas TpPaVeBj con 4.4 % y TpPaVeSe con 5.1 % y los humedales lacustres asociados a los espejos de aguas, AaArA con un 8.2 %. Las clases que no se asocian a humedales con mayores errores de clase fueron SD (Suelos Desnudos) con un 29.4 %, Pastos con 19.6 % y CT (Construcciones) con un 29.3 %.

Ref/Pred	AaArA	TpPaVeBj	TpPaVeSe	ZU	Veg_S	SD	Pastos	CT	Bosques
<b>AaArA</b>	2460	87	65	0	3	6	20	36	2
<b>TpPaVeBj</b>	19	3277	50	4	10	4	9	52	2
<b>TpPaVeSe</b>	15	66	2970	5	9	10	18	33	3
<b>ZU</b>	6	3	0	948	9	5	7	21	1
<b>Veg_S</b>	9	36	58	12	2174	12	61	103	35
<b>SD</b>	35	60	116	32	81	1766	118	263	29
<b>Pastos</b>	35	83	121	19	94	26	2412	160	50
<b>CT</b>	52	135	185	16	133	53	172	1981	73
<b>Bosques</b>	4	12	27	3	46	14	39	49	1806
<b>Err_Clase (%)</b>	<b>8.2</b>	<b>4.4</b>	<b>5.1</b>	<b>5.2</b>	<b>13</b>	<b>29.4</b>	<b>19.6</b>	<b>29.3</b>	<b>9.7</b>

**Tabla 4-9:** Matriz de confusión entrenamiento modelo SAR\_S1A\_2015 - Var\_Aux

En la Tabla 4-10, se reportan los errores de comisión (EC) y omisión (EO) por cada clase utilizada en el modelo de detección SAR\_S1A\_2015 - Var\_Aux. De la misma forma en la Tabla 4-11, se reportan la Exactitud del Usuario (UA) y del Productor (PA), para los tres escenarios con los mayores rendimientos de exactitud general, SAR\_S1A\_2015, SAR\_S1A\_2015 - Var\_Aux y SAR\_S1A\_VVDES\_2015 - Var\_Aux.

En este estudio se evaluará el rendimiento dado por la matriz de confusión (validación) del escenario SAR\_S1A\_2015 - Var\_Aux, indicado en la Tabla 4-10. Los errores de omisión (EO) obtenidos de la muestra de validación para las clases de humedales palustres, TpPaVeBj (asociados a ciénegas o pantanos con vegetación baja) fue de 2.73 % y TpPaVeSe (humedales con arbustos y relictos de bosque) de 4.07 % y para la clase lacustre AaArA asociados a espejos de agua obtuvo un 6.04 %. Por otra parte, la clase de no humedal ZU (Zonas Urbanas) obtuvo un EO de 4.80 %, estos fueron los EO más bajos del modelo de detección RF. Los EO bajos indican que las clases de humedales detectadas se han interpretado de forma satisfactoria en el mapa cartográfico y la probabilidad que un humedal de referencia pueda ser omitido o clasificado incorrectamente es baja. De lo anterior se concluye que la sub-estimación de la clase de humedales no es significativa, debido que la tasa de falsos negativos es baja, lo que se traduce en una correspondencia entre el modelo de detección (interpretación) y la realidad (Deenik, 2022; Na et al., 2018).

Por otra parte, las clases con mayores EO, que indican alta probabilidad de omisión (tasa de falsos negativos) y sub-estimación fueron las clases asociadas a no humedales como las

Construcciones (CT) con un 28.67 % y Suelos Desnudos (SD) con un 28.64 % (Tabla 4-10). Las confusiones de clasificación para la clase CT se presentaron en las clases de Pastos, Veg\_S (Vegetación Secundaria) y TpPaVeSe, y en la clase SD en las categorías CT y Pastos.

Los errores de comisión (EC) reportados en las clases de humedales detectados, se refieren a clases que no existen en un área o errores en la interpretación de las clases (falsos positivos), lo que se traduce en una sobre-estimación de los humedales de validación. Las clases de humedal arrojaron EC de 15.13 % en TpPaVeSe, 10.90 % en TpPaVeBj y 6.85 % en la clase AaArA. Estos desvíos en las clasificaciones de humedales de referencia en el modelo de detección (interpretación) indican que clase AaArA, son los humedales que con menor probabilidad o frecuencia aparecerán en otras clases o áreas del terreno donde no existen, lo que se traduce en una baja sobre-estimación de la clase, seguido de la clase TpPaVeBj y TpPaVeSe respectivamente (Na et al., 2018).

Los EO obtenidos en una clase, corresponderán a EC en otra clase, es decir, que los píxeles de humedales clasificados erróneamente en la clase TpPaVeSe se desviaron a las clases CT, SD y Pastos, mientras que las desviaciones de la clase TpPaVeBj se presentaron en las clases CT y Pastos. De igual forma los EC más altos de las clases pertenecientes a no humedales se presentaron en las clases CT con 23.84 % y Pastos con 17.27 %.

Pred\Ref	AaArA	TpPaVeBj	TpPaVeSe	ZU	Veg_S	SD	Pastos	CT	Bosques
AaArA	1088	5	7	0	5	21	20	21	1
TpPaVeBj	27	1423	19	2	17	18	36	48	7
TpPaVeSe	25	16	1296	0	29	49	37	62	13
ZU	0	0	5	476	9	14	6	8	0
Veg_S	0	1	5	0	956	39	34	64	10
SD	0	2	3	7	3	785	12	22	1
Pastos	4	4	2	7	27	62	977	82	16
CT	12	10	13	7	44	103	60	856	19
Bosques	2	2	1	1	10	9	18	37	733
T_Ref	1158	1463	1351	500	1100	1100	1200	1200	800
EO(%)	6.04	2.73	4.07	4.80	13.09	28.64	18.58	28.67	8.38
EC(%)	6.85	10.90	15.13	8.11	13.80	5.99	17.27	23.84	9.84

Tabla 4-10: Matriz de confusión validación modelo SAR\_S1A.2015 - Var\_Aux

En la Tabla 4-11, se reporta las exactitudes específica UA (Exactitud del Usuario) y PA (Exactitud del Productor) de cada clase, en los tres escenarios modelados que obtuvieron los rendimientos más favorables ( Exactitud General, Kappa y OOB).

La Exactitud del Productor (1-EO), revela la probabilidad que un píxel de referencia sea clasificado correctamente en el modelo resultante, es decir, que contiene información sobre las clases de referencia que se clasificaron correctamente en el terreno (Deenik, 2022; Na et al., 2018; Slagter, 2019).

Clase	Escenarios SAR Sentinel-1A 2015					
	SAR_S1A_2015		SAR_S1A_2015 - Var_Aux		SAR_S1A_VVDES_2015 - Var_Aux	
	UA <sup>1</sup> (%)	PA <sup>2</sup> (%)	UA(%)	PA(%)	UA(%)	PA(%)
<b>AaArA</b>	94.27	95.25	<b>93.15</b>	<b>93.96</b>	88.96	<b>88.34</b>
<b>TpPaVeBj</b>	85.95	97.81	<b>89.10</b>	<b>97.27</b>	86.06	93.64
<b>TpPaVeSe</b>	85.51	96.97	<b>84.87</b>	<b>95.93</b>	<b>79.87</b>	92.52
<b>ZU</b>	86.93	91.80	91.89	<b>95.20</b>	87.48	93.60
<b>Veg_S</b>	84.28	87.27	86.20	86.91	80.05	80.64
<b>SD</b>	91.80	73.27	<b>94.01</b>	71.36	89.06	<b>61.45</b>
<b>Pastos</b>	85.42	80.58	82.73	81.42	78.14	76.25
<b>CT</b>	75.68	67.17	76.16	71.33	<b>66.05</b>	68.75
<b>Bosques</b>	89.91	85.75	90.16	91.63	88.56	82.25

**Tabla 4-11:** Exactitud del Usuario (UA) y del Productor (PA)

En el escenario SAR\_S1A\_2015 - Var\_Aux la clase TpPaVeBj obtuvo el porcentaje más alto de PA con 97.27 %, que es igual a la sensibilidad del modelo o tasa de verdaderos positivos (Tabla 4-12), indicando, que tan bien son clasificados los pixeles de referencia, es decir, que hay bajas probabilidades que estos humedales se omitan en el modelo de detección (Rico Cabrera, 2021). La alta sensibilidad del modelo permite deducir la capacidad del modelo para poder detectar y discriminar correctamente los humedales TpPaVeBj de las otras clases (proporción de verdaderos positivos que fueron correctamente clasificados).

Del mismo modo las clases de TpPaVeSe y AaArA arrojaron PA de 95.93 % y 93.96 %, concluyendo que el modelo tuvo alta sensibilidad en estas clases, para detectar y discriminar los pixeles de referencia en el modelo, lo anterior, se traduce en la capacidad del algoritmo RF para discriminar las clases de humedales reales (verdaderos positivos) con las que no pertenecen a la clase (verdaderos negativos).

La Exactitud del Usuario (1-EC) corresponde al error de comisión y revela la confiabilidad del modelo, es decir, con que frecuencia la clase en el mapa estará realmente presente en el terreno (Rico Cabrera, 2021). La UA fue generalmente alta para todas las clases de humedales (mayores al 84.87 %), lo que indica que las clasificaciones reflejaron con precisión las clases de humedales de validación presentes en el terreno. Las probabilidades más altas UA en las clases de humedales fueron obtenidas por AaArA con 93.15 % y TpPaVeBj con 89.10 %.

Los porcentajes mínimos de UA y PA para las clases de humedales en los tres escenarios de modelación (Tabla 4-11) fueron: UA (79.87 %) y PA (88.34 %). Lo anterior significa en términos generales, que las clases de humedales de referencia han sido correctamente identifi-

<sup>1</sup>Exactitud del Usuario

<sup>2</sup>Exactitud del Productor

cadadas como humedales, con una probabilidad mayor al 88.34 %, y con probabilidades mayores 79.87 % las clases de humedales identificadas en el modelo pertenecen realmente a humedales en el terreno. Con respecto a las otras clases no asociadas a humedales la exactitud UA fluctuó entre el 66.05 % - 94.01 % y PA entre el 61.45 % - 95.20 %, donde las mayores confusiones de detección se presentaron en las clases CT, Pastos y SD.

La sensibilidad y especificidad del modelo, indicada en la Tabla 4-12, para el escenario SAR\_S1A\_2015 - Var\_Aux arrojó rangos satisfactorios en las clases de humedales. El modelo es sensible (tasa de verdaderos positivos) con probabilidades del 93.96 % al 97.27 % y específico (tasa de verdaderos negativos) con probabilidades del 97.3 % y 99.1 %, es decir, que el modelo presenta gran capacidad para discriminar las clases de humedales de otras categorías que no son humedales existentes en el terreno.

Para las otras clases asociados a no humedales, se obtuvieron rangos de sensibilidad de 71.33 % a 95.20 % y especificidad de 96.9 % a 99.6 %, presentando las probabilidades más altas en sensibilidad en la clase ZU y Bosques (91.63 %) y en especificidad las clases ZU y SD (99.4 %).

	<b>Sensibilidad (%)</b>	<b>Especificidad (%)</b>
<b>AaArA</b>	<b>93.96</b>	<b>99.1</b>
<b>TpPaVeBj</b>	<b>97.27</b>	97.9
<b>TpPaVeSe</b>	95.93	<b>97.3</b>
<b>ZU</b>	<b>95.20</b>	<b>99.6</b>
<b>Veg_S</b>	86.91	98.3
<b>SD</b>	71.36	<b>99.4</b>
<b>Pastos</b>	81.42	97.6
<b>CT</b>	<b>71.33</b>	<b>96.9</b>
<b>Bosques</b>	<b>91.63</b>	99.1

**Tabla 4-12:** Sensibilidad - Especificidad SAR\_S1A\_2015 - Var\_Aux

Los resultados obtenidos en la matriz de confusión del escenario SAR\_S1A\_2015 - Var\_Aux permiten concluir que para las clases de humedales AaArA, TpPaVeBj y TpPaVeSe, se obtuvo alta precisión y sensibilidad en el modelo de Machine Learning RF, para la detección de humedales en el área de estudio, lo que indica, que el modelo seleccionado maneja los umbrales para discriminar y detectar de forma satisfactoria las clases de humedales, lo que se traduce en concordancia entre lo detectado y la realidad de lo que existe en el terreno. En las clases de no humedales las menores precisiones se obtuvieron en las clases SD y CT y las de menor sensibilidad en las clases CT y Pastos.

### 4.5.2. Importancia de variables Modelo SAR\_S1A\_2015 - Var\_Aux

La importancia de las variables de entrada al modelo, se pueden determinar evaluando la MDA (Disminución Media de la Precisión) y el índice de Gini (que evalúa la impureza de los datos de entrenamiento) (Slagter, 2019). De las 29 variables (Figura 4.12) utilizadas en el modelo SAR\_S1A\_2015 - Var\_Aux, las variables más importantes y relevantes para la clasificación de los datos según la métrica MDA (cuantifican el cambio relativo en la precisión de los predictores en el modelo) fueron: la polarimetría VV de órbita descendente (VVDES) para las bandas SAR Sentinel-1A y las variables auxiliares, NDVI y la pendiente del terreno (SLOPE), concordantes con los resultados obtenidos por Deenik (2022) (Figura 4.12).

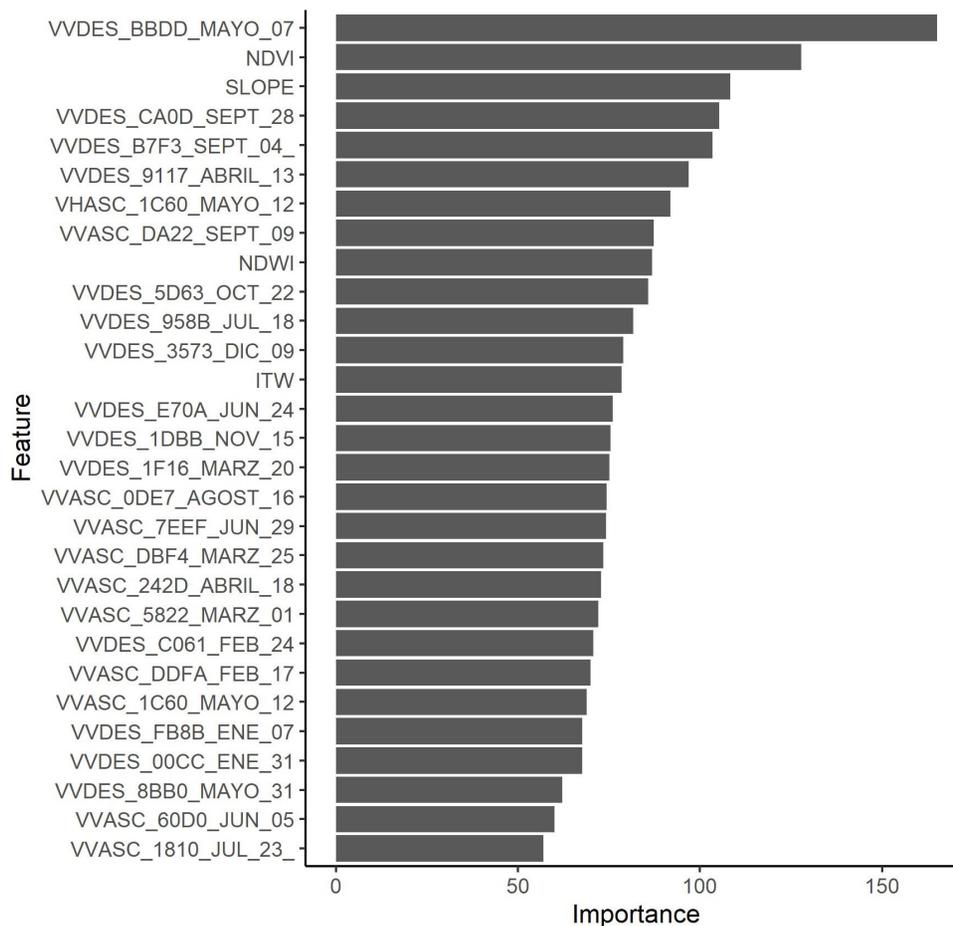


Figura 4.12: Importancia de variables MDA SAR\_S1A\_2015 - Var\_Aux

El índice de Gini estima la importancia de las variables, ya que es una forma de calcular que tan bien cada nodo clasifica (o divide) los datos (Slagter, 2019). Además, es útil para evaluar la influencia de las variables de entrada en la estructura de un árbol de decisión (Corcoran et al., 2013).

En la Figura 4.13 se muestra las variables con mayor ganancia de Gini y que tuvieron más aporte en la clasificación y división de los datos, como fue el NDVI, la pendiente (SLOPE) y el ITW utilizados como predictores auxiliares en el modelo de detección. Así mismo, se puede

observar que las variables NDVI, la pendiente y banda VVDES\_BBDD\_Mayo\_07, obtuvieron una importancia relativa en ambas métricas.

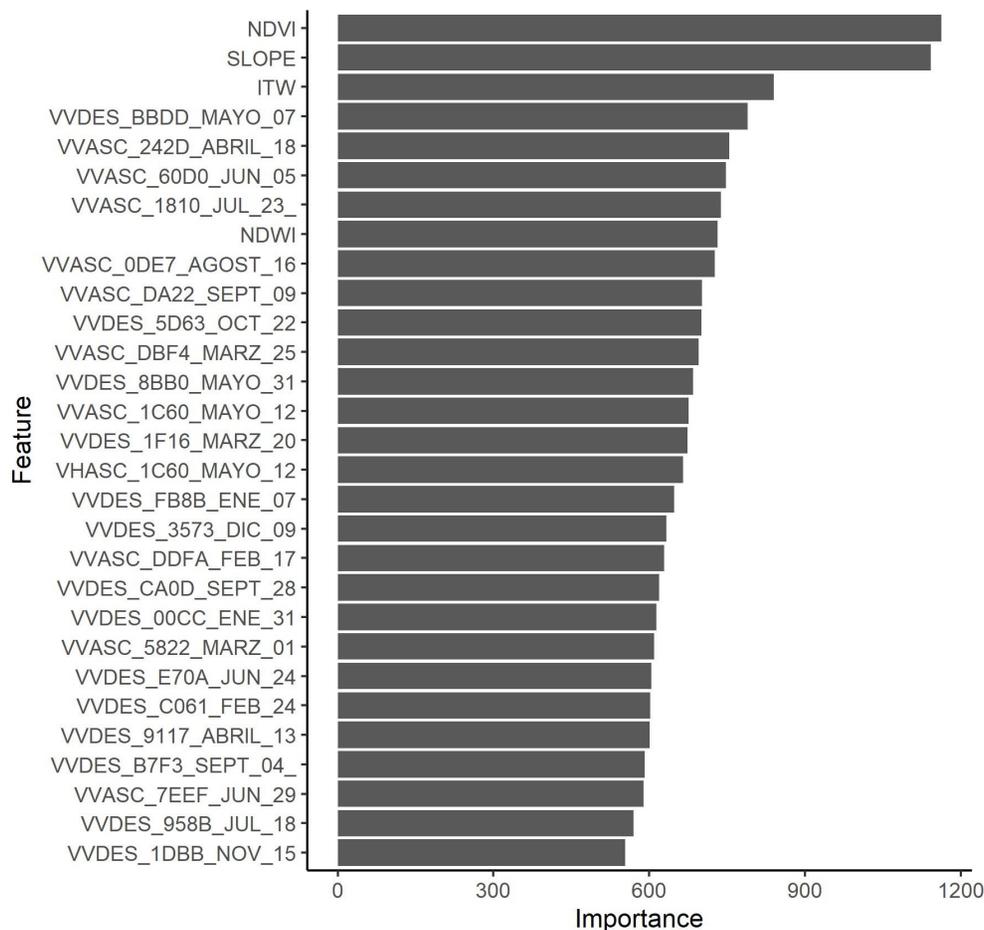


Figura 4.13: Importancia Gini SAR\_S1A\_2015 - Var\_Aux

### 4.5.3. Mapa detección de humedales modelo SAR\_S1A\_2015 - Var\_Aux

El modelo de detección RF utilizó imágenes SAR Sentinel-1A 2015 y variables auxiliares (NDVI, NDWI, pendiente, ITW), detectando nuevas áreas potenciales de humedales basados en muestras de entrenamiento obtenidos del inventario de humedales de la CRC. Las clases de humedales de estudio se clasificaron en AaArA (espejos de agua), TpPaVeBj (ciénegas con vegetación baja) y TpPaVeSe (ciénegas con vegetación secundaria) y otras clases asociadas a no humedales obtenidas del mapa de coberturas del SGC (Bosques, Pastos, Veg\_S, ZU, SD, CT).

El modelo evaluado en este estudio fue SAR\_S1A\_2015 - Var\_Aux, ya que presentó mayor exactitud general (87.01 %), comparables con otros estudios de clasificación de humedales que han obtenido rangos de exactitud de 70.2 % a 94.3 % (LaRocque et al., 2020). El modelo de detección con RF representado en la Figura 4.14, fue capaz de detectar humedales

potenciales en el área de estudio (AE1) del Municipio de Popayán, así como otras clases de coberturas que coinciden con la realidad del terreno. La mayor sensibilidad se obtuvo en la clases TpPaVeBj y TpPaVeSe, mientras la mayor precisión en la clase AaArA.

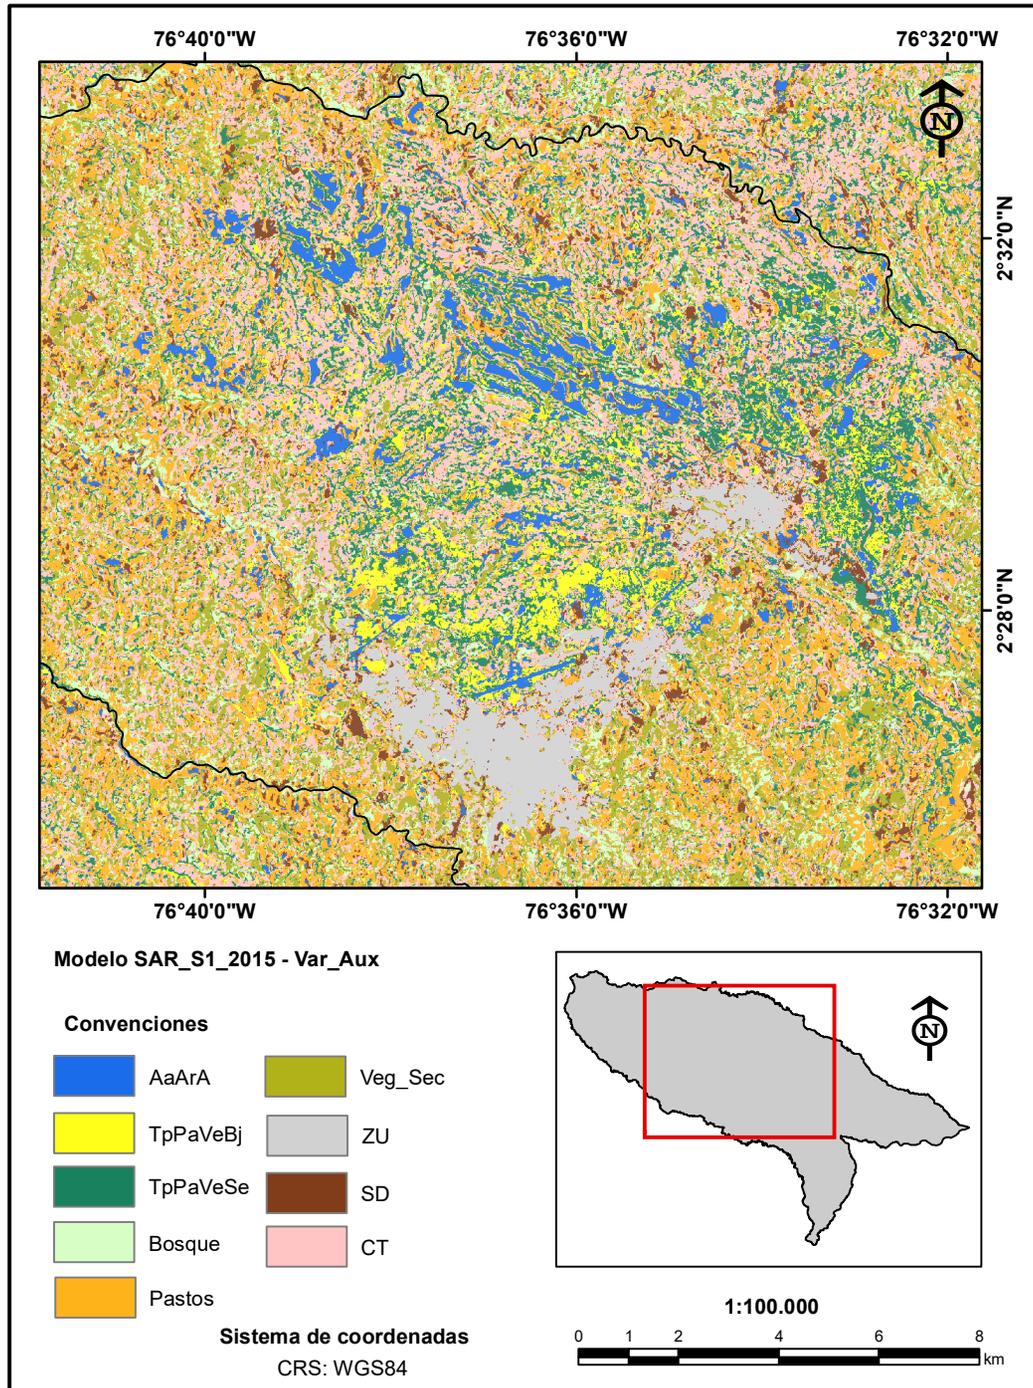


Figura 4.14: Mapa detección humedales SAR\_S1A\_2015 - Var\_Aux AE1

El cuadrángulo (C1) contiene el mapa de detección de humedales (izquierda) y la imagen Sentinel-2A (derecha) utilizada en este estudio, con orientación hacia el oeste del Municipio de Popayán como se indica en la Figura 4.15, donde se observa la distribución de áreas de humedales palustres y lacustres. La mayor concentración de áreas húmedas detectadas como ciénegas con vegetación baja se presentaron alrededor del casco urbano. La presencia de cuerpos de agua y áreas de inundación detectadas son resultado de las intensas lluvias que se presentaron en el año 2015. También se observan áreas dispersas de humedales en menor proporción con vegetación secundaria. La distribución de los humedales en Popayán nos permite inferir como se forman y se interconectan los complejos de humedales.

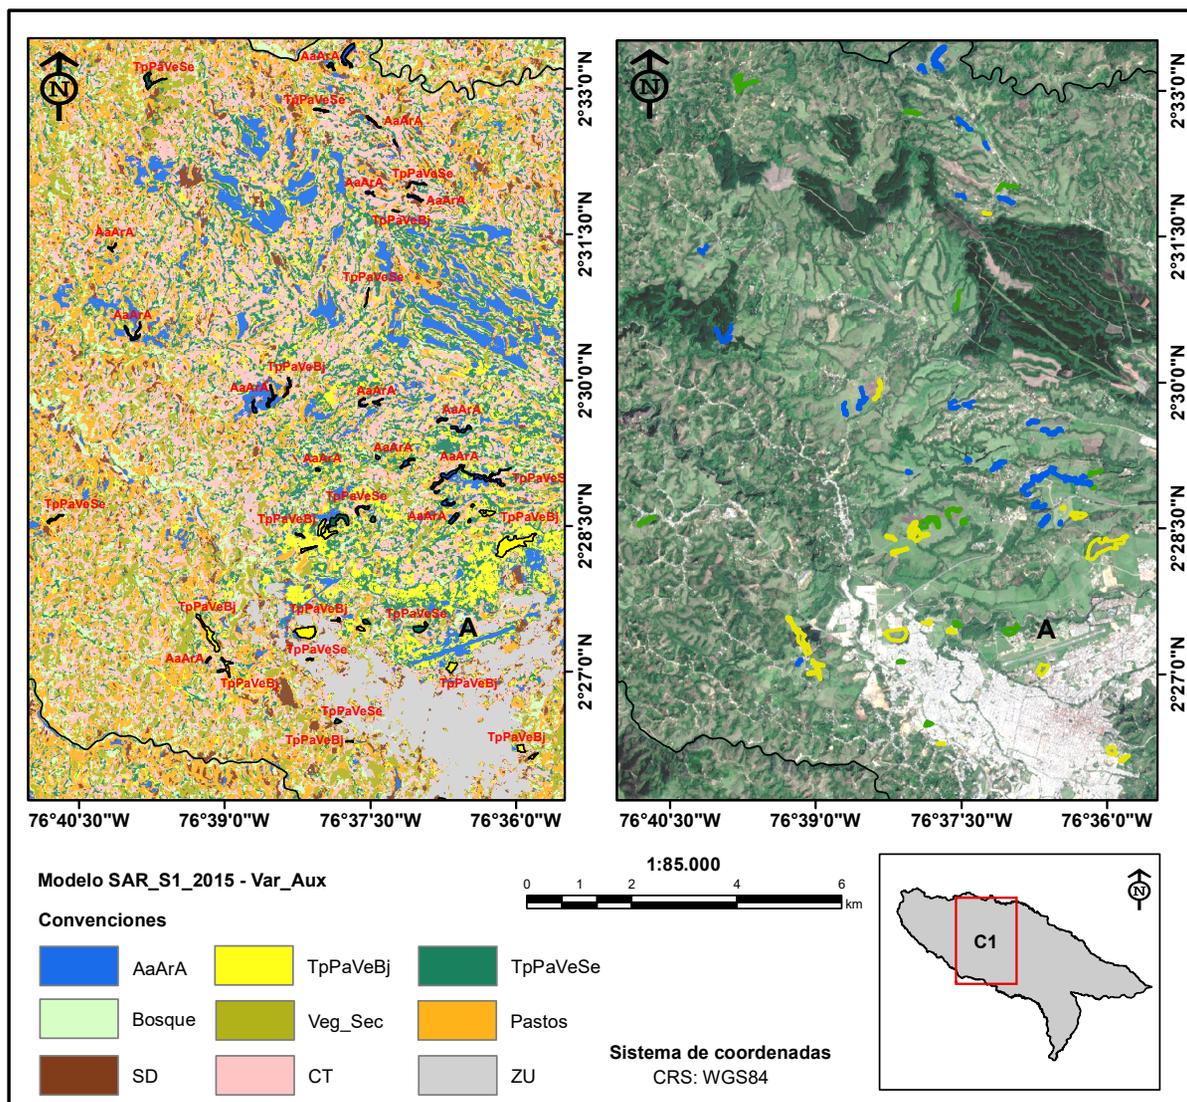


Figura 4.15: Mapa detección humedales SAR\_S1A\_2015 - Var\_Aux C1

El modelo presenta un nivel de dificultad mayor en la discriminación de espejos de agua y carreteras de tipo de superficie asfáltica (aeropuerto) evidenciando falsos positivos (A), esto

debido a que se presentan objetos de la superficie terrestre con características y condiciones similares en las variables derivadas de datos SAR, DEM y ópticas que hace compleja la discriminación y clasificación (Behnamian et al., 2017). Por otra parte, se detectaron cuerpos de agua que pertenecen a tramos de ríos (ej río Cauca). El análisis visual de la detección con imágenes ópticas del área de estudio perteneciente al mismo período evaluado, permite concluir sobre las limitaciones que se asocian con las otras clases para que se detecte una clase de humedal específica.

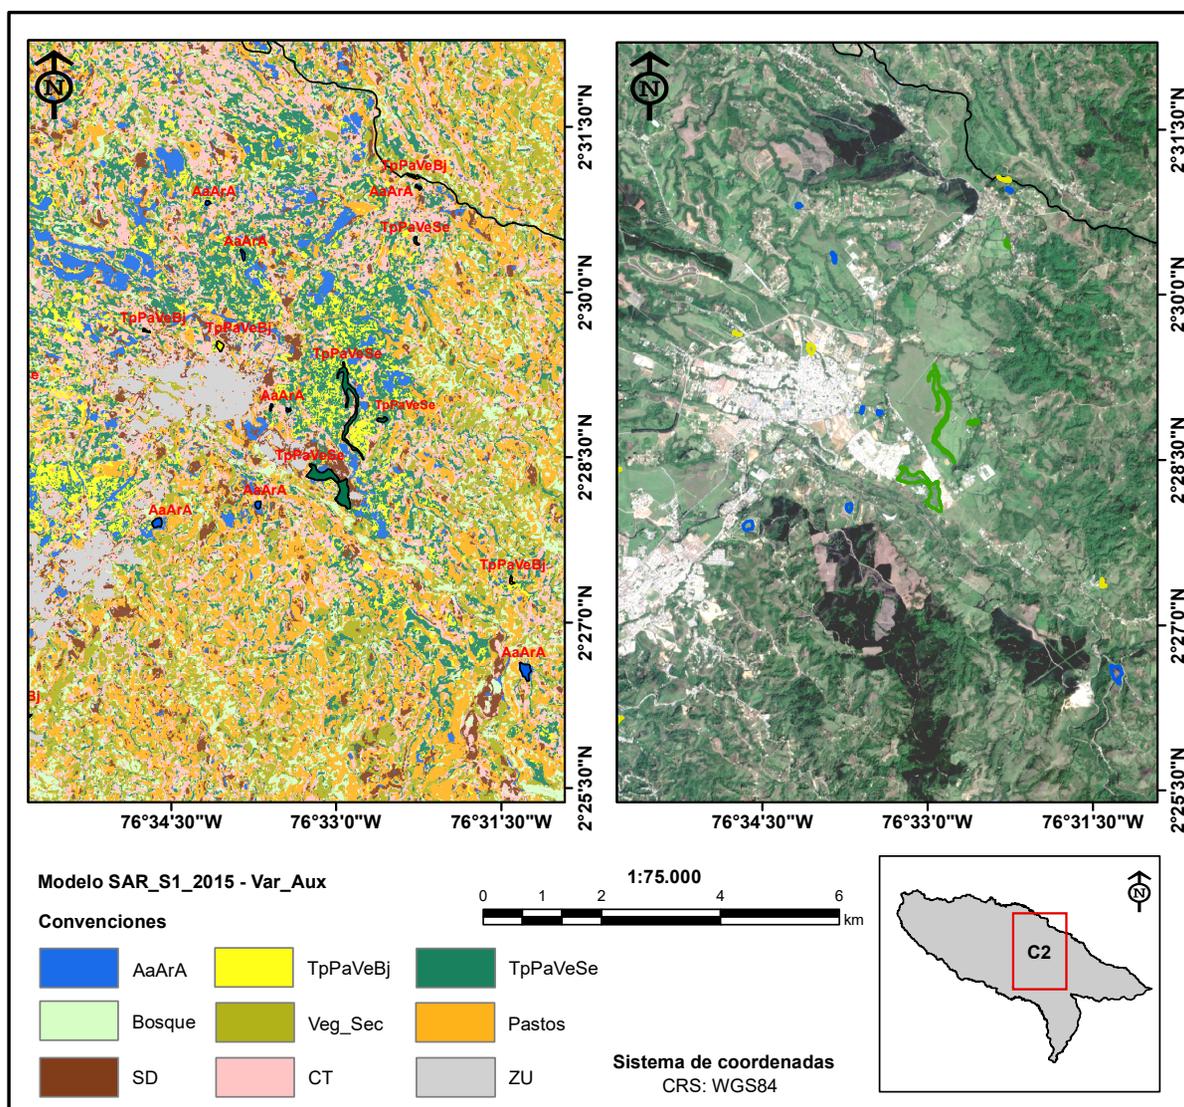


Figura 4.16: Mapa detección humedales SAR\_S1A\_2015 - Var\_Aux C2

La visualización del cuadrángulo (C2) con Sentinel-2A (derecha) en la Figura 4.16, con orientación hacia el este del Municipio de Popayán, se observa mayor proporción de áreas asociadas a ciénagas con vegetación secundaria hacia la zona rural del Municipio y distribución dispersa de cuerpos de agua, zonas inundadas y áreas de humedales asociados a ciénagas con vegetación baja (izquierda).

## 4.6. Modelo de Detección de Humedales Datos Aéreos UAVSAR

### 4.6.1. Rendimiento del modelo

En la Tabla 3-9 se indican las 12 variables predictoras de la descomposición polarimétrica Cloude-Pottier y Freeman-Durden, extraídas de imágenes aéreas UAVSAR que se utilizaron como entrada en el modelo de detección (Montgomery et al., 2021; Sultana et al., 2016). Se modelaron dos escenarios, el primero con las variables polarimétricas únicamente (UAVSAR\_2015 - Ver Anexo C) y el otro fusionando variables auxiliares como la pendiente y el ITW (UAVSAR\_2015 - Var\_Aux). Los resultados del rendimiento general del modelo de detección se reportan en la Tabla 4-13, donde se observa que el mayor rendimiento lo obtuvo el escenario UAVSAR\_2015 - Var\_Aux con el aporte significativo de las variables auxiliares arrojando un porcentaje de Exactitud General de 66.53 %. De la misma manera el coeficiente Kappa y el error OOB, mejoró significativamente la validación interna de precisión y la concordancia de clasificación en el modelo UAVSAR, (61.42 % y 34.1 %) en comparación con el primer escenario polarimétrico UAVSAR\_2015 (49.38 % y 43.84 %).

Escenarios Modelados	Exactitud General (%)	Kappa (%)	OOB (%)
UAVSAR_2015	56.13	49.38	43.84
UAVSAR_2015 - Var_Aux	66.53	61.42	34.1

**Tabla 4-13:** Evaluación del rendimiento de los modelos UAVSAR

En la Tabla 4-14, se reportan los errores de clase (Err\_Clase) obtenidos de la matriz de confusión de entrenamiento del escenario UAVSAR\_2015 - Var\_Aux, donde las clases de humedales palustres concernientes a los TpPaVeBj y TpPaVeSe, obtuvieron las desviaciones más bajas con un 19.86 % y 18.58 %. Por otra parte, los humedales lacustres relacionados a los espejos de agua tuvieron un error del 33.69 %. Las clases con mayores errores de clase en el entrenamiento fueron CT, Pastos, SD con 71.88 %, 51.84 % y 51.43 % respectivamente.

En la Tabla 4-15 se indica la matriz de confusión de validación del modelo RF, donde se reportan los errores de comisión (EC) y omisión (EO), por cada clase del modelo SAR\_UAVSAR\_2015 - Var\_Aux . Del mismo modo en la Tabla 4-16 se reportan las métricas de exactitud del Usuario (UA) y del Productor (PA) por cada clase para los escenarios modelados UAVSAR\_2015 y UAVSAR\_2015 - Var\_Aux.

En el escenario UAVSAR\_2015 - Var\_Aux, el error de omisión (EO) más alto para las clases de humedales (Tabla 4-15) lo arrojó la clase lacustre (AaArA) con un 31.7 % y el más bajo lo obtuvo la clase TpPaVeSe con 16.4 %. Lo anterior indica que la tasa de sub-estimación en las clases de referencia de los humedales es favorable con Exactitud del Productor (1 - EO) que oscilaron en rangos de 68.3 % a 83.6 % (Tabla 4-16), donde la mayor desviación de clasificación, se presentó en los espejos de agua (AaArA), con la mayor frecuencia de falsos

negativos en la muestra de validación de la clase TpPaVeSe (60) y TpPaVeBj (40) (Tabla 4-15).

Ref/Pred	AaArA	TpPaVeBj	TpPaVeSe	ZU	Veg_S	SD	Pastos	CT	Bosques
AaArA	738	125	126	11	28	28	34	12	11
TpPaVeBj	38	1808	250	14	49	18	51	9	19
TpPaVeSe	24	197	1871	17	69	37	48	21	14
ZU	4	4	24	740	50	11	34	24	18
Veg_S	22	37	179	48	1300	52	126	33	89
SD	28	48	213	54	136	613	97	38	35
Pastos	59	95	198	73	238	88	770	23	55
CT	5	50	166	43	121	53	75	207	16
Bosques	6	14	87	29	220	36	52	7	579
Err_Clase (%)	<b>33.69</b>	<b>19.86</b>	<b>18.58</b>	18.59	31.07	<b>51.43</b>	<b>51.84</b>	<b>71.88</b>	43.79

Tabla 4-14: Matriz confusión entrenamiento modelo UAVSAR\_2015 - Var\_Aux

Pred/Ref	AaArA	TpPaVeBj	TpPaVeSe	ZU	Veg_S	SD	Pastos	CT	Bosques
AaArA	319	17	2	1	5	14	26	4	5
TpPaVeBj	40	755	72	1	21	15	40	21	7
TpPaVeSe	60	106	803	9	71	76	64	71	31
ZU	2	13	8	390	25	26	33	19	14
Veg_S	7	18	30	23	549	60	96	46	78
SD	12	11	15	8	33	266	48	34	10
Pastos	16	20	21	13	61	51	305	27	19
CT	6	3	6	2	17	21	13	84	7
Bosques	5	9	4	7	38	24	17	9	234
T_Ref	467	952	961	454	820	553	642	315	405
EO (%)	<b>31.7</b>	20.7	<b>16.4</b>	<b>14.1</b>	<b>33.0</b>	51.9	52.5	73.3	42.2
EC (%)	<b>18.8</b>	<b>22.3</b>	<b>37.8</b>	<b>26.4</b>	39.5	39.1	42.8	<b>47.2</b>	32.6
PA (%)	<b>68.3</b>	79.3	83.6	<b>85.9</b>	<b>67.0</b>	48.1	47.5	<b>26.7</b>	57.8
UA (%)	<b>81.2</b>	<b>77.7</b>	<b>62.2</b>	<b>73.6</b>	60.5	60.9	57.2	52.8	<b>67.4</b>

Tabla 4-15: Matriz de confusión validación modelo UAVSAR\_2015 - Var\_Aux

De igual forma los humedales TpPaVeSe fueron omitidos (falsos negativos) por la clase TpPaVeBj (72) y los humedales TpPaVeBj por la clase TpPaVeSe (106) (Tabla 4-15). Las desviaciones en las clases de humedales muy posiblemente ocurrieron por la presencia de condiciones similares en los humedales que pueden dificultar la clasificación, aportando mecanismos de retrodispersión idénticos en las clases de coberturas del terreno.

Con respecto a las otras categorías las ZU arrojaron el menor desvío en el modelo de detección con un EO de 14.1 % y un PA de 85.9 %, seguido de las Veg\_S (Vegetación Secundaria) con EO de 33.0 % y un PA de 67.0 %. Las clases CT, Pastos, SD y Bosques arrojaron las mayores desviaciones de omisión en la muestra de validación, arrojando la clase CT la mayor incertidumbre de interpretación en el terreno (PA = 26.7 %).

Por otra parte, se evaluó los Errores de Comisión (EC) y la Exactitud del Usuario (UA), que revelan la confiabilidad del modelo y la probabilidad que la clase detectada esté realmente presente en el terreno. Para las clases de humedales los menores porcentajes de EC se obtuvieron para la clase AaArA, con el 18.8 % y UA (1-EC) de 81.2 %, seguido de las clases TpPaVeBj y TpPaVeSe con EC 22.3 % y 37.8 % y UA de 77.7 % y 62.2 % respectivamente. Lo anterior indica que las mayores frecuencias de falsos positivos se generaron en la clase de humedales con vegetación secundaria, detectando áreas en sitios donde no existe la clase. En las otras categorías los EC fluctuaron en un rango de 26.4 % a 47.2 %, obteniendo las mayores exactitudes UA en las clases ZU y Bosques con 73.6 % y 67.4 % respectivamente.

Con los resultados obtenidos se puede deducir en términos generales que las clases de humedales de referencia han sido correctamente interpretadas como humedales con probabilidades mayores al 68.3 % y las áreas detectadas como humedales en el modelo presentan probabilidades mayores al 62.2 %, es decir, que efectivamente estas áreas sean humedales.

En la Tabla 4-16 se contrastan la Exactitud UA y PA de los escenarios UAVSAR\_2015 y UAVSAR\_2015 - Var\_Aux, donde se observa el aporte significativo de las Var\_Aux al modelo de detección, mejorando la exactitud de las clases.

La Exactitud del Productor (PA) revela la probabilidad que la clase (pixel) de referencia se clasifique correctamente en el modelo, por lo que las probabilidades de interpretación de las clases de humedales en las características reales del terreno son satisfactorias en las ciénegas con vegetación secundaria (arbustos y relictos de bosque) y vegetación baja (pastos) (Rico Cabrera, 2021).

En términos generales para el modelo UAVSAR\_2015, en cuanto a exactitud UA y PA se puede concluir que las clases de humedales de referencia han sido clasificadas correctamente como humedales con probabilidades que fluctúan del 61.5 % al 73.3 % (PA) y con un rango de probabilidad de 53.1 % al 66.9 % (UA) las clases de humedales identificadas en el modelo pertenecen realmente a humedales. Así mismo en el modelo UAVSAR\_2015 - Var\_Aux se observa el aporte de las Var\_Aux (pendiente -ITW), clasificando las clases de humedales de referencias correctamente con probabilidades que fluctúan del 68.3 % al 83.6 % (PA) e identifica las clases de humedales en el modelo, asociados realmente a humedales con un rango de probabilidad del 62.2 % al 81.2 % (UA) (Tabla 4-16).

En la Tabla 4-16 y la Tabla 4-17, se puede observar que para las clases de humedales cartografiadas, el modelo UAVSAR\_2015 - Var\_Aux, la clase AaArA obtuvo alta precisión y baja sensibilidad, indicando que cuando el modelo detecta la clase es altamente confiable. Para la clase TpPaVeBj obtuvo alta precisión y alta sensibilidad, indicando que el modelo detecta y maneja muy bien la clase y por último para la clase TpPaVeSe, se obtuvo baja

precisión y alta sensibilidad, indicando que el modelo detecta bien la clase, pero incluye falsos positivos (clases de otros humedales). Por otra parte en la Tabla 4-17, se muestra la capacidad del modelo para discriminar de forma satisfactoria las clases de humedales TpPaVeSe y TpPaVeBj con alta sensibilidad, así como también discriminar las clases de humedales de otras que no lo son, con alta especificidad.

Clase	Escenarios UAVSAR			
	UAVSAR_2015		UAVSAR_2015 - Var_Aux	
	UA(%)	PA(%)	UA(%)	PA(%)
<b>AaArA</b>	<b>66.9</b>	<b>61.5</b>	<b>81.2</b>	<b>68.3</b>
<b>TpPaVeBj</b>	65.0	<b>73.3</b>	77.7	79.3
<b>TpPaVeSe</b>	<b>53.1</b>	71.4	<b>62.2</b>	<b>83.6</b>
<b>ZU</b>	66.5	73.6	73.6	85.9
<b>Veg_S</b>	51.4	55.2	60.5	67.0
<b>SD</b>	54.9	39.2	60.9	48.1
<b>Pastos</b>	46.4	37.1	57.2	47.5
<b>CT</b>	45.9	21.3	52.8	26.7
<b>Bosques</b>	47.9	39.8	67.4	57.8

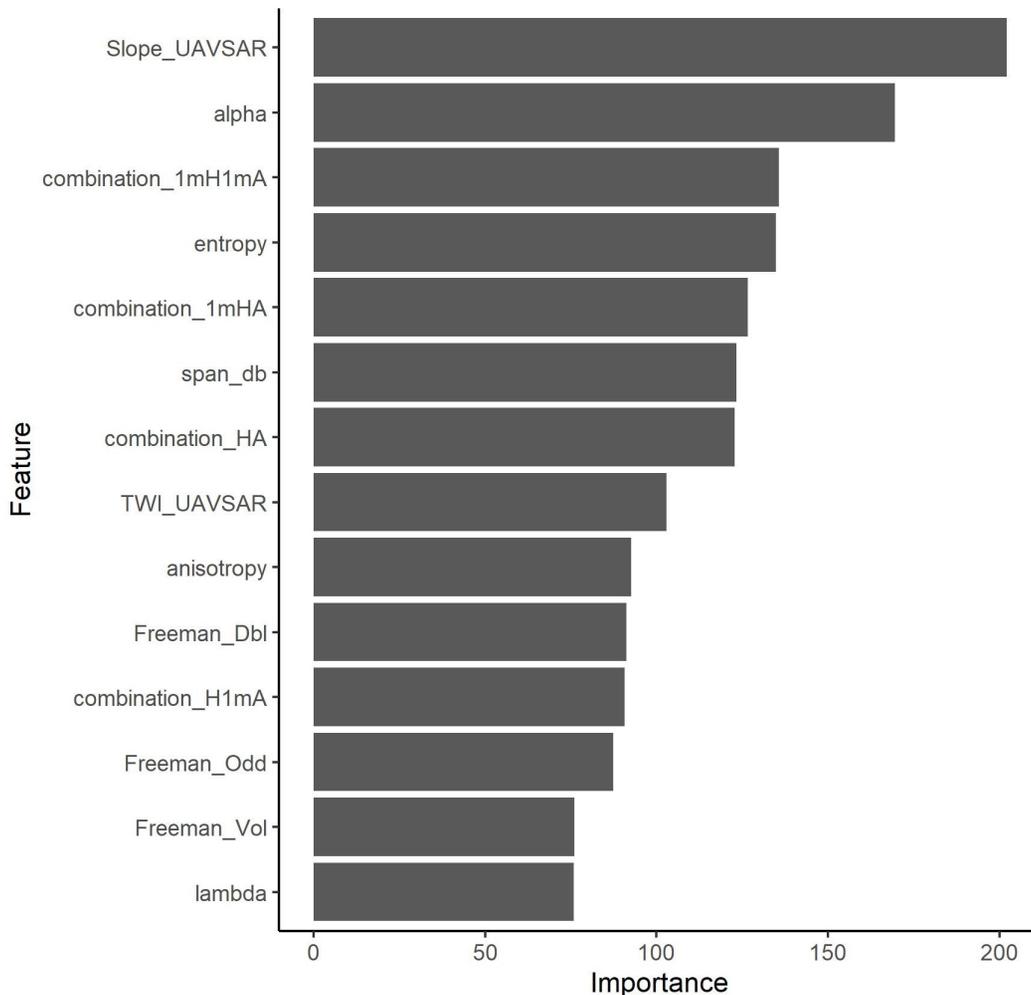
Tabla 4-16: Exactitud del Usuario (UA) y del Productor (PA)

	Sensibilidad (%)	Especificidad (%)
<b>AaArA</b>	68.3	98.6
<b>TpPaVeBj</b>	79.3	95.3
<b>TpPaVeSe</b>	83.6	89.4
<b>ZU</b>	85.9	97.3
<b>Veg_S</b>	67.0	92.4
<b>SD</b>	48.1	96.6
<b>Pastos</b>	47.5	95.4
<b>CT</b>	26.7	98.6
<b>Bosques</b>	57.8	97.8

Tabla 4-17: Sensibilidad - Especificidad UAVSAR\_2015 - Var\_Aux

### 4.6.2. Importancia de variables Modelo UAVSAR\_2015 - Var\_Aux

La importancia de las variables de entrada al modelo, se determina evaluando la MDA expuesto en la Figura 4.17, muestra que de las catorce variables utilizadas en el modelo UAVSAR\_2015 - Var\_Aux, las variables más importantes y con mayor aporte en la clasificación fueron la pendiente (Slope\_UAVSAR), ángulo alpha y combination\_1mH1mA, estos últimos parámetros de descomposición de Cloude-Pottier.



**Figura 4.17:** Importancia de variables MDA UAVSAR\_2015 - Var\_Aux

Por otra parte, en la Figura 4.18, se indica la ganancia del índice de Gini, que estima la importancia de las variables de entrada evaluando la impureza de los datos de entrenamiento, ya que estima, qué tan bien cada nodo divide los datos. Por consiguiente, las variables que aportaron mayormente a la clasificación para detectar los objetos contenidos en los humedales de estudio fueron la pendiente (Slope\_UAVSAR) de forma significativa, seguido del ITW y en igual medida el ángulo alpha y Freeman.Dbl (Dispersión por doble rebote).

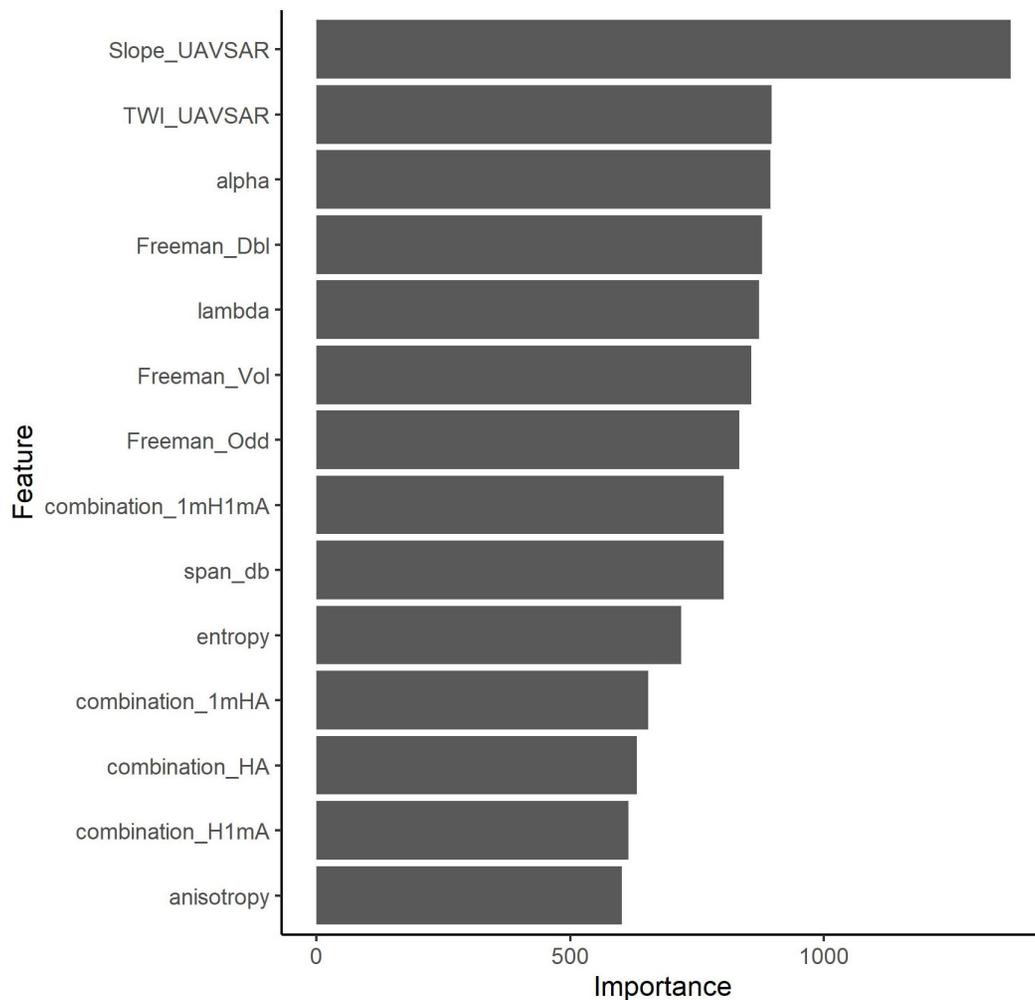


Figura 4.18: Importancia Gini UAVSAR\_2015 - Var\_Aux

### 4.6.3. Mapa detección de humedales modelo UAVSAR\_2015 - Var\_Aux

El modelo de detección RF UAVSAR\_2015 - Var\_Aux, en el área de estudio (AE2) se implementó con datos SAR aéreos UAVSAR 2015 en banda L, derivando variables de descomposiciones polarimétricas Freeman- Durden y Cloude- Pottier y variables auxiliares (pendiente, ITW), detectando áreas potenciales de humedales de las clases de estudio, así como otras coberturas mostradas en la Figura 4.19.

La inspección visual permite detectar la existencia de ciénegas con vegetación baja (TpPaVeBj) concentradas alrededor del caso urbano, clase que obtuvo buena sensibilidad y confiabilidad en el desempeño del modelo. La presencia de ciénegas con vegetación secundaria (TpPaVeSe) presenta mayor dificultad en la clasificación debido a mecanismos de dispersión similares de los objetos que presenta un humedal. Sin embargo fue la clase que obtuvo la más alta sensibilidad y concordancia con los datos de validación en el modelo, reafirmando la bondad de la banda L en la discriminación de humedales boscosos o con vegetación densa

(Mahdavi et al., 2017a). Por otra parte, la existencia de agua abierta obtuvo alta confiabilidad en el mapa temático. En esta clase se presenta limitaciones por sub-estimación en las áreas de existencia.

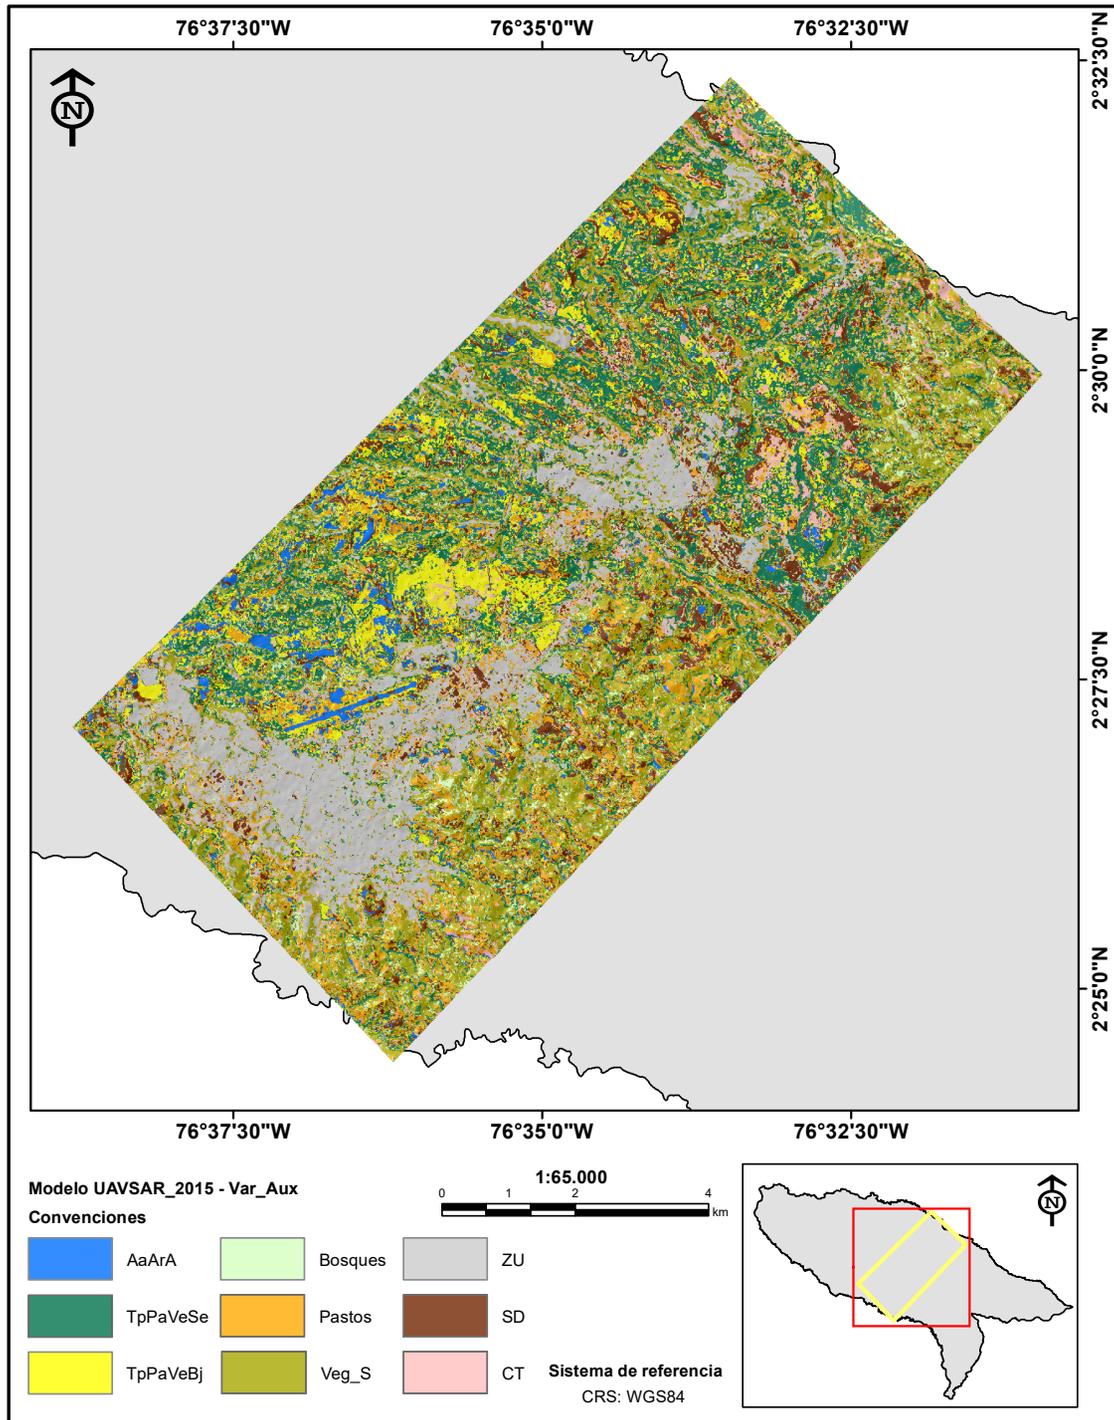


Figura 4.19: Mapa detección humedales UAVSAR\_2015 - Var\_Aux (AE2)

En el cuadrángulo (C1) se visualiza el modelo de detección con UAVSAR (superior) y la imagen Sentinel-2A (inferior) como se muestran en la Figura 4.20, orientado hacia el norte del Municipio de Popayán, evidenciando menor extensión en los humedales asociados a espejos de agua, en comparación con el modelo SAR Sentinel-1A. La clase de espejos de agua presentó la mayor confiabilidad de detección. Ciénegas con vegetación secundaria se observan con alta distribución y mayor tasa de sensibilidad, sin embargo se presentaron mayores desviaciones (falsos positivos). Los humedales asociados a ciénegas con vegetación baja, obtuvieron métricas favorables de rendimiento. Su distribución y ubicación presentaron similitud con el modelo SAR Sentinel-1A en esta clase de humedales.

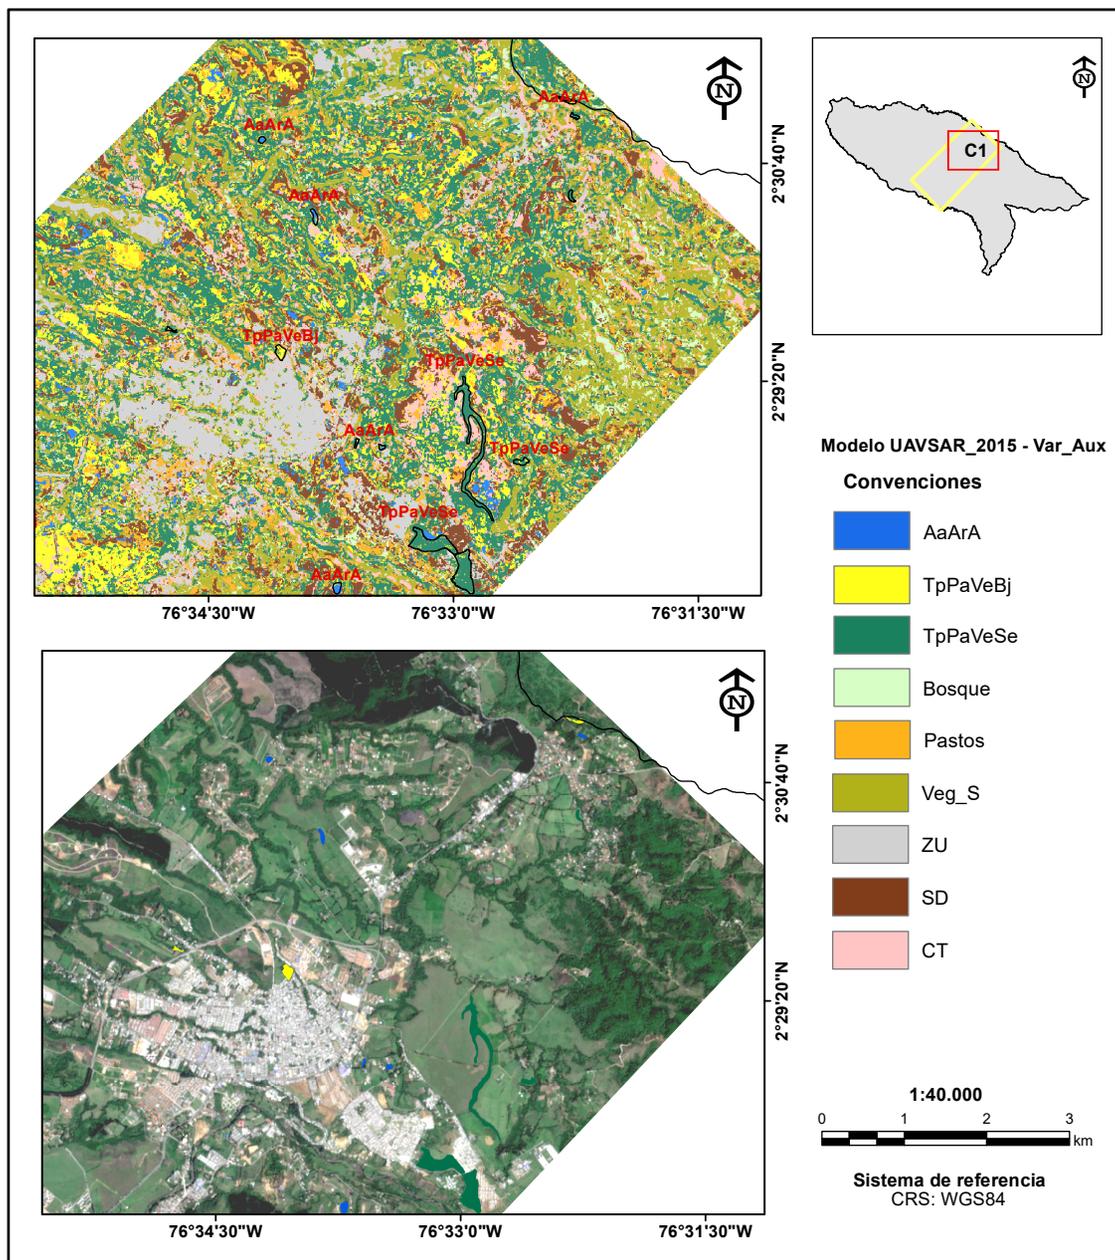


Figura 4.20: Mapa detección humedales UAVSAR\_2015 - Var\_Aux C1

El cuadrángulo C2 indicado en la Figura 4.21, se observa la distribución y extensión de los humedales palustres asociados a ciénegas con vegetación baja, donde se infiere la cantidad de humedad que retiene esta zona alrededor del casco urbano con orientación hacia el sur del Municipio. Por otra parte la carretera de tipo de superficie asfáltica ubicada en el aeropuerto, fue detectada como espejo de agua, al igual que en modelo SAR Sentinel-1A, debido al retorno y mecanismo de retrodispersión similar en ambas coberturas del terreno.

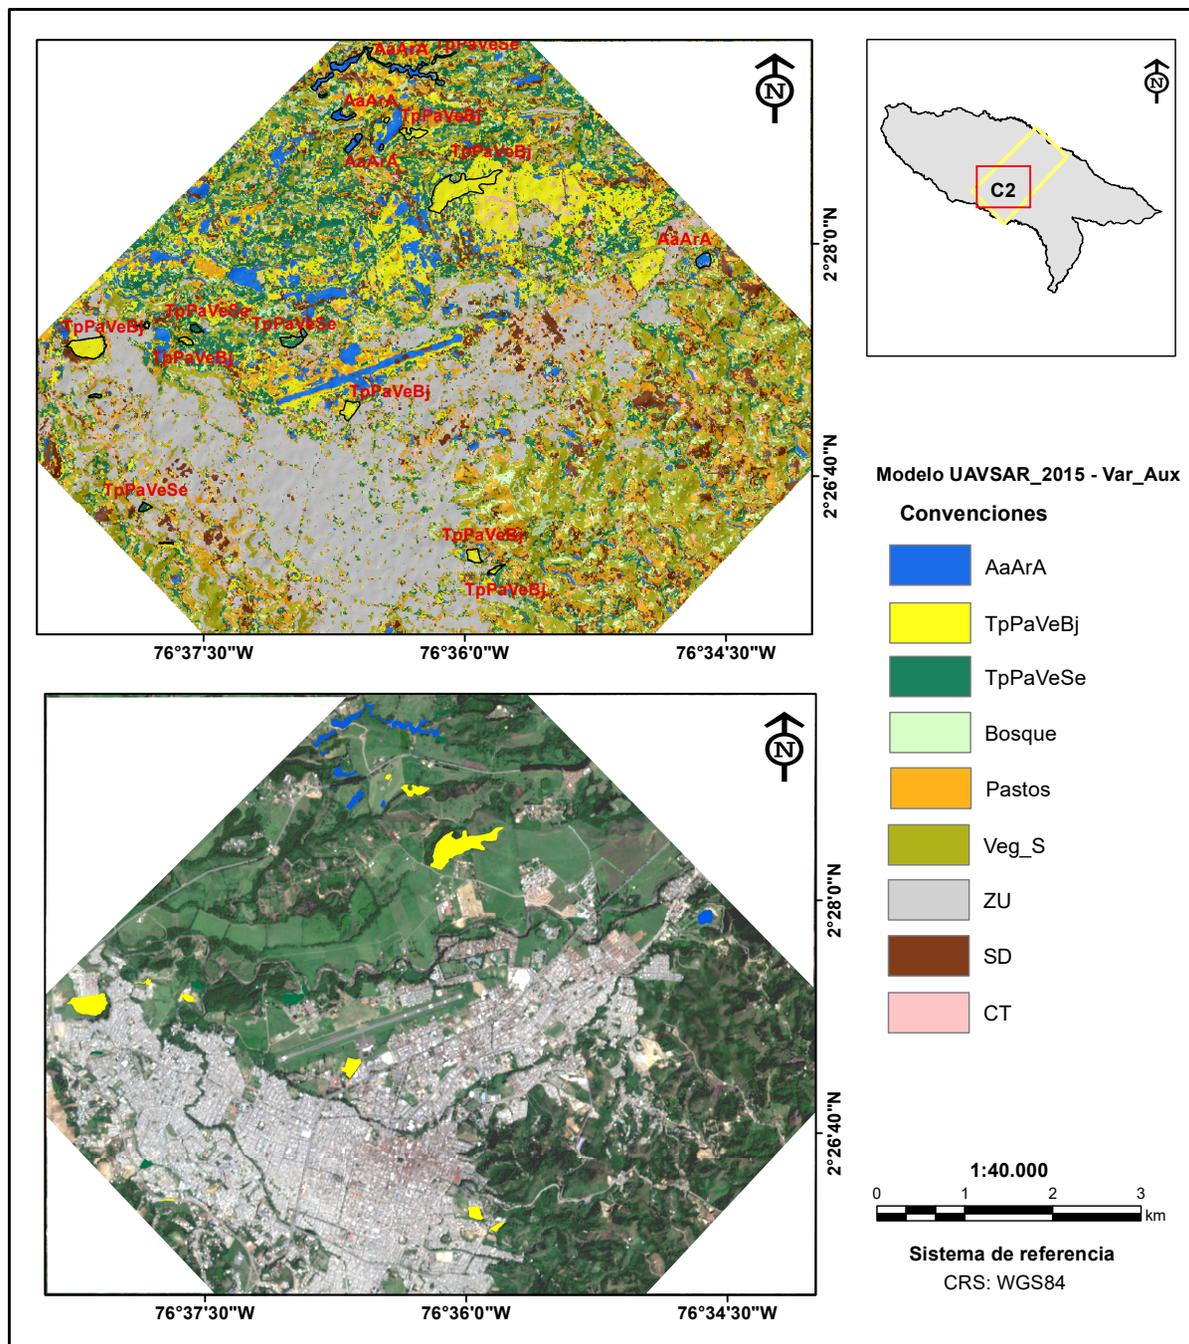


Figura 4.21: Mapa detección humedales UAVSAR\_2015 - Var\_Aux C2

#### 4.6.4. Prueba de las hipótesis planteadas

I– Hipótesis I:

$$H_0 : \sigma_{VVASC} = \sigma_{VVDES}$$

$$\sigma_{VHASC} = \sigma_{VHDES}$$

Para dar respuesta a la primera hipótesis de investigación planteada sobre la influencia de la información de retrodispersión de las imágenes Sentinel-1, según el modo de orbital ascendente y descendente, se realizó el test paramétrico de comparación de medias con corrección (en caso que las varianzas sean iguales) como sin ella (Ver Anexo B), para un nivel de significancia alpha de 0.05. Los resultados obtenidos en ambas pruebas arrojaron un p-value ( $< 2.2e-16$ ) menor al nivel de significancia, que permite concluir que no se dispone de evidencia suficiente para considerar que las medias de las bandas VVASC y VVDES presenten similitud, es decir, que existe una diferencia entre la información de retrodispersión contenida por la banda VVASC y VVDES.

Por otra parte, la técnica no paramétrica de Analisis de Componentes Principales, refuerza la conclusión anterior, ratificando que existe diferencia en la información de retrodispersión según el modo de adquisición (ASC y DES) de la banda polarimétrica VV, mostrada en el primer plano factorial.

Con respecto a la hipótesis de la polarimetría VH (ASC y DES), no fue posible dar respuesta en este estudio, debido a la escasa temporalidad de escenas SAR Sentinel-1 en el año 2014 y 2015, razón por la cual necesita ser abordada en estudios posteriores.

II– Hipótesis II:

$$H_0 : \text{Exactitud\_Dual} - \text{pol} < \text{Exactitud\_Quad} - \text{pol}$$

La segunda hipótesis de este estudio, se basa en la comparación de las métricas obtenidas por los modelo detección de humedales satelital Dual-pol (Sentinel-1) y aéreo Quad-pol (UAVSAR). Para responder la hipótesis planteada se analizaron las métricas de Exatitud General, índice Kappa y la métrica de precisión interna OOB indicadas en la Tabla 4-18. En este estudio se ratifico el rendimiento más favorable y satisfactorio en el modelo Satelital Dual-pol. Sin embargo, es importante tener en cuenta la limitación en las imágenes UAVSAR, reportadas en este estudio.

Escenarios SAR	Exactitud General (%)	Kappa (%)	OOB (%)
SAR_S1.2015 - Var_Aux	<b>87.01</b>	<b>85.27</b>	<b>14.05</b>
UAVSAR_2015 - Var_Aux	66.53	61.42	34.1

**Tabla 4-18:** Evaluación del rendimiento de los modelos SAR

---

---

## 5. Conclusiones y recomendaciones

---

---

### 5.1. Conclusiones

El escenario con datos SAR satelitales Sentinel-1 (Dual-pol) en banda C, fusionado con variables complementarias auxiliares (Var\_Aux : pendiente del terreno, ITW, NDVI y NDWI), modelo SAR\_S1A\_2015 - Var\_Aux, mostró alta potencialidad y confiabilidad en la detección de humedales. La evaluación del rendimiento cuantitativo y cualitativo de este modelo, demostro el buen manejo y discriminación de las clases de humedales en el terreno, lo que se traduce, en concordancia entre lo detectado y la realidad. Sin embargo, los errores por omisión y comisión (falsos positivos y falsos negativos) muestran los niveles de dificultad para discriminar clases de humedales y no humedales, que se evidencian cualitativamente en el mapa temático. En la clase lacustre (espejos de agua), se clasificaron carreteras con tipo de superficie en pavimento asfáltico y tramos de ríos, como falsos positivos.

El escenario con datos aéreos UAVSAR (Quad-pol) de banda L y variables complementarias auxiliares (pendiente, ITW) modelo UAVSAR\_2015 - Var\_Aux, mostró rendimientos favorable de sensibilidad (Exactitud del Productor) en los humedales palustres con mayor desvío de clasificación en las muestras de referencia (falsos negativos) de la clase lacustre. Sin embargo, la clase lacustre presentó la más alta confiabilidad en la detección (cuando el modelo detecta esta clase es altamente confiable en el terreno).

El análisis descriptivo del coeficiente de retrodispersión (backscatter), para el período temporal de octubre a diciembre de las imágenes Sentinel-1A (Dual-pol en banda C) 2014 y 2015, permiten concluir que la polarimetría VVDES se caracterizó por presentar retornos de intensidad más bajos en el área de estudio (AE1) y de los polígonos de humedales, importantes para la detección de humedales con cuerpos de agua sin vegetación emergente o inundada. Así mismo se puede inferir humedales colonizados por vegetación debido a la distribución de retornos altos en la intensidad de retrodispersión.

El análisis en la distribución de la intensidad de retrodispersión mediante estadística zonal y centroides para los años 2014 y 2015 (octubre, noviembre y diciembre) en los polígonos de humedales, demostró que la mediana es más sensible a datos atípicos hacia valores bajos y mínimos de la distribución (2014-2015), detectando humedales lacustres (espejos de agua), con los rangos más bajos de energía retrodispersada en la polarimetría VVASC y VVDES. La distribución de datos de los centroides permite inducir la presencia de humedales palustres colonizados por vegetación debido a la presencia de datos atípicos hacia valores altos de la distribución (2014).

Los métodos no supervisados en el estudio de humedales han sido importantes para establecer segmentación y separabilidad de las clases de humedales, así como la determinación de umbrales, que permitan conformar categorías según los retornos de energía de los objetos. Los conglomerados jerárquicos 2014 - 2015, representados en el primer plano factorial arrojaron que los humedales lacustres presentaron los rangos de intensidades de retrodispersión más bajas y los rangos de intensidades de los humedales palustres dependen de la colonización de la vegetación que presenten. Aunque geométricamente hay similitudes en la energía retrodispersada en las clases de humedales su distribución espacial es variable, lo cual no permitió sectorizarlos espacialmente.

El análisis de componentes principales (ACP) de las imágenes satelitales SAR Sentinel 1A (VVASC y VVDES), mostraron buena representatividad en el círculo de correlaciones del primer plano factorial (varianza explicativa de 86.59%). Así mismo, se evidenció redundancia y multicolinealidad en las bandas polarimétricas que pertenecen a la misma órbita, permitiendo reducir la dimensionalidad de las variables predictoras. De igual modo el ACP demostró que las bandas en órbita ASC y DES de la polarimetría VV, contienen información de retrodispersión diferente, lo que implica un análisis por separado en el modo ascendente y descendente.

De los escenarios satelitales modelados SAR S1 con RF para detectar humedales, los que presentaron mayor rendimiento en cuanto a la Exactitud General, índice Kappa y error de precisión interna OOB fueron los escenarios, SAR\_S1A\_2015 - Var\_Aux , SAR\_S1A\_2015 , SAR\_S1A\_VVDES\_2015 - Var\_Aux. Por otra parte, de los modelos de detección de humedales con datos aéreos UAVSAR a partir de descomposición polarimetría Freeman Durden y Cloude Pottier, UAVSAR\_2015 y UAVSAR\_2015 - Var\_Aux, el mayor rendimiento fue obtenido por el escenario UAVSAR\_2015 - Var\_Aux.

El escenario evaluado en este estudio mediante la matriz de confusión fue el SAR\_S1A\_2015 - Var\_Aux, proporcionó información detallada del desempeño y rendimiento del modelo supervisado RF (clasificación). Los altos porcentajes de sensibilidad (tasa de verdaderos positivos) y especificidad (tasa de verdaderos negativos) del escenario SAR\_S1A\_2015 - Var\_Aux, explica la capacidad para discriminar las clases de humedales de otras categorías que no son humedales en el terreno. El porcentaje de error de comisión (EC) más bajo fue obtenido por la clase de humedal lacustre AaArA (espejos de agua), indicando baja sobre-estimación (falsos positivos) del modelo en esta clase, mientras que los errores de omisión (EO), que se traduce en la sub-estimación del modelo, no fue significativa para las clases de humedales, lo que indica, baja frecuencia de falsos negativos. Las clases de no humedales arrojaron los más altos EO.

Las variables con mayor aporte y relevancia del modelo de detección SAR\_S1A\_2015 - Var\_Aux evaluado fueron: la polarimetría VVDES (VVDES\_BBDD\_Mayo\_07) y las Var\_Aux (variables auxiliares) NDVI y la pendiente, determinada por la métrica MDA. En la evaluación de la métrica de Gini, el ITW tuvo una influencia importante en la división de los datos y estructura de los árboles de decisión. Lo anterior permite deducir el buen aporte

de las variables auxiliares predictoras en la detección de humedales evaluadas en este estudio.

El modelo UAVSAR\_2015 - Var\_Aux, discriminó con mayor exactitud las muestras de referencia de clase de humedal palustre TpPaVeSe (mayor PA), con menor proporción de falsos negativos (baja sub-estimación) e identificó con más fiabilidad la clase de humedal lacustre AaArA en el terreno (mayor UA), con menor frecuencia de falsos positivos (baja sobre-estimación). La alta especificidad del modelo en las clases de humedales, evidencia la capacidad para discriminar las áreas que no se asocian a humedales. La mayor sensibilidad fue obtenida por las clases TpPaVeSe y TpPaVeBj, esto explica el potencial de la banda L para manejar y discriminar los humedales colonizados por vegetación densas, arbustivas y herbáceas.

Las variables con mayor aporte y relevancia del modelo de UAVSAR\_2015 - Var\_Aux fueron la pendiente (Var\_Aux) y los descriptores polarimétricos de Cloude Pottier como fueron el ángulo Alpha, combination 1mH1mA, y la entropía, determinada por la métrica MDA. La evaluación de la métrica de Gini, determinó una influencia importante en la división de los datos la pendiente de forma significativa, seguido del ITW y en igual medida el ángulo alpha y Freeman Dbl (Dispersión por doble rebote).

Los mapas temáticos resultantes de detección de humedales UAVSAR y Sentinel-1, obtenidos a escalas de semidetalladas, muestran la distribución y complejos de humedales que presentan características similares e interconexiones entre sí. Es importante resaltar que independiente del área mínima de cartografiable (AMC), el modelo puede tener excepciones al detectar humedales con áreas inferiores a las proyectadas por la escala de trabajo.

### **5.1.1. Importancia y aplicación a la Geomática**

El objetivo de esta investigación fue evaluar el potencial de las imágenes SAR, satelitales y aéreas en banda C y L, para la detección de humedales utilizando un modelo no paramétrico de Machine Learning como Random Forest y fusionando datos SAR, ópticos y variables extraídas del DEM. Este estudio mejora las metodologías existentes y se convierte en un instrumento importante para actualizar y detectar humedales que aún no están identificados en el Municipio de Popayán.

La metodología propuesta se puede extrapolar y replicar a los municipios del Cauca y a otras zonas del país donde se tengan los mismo insumos empleados en el presente estudio, para ubicar, identificar y comprender la distribución espacial de las áreas de humedales. Lo anterior, es importante para comprender la función y conectividad hidrológica de los complejos de humedales, así como ayudar a determinar áreas prioritarias para la conservación y protección.

### **5.1.2. Limitaciones**

La temporalidad de la polarización VH de Sentinel-1 en el año 2015 fue limitada, razón por la cual no se sensibilizó esta variable predictoras en el modelo de detección. Es importante que en otros estudios se determine el aporte de la banda VH en la detección de humedales.

La escasa temporalidad de las imágenes aéreas UAVSAR, no permitió sensibilizar los descriptores polarimétricos en diferentes períodos del año 2015 para así evaluar el aporte temporal en el modelo.

Las muestras de entrenamiento y de validación de los humedales, fueron reducidas debido al cubrimiento del área de estudio por las imágenes UAVSAR.

## 5.2. Recomendaciones

Debido al comportamiento dinámico de los humedales, es necesario que las futuras investigaciones promuevan un enfoque multitemporal con datos SAR, para estudiar la estacionalidad de estos ecosistemas y el efecto del cambio climático, centrándose en el monitoreo y detección de cambios, que permitan cuantificar las perturbaciones antrópicas y naturales.

Las imágenes PlanetScope (de licencia académica) podrían ser un buen insumo para validar y verificar los resultados obtenidos en posteriores estudios, ya que presentan una alta resolución espacial. Las variables espectrales que puedan derivarse e implementarse en el sinergismo con imágenes SAR, dependerán de la disponibilidad y condiciones atmosféricas del área de estudio.

# Bibliografía

- Abdelmajeed, A. Y. A., Albert-Saiz, M., Rastogi, A., and Juszczak, R. (2023). Cloud-based remote sensing for wetland monitoring—a review. *Remote Sensing*, 15(6):1660. [1](#)
- Adam, S., Wiebe, J., Collins, M., and Pietroniro, A. (1998). Radarsat flood mapping in the peace-athabasca delta, canada. *Canadian Journal of Remote Sensing*, 24(1):69–79. [8](#)
- Ainsworth, T., Kelly, J., and Lee, J.-S. (2009). Classification comparisons between dual-pol, compact polarimetric and quad-pol sar imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(5):464–471. [7](#)
- Amani, M., Mahdavi, S., Afshar, M., Brisco, B., Huang, W., Mohammad Javad Mirzadeh, S., White, L., Banks, S., Montgomery, J., and Hopkinson, C. (2019). Canadian wetland inventory using google earth engine: The first map and preliminary results. *Remote Sensing*, 11(7):842. [11](#), [34](#)
- Amani, M., Salehi, B., Mahdavi, S., Granger, J., and Brisco, B. (2017). Wetland classification in newfoundland and labrador using multi-source sar and optical data integration. *GIScience & Remote Sensing*, 54(6):779–796. [11](#), [12](#), [20](#)
- Behnamian, A., Banks, S., White, L., Brisco, B., Millard, K., Pasher, J., Chen, Z., Duffe, J., Bourgeau-Chavez, L., and Battaglia, M. (2017). Semi-automated surface water detection with synthetic aperture radar data: A wetland case study. *Remote Sensing*, 9(12):1209. [46](#)
- Berhane, T. M., Lane, C. R., Wu, Q., Autrey, B. C., Anenkhonov, O. A., Chepinoga, V. V., and Liu, H. (2018). Decision-tree, rule-based, and random forest classification of high-resolution multispectral imagery for wetland mapping and inventory. *Remote sensing*, 10(4):580. [12](#), [20](#)
- Bian, L., Melesse, A. M., Leon, A. S., Verma, V., and Yin, Z. (2021). A deterministic topographic wetland index based on lidar-derived dem for delineating open-water wetlands. *Water*, 13(18):2487. [11](#), [34](#)
- Bourgeau-Chavez, L., Riordan, K., Powell, R., Miller, N., and Nowels, M. (2009). Improving wetland characterization with multi-sensor, multi-temporal sar and optical/infrared data fusion. [2](#), [7](#)
- Brisco, B., Li, K., Tedford, B., Charbonneau, F., Yun, S., and Murnaghan, K. (2013). Compact polarimetry assessment for rice and wetland mapping. *International Journal of Remote Sensing*, 34(6):1949–1964. [8](#)

- Brisco, B., Short, N., Sanden, J. v. d., Landry, R., and Raymond, D. (2009). A semi-automated tool for surface water mapping with radarsat-1. *Canadian Journal of Remote Sensing*, 35(4):336–344. [6](#)
- Brisco, B., Touzi, R., van der Sanden, J. J., Charbonneau, F., Pultz, T., and D'Iorio, M. (2008). Water resource applications with radarsat-2—a preview. *International Journal of Digital Earth*, 1(1):130–147. [8](#)
- Catry, T., Li, Z., Roux, E., Herbreteau, V., Gurgel, H., Mangeas, M., Seyler, F., and 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):468. [1](#), [6](#), [7](#), [8](#), [9](#)
- Chatziantoniou, A., Petropoulos, G. P., and Psomiadis, E. (2017). Co-orbital sentinel 1 and 2 for lule mapping with emphasis on wetlands in a mediterranean setting based on machine learning. *Remote Sensing*, 9(12):1259. [21](#)
- Chuvieco, E. (2010). *Teledetección ambiental: La observación de la tierra desde el espacio*. Ariel Ciencias. Editorial Ariel. [1](#)
- Congalton, R. G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote sensing of environment*, 37(1):35–46. [12](#)
- Corcoran, J. M., Knight, J. F., and Gallant, A. L. (2013). Influence of multi-source and multi-temporal remotely sensed and ancillary data on the accuracy of random forest classification of wetlands in northern minnesota. *Remote Sensing*, 5(7):3212–3238. [42](#)
- Correa Muñoz, N. A. (2020). Method for landslides detection with semi-automatic procedures: The case in the zone center-east of cauca department, colombia. [17](#)
- Costa, M., Niemann, O., Novo, E., and Ahern, F. (2002). Biophysical properties and mapping of aquatic vegetation during the hydrological cycle of the amazon floodplain using jers-1 and radarsat. *International Journal of Remote Sensing*, 23(7):1401–1426. [6](#)
- Costa, M., Silva, T. S., and Evans, T. L. (2013). Wetland classification. *Remote Sensing of Natural Resources*. CRC Press, Boca Raton-FL, pages 461–478. [6](#)
- Crowson, M., Warren-Thomas, E., Hill, J. K., Hariyadi, B., Agus, F., Saad, A., Hamer, K. C., Hodgson, J. A., Kartika, W. D., Lucey, J., et al. (2019). A comparison of satellite remote sensing data fusion methods to map peat swamp forest loss in sumatra, indonesia. *Remote sensing in ecology and conservation*, 5(3):247–258. [21](#)
- Dabboor, M., White, L., Brisco, B., and Charbonneau, F. (2015). Change detection with compact polarimetric sar for monitoring wetlands. *Canadian Journal of Remote Sensing*, 41(5):408–417. [7](#)
- de Almeida Furtado, L. F., Silva, T. S. F., and de Moraes Novo, E. M. L. (2016). Dual-season and full-polarimetric c band sar assessment for vegetation mapping in the amazon várzea wetlands. *Remote Sensing of Environment*, 174:212–222. [35](#)

- Deenik, K. (2022). *Classifying wetlands using random forest machine learning, airborne light detection and ranging and Earth observation satellite data in the Okanagan basin, British Columbia*. PhD thesis, University of British Columbia. [1](#), [2](#), [11](#), [12](#), [13](#), [21](#), [34](#), [35](#), [38](#), [39](#), [42](#)
- Di Baldassarre, G., Schumann, G., Brandimarte, L., and Bates, P. (2011). Timely low resolution sar imagery to support floodplain modelling: a case study review. *Surveys in geophysics*, 32(3):255–269. [8](#)
- Dronova, I. (2015). Object-based image analysis in wetland research: A review. *Remote Sensing*, 7(5):6380–6413. [6](#)
- Duy, N. B. (2015). Automatic detection of surface water bodies from sentinel-1 sar images using valley-emphasis method. *Vietnam Journal of Earth Sciences*, 37(4):328–343. [12](#)
- Estupinan-Suarez, L., Florez-Ayala, C., Quinones, M., Pacheco, A., and Santos, A. (2015). Detection and characterization of colombian wetlands: Integrating geospatial data with remote sensing derived data. using alos palsar and modis imagery. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*. [2](#), [11](#)
- Evans, T. L. and Costa, M. (2013). Landcover classification of the lower nhecolândia sub-region of the brazilian pantanal wetlands using alos/palsar, radarsat-2 and envisat/asar imagery. *Remote Sensing of Environment*, 128:118–137. [6](#)
- Filatow, D., Harvey, G., Carswell, T., and Cameron, E. (2020). Predictive wetland mapping of the williston drainage basin: Update. *Knowledge Management Branch, BC Ministry of Environment and Climate Change Strategy, Victoria. BC*. [12](#)
- Franklin, S. E. and Ahmed, O. S. (2017). Object-based wetland characterization using radarsat-2 quad-polarimetric sar data, landsat-8 oli imagery, and airborne lidar-derived geomorphometric variables. *Photogrammetric Engineering & Remote Sensing*, 83(1):27–36. [11](#)
- Freeman, A. and Durden, S. L. (1998). A three-component scattering model for polarimetric sar data. *IEEE transactions on geoscience and remote sensing*, 36(3):963–973. [10](#)
- Gulácsi, A. and Kovács, F. (2020). Sentinel-1-imagery-based high-resolution water cover detection on wetlands, aided by google earth engine. *Remote Sensing*, 12(10):1614. [25](#), [29](#)
- Guo, M., Li, J., Sheng, C., Xu, J., and Wu, L. (2017). A review of wetland remote sensing. *Sensors (Switzerland)*, 17(4):1–36. [2](#), [11](#)
- Halabisky, M., Babcock, C., and Moskal, L. M. (2018). Harnessing the temporal dimension to improve object-based image analysis classification of wetlands. *Remote Sensing*, 10(9):1467. [12](#)
- Han, D., Vahedifard, F., and Aanstoos, J. V. (2017). Investigating the correlation between radar backscatter and in situ soil property measurements. *International journal of applied earth observation and geoinformation*, 57:136–144. [7](#)

- Henderson, F. M. and Lewis, A. J. (2008). Radar detection of wetland ecosystems: A review. *International Journal of Remote Sensing*, 29(20):5809–5835. [1](#), [5](#), [6](#), [7](#), [9](#)
- Henry, J.-B., Chastanet, P., Fellah, K., and Desnos, Y.-L. (2006). Envisat multi-polarized asar data for flood mapping. *International Journal of Remote Sensing*, 27(10):1921–1929. [12](#)
- Hess, L. L., Melack, J. M., Filoso, S., and Wang, Y. (1995). Delineation of inundated area and vegetation along the amazon floodplain with the sir-c synthetic aperture radar. *IEEE Transactions on Geoscience and Remote Sensing*, 33(4):896–904. [12](#)
- Hess, L. L., Melack, J. M., Novo, E. M., Barbosa, C. C., and Gastil, M. (2003). Dual-season mapping of wetland inundation and vegetation for the central amazon basin. *Remote sensing of environment*, 87(4):404–428. [6](#), [8](#)
- Hess, L. L., Melack, J. M., and Simonett, D. S. (1990). Radar detection of flooding beneath the forest canopy: a review. *International Journal of Remote Sensing*, 11(7):1313–1325. [5](#), [6](#), [7](#)
- Hird, J. N., DeLancey, E. R., McDermid, G. J., and 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):1315. [11](#), [19](#)
- Hong, S.-H., Kim, H.-O., Wdowinski, S., and Feliciano, E. (2015). Evaluation of polarimetric sar decomposition for classifying wetland vegetation types. *Remote Sensing*, 7(7):8563–8585. [6](#)
- Huang, W., DeVries, B., Huang, C., Lang, M. W., Jones, J. W., Creed, I. F., and Carroll, M. L. (2018). Automated extraction of surface water extent from sentinel-1 data. *Remote Sensing*, 10(5):797. [1](#), [12](#), [26](#)
- Jing, L., Zhou, Y., Zeng, Q., Liu, S., Lei, G., Lu, C., and Wen, L. (2020). Exploring wetland dynamics in large river floodplain systems with unsupervised machine learning: A case study of the dongting lake, china. *Remote Sensing*, 12(18):2995. [29](#)
- Kaplan, G. and Avdan, U. (2017). Mapping and monitoring wetlands using sentinel-2 satellite imagery. [11](#)
- Karlson, M., Gålfalk, M., Crill, P., Bousquet, P., Saunois, M., and Bastviken, D. (2019). Delineating northern peatlands using sentinel-1 time series and terrain indices from local and regional digital elevation models. *Remote Sensing of Environment*, 231:111252. [2](#), [11](#), [12](#), [13](#), [21](#)
- Kasischke, E. S. and Bourgeau-Chavez, L. L. (1997). Monitoring south florida wetlands using ers-1 sar imagery. *Photogrammetric Engineering and Remote Sensing*, 63(3):281–291. [8](#)
- Kasischke, E. S., Bourgeau-Chavez, L. L., Rober, A. R., Wyatt, K. H., Waddington, J. M., and Turetsky, M. R. (2009). Effects of soil moisture and water depth on ers sar backscatter measurements from an alaskan wetland complex. *Remote Sensing of Environment*. 113: 1868-1873, 113:1868–1873. [7](#)

- Kasischke, E. S., Melack, J. M., and Dobson, M. C. (1997). The use of imaging radars for ecological applications—a review. *Remote sensing of environment*, 59(2):141–156. [7](#), [8](#)
- LaRocque, A., Phiri, C., Leblon, B., Pirotti, F., Connor, K., and Hanson, A. (2020). Wetland mapping with landsat 8 oli, sentinel-1, alos-1 palsar, and lidar data in southern new brunswick, canada. *Remote Sensing*, 12(13):2095. [2](#), [11](#), [12](#), [20](#), [37](#), [43](#)
- Lee, J. S. and Pottier, E. (2009). Polarimetric radar imaging: From basics to applications, 2009. *Optical Science and Engineering*. [6](#)
- Li, G., Lu, D., Moran, E., Dutra, L., and Batistella, M. (2012). A comparative analysis of alos palsar l-band and radarsat-2 c-band data for land-cover classification in a tropical moist region. *ISPRS Journal of Photogrammetry and Remote Sensing*, 70:26–38. [8](#)
- Li, J., Chen, W., and Touzi, R. (2007). Optimum radarsat-1 configurations for wetlands discrimination: a case study of the mer bleue peat bog. *Canadian Journal of Remote Sensing*, 33(sup1):S46–S55. [7](#)
- Li, Z., Chen, H., White, J. C., Wulder, M. A., and Hermosilla, T. (2020). Discriminating treed and non-treed wetlands in boreal ecosystems using time series sentinel-1 data. *International Journal of Applied Earth Observation and Geoinformation*, 85:102007. [2](#)
- Liu, J., Li, P., Tu, C., Wang, H., Zhou, Z., Feng, Z., Shen, F., and Li, Z. (2022). Spatiotemporal change detection of coastal wetlands using multi-band sar coherence and synergetic classification. *Remote Sensing*, 14(11):2610. [2](#)
- Lunetta, R. S. E. and Christopher, D. (1998). *Remote Sensing Change Detection: Environmental monitoring methods and applications/Ross S. Lunetta and Christopher D. Elvidge*. Number GE45. R44. L86 1998. [5](#)
- Luo, S., Wang, C., Pan, F., Xi, X., Li, G., Nie, S., and Xia, S. (2015). Estimation of wetland vegetation height and leaf area index using airborne laser scanning data. *Ecological Indicators*, 48:550–559. [19](#)
- Mahdavi, S., Maghsoudi, Y., and Amani, M. (2017a). Effects of changing environmental conditions on synthetic aperture radar backscattering coefficient, scattering mechanisms, and class separability in a forest area. *Journal of Applied Remote Sensing*, 11(3):036015–036015. [53](#)
- Mahdavi, S., Salehi, B., Granger, J., Amani, M., Brisco, B., and Huang, W. (2018). Remote sensing for wetland classification: a comprehensive review. *GIScience and Remote Sensing*, 55(5):623–658. [1](#), [5](#), [10](#), [11](#), [12](#), [35](#)
- Mahdavi, S., Salehi Sr, B., Amani, M., Granger, J. E., Brisco, B., and Huang, W. (2017b). A comparison between different synthetic aperture radar (sar) sensors for wetland classification. In *Imaging and Geospatial Technology Forum, IGTF*, pages 12–16. [6](#)

- Mahdianpari, M., Salehi, B., Mohammadimanesh, F., Homayouni, S., and 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):43. [5](#), [7](#), [11](#), [12](#), [35](#)
- Mahdianpari, M., Salehi, B., Mohammadimanesh, F., and Motagh, M. (2017). Random forest wetland classification using ALOS-2 L-band, RADARSAT-2 C-band, and TerraSAR-X imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130:13–31. [2](#), [5](#), [7](#), [10](#), [12](#), [35](#), [37](#)
- Manjusree, P., Kumar, L. P., Bhatt, C. M., Rao, G. S., and Bhanumurthy, V. (2012). Optimization of threshold ranges for rapid flood inundation mapping by evaluating backscatter profiles of high incidence angle sar images. *International Journal of Disaster Risk Science*, 3(2):113–122. [9](#), [23](#), [25](#)
- Martinis, S., Kuenzer, C., Wendleder, A., Huth, J., Twele, A., Roth, A., and Dech, S. (2015). Comparing four operational sar-based water and flood detection approaches. *International Journal of Remote Sensing*, 36(13):3519–3543. [8](#)
- Matasci, G., Hermosilla, T., Wulder, M. A., White, J. C., Coops, N. C., Hobart, G. W., and Zald, H. S. (2018). Large-area mapping of canadian boreal forest cover, height, biomass and other structural attributes using landsat composites and lidar plots. *Remote sensing of environment*, 209:90–106. [19](#)
- Mattivi, P., Franci, F., Lambertini, A., and Bitelli, G. (2019). Twi computation: a comparison of different open source giss. *Open Geospatial Data, Software and Standards*, 4(1):1–12. [19](#)
- Merchant, M. A., Warren, R. K., Edwards, R., and Kenyon, J. K. (2019). An object-based assessment of multi-wavelength sar, optical imagery and topographical datasets for operational wetland mapping in boreal yukon, canada. *Canadian Journal of Remote Sensing*, 45(3-4):308–332. [12](#), [20](#)
- Montgomery, J., Mahoney, C., Brisco, B., Boychuk, L., Cobbaert, D., and Hopkinson, C. (2021). Remote sensing of wetlands in the prairie pothole region of north america. *Remote Sensing*, 13(19):3878. [10](#), [12](#), [35](#), [37](#), [47](#)
- Moser, L., Schmitt, A., Wendleder, A., and Roth, A. (2016). Monitoring of the lac bam wetland extent using dual-polarized x-band sar data. *Remote Sensing*, 8(4):302. [6](#), [7](#), [8](#), [35](#)
- Munoz, S. R. and Bangdiwala, S. I. (1997). Interpretation of kappa and b statistics measures of agreement. *Journal of Applied Statistics*, 24(1):105–112. [37](#)
- Na, X., Zang, S., Wu, C., Tian, Y., and Li, W. (2018). Hydrological regime monitoring and mapping of the zhalong wetland through integrating time series radarsat-2 and landsat imagery. *Remote Sensing*, 10(5):702. [38](#), [39](#)

- Ottinger, M. and Kuenzer, C. (2020). Spaceborne l-band synthetic aperture radar data for geoscientific analyses in coastal land applications: a review. *Remote Sensing*, 12(14):2228. [1](#), [2](#)
- Ouchi, K. (2013). Recent trend and advance of synthetic aperture radar with selected topics. *Remote Sensing*, 5(2):716–807. [6](#)
- Pardo, C. E. and Del Campo, P. C. (2007). Combination of factorial methods and cluster analysis in r: The package factoclass. *Revista Colombiana de Estadística*, 30(2):231–245. [29](#)
- Pettorelli, N. (2019). *Satellite remote sensing and the management of natural resources*. Oxford University Press. [11](#), [34](#)
- Pham-Duc, B., Prigent, C., and Aires, F. (2017). Surface water monitoring within cambodia and the vietnamese mekong delta over a year, with sentinel-1 sar observations. *Water*, 9(6):366. [7](#), [8](#), [9](#), [12](#), [23](#), [25](#)
- Pulvirenti, L., Pierdicca, N., Chini, M., and Guerriero, L. (2011). An algorithm for operational flood mapping from synthetic aperture radar (sar) data based on the fuzzy logic. *Natural Hazard and Earth System Sciences*. [12](#)
- Pulvirenti, L., Pierdicca, N., Chini, M., and Guerriero, L. (2013). Monitoring flood evolution in vegetated areas using cosmo-skymed data: The tuscan 2009 case study. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 6(4):1807–1816. [8](#)
- Refice, A., Zingaro, M., D’Addabbo, A., and Chini, M. (2020). Integrating c-and l-band sar imagery for detailed flood monitoring of remote vegetated areas. *Water*, 12(10):2745. [29](#)
- Rico Cabrera, R. (2021). Mapeo de coberturas en el humedal ciénaga grande de santa marta usando datos de radar de apertura sintética polarimétricos. [1](#), [2](#), [23](#), [26](#), [29](#), [40](#), [49](#)
- Schmitt, A. and Brisco, B. (2013). Wetland monitoring using the curvelet-based change detection method on polarimetric sar imagery. *Water*, 5(3):1036–1051. [7](#)
- Schmullius, C. and Evans, D. (1998). Synthetic aperture radar (sar) frequency and polarization requirements for applications in ecology, geology, hydrology, and oceanography: a tabular status quo after sir-c/x-sar. *Oceanographic Literature Review*, 3(45):574. [5](#), [7](#)
- Silva, T. S., Costa, M. P., Melack, J. M., and Novo, E. M. (2008). Remote sensing of aquatic vegetation: theory and applications. *Environmental monitoring and assessment*, 140(1-3):131–145. [6](#)
- Slagter, B. (2019). Characterisation of wetland types using sentinel-1 radar time series data. Master’s thesis. [21](#), [39](#), [42](#)
- Slagter, B., Tsendbazar, N.-E., Vollrath, A., and Reiche, J. (2020). Mapping wetland characteristics using temporally dense sentinel-1 and sentinel-2 data: A case study in the st. lucia wetlands, south africa. *International Journal of Applied Earth Observation and Geoinformation*, 86:102009. [37](#)

- Souza-Filho, P. W. M., Paradella, W. R., Rodrigues, S. W., Costa, F. R., Mura, J. C., and Gonçalves, F. D. (2011). Discrimination of coastal wetland environments in the amazon region based on multi-polarized l-band airborne synthetic aperture radar imagery. *Estuarine, Coastal and Shelf Science*, 95(1):88–98. [9](#)
- Sultana, S., Arima, E. Y., and Tasker, K. A. (2016). Combining h/a/alpha polarimetric decomposition of polsar data with image classification for wetland identification: A case study of pacaya-samiria national reserve, peru. *Papers in Applied Geography*, 2(1):9–24. [10](#), [29](#), [35](#), [47](#)
- Townsend, P. A. (2001). Mapping seasonal flooding in forested wetlands using multi-temporal radarsat sar. *Photogrammetric engineering and remote sensing*, 67(7):857–864. [6](#), [7](#), [9](#)
- Töyrä, J., Pietroniro, A., and Martz, L. W. (2001). Multisensor hydrologic assessment of a freshwater wetland. *Remote sensing of Environment*, 75(2):162–173. [8](#)
- Tsyganskaya, V., Martinis, S., Marzahn, P., and Ludwig, R. (2018). SAR-based detection of flooded vegetation—a review of characteristics and approaches. *International Journal of Remote Sensing*, 39(8):2255–2293. [1](#), [5](#), [9](#), [10](#), [12](#)
- Twele, A., Cao, W., Plank, S., and Martinis, S. (2016). Sentinel-1-based flood mapping: a fully automated processing chain. *International Journal of Remote Sensing*, 37(13):2990–3004. [12](#)
- Waite, W. P. and MacDonald, H. C. (1971). "vegetation penetration" with k-band imaging radars. *IEEE Transactions on Geoscience Electronics*, 9(3):147–155. [1](#)
- Wang, Y. (2002). Mapping extent of floods: What we have learned and how we can do better. *Natural Hazards Review*, 3(2):68–73. [6](#)
- Wdowinski, S., Kim, S.-W., Amelung, F., Dixon, T. H., Miralles-Wilhelm, F., and Sonenshein, R. (2008). Space-based detection of wetlands' surface water level changes from l-band sar interferometry. *Remote Sensing of Environment*, 112(3):681–696. [8](#)
- White, L., Brisco, B., Daboor, M., Schmitt, A., and Pratt, A. (2015). A collection of sar methodologies for monitoring wetlands. *Remote sensing*, 7(6):7615–7645. [5](#), [6](#), [10](#)
- Wilson, J. P. and Gallant, J. C. (2000). *Terrain analysis: principles and applications*. John Wiley & Sons. [34](#)

---

---

# Anexos

---

---



# Anexo A

1. Inventario de humedales área de estudio
2. Imágenes Sentinel-1A año 2015
3. Distribución de polígonos de coberturas SGC 1:25.000
4. Frecuencia de polígonos utilizados en los Modelos de Detección SAR S1A y UAVSAR

## Inventario Base de Datos Humedales Área de Estudio

ID	Nombre	Clase	Origen	Tipo	Uso	Area_m2
ARV1	El Abrazo	AaArA	Artificial	Lacustre	Reservorio	3751,74
ARV2	Sin Nombre	AaArA	Artificial	Lacustre	Reservorio	3432,12
ARR3	El Aljibe	TpPaVeSe	Artificial	Palustre	Reservorio, Recreación	5719,86
NDS4	Genagra	TpPaVeBj	Natural	Palustre	Desecación	128999
ARV5	Hispala	AaArA	Artificial	Lacustre	Reservorio seco	4184,9
PRV6	La Paz 1	TpPaVeSe	Artificial	Palustre	Reservorio	4411,84
PRV7	La Paz 2	TpPaVeBj	Artificial	Palustre	Reservorio	21223,2
PCR8	Manzanares 1	TpPaVeSe	Artificial	Palustre	Conservación, Recreación	9141,4
PRV9	Parque Industrial	AaArA	Artificial	Lacustre	Reservorio	7850,39
PCR10	Praga 1	TpPaVeSe	NA	Palustre	Conservación, Recreación	3150,98
PRV11	San Bernardino 2	TpPaVeBj	Artificial	Palustre	Reservorio	2563
PRV12	San Bernardino 3	AaArA	Artificial	Lacustre	Reservorio	2404,25
PRV13	Yerbabuena	AaArA	Artificial	Lacustre	Reservorio	3137,34
ARV14	Club Campestre	AaArA	Artificial	Lacustre	Reservorio	19129,4
PRV15	Nueva Esperanza 1	TpPaVeSe	Artificial	Palustre	Reservorio	5855,18
PRV16	Nueva Esperanza 2	TpPaVeSe	Artificial	Palustre	Reservorio	3466,75
NIA17	Las guacas 2	TpPaVeSe	Natural	Palustre	I.A <sup>1</sup>	74288,9
NIA18	Las guacas 1	TpPaVeSe	Natural	Palustre	I.A	74822,9
ARV19	Claridad	AaArA	Artificial	Lacustre	Reservorio	9236,87
ARV20	El Uvo 2	TpPaVeSe	Natural	Palustre	Reservorio	7857,48
ARV21	El Tablon	AaArA	Artificial	Lacustre	Reservorio	4274,88
ARV22	El Uvo 1	TpPaVeSe	Natural	Palustre	Reservorio	13888,6
ARV23	Santillana 6	TpPaVeSe	Natural	Palustre	Reservorio	23328,9
ARV24	Santillana 1	TpPaVeBj	Natural	Palustre	Reservorio	26494,3
ARV25	Esperanza 1	AaArA	Artificial	Lacustre	Reservorio	8318,48
ARV26	Esperanza 2	AaArA	Artificial	Lacustre	Reservorio	7235,84
ARV27	Esperanza 3	TpPaVeBj	Artificial	Palustre	Reservorio	11114,7
ARV28	La lomita 1	TpPaVeBj	Natural	Palustre	Reservorio	6886,33
ARV29	Esperanza 4	AaArA	Natural	Lacustre	Reservorio	8856,41
ARV30	La Corona 2	AaArA	Artificial	Lacustre	Reservorio	3587,36
ARV31	La Corona 1	AaArA	Artificial	Lacustre	Reservorio	5755,51
ARV32	Las Vegas 2	AaArA	Artificial	Lacustre	Reservorio	7165,11
ARV33	Santa catalina	TpPaVeBj	Natural	Palustre	Reservorio	16909,8
ARV34	Santillana 5	TpPaVeBj	Natural	Palustre	Reservorio	5630,1
ARV35	Las Vegas 1	AaArA	Natural	Lacustre	Reservorio	36875,6
NRV36	Santillana 2	TpPaVeBj	Natural	Palustre	Reservorio	21710,4
NRV37	Santillana 4	TpPaVeBj	Natural	Palustre	Reservorio	11188,2
NRV38	Padua	TpPaVeBj	Natural	Palustre	Reservorio	67209,7
NRV39	Las Chozas	TpPaVeBj	Natural	Palustre	Reservorio	55952,7

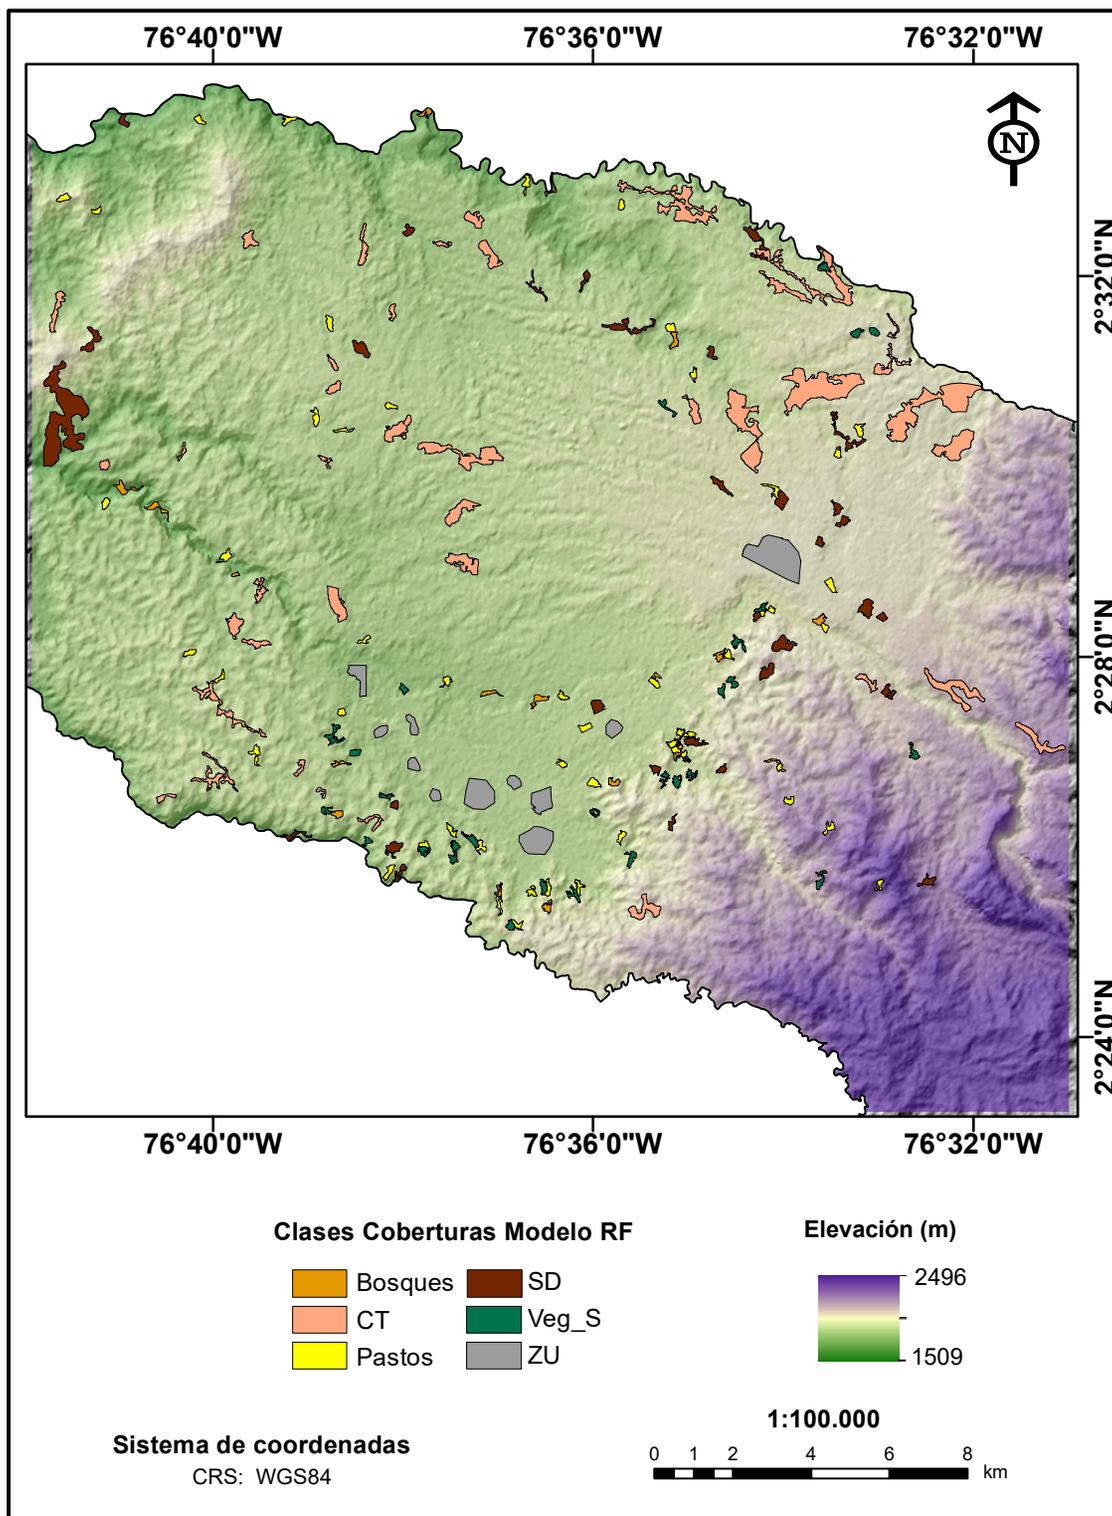
ID	Nombre	Clase	Origen	Tipo	Uso	Area_m2
NRV40	San Francisco 2	AaArA	Natural	Lacustre	Reservorio	31171,3
NRV41	Morobio 1	AaArA	Natural	Lacustre	Reservorio	13781,8
NRV42	Moribio 2	AaArA	Artificial	Lacustre	Reservorio	9832,43
NRV43	Moribio 3	AaArA	Artificial	Lacustre	Reservorio	4811,28
NRV44	Clarete	TpPaVeSe	Natural	Palustre	Reservorio	5206,48
NRV45	Morinda 3	AaArA	Artificial	Palustre	Reservorio	6389,6
NRV46	Morinda 2	AaArA	Artificial	Palustre	Reservorio	8317,27
NRV47	Morinda 1	AaArA	Artificial	Palustre	Reservorio	6742,26
NRV48	Rayos de Sol 1	TpPaVeBj	Natural	Palustre	Reservorio	5039,4
NRV49	San Bernardino 4	AaArA	Artificial	Lacustre	Reservorio	32010,3
NRV50	Valencia	AaArA	Artificial	Lacustre	Reservorio	17736,1
NRV51	La Rejoja 1	AaArA	Natural	Palustre	Reservorio	4288,63
NRV52	La Rejoja 2	TpPaVeBj	Natural	Palustre	Reservorio	2650,51
NRV53	Los Naranjos	AaArA	Artificial	Lacustre	Reservorio	11686,1
NRV54	SENA 1	AaArA	Artificial	Lacustre	Reservorio	3209,2
NRV55	Santa Leticia	AaArA	Natural	Lacustre	Reservorio	4689,31
NRV56	Rayos de Sol 2	AaArA	Artificial	Lacustre	Reservorio	3561,85
NRV57	SENA 3	AaArA	Artificial	Lacustre	Reservorio	2673,4
NRV58	La Eugenia 1	AaArA	Artificial	Lacustre	Reservorio	11588,8
NRV59	La Eugenia 2	AaArA	Artificial	Lacustre	Reservorio	2028,01
NRV60	Guindalito	AaArA	Natural	Lacustre	Reservorio	18401,1
NRV61	San Francisco 1	AaArA	Natural	Palustre	Reservorio	15997,6
NRV62	Villa Maria Lucia	TpPaVeBj	Natural	Palustre	Reservorio	25506,3
NRV63	Sin Nombre	TpPaVeSe	Natural	Palustre	Reservorio	27705,5
NRV64	Ciudad 2000	TpPaVeBj	Natural	Palustre	Reservorio	4223,01
NRV65	La Rioja	TpPaVeBj	Natural	Palustre	Reservorio	2827,49
NRV66	Sin Nombre	TpPaVeBj	Natural	Palustre	Reservorio	8488,07
NRV67	Sin Nombre	TpPaVeSe	Natural	Palustre	Reservorio	7345,1
NRV68	La Corona	TpPaVeSe	NA	Palustre	Reservorio	8185,53
NRV69	Las Monjas	TpPaVeBj	NA	Palustre	Reservorio	2091,73
NPJ70	La Colina	TpPaVeSe	NA	Palustre	Paisajistico	9821,78
NIT71	La Heroica	TpPaVeSe	Natural	Palustre	Intervenido	7476,21
NIA72	Las Palmas	TpPaVeSe	NA	Palustre	I.A	3627,89
NIA73	Centro canino 1	TpPaVeSe	NA	Palustre	I.A	3851,46
NIA74	Centro canino 2	TpPaVeSe	NA	Palustre	I.A	21174
NIA75	Villa Paula	TpPaVeBj	Artificial	Palustre	I.A	24800,6
NRV76	Los Tejares 1	TpPaVeBj	Natural	Palustre	Reservorio	13034,6
ARV77	Hda Las Guacas	TpPaVeBj	Natural	Palustre	Reservorio	5190,55
NIA78	Lame	TpPaVeSe	NA	Palustre	I.A	104211
NCV79	La Carola	TpPaVeBj	Natural	Palustre	Conservación	13622,8
AIT80	Florida 2	AaArA	NA	Lacustre	Industrial	35808,6

<sup>1</sup>Interés Ambiental

## Imágenes Sentinel-1A año 2015

#	Imagen GRD	Fecha	Órbita	Polarimetría
1	S1A_IW_GRDH_1SSV_20151209T105134_20151209T105159_008964_00CD8C_3573	09-12-15	Descendente	VV
2	S1A_IW_GRDH_1SSV_20151115T105135_20151115T105200_008614_00C3A8_1DBB	15-11-15	Descendente	VV
3	S1A_IW_GRDH_1SSV_20151022T105121_20151022T105146_008264_00BA49_5D63	22-10-15	Descendente	VV
4	S1A_IW_GRDH_1SSV0150928T105121_20150928T105146_007914_00B0CE_CA0D	28-09-15	Descendente	VV
5	S1A_IW_GRDH_1SSV_20150909T232125_20150909T232150_007645_00A9A5_DA22	09-09-15	Ascendente	VV
6	S1A_IW_GRDH_1SDV_20150512T232100_20150512T232125_005895_00797F_1C60	12-05-15	Ascendente	VV +VH
7	S1A_IW_GRDH_1SSV_20150904T105120_20150904T105145_007564_00A76C_B7F3	04-09-15	Descendente	VV
8	S1A_IW_GRDH_1SSV_20150816T232125_20150816T232150_007295_00A019_0DE7	16-08-15	Ascendente	VV
9	S1A_IW_GRDH_1SSV0150723T232123_20150723T232148_006945_00966E_1810	23-07-15	Ascendente	VV
10	S1A_IW_GRDH_1SSV_20150718T105118_20150718T105143_006864_009424_958B	18-07-15	Descendente	VV
11	S1A_IW_GRDH_1SSV_20150629T232123_20150629T232148_006595_008C9D_7EEF	29-06-15	Ascendente	VV
12	S1A_IW_GRDH_1SSV_20150624T105117_20150624T105142_006514_008A68_E70A	24-06-15	Descendente	VV
13	S1A_IW_GRDH_1SSV0150605T232121_20150605T232146_006245_0082B6_60D0	05-06-15	Ascendentes	VV
14	S1A_IW_GRDH_1SSV_20150531T105116_20150531T105141_006164_00804A_8BB0	31-05-15	Descendente	VV
15	S1A_IW_GRDH_1SSV_20150507T105114_20150507T105139_005814_0077A0_BBDD	07-05-15	Descendente	VV
16	S1A_IW_GRDH_1SSV_20150418T232118_20150418T232143_005545_007177_242D	18-04-15	Ascendentes	VV
17	S1A_IW_GRDH_1SSV_20150413T105113_20150413T105138_005464_006F8B_9117	13-04-15	Descendentes	VV
18	S1A_IW_GRDH_1SSV_20150325T232117_20150325T232142_005195_0068EA_DBF4	25-03-15	Ascendente	VV
19	S1A_IW_GRDH_1SSV_20150320T105112_20150320T105137_005114_0066F6_1F16	20-03-15	Descendente	VV
20	S1A_IW_GRDH_1SSV_20150301T232117_20150301T232142_004845_006083_5822	01-03-15	Ascendentes	VV
21	S1A_IW_GRDH_1SSV_20150224T105112_20150224T105137_004764_005E83_C061	24-02-15	Descendente	VV
22	S1A_IW_GRDH_1SSV_20150217T232117_20150217T232142_004670_005C42_DDFA	17-02-15	Ascendente	VV
23	S1A_IW_GRDH_1SSV_20150131T105112_20150131T105137_004414_005651_00CC	31-01-15	Descendente	VV
24	S1A_IW_GRDH_1SSV_20150107T105113_20150107T105138_004064_004E88_FB8B	07-01-15	Descendente	VV

## Distribución de polígonos de coberturas SGC 1:25.000



### Frecuencias de polígonos Modelo SAR S1A

Clase humedal	# Polígonos	Área ha
AaArA	36	37.99
Bosque	18	40
CT	42	545.67
Pastos	51	116.24
SD	34	206.75
TpPaVeBj	23	48.33
TpPaVeSe	21	42.45
Veg.Sec	29	69.16
ZU	11	177.81
<b>Total</b>	<b>265</b>	<b>1284.4</b>

### Frecuencias de polígonos Modelo UAVSAR

Clase humedal	# Polígonos	Área ha
AaArA	15	15.76
Bosque	9	21
CT	12	260
Pastos	29	62.1
SD	18	65.9
TpPaVeBj	14	31.79
TpPaVeSe	12	32.12
Veg.Sec	23	52.33
ZU	10	165.6
<b>Total</b>	<b>142</b>	<b>706.6</b>

# Anexo B

1. Conglomerados Jerárquicos Sentinel-1A 2014
2. Métricas Conglomerados Jerárquicos Sentinel-1A 2014
3. Conglomerados Jerárquicos Sentinel-1A 2015
4. Métricas Conglomerados Jerárquicos Sentinel-1A 2015
5. Número de conglomerados: Técnica del codo
6. Test de comparación de medias para dos muestras - Two Sample t-test



## Conglomerados Jerárquicos Sentinel-1A 2015

### Conglomerados Jerárquicos 2015

ARV1	ARV2	ARR3	NDS4	ARV5	PRV6	PRV7	PCR8	PRV9	PRC10	PRV11
1	2	3	1	2	3	1	3	1	1	3
PRV12	PRV13	ARV14	PRV15	PRV16	NIA17	NIA18	ARV19	ARV20	ARV21	ARV22
3	1	4	3	1	1	1	4	3	2	3
ARV23	ARV24	ARV25	ARV26	ARV27	ARV28	ARV29	ARV30	ARV31	ARV32	ARV33
1	1	2	2	1	3	4	1	2	2	3
ARV34	ARV35	NRV36	NRV37	NRV38	NRV39	NRV40	NRV41	NRV42	NRV43	NRV44
3	5	1	1	1	1	4	4	4	2	3
NRV45	NRV46	NRV47	NRV48	NRV49	NRV50	NRV51	NRV52	NRV53	NRV54	NRV55
1	1	1	3	2	2	1	3	1	3	1
NRV56	NRV57	NRV58	NRV59	NRV60	NRV61	NRV62	NRV63	NRV64	NRV65	NRV66
3	3	2	3	4	4	3	3	3	3	3
NRV67	NRV68	NRV69	NPJ70	NIT71	NIA72	NIA73	NIA74	NIA75	NRV76	ARV77
3	3	3	3	3	3	3	3	1	3	1
NIA78	NCV79	AIT80								
1	3	5								

## Métricas Conglomerados Jerárquicos Sentinel-1A 2015

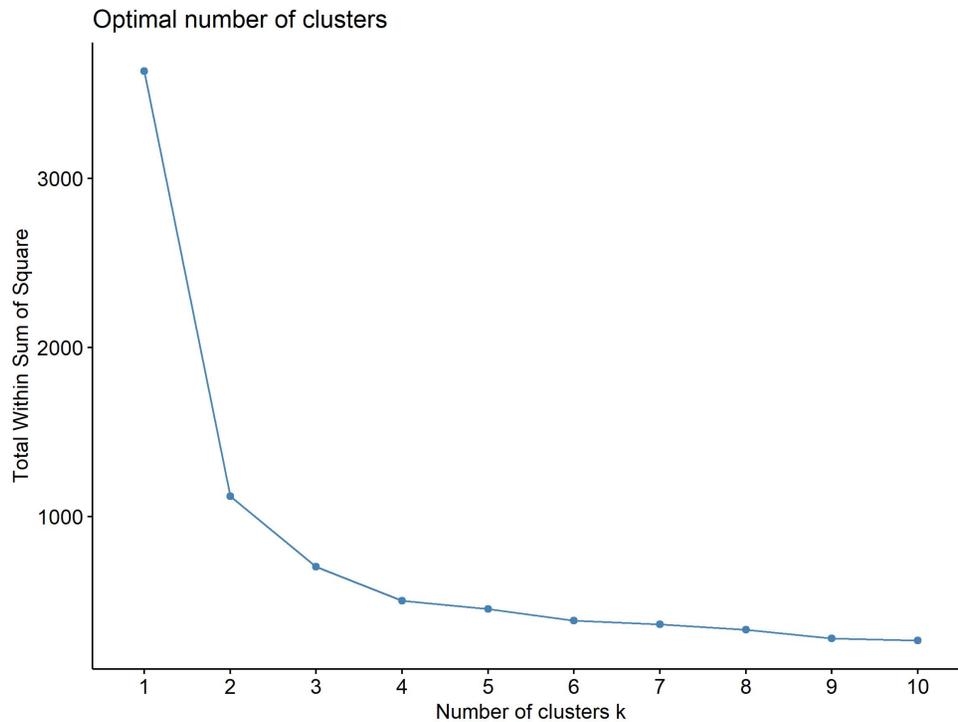
### Test Conglomerados Jerárquicos I 2015

class: 1					class: 3				
[1] Test.Value	Class.Mean	Frequency	Global.Mean		Test.Value	Class.Mean	Frequency	Global.Mean	
<0 rows> (or 0-length row.names)									
-----									
class: 2									
WASC_DA22	-2.202	-13.437	11	-11.941	WDES_958B	6.436	-10.144	33	-12.451
WDES_1DBB	-2.305	-12.789	11	-11.106	WDES_E70A	6.118	-9.860	33	-12.099
WDES_CA0D	-2.359	-14.099	11	-12.399	VHASC_1C60	6.109	-15.316	33	-17.027
WASC_0DE7	-2.466	-14.203	11	-12.268	WDES_1F16	6.099	-8.836	33	-11.073
WDES_3573	-2.509	-14.049	11	-12.112	WDES_8BB0	6.075	-8.892	33	-11.281
WDES_B7F3	-2.536	-14.482	11	-12.681	WDES_FB8B	6.069	-11.086	33	-13.197
WDES_958B	-2.605	-14.410	11	-12.451	WDES_9117	6.049	-9.344	33	-11.524
WASC_7EEF	-2.644	-13.880	11	-11.892	WASC_242D	6.043	-9.302	33	-11.656
WDES_5D63	-2.923	-13.729	11	-11.682	WDES_00CC	6.001	-10.385	33	-12.642
WASC_1810	-2.945	-14.476	11	-12.185	WASC_1810	5.985	-9.966	33	-12.185
WDES_1F16	-2.983	-13.370	11	-11.073	WDES_3573	5.985	-9.909	33	-12.112
WDES_00CC	-3.033	-15.036	11	-12.642	WASC_60D0	5.965	-10.183	33	-12.384
WDES_FB8B	-3.034	-15.411	11	-13.197	WVASC_DDF4	5.962	-10.495	33	-12.796
WASC_242D	-3.123	-14.209	11	-11.656	WASC_1C60	5.947	-9.634	33	-11.829
WDES_E70A	-3.157	-14.524	11	-12.099	WASC_0DE7	5.928	-10.050	33	-12.268
WASC_60D0	-3.168	-14.837	11	-12.384	WASC_DBF4	5.898	-9.232	33	-11.405
WASC_DDF4	-3.201	-15.390	11	-12.796	WDES_CA0D	5.881	-10.381	33	-12.399
WDES_C061	-3.208	-15.091	11	-12.514	WDES_B7F3	5.868	-10.697	33	-12.681
WDES_8BB0	-3.242	-13.956	11	-11.281	WDES_5D63	5.863	-9.726	33	-11.682
VHASC_1C60	-3.284	-18.958	11	-17.027	WDES_1DBB	5.810	-9.086	33	-11.106
WASC_DBF4	-3.325	-13.977	11	-11.405	WASC_7EEF	5.792	-9.817	33	-11.892
WASC_5822	-3.394	-14.724	11	-11.847	WDES_C061	5.770	-10.305	33	-12.514
WDES_9117	-3.473	-14.150	11	-11.524	WASC_DA22	5.662	-10.108	33	-11.941
WASC_1C60	-3.512	-14.549	11	-11.829	WASC_5822	5.597	-9.586	33	-11.847
					WDES_BBDD	2.784	-9.461	33	-10.296

## Test Conglomerados Jerárquicos II 2015

class: 4					class: 5				
	Test.Value	Class.Mean	Frequency	Global.Mean		Test.Value	Class.Mean	Frequency	Global.Mean
WASC_DA22	-4.463	-15.572	8	-11.941	WDES_9117	-2.389	-16.029	2	-11.524
WDES_E70A	-4.800	-16.515	8	-12.099	WDES_5D63	-2.638	-16.290	2	-11.682
VHASC_1C60	-5.159	-20.660	8	-17.027	WDES_1DBB	-2.655	-15.937	2	-11.106
WDES_CA0D	-5.215	-16.899	8	-12.399	WDES_BBDD	-3.270	-15.425	2	-10.296
WDES_1F16	-5.220	-15.888	8	-11.073	VHASC_1C60	-3.356	-21.947	2	-17.027
WDES_B7F3	-5.269	-17.162	8	-12.681	WDES_8BB0	-3.601	-18.689	2	-11.281
WASC_DBF4	-5.273	-16.289	8	-11.405	WASC_242D	-3.613	-19.022	2	-11.656
WDES_FB88	-5.307	-17.836	8	-13.197	WDES_958B	-3.624	-19.246	2	-12.451
WDES_958B	-5.344	-17.265	8	-12.451	WASC_5822	-3.654	-19.571	2	-11.847
WDES_3573	-5.381	-17.090	8	-12.112	WASC_DDF4	-3.675	-20.220	2	-12.796
WDES_00CC	-5.412	-17.758	8	-12.642	WASC_1C60	-3.706	-18.986	2	-11.829
WASC_1C60	-5.421	-16.858	8	-11.829	WASC_60D0	-3.770	-19.664	2	-12.384
WDES_8BB0	-5.428	-16.645	8	-11.281	WDES_C061	-3.795	-20.117	2	-12.514
WDES_C061	-5.441	-17.750	8	-12.514	WASC_7EEF	-3.810	-19.034	2	-11.892
WASC_60D0	-5.501	-17.487	8	-12.384	WDES_FB88	-3.848	-20.200	2	-13.197
WASC_242D	-5.501	-17.043	8	-11.656	WASC_DBF4	-3.851	-18.832	2	-11.405
WASC_5822	-5.586	-17.520	8	-11.847	WASC_1810	-3.855	-19.664	2	-12.185
WASC_0DE7	-5.596	-17.530	8	-12.268	WDES_1F16	-3.898	-18.556	2	-11.073
WDES_5D63	-5.616	-16.394	8	-11.682	WASC_0DE7	-3.935	-19.971	2	-12.268
WASC_1810	-5.619	-17.422	8	-12.185	WDES_E70A	-3.988	-19.738	2	-12.099
WDES_9117	-5.635	-16.629	8	-11.524	WDES_CA0D	-4.047	-19.667	2	-12.399
WASC_DDF4	-5.666	-18.295	8	-12.796	WDES_00CC	-4.062	-20.636	2	-12.642
WASC_7EEF	-5.863	-17.172	8	-11.892	WDES_B7F3	-4.127	-19.986	2	-12.681
WDES_1DBB	-6.122	-16.459	8	-11.106	WDES_3573	-4.171	-20.146	2	-12.112
					WASC_DA22	-4.377	-19.354	2	-11.941

## Número de conglomerados: Técnica del codo



### Two Sample t-test - varianzas iguales

data	vvasc\$Retrodispersion and vvdes\$Retrodispersion	
t	1035	
df	87976150	
p-values	<b>2.2 e-16</b>	
hipótesis alternativa	<b>true difference in means is not equal to 0</b>	
95 percent confidence	0.5432152	0.5452765
sample estimates	mean of x	mean of y
	<b>-7.863791</b>	<b>-8.408037</b>

### Two Sample t-test - varianzas diferentes

data	vvasc\$Retrodispersion and vvdes\$Retrodispersion	
t	1029	
df	77303105	
p-values	<b>2.2 e-16</b>	
hipótesis alternativa	<b>true difference in means is not equal to 0</b>	
95 percent confidence	0.5432093	0.5452824
sample estimates	mean of x	mean of y
	<b>-7.863791</b>	<b>-8.408037</b>

# Anexo C

1. Matriz de Confusión SAR\_S1\_2015
2. Matriz de Confusión SAR\_S1\_2015 - Var\_Aux
3. Matriz de Confusión ACP\_SAR\_S1\_2015
4. Matriz de Confusión ACP\_SAR\_S1\_2015 - Var\_Aux
5. Matriz de Confusión SAR\_S1\_VVASC\_2015
6. Matriz de Confusión SAR\_S1\_VVASC\_2015 - Var\_Aux
7. Matriz de Confusión SAR\_S1\_VVDES\_2015
8. Matriz de Confusión SAR\_S1\_VVDES\_2015 - Var\_Aux
9. Matriz de Confusión ACP\_SAR\_S1\_VVASC\_VVDES\_2015
10. Matriz de Confusión ACP\_SAR\_S1\_VVASC\_VVDES\_2015 - Var\_Aux
11. Matriz de Confusión SAR\_UAVSAR\_2015

### Modelo de Detección Random Forest Variables SAR\_S1A\_2015

#### Matriz de Confusión Entrenamiento SAR\_S1A\_2015

	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU	class.error
AaArA	2511	0	27	25	70	38	4	4	0	0.063
Bosques	3	1761	61	41	24	40	4	44	22	0.120
CT	53	75	1864	145	185	217	83	133	45	0.334
Pastos	49	46	136	2413	112	99	37	82	26	0.196
TpPaVeBj	8	9	21	7	3330	33	2	12	5	0.028
TpPaVeSe	7	6	24	11	41	3007	7	20	6	0.039
SD	38	20	207	107	83	118	1808	77	42	0.277
Veg_S	11	34	84	53	57	65	14	2165	17	0.134
ZU	4	16	23	5	5	3	6	16	922	0.078

#### Matriz de Confusión Validación SAR\_S1A\_2015

Predicción/Referencia	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU
AaArA	1103	1	27	19	3	1	13	3	0
Bosques	0	686	37	15	1	1	8	11	4
CT	8	30	806	59	12	7	86	45	12
Pastos	4	23	65	967	0	2	49	18	4
TpPaVeBj	25	11	80	51	1431	15	31	21	0
TpPaVeSe	15	26	62	33	9	1310	45	29	3
SD	2	1	39	14	5	2	806	3	6
Veg_S	1	11	65	34	2	7	47	960	12
ZU	0	11	19	8	0	6	15	10	459

	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU
Sensibilidad	0.952	0.857	0.671	0.805	0.978	0.969	0.732	0.872	0.918
Especificidad	0.992	0.991	0.970	0.980	0.972	0.973	0.991	0.979	0.992

### Modelo de Detección Random Forest Variables SAR\_S1A\_2015 y Var\_Aux

#### Matriz de Confusión Entrenamiento SAR\_S1A\_2015 y Var\_Aux

	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU	class.error
AaArA	2460	2	36	20	87	65	6	3	0	0.082
Bosques	4	1806	49	39	12	27	14	46	3	0.097
CT	52	73	1981	172	135	185	53	133	16	0.293
Pastos	35	50	160	2412	83	121	26	94	19	0.196
TpPaVeBj	19	2	52	9	3277	50	4	10	4	0.044
TpPaVeSe	15	3	33	18	66	2970	10	9	5	0.051
SD	35	29	263	118	60	116	1766	81	32	0.294
Veg_S	9	35	103	61	36	58	12	2174	12	0.130
ZU	6	1	21	7	3	0	5	9	948	0.052

#### Matriz de Confusión Validación SAR\_S1A\_2015 y Var\_Aux

Predicción/Referencia	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU
AaArA	1088	1	21	20	5	7	21	5	0
Bosques	2	733	37	18	2	1	9	10	1
CT	12	19	856	60	10	13	103	44	7
Pastos	4	16	82	977	4	2	62	27	7
TpPaVeBj	27	7	48	36	1423	19	18	17	2
TpPaVeSe	25	13	62	37	16	1296	49	29	0
SD	0	1	22	12	2	3	785	3	7
Veg_S	0	10	64	34	1	5	39	956	0
ZU	0	0	8	6	0	5	14	9	476

	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU
Sensibilidad	0.940	0.916	0.713	0.814	0.973	0.959	0.714	0.869	0.952
Especificidad	0.991	0.991	0.969	0.976	0.979	0.973	0.994	0.983	0.996

### Modelo de Detección Random Forest Variables ACP\_SAR\_S1A\_2015

#### Matriz de Confusión Entrenamiento ACP\_SAR\_S1A\_2015

	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU	class.error
AaArA	2117	10	64	56	171	193	54	14	0	0.210
Bosques	8	1383	124	90	64	122	56	114	39	0.309
CT	78	142	1224	275	267	319	205	231	59	0.563
Pastos	102	105	259	1766	210	203	151	179	25	0.411
TpPaVeBj	57	62	146	86	2606	356	54	55	5	0.240
TpPaVeSe	47	42	172	104	321	2296	64	74	9	0.266
SD	80	73	302	200	177	177	1301	143	47	0.480
Veg_S	15	107	179	128	97	143	80	1738	13	0.305
ZU	4	21	23	11	10	6	15	22	888	0.112

#### Matriz de Confusión Validación ACP\_SAR\_S1A\_2015

Predicción/Referencia	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU
AaArA	926	3	37	37	18	19	25	5	0
Bosques	5	566	62	33	14	9	38	43	11
CT	18	58	546	122	57	54	136	78	14
Pastos	27	36	118	714	38	31	81	60	7
TpPaVeBj	67	35	115	94	1152	131	64	54	1
TpPaVeSe	91	33	108	85	138	1052	74	76	6
SD	19	19	105	47	19	18	588	29	8
Veg_S	5	39	88	61	25	29	73	744	12
ZU	0	11	21	7	2	8	21	11	441

	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU
Sensibilidad	0.799	0.707	0.455	0.595	0.787	0.778	0.534	0.676	0.882
Especificidad	0.983	0.976	0.938	0.954	0.933	0.928	0.969	0.962	0.991

**Modelo de Detección Random Forest Variables ACP\_SAR\_S1A\_2015\_Var\_Aux**

**Matriz de Confusión Entrenamiento ACP\_SAR\_S1A\_2015\_Var\_Aux**

	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU	class.error
AaArA	2294	12	57	38	118	130	21	9	0	0.144
Bosques	12	1609	91	69	21	74	21	100	3	0.196
CT	50	111	1668	258	153	233	116	190	21	0.404
Pastos	49	83	302	2026	111	169	85	155	20	0.325
TpPaVeBj	38	24	108	39	2872	300	11	31	4	0.162
TpPaVeSe	46	22	102	57	271	2557	27	39	8	0.183
SD	61	64	338	198	74	151	1431	153	30	0.428
Veg_S	13	78	169	87	44	100	45	1953	11	0.219
ZU	7	6	23	9	1	1	9	8	936	0.064

**Matriz de Confusión Validación ACP\_SAR\_S1A\_2015\_Var\_Aux**

Predicción/Referencia	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU
AaArA	994	2	20	24	21	14	36	7	0
Bosques	3	666	44	34	7	9	33	42	1
CT	20	32	736	103	39	43	153	86	9
Pastos	14	29	115	842	10	24	97	44	10
TpPaVeBj	50	14	48	52	1267	105	22	18	1
TpPaVeSe	63	20	86	52	105	1135	68	52	2
SD	7	4	53	30	2	5	629	15	7
Veg_S	7	28	89	56	11	11	41	827	0
ZU	0	5	9	7	1	5	21	9	470

	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU
Sensibilidad	0.858	0.832	0.613	0.701	0.866	0.840	0.571	0.751	0.940
Especificidad	0.985	0.980	0.944	0.960	0.963	0.947	0.985	0.972	0.993

## Modelo de Detección Random Forest Variables SAR\_S1A\_VVASC\_2015

### Matriz de Confusión Entrenamiento SAR\_S1A\_VVASC\_2015

	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU	class.error
AaArA	2196	8	65	54	144	140	47	25	0	0.180
Bosques	43	1414	80	61	69	151	22	87	73	0.293
CT	107	116	1260	207	333	359	174	172	72	0.550
Pastos	114	66	179	1813	233	255	136	124	80	0.395
TpPaVeBj	40	30	80	37	2928	200	41	65	6	0.145
TpPaVeSe	6	30	84	54	179	2686	32	50	8	0.141
SD	115	56	189	134	215	198	1440	122	31	0.424
Veg_S	32	78	134	75	172	217	59	1681	52	0.327
ZU	2	51	34	25	11	17	13	62	785	0.215

### Matriz de Confusión Validación SAR\_S1A\_VVASC\_2015

Predicción/Referencia	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU
AaArA	989	12	51	55	15	4	35	12	0
Bosques	4	579	50	27	16	3	26	24	29
CT	26	33	522	82	20	27	115	60	10
Pastos	21	19	101	737	11	10	52	31	12
TpPaVeBj	54	41	152	93	1301	61	95	77	3
TpPaVeSe	42	50	137	91	69	1209	83	91	10
SD	17	5	79	43	11	14	638	32	5
Veg_S	5	35	80	49	20	15	44	747	40
ZU	0	26	28	23	0	8	12	26	391

	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU
Sensibilidad	0.854	0.723	0.435	0.614	0.889	0.894	0.580	0.679	0.782
Especificidad	0.978	0.980	0.956	0.970	0.931	0.932	0.976	0.967	0.986

### Modelo de Detección Random Forest Variables SAR\_S1A\_VVASC\_2015\_Var\_Aux

#### Matriz de Confusión Entrenamiento SAR\_S1A\_VVASC\_2015\_Var\_Aux

	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU	class.error
AaArA	2237	14	83	35	132	123	30	25	0	0.165
Bosques	27	1599	70	60	23	95	11	112	3	0.201
CT	60	67	1646	248	156	286	107	205	25	0.412
Pastos	63	74	259	2044	117	190	86	138	29	0.319
TpPaVeBj	37	8	99	31	2947	240	17	45	3	0.140
TpPaVeSe	19	11	99	30	234	2672	18	39	7	0.146
SD	72	45	308	201	89	163	1447	142	33	0.421
Veg_S	17	66	177	100	50	145	42	1894	9	0.242
ZU	8	8	26	11	5	4	10	7	921	0.079

#### Matriz de Confusión Validación SAR\_S1A\_VVASC\_2015\_Var\_Aux

Predicción/Referencia	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU
AaArA	997	14	29	26	12	9	30	15	0
Bosques	6	650	45	28	6	2	19	21	0
CT	25	36	708	93	32	37	118	56	16
Pastos	10	16	103	832	9	11	80	46	5
TpPaVeBj	52	5	70	48	1308	74	34	24	2
TpPaVeSe	50	36	106	75	82	1195	66	73	0
SD	11	2	39	44	2	5	664	15	9
Veg_S	7	39	93	46	11	13	72	839	2
ZU	0	2	7	8	1	5	17	11	466

	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU
Sensibilidad	0.861	0.812	0.590	0.693	0.894	0.884	0.603	0.762	0.932
Especificidad	0.984	0.986	0.952	0.967	0.963	0.942	0.985	0.967	0.994

### Modelo de Detección Random Forest Variables SAR\_S1A\_VVDES\_2015

#### Matriz de Confusión Entrenamiento SAR\_S1A\_VVDES\_2015

	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU	class.error
AaArA	2335	4	59	26	132	92	19	12	0	0.128
Bosques	74	1529	91	41	96	78	25	53	13	0.235
CT	102	65	1639	130	258	287	115	148	56	0.414
Pastos	117	39	167	2146	172	151	69	105	34	0.2847
TpPaVeBj	20	13	45	23	3215	71	6	21	13	0.061
TpPaVeSe	22	6	36	18	73	2915	25	24	10	0.068
SD	89	45	258	103	123	169	1580	87	46	0.368
Veg_S	47	33	101	59	123	123	41	1950	23	0.220
ZU	4	13	38	14	14	16	26	50	825	0.175

#### Matriz de Confusión Validación SAR\_S1A\_VVDES\_2015

Predicción/Referencia	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU
AaArA	1033	27	42	51	4	6	26	15	0
Bosques	3	609	33	11	3	2	22	10	8
CT	24	33	714	74	17	18	112	46	22
Pastos	15	16	57	859	6	1	41	33	8
TpPaVeBj	45	49	95	77	1392	18	44	65	4
TpPaVeSe	32	33	111	53	26	1284	65	59	10
SD	5	13	50	29	6	7	718	14	15
Veg_S	1	15	70	31	3	10	52	851	20
ZU	0	5	28	15	6	5	20	7	413

	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU
Sensibilidad	0.892	0.761	0.595	0.715	0.951	0.950	0.652	0.773	0.826
Especificidad	0.980	0.989	0.960	0.979	0.952	0.954	0.984	0.977	0.990

**Modelo de Detección Random Forest Variables SAR\_S1A\_VVDES\_2015\_Var\_Aux**

**Matriz de Confusión Entrenamiento SAR\_S1A\_VVDES\_2015\_Var\_Aux**

	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU	class.error
AaArA	2316	12	75	40	104	99	14	18	1	0.135
Bosques	22	1677	88	57	23	45	19	66	3	0.162
CT	56	71	1873	202	154	202	69	153	20	0.331
Pastos	44	47	210	2269	94	145	51	106	34	0.244
TpPaVeBj	27	6	75	16	3159	115	3	20	6	0.078
TpPaVeSe	52	5	62	31	122	2820	12	19	6	0.099
SD	67	42	326	147	69	141	1571	100	37	0.372
Veg_S	24	42	141	88	41	78	25	2041	20	0.184
ZU	8	1	29	8	3	0	18	10	923	0.077

**Matriz de Confusión Validación SAR\_S1A\_VVDES\_2015\_Var\_Aux**

Predicción/Referencia	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU
AaArA	1023	7	17	20	13	15	39	15	1
Bosques	6	658	26	14	3	2	15	19	0
CT	34	31	825	77	24	27	152	65	14
Pastos	11	41	83	915	11	7	50	50	3
TpPaVeBj	40	17	53	32	1370	32	22	23	3
TpPaVeSe	33	17	79	54	36	1250	66	30	0
SD	7	4	36	22	0	2	676	5	7
Veg_S	4	24	75	48	5	13	48	887	4
ZU	0	1	6	18	1	3	32	6	468

	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU
Sensibilidad	0.883	0.822	0.687	0.762	0.936	0.925	0.614	0.806	0.936
Especificidad	0.985	0.990	0.951	0.970	0.973	0.963	0.990	0.974	0.992

### Modelo de Detección Random Forest ACP\_SAR\_S1A\_VVASC\_VVDES\_2015

#### Matriz de Confusión Entrenamiento ACP\_SAR\_S1A\_VVASC\_VVDES\_2015

	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU	class.error
AaArA	2169	5	90	57	163	161	27	7	0	0.190
Bosques	5	1448	117	90	73	106	29	100	32	0.276
CT	83	139	1361	249	241	282	205	192	48	0.514
Pastos	89	88	260	1865	197	189	132	152	28	0.378
TpPaVeBj	42	53	121	65	2796	256	34	45	15	0.184
TpPaVeSe	39	36	99	78	237	2521	43	66	10	0.194
SD	74	56	293	187	148	182	1385	131	44	0.446
Veg_S	19	119	121	113	82	132	51	1841	22	0.264
ZU	4	12	24	10	5	5	7	26	907	0.093

#### Matriz de Confusión Validación ACP\_SAR\_S1A\_VVASC\_VVDES\_2015

Predicción/Referencia	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU
AaArA	950	2	41	26	9	8	22	7	0
Bosques	3	582	55	25	14	13	27	38	8
CT	33	44	608	104	41	44	131	71	9
Pastos	19	44	95	766	22	24	84	59	2
TpPaVeBj	69	28	110	83	1251	88	51	32	0
TpPaVeSe	65	41	109	83	88	1130	69	82	7
SD	12	18	72	40	22	9	620	16	7
Veg_S	7	32	93	62	11	29	74	782	7
ZU	0	9	17	11	5	6	22	13	460

	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU
Sensibilidad	0.820	0.727	0.506	0.638	0.855	0.836	0.563	0.710	0.920
Especificidad	0.986	0.979	0.945	0.959	0.945	0.936	0.977	0.964	0.991

### Modelo de Detección Random Forest ACP\_SAR\_S1A\_VVASC\_VVDES\_2015-Var\_Aux

#### Matriz de Confusión Entrenamiento ACP\_SAR\_S1A\_VVASC\_VVDES\_2015-Var\_Aux

	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU	class.error
AaArA	2289	6	68	41	115	136	18	6	0	0.146
Bosques	13	1640	101	49	20	60	24	89	4	0.180
CT	54	91	1743	228	158	231	110	165	20	0.378
Pastos	43	88	263	2111	109	147	82	136	21	0.296
TpPaVeBj	32	31	80	31	2957	246	13	33	4	0.137
TpPaVeSe	40	16	68	47	239	2658	21	31	9	0.151
SD	52	62	324	189	64	154	1494	130	31	0.402
Veg_S	14	73	142	82	55	84	44	1992	14	0.203
ZU	8	7	10	5	2	2	10	12	944	0.056

#### Matriz de Confusión Validación ACP\_SAR\_S1A\_VVASC\_VVDES\_2015-Var\_Aux

Predicción/Referencia	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU
AaArA	1004	2	18	24	19	17	25	11	0
Bosques	1	668	40	29	2	6	31	35	0
CT	25	30	785	99	29	32	148	76	8
Pastos	18	31	97	856	10	15	73	39	6
TpPaVeBj	47	7	54	52	1299	85	20	12	2
TpPaVeSe	51	26	83	49	85	1173	64	49	1
SD	9	7	38	28	4	5	672	16	8
Veg_S	3	29	78	57	13	13	49	852	1
ZU	0	0	7	6	2	5	18	10	474

	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU
Sensibilidad	0.867	0.835	0.654	0.713	0.887	0.868	0.610	0.774	0.948
Especificidad	0.986	0.984	0.948	0.966	0.966	0.952	0.986	0.972	0.994

### Modelo de Detección Random Forest Variables SAR\_UAVSAR\_2015

#### Matriz de Confusión Entrenamiento SAR\_UAVSAR\_2015

	AaArA	Bosques	CT	Pastos	SD	TpPaVeBj	TpPaVeSe	Veg_S	ZU	class.error
AaArA	684	37	9	53	42	124	101	53	10	0.385
Bosques	27	435	12	57	43	52	139	219	46	0.578
CT	22	23	172	71	49	92	162	107	38	0.766
Pastos	74	60	41	645	98	174	223	192	92	0.597
SD	63	43	39	110	503	114	212	127	51	0.601
TpPaVeBj	45	24	13	73	31	1679	304	74	13	0.256
TpPaVeSe	33	73	30	59	61	306	1560	152	24	0.321
Veg_S	44	122	48	131	62	84	281	1022	92	0.458
ZU	6	23	26	50	15	8	22	108	651	0.284

#### Matriz de Confusión Validación SAR\_UAVSAR\_2015

Predicción/Referencia	AaArA	Bosques	CT	Pastos	SD	TpPaVeBj	TpPaVeSe	Veg_S	ZU
AaArA	280	14	12	37	29	17	12	15	1
Bosques	17	159	10	22	26	14	22	50	11
CT	7	6	70	19	16	6	10	20	6
Pastos	34	32	24	236	49	30	24	50	28
SD	19	19	27	48	212	12	22	31	10
TpPaVeBj	37	20	31	65	56	702	125	41	2
TpPaVeSe	43	50	71	91	75	137	679	122	11
Veg_S	26	86	53	81	65	23	54	449	46
ZU	4	19	17	43	25	11	13	42	339

	AaArA	Bosques	CT	Pastos	TpPaVeBj	TpPaVeSe	SD	Veg_S	ZU
Sensitividad	0.60	0.39	0.22	0.37	0.74	0.71	0.38	0.55	0.75
Especificidad	0.97	0.97	0.98	0.94	0.92	0.87	0.96	0.91	0.97