

**Universidad de Costa Rica**  
**Facultad de Ingeniería**  
**Escuela de Ingeniería de Biosistemas**

**Trabajo Final de Graduación para optar por el título de  
Licenciatura en Ingeniería Agrícola y de Biosistemas**

**Evaluación de dos clasificadores para la identificación de áreas inundables con  
diferentes metodologías de procesamiento mediante imágenes de Radar de Apertura  
Sintética en la planicie inundable de la margen derecha del Río Tempisque, Costa Rica**

**Angie Valeria Jiménez Abarca**

**B63548**

**María José Guerrero Madrigal**

**B53213**

**Directora**

**Alejandra Rojas González, Ph.D.**

**Comité asesor**

**Melissa Rojas Downing, Ph.D.**

**Felipe Calleja Apéstegui, Ph.D.**

**Proyecto de Graduación**

**Ciudad Universitaria Rodrigo Facio**

**Febrero, 2023**

## HOJA DE APROBACIÓN

Este Trabajo Final de Graduación fue aceptado por la Comisión de Trabajos Finales de Graduación de la Escuela de Ingeniería de Biosistemas de la Universidad de Costa Rica, como requisito para optar al grado y título de Licenciatura en Ingeniería Agrícola y de Biosistemas.



Angie Valeria Jiménez Abarca  
Estudiante



María José Guerrero Madrigal  
Estudiante

Miembros de Tribunal Examinador del Trabajo Final de Graduación



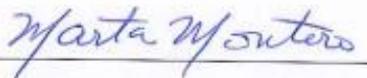
Ing. Alejandra Rojas González, Ph.D.  
Directora Trabajo Final de Graduación



Ing. Melissa Rojas Downing, Ph.D.  
Comité Asesor



Ing. Felipe Calleja Apéstegui, Ph.D.  
Comité Asesor



Dra. Marta Montero Calderón  
Presidente Tribunal Examinador



Ing. Heijeen Aguilar Arias  
Lectora Invitada

## **DEDICATORIA**

A nuestros padres y madres por su apoyo y amor incondicional, sin ellos nada esto sería posible.

## **AGRADECIMIENTOS**

A nuestras familias por su apoyo y cariño durante la etapa universitaria.

A nuestros amigos que han estado presentes a lo largo de nuestra vida universitaria, que han sido de gran apoyo y compañía durante este proceso.

Al comité asesor de este trabajo final de graduación conformado por la Dra. Alejandra Rojas González, Dra. Melissa Rojas Downing y el Dr. Felipe Calleja Apéstegui, por su acompañamiento y ayuda.

A Saulo por su apoyo, ayuda y cariño incondicional.

## ÍNDICE

<b>HOJA DE APROBACIÓN.....</b>	<b>I</b>
<b>DEDICATORIA.....</b>	<b>II</b>
<b>AGRADECIMIENTOS.....</b>	<b>III</b>
<b>ÍNDICE .....</b>	<b>IV</b>
<b>ÍNDICE DE FIGURAS.....</b>	<b>VI</b>
<b>ÍNDICE DE TABLAS.....</b>	<b>VIII</b>
<b>RESUMEN.....</b>	<b>1</b>
<b>1. INTRODUCCIÓN.....</b>	<b>2</b>
1.1. <i>Objetivos .....</i>	<i>4</i>
<b>2. MARCO TEÓRICO.....</b>	<b>5</b>
2.1. <i>Eventos meteorológicos extremos: Inundaciones .....</i>	<i>5</i>
2.1.1. <i>Tormenta tropical Nate.....</i>	<i>6</i>
2.2. <i>Información de la zona de estudio.....</i>	<i>6</i>
2.3. <i>Aplicación de teledetección para el análisis de inundaciones .....</i>	<i>7</i>
2.3.1. <i>Fundamentos teóricos sobre la aplicación de SAR en inundaciones .....</i>	<i>7</i>
2.3.2. <i>Características SENTINEL-1.....</i>	<i>8</i>
2.3.3. <i>Preprocesamiento de imágenes SAR .....</i>	<i>9</i>
2.3.3.1. <i>Aplicación del archivo de órbita .....</i>	<i>9</i>
2.3.3.2. <i>Reducción de ruido térmico.....</i>	<i>9</i>
2.3.3.3. <i>Corrección de artefactos radiométricos en el borde de la imagen .....</i>	<i>9</i>
2.3.3.4. <i>Calibración radiométrica.....</i>	<i>10</i>
2.3.3.5. <i>Reducción de ruido granular.....</i>	<i>10</i>
2.3.3.5.1. <i>Evaluación cuantitativa de la reducción de ruido granular.....</i>	<i>11</i>
2.3.3.6. <i>Corrección geométrica .....</i>	<i>12</i>
2.3.4. <i>Procesamiento de imágenes SAR para detección de inundaciones.....</i>	<i>12</i>
2.3.4.1. <i>Clasificador Random Forest .....</i>	<i>12</i>
2.3.4.2. <i>Técnica de Umbrales de Calibración.....</i>	<i>13</i>
2.3.5. <i>Imágenes satelitales.....</i>	<i>14</i>
2.3.6. <i>Índices espectrales derivados de imágenes satelitales .....</i>	<i>15</i>
2.3.6.1. <i>Índice Diferencial de Agua Normalizado.....</i>	<i>15</i>
2.3.7. <i>Método de validación de resultados .....</i>	<i>16</i>
<b>3. METODOLOGÍA.....</b>	<b>17</b>
3.1. <i>Sitio de estudio.....</i>	<i>17</i>
3.2. <i>Métodos.....</i>	<i>17</i>
3.2.1. <i>Definición de métodos.....</i>	<i>18</i>
3.2.1.1. <i>Preprocesamiento de las imágenes SAR .....</i>	<i>18</i>

3.2.1.2.	<i>Procesamiento</i> .....	21
3.2.1.2.1.	<i>Técnica de Umbrales de Calibración</i> .....	23
3.2.1.2.2.	<i>Clasificador Random Forest</i> .....	24
3.2.1.2.3.	<i>Descarte de cuerpos de agua fijos previos al evento de inundación</i> ....	25
3.2.1.2.4.	<i>Cálculo de áreas inundadas</i> .....	25
3.3.	<i>Análisis estadístico</i> .....	26
3.3.1.	<i>Índice Kappa</i> .....	26
3.3.2.	<i>Medida F</i> .....	27
3.3.3.	<i>Efecto de aleatoriedad en datos de entrenamiento</i> .....	28
<b>4.</b>	<b>RESULTADOS Y DISCUSIÓN</b> .....	<b>29</b>
4.1.	<i>Preprocesamiento</i> .....	29
4.2.	<i>Procesamiento</i> .....	34
4.2.1.	<i>Técnica de Umbrales de Calibración</i> .....	36
4.2.2.	<i>Clasificador Random Forest</i> .....	41
4.3.	<i>Análisis estadístico</i> .....	45
4.3.1.	<i>Índice Kappa</i> .....	45
4.3.2.	<i>Medida F</i> .....	52
4.3.3.	<i>Resumen de resultados del Índice Kappa y Medida F</i> .....	58
4.3.4.	<i>Efecto de aleatoriedad en datos de entrenamiento</i> .....	58
<b>5.</b>	<b>CONCLUSIONES</b> .....	<b>60</b>
<b>6.</b>	<b>RECOMENDACIONES</b> .....	<b>61</b>
<b>7.</b>	<b>REFERENCIAS</b> .....	<b>63</b>
<b>8.</b>	<b>ANEXOS</b> .....	<b>71</b>

## ÍNDICE DE FIGURAS

<b>Figura 1.</b> Ejemplo de técnica de UC (Cattaneo et al., 2011). .....	13
<b>Figura 2.</b> Zona de estudio, planicie inundable de la margen derecha del Río Tempisque. ....	17
<b>Figura 3.</b> Diagrama de flujo de la metodología desarrollada.....	18
<b>Figura 4.</b> Diagrama de flujo del preprocesamiento de imágenes y combinaciones desarrolladas. .....	20
<b>Figura 5.</b> Preprocesamiento de imágenes SAR antes y después del evento de inundación (polarización VH, filtro Lee y calibración radiométrica sigma 0).....	29
<b>Figura 6.</b> Comparación de imágenes SAR con calibración radiométrica sigma 0 y gamma 0 (después del evento de inundación, polarización VH y filtro Lee Sigma). .....	30
<b>Figura 7.</b> Comparación de imágenes SAR con y sin la aplicación de filtro Boxcar (después del evento de inundación, polarización VH y calibración sigma 0). .....	30
<b>Figura 8.</b> Comparación de imágenes SAR con tamaño de ventanas diferentes para el filtro Lee y Lee Sigma (después del evento de inundación, polarización VH y calibración sigma 0). Con círculo rojo se indica el poblado de Palmira (A) y la Central Azucarera Tempisque (B). .....	31
<b>Figura 9.</b> Comparación de distorsión de borde para el filtro Frost y Boxcar con tamaño de ventanas diferentes (después del evento de inundación, polarización VH y calibración sigma 0). .....	31
<b>Figura 10.</b> Comparación de preprocesamiento con filtro Lee y Boxcar (después del evento de inundación, polarización VH y calibración sigma 0). Con círculo rojo se indica el poblado de Filadelfia. ....	32
<b>Figura 11.</b> Gráfico de cajas para PSNR con respecto al tamaño de ventanas, obtenido de InfoStat. Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de $Q_1-1.5*RIC$ y $Q_3+1.5*RIC$ , donde RIC es el rango intercuartil. ....	33
<b>Figura 12.</b> Gráfico de cajas para MSE (A) y AD (B) con respecto al tamaño de ventanas, obtenido de InfoStat.....	33
<b>Figura 13.</b> Gráfico de cajas para PSNR con respecto al filtro de efecto granular, obtenido de InfoStat. Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de $Q_1-1.5*RIC$ y $Q_3+1.5*RIC$ , donde RIC es el rango intercuartil. ....	34
<b>Figura 14.</b> Gráfico de cajas para MSE (A) y AD (B) con respecto filtro de efecto granular, obtenido de InfoStat. Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de $Q_1-1.5*RIC$ y $Q_3+1.5*RIC$ , donde RIC es el rango intercuartil.....	34
<b>Figura 11.</b> Cálculo del índice NDWI en la zona de estudio. Las áreas blancas representan zonas con nubes que fueron descartadas.....	35
<b>Figura 12.</b> Índice NDWI (a) 70% de datos de entrenamiento, (b) 30% de datos para validación de resultados. Las áreas blancas representan zonas con nubes que fueron descartadas. ....	36
<b>Figura 13.</b> Histogramas de retrodispersión a partir de datos de entrenamiento para la banda VH (A) y VV (B) (calibración radiométrica Sigma 0, Filtro Lee Sigma y tamaño de ventana 5x5), obtenidos de SNAP.....	36
<b>Figura 14.</b> Mapa de inundación en zona de estudio mediante UC (calibración radiométrica Sigma 0, filtro Frost y tamaño de ventana 5x5).....	38
<b>Figura 15.</b> Comparación de polarización VH y VV en mapas de inundación (calibración radiométrica Sigma 0, filtro Frost y Boxcar y tamaño de ventana 5x5).....	39
<b>Figura 16.</b> Comparación de calibración radiométrica Sigma 0 y Gamma 0 en mapas de inundación (polarización VH, filtro Lee y tamaño de ventana 5x5).....	39

<b>Figura 17.</b> Comparación de calibración radiométrica Sigma 0 y Gamma 0 en mapas de inundación (polarización VH, filtro Boxcar y tamaño de ventana 5x5).....	40
<b>Figura 18.</b> Comparación de filtros de efecto granular y tamaño de ventana en mapas de inundación (polarización VH y calibración radiométrica Sigma 0). .....	40
<b>Figura 20.</b> Comparación de filtros de efecto granular y tamaño de ventana en mapas de inundación (polarización VH y calibración radiométrica Sigma 0). .....	43
<b>Figura 21.</b> Comparación de calibración radiométrica Sigma 0 y Gamma 0 en mapas de inundación (polarización VH, filtro Lee y tamaño de ventana 5x5).....	43
<b>Figura 22.</b> Comparación de tamaño de ventanas en filtros de ruido granular en mapas de inundación (polarización VV, filtro Lee Sigma y calibración sigma 0). .....	44
<b>Figura 23.</b> Comparación de polarización VH y VV en mapas de inundación (calibración radiométrica Sigma 0, filtro Frost y tamaño de ventana 5x5).....	45
<b>Figura 24.</b> Gráfico de cajas del índice kappa con respecto a la metodología de procesamiento y polarización, obtenido de InfoStat. Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de $Q_1-1.5*RIC$ y $Q_3+1.5*RIC$ , donde RIC es el rango inter-cuartil.....	46
<b>Figura 25.</b> Gráfico de cajas del índice kappa con respecto a la metodología de procesamiento y calibración radiométrica, obtenido de InfoStat. Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de $Q_1-1.5*RIC$ y $Q_3+1.5*RIC$ , donde RIC es el rango inter-cuartil.....	47
<b>Figura 26.</b> Gráfico de cajas del índice kappa con respecto al filtro de efecto granular y tamaño de ventana para la técnica UC, obtenido de InfoStat. Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de $Q_1-1.5*RIC$ y $Q_3+1.5*RIC$ , donde RIC es el rango inter-cuartil.....	47
<b>Figura 27.</b> Gráfico de cajas del índice kappa con respecto al filtro de efecto granular y tamaño de ventana para la técnica RF, obtenido de InfoStat. Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de $Q_1-1.5*RIC$ y $Q_3+1.5*RIC$ , donde RIC es el rango inter-cuartil.....	48
<b>Figura 28.</b> Gráfico de cajas de la medida F con respecto a la metodología de procesamiento y polarización, obtenido de InfoStat. Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de $Q_1-1.5*RIC$ y $Q_3+1.5*RIC$ , donde RIC es el rango inter-cuartil.....	52
<b>Figura 29.</b> Gráfico de cajas de la medida F con respecto a la metodología de procesamiento y calibración radiométrica, obtenido de InfoStat. Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de $Q_1-1.5*RIC$ y $Q_3+1.5*RIC$ , donde RIC es el rango inter-cuartil.....	53
<b>Figura 30.</b> Gráfico de cajas de la medida F con respecto al filtro de efecto granular y tamaño de ventana para la técnica UC, obtenido de InfoStat. Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de $Q_1-1.5*RIC$ y $Q_3+1.5*RIC$ , donde RIC es el rango inter-cuartil.....	53
<b>Figura 31.</b> Gráfico de cajas de la medida F con respecto al filtro de efecto granular y tamaño de ventana para la técnica RF, obtenido de InfoStat. Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de $Q_1-1.5*RIC$ y $Q_3+1.5*RIC$ , donde RIC es el rango inter-cuartil.....	54
<b>Figura 32.</b> Gráfico de cajas para exactitud del usuario (A) y exactitud del productor (B). Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de $Q_1-1.5*RIC$ y $Q_3+1.5*RIC$ , donde RIC es el rango inter-cuartil.....	57

## ÍNDICE DE TABLAS

<b>Tabla 1.</b> División de tareas por objetivos.....	5
<b>Tabla 2.</b> Bandas más utilizadas en SAR. Modificado de: Podest (2018b).....	8
<b>Tabla 3.</b> Ejemplo de matriz de confusión para validación de clasificación .....	16
<b>Tabla 4.</b> Características de imágenes SAR de Sentinel-1 a utilizar en el caso de estudio.....	21
<b>Tabla 5.</b> Características de imágenes satelitales de PlanetScope a utilizar en el caso de estudio .....	22
<b>Tabla 6.</b> Parámetros seleccionados en la clasificación supervisada con RF en SNAP.....	24
<b>Tabla 7.</b> Especificaciones de las series de datos de entrenamiento generadas de forma aleatoria .....	28
<b>Tabla 8.</b> Parámetros de rendimiento para las imágenes SAR después del evento de inundación con polarización VH .....	32
<b>Tabla 9.</b> Resultados de UC según su polarización y calibración radiométrica .....	37
<b>Tabla 10.</b> Área aproximada de inundación en la zona de estudio mediante técnica UC (calibración radiométrica Sigma 0).....	41
<b>Tabla 11.</b> Área aproximada de inundación en la zona de estudio mediante técnica RF (calibración radiométrica Sigma 0).....	45
<b>Tabla 12.</b> Resultado del análisis de varianza SC tipo III del índice kappa para UC.....	49
<b>Tabla 13.</b> Resultado de prueba Tukey del índice kappa para UC .....	49
<b>Tabla 14.</b> Resultado del análisis de varianza SC tipo III del índice kappa para RF .....	50
<b>Tabla 15.</b> Resultado de prueba Tukey del índice kappa para metodología RF.....	50
<b>Tabla 16.</b> Resultado del análisis de varianza SC tipo III del índice kappa para las metodologías de procesamiento UC y RF .....	51
<b>Tabla 17.</b> Resultado de prueba Tukey del índice kappa para ambas metodologías UC y RF .....	51
<b>Tabla 18.</b> Resumen de combinaciones más confiables para metodologías de procesamiento según el índice kappa .....	51
<b>Tabla 19.</b> Resumen de combinaciones menos confiables para metodologías de procesamiento según el índice kappa .....	52
<b>Tabla 20.</b> Resultado del análisis de varianza SC tipo III de la medida F para UC .....	54
<b>Tabla 21.</b> Resultado de prueba Tukey de medida F para UC .....	55
<b>Tabla 22.</b> Resultado del análisis de varianza SC tipo III de la medida F para RF.....	55
<b>Tabla 23.</b> Resultado de prueba Tukey de medida F para RF .....	56
<b>Tabla 24.</b> Resultado del análisis de varianza SC tipo III de la medida F para las metodologías de procesamiento UC y RF .....	56
<b>Tabla 25.</b> Resultado de prueba Tukey para ambas metodologías UC y RF.....	56
<b>Tabla 26.</b> Resumen de combinaciones más confiables para metodologías de procesamiento según la medida F .....	57
<b>Tabla 27.</b> Resumen de combinaciones menos confiables para metodologías de procesamiento según la medida F .....	58
<b>Tabla 28.</b> Resultado del análisis de varianza SC tipo III en la aleatoriedad de datos de entrenamiento del índice kappa .....	59
<b>Tabla 29.</b> Resultado de prueba Tukey en la aleatoriedad de datos de entrenamiento del índice kappa para la metodología de procesamiento .....	59
<b>Tabla 30.</b> Resultado del análisis de varianza SC tipo III en la aleatoriedad de datos de entrenamiento de la medida F .....	59
<b>Tabla 31.</b> Resultado de prueba Tukey en la aleatoriedad de datos de entrenamiento de la medida F para la metodología de procesamiento.....	59

## RESUMEN

Los eventos de inundación se caracterizan por provocar importantes pérdidas humanas y económicas alrededor del mundo. A nivel nacional, la margen derecha del río Tempisque en Guanacaste es seriamente impactada por inundaciones. Pueblos aledaños se han visto afectados por pérdidas de viviendas, bienes materiales, cultivos y muertes humanas. Esta zona es propensa a inundaciones, por lo que eventos como la tormenta tropical Nate provocan devastación en el sitio. Las entidades encargadas de la gestión del riesgo y emergencias en Costa Rica requieren de tecnología que permita analizar eventos climáticos que han repercutido gravemente en el país. La tecnología Radar de Apertura Sintética (SAR) es una forma de afrontar esta problemática.

El objetivo de este estudio fue evaluar dos clasificadores para la identificación de áreas inundadas mediante imágenes SAR de Sentinel-1 en la margen derecha del Río Tempisque, utilizando diferentes metodologías de preprocesamiento y procesamiento. Para esto se evaluó el clasificador Random Forrest (RF) y Umbrales de Calibración (UC) con 32 diferentes metodologías de preprocesamiento, variando filtro de speckle, tamaño de ventana del filtro, calibración radiométrica y polarización de las imágenes SAR con el software “*Sentinel Applications Platform*” (SNAP). Finalmente, se realizó un análisis estadístico que permitió determinar la confiabilidad de los resultados de cada clasificador y así definir cuáles fueron las mejores combinaciones de procesamientos para cada metodología, y cuál tuvo mejores resultados para la zona de estudio establecida.

Los filtros con tamaño de ventana 5x5 tuvieron mejor rendimiento en la eliminación del ruido granular, con valores de diferencia promedio; la relación señal-ruido pico y el error cuadrático medio más confiables que los filtros con tamaño de ventana 7x7. Este comportamiento se cumplió tanto para las imágenes procesadas con calibración Sigma 0 como con Gamma 0, así como con ambas polarizaciones utilizadas (VV y VH). Con la técnica de UC se detectó un total de 69,880 km<sup>2</sup> de área inundada, mientras con RF se detectó 73,768 km<sup>2</sup> de área; estos resultados para las metodologías de procesamiento con mejores índices de confiabilidad. Estas metodologías fueron con calibración Sigma 0, polarización VH y filtro de Frost 5x5 para UC y con Gamma 0, polarización VH y filtro de efecto granular Lee 5x5 para RF.

Se concluye mediante evaluación estadística que existen diferencias significativas para índice kappa y medida F entre las metodologías de clasificación utilizadas. RF presentó mejor índice kappa, mientras UC tuvo una mejor medida F. La metodología con mejor exactitud en la detección de áreas inundadas y la posibilidad de detectar las mismas áreas con una clasificación correcta fue con el clasificador RF; utilizando polarización VH, calibración radiométrica Sigma 0, filtro de efecto granular Lee con tamaño de ventana 5x5. La metodología con mejor rendimiento combinado de sensibilidad y especificidad fue con el clasificador UC; utilizando polarización VH, calibración radiométrica Gamma 0, filtro de efecto granular Frost con número de ventana 5x5. En este caso de estudio, la mejor polarización para detectar áreas inundadas fue VH. Así como la mejor calibración radiométrica fue con Sigma 0 y tamaño de ventana 5x5 y los mejores filtros fueron Boxcar, Lee Sigma y Lee. Dichos resultados son de gran utilidad para las entidades encargadas de la gestión del riesgo, ya que permiten crear y mejorar planes de emergencia durante inundaciones.

## 1. INTRODUCCIÓN

Las inundaciones forman parte de los desastres naturales más devastadores del mundo, y conforme pasan los años se vuelven más recurrentes (Manavalan, 2017). Estos eventos afectaron de manera directa las actividades cotidianas de miles de personas a nivel mundial; incluidos cientos de muertes, decenas de miles de viviendas dañadas o destruidas y cientos de miles de personas desplazadas en el 2021 (Valencia, 2022). Según indica Aon Benfield Corporation (2022) las pérdidas económicas relacionadas a desastres naturales fueron principalmente provocadas por inundaciones, ciclones tropicales y tormentas. Estos eventos representaron el 72% de las pérdidas económicas a nivel mundial (Aon Benfield Corporation, 2022). Cabe destacar que la pérdida de vidas humanas también toma un papel importante. En el año 2021, 250 habitantes de Europa Occidental y Central murieron a causa de inundaciones, y este mismo año, 545 personas fallecieron en China como consecuencia de inundaciones estacionales (Aon Benfield Corporation, 2022).

En Costa Rica, uno de los principales causantes de afectaciones a nivel social y económico corresponden a los eventos hidrometeorológicos (Retana, 2020). Durante el periodo de 1968 a 2020 se presentaron 8.721 eventos de inundación, los cuales repercutieron en 129 fallecimientos de personas, 56.122 viviendas afectadas, más de 3.000 casas completamente destruidas y más de 480,5 kilómetros de carreteras afectadas (Oficina de las Naciones Unidas para la Reducción del Riesgo de Desastres [UNDRR], 2020). El costo por daños y pérdidas ocasionados por eventos hidrometeorológicos en Costa Rica según la Contraloría General de la República será de 0,68% a 1,05% del PIB para el 2025; mientras que en un escenario de mayor riesgo estaría entre el 1,64% y el 2,50% del PIB, lo cual equivale a aproximadamente 57.000 millones de colones (Martínez Blanco et al., 2022).

Entre los eventos que han tenido mayor afectación económica en el país se destacan la tormenta tropical Nate y el huracán Otto (Núñez Chacón, 2017; Vallejos Vásquez et al., 2012). La tormenta tropical Nate afectó el 85% del territorio costarricense, con afectaciones severas en un 45% del país (Suárez et al., s/f). Esto provocó que mediante el Decreto Ejecutivo N°40677-MP se declararan 76 cantones en estado de emergencia, incluyendo Carrillo, Santa Cruz, Liberia y Nicoya (Comisión Nacional de Emergencias [CNE], 2018). El huracán Otto tuvo un efecto directo en poblados de la zona norte del país. Las precipitaciones en estas regiones provocaron deslizamientos y avalanchas. Los poblados de mayor afectación fueron Upala, Bagaces y Bijagua (Instituto Meteorológico Nacional [IMN], 2016).

Valencia (2022) recalca que, en los últimos decenios, el cambio climático ha causado la pérdida de cientos de vidas, graves daños a la producción agrícola y la infraestructura y el desplazamiento humano. Además, indican que conforme continúe el incremento de emisiones de gases de efecto invernadero a la atmósfera, aumentará la probabilidad de que se den eventos climáticos extremos. Dichos eventos afectarán diversas regiones en el mundo, incluyendo Latinoamérica (Valencia, 2022).

Una inundación corresponde a un cambio drástico en el nivel de un cuerpo de agua, sobrepasando el nivel habitual de dicho cuerpo (Grupo Intergubernamental de Expertos sobre el Cambio Climático [IPCC], 2014). A nivel nacional, Costa Rica presenta dos tipos de inundaciones: inundaciones de llanura e inundaciones de montaña o pie de montaña (Vallejos Vásquez et al., 2012). En las inundaciones de llanura, el nivel del agua sube paulatinamente y la población puede ser evacuada a tiempo. Por consiguiente, se tienen principalmente pérdidas económicas, ya sea por infraestructura o actividades agrícolas. Sin embargo, las inundaciones de montaña causan más pérdidas de vidas humanas. En estas, la intensidad de precipitación

suele ser más alta, lo cual genera deslizamientos y un aumento drástico del caudal en cuerpos de agua (Vallejos Vásquez et al., 2012).

A nivel local, pueblos como Filadelfia y La Guinea, en la margen derecha del río Tempisque en Guanacaste, son seriamente afectados por inundaciones. Estos eventos han repercutido en pérdidas de viviendas, bienes materiales, cultivos y han obligado a las comunidades a evacuar el área por su seguridad. Es importante mencionar que, cuando el río Tempisque se desborda, sucede lo mismo en los ríos Cañas, Las Palmas, Enmedio, Diría, Charco y Bolsón, lo cual afecta a los poblados aledaños (Pizarro & Marchena, 2008). De acuerdo con Pizarro & Marchena (2008), factores como la deforestación, la topografía del terreno, o el aumento de asentamientos urbanos, hacen que la zona sea más propensa a los eventos de inundación. Además, asegura que desde la época colonial se han dado desbordamientos de ríos durante la época lluviosa, razón por la cual los vecinos de la zona están acostumbrados a dichos eventos.

Al ser un área vulnerable a inundaciones por desbordamientos de ríos, eventos como la tormenta tropical Nate provocan devastación en la margen derecha del río Tempisque. Este evento inició el 3 de octubre del 2017 y tres días después la tormenta abandonó el país (Rodríguez, 2018). La tormenta causó la muerte de 14 personas; al mismo tiempo, generó daños y pérdidas económicas valoradas en más de 530 millones de dólares por infraestructura y actividades agrícolas a nivel nacional (CNE, 2018). A nivel local, el 93% de las viviendas del cantón de Corralillo fueron afectadas, por lo que más de 1.000 personas tuvieron que desplazarse a albergues (Rodríguez, 2018). Las pérdidas económicas en este cantón fueron de aproximadamente cinco millones de dólares (CNE, 2018).

La información anterior denota la importancia de implementar métodos tecnológicos que generen información relevante para afrontar eventos de inundación. El determinar la extensión y tiempo de permanencia de una inundación permite crear o mejorar planes de emergencia; además de evaluar los daños ocasionados por el evento. De este modo, los entes encargados de la gestión del riesgo y rescatistas pueden tomar las decisiones pertinentes según los datos proporcionados (Kussul et al., 2011). La tecnología de radar de apertura sintética (SAR) se ha empleado para mapear áreas de inundación en diferentes partes del mundo como Europa, Asia y América (Manavalan, 2017).

La tecnología SAR para el mapeo de inundaciones funciona mediante un sensor de imágenes de observación de la tierra que opera las 24 horas del día. Además, permite obtener información crítica de áreas con condiciones climáticas adversas, por ejemplo, bajo nubosidad. Este tipo de radares emiten un haz de microondas que se refleja en la superficie terrestre y que permite interpretar los datos de una superficie de interés. Por esta razón pueden captar imágenes a diferentes ángulos, extensiones, resoluciones, orientaciones, polarizaciones, entre otros parámetros controlables (Belmonte & Caamaño, 2009). La tecnología SAR permite realizar análisis sencillos y en poco tiempo, con alta precisión a pesar de las diferentes topografías (Scarpino et al., 2018). Por esto, la información obtenida de imágenes SAR es una importante herramienta durante inundaciones, pues un correcto procesamiento permite obtener información de gran utilidad.

Las imágenes SAR de libre acceso pueden ser descargadas mediante distintas plataformas de datos, como por ejemplo “Alaska Satellite Facility” (ASF). Esto para obtener información precisa sobre las condiciones de saturación del suelo de un área de interés sin importar su topografía, condiciones climatológicas o el momento del día (Avedaño et al., 2014). Uno de los radares con información de libre acceso a considerar es el Sentinel-1, el cual pertenece a los satélites de la Agencia Espacial Europea (ESA) y captura imágenes de la tierra cada seis días (ASF, 2021). Este satélite tiene una resolución espacial de hasta cinco metros y un ancho

de banda de hasta 400 kilómetros; además, permite el acceso al 90% de la superficie del mundo (Torres et al., 2012).

Los datos resultantes del análisis de imágenes SAR dependerán de los satélites que se encuentren en la zona de interés y de sus órbitas, las cuales determinan la disponibilidad de las imágenes en el tiempo (National Aeronautics Space Administration [NASA], 2018). También dependerán del tratamiento previo y de las metodologías o algoritmos empleados para la determinación de áreas inundadas. Por esto es importante para entidades como la CNE, la disponibilidad de una metodología que permita generar información de utilidad sobre eventos hidrometeorológicos como inundaciones. Esto permitirá realizar análisis de eventos climáticos que han generado inundaciones alrededor del país, de modo que sea posible planificar y aumentar la eficiencia de los planes de emergencia.

En Costa Rica, se han dispuesto recursos del gobierno para cubrir los daños generados durante eventos de emergencia hidrometeorológicos, mediante asistencia, rehabilitación y reconstrucción (Salgado, 2009). Aun así, el país requiere de tecnología que permita analizar eventos climáticos que han repercutido seriamente en pérdidas humanas y económicas e implementarlos en el manejo de emergencias.

Para interpretar de forma inmediata los datos que brindan las imágenes SAR, es necesario contar con una metodología de preprocesamiento y procesamiento de estas. El software de Sentinel Applications Platform (SNAP), tiene a disposición diferentes algoritmos de clasificación basados en píxeles, que se utilizan para el mapeo y clasificación de imágenes SAR (Clemente et al., 2020). Por lo tanto, al evaluar diferentes metodologías ya existentes de preprocesamiento y procesamiento de imágenes SAR, es posible definir un procedimiento que mejor se adapte a las condiciones del área de estudio y que las autoridades nacionales puedan implementar en su control de emergencias.

Para esta investigación se pretende realizar una comparación de metodologías para la determinación de áreas inundables en la llanura del Río Tempisque, aplicando diferentes preprocesamientos y procesamientos para el análisis de datos. Lo anterior permitirá determinar qué metodología presenta resultados más confiables para la identificación de inundaciones en la zona de estudio, considerando como evento hidrometeorológico la tormenta tropical Nate.

### **1.1. Objetivos**

El objetivo general de este trabajo es evaluar dos clasificadores para la identificación de áreas inundables mediante imágenes de Radar de Apertura Sintética en la planicie inundable de la margen derecha del Río Tempisque de Costa Rica, utilizando diferentes metodologías de procesamiento.

Los objetivos específicos son:

1. Evaluar 16 metodologías de preprocesamiento de imágenes SAR de Sentinel-1 de la planicie inundable del Río Tempisque posterior a la tormenta tropical Nate, para la detección de áreas inundadas.
2. Identificar áreas inundadas en la planicie inundable del Río Tempisque posterior a la tormenta tropical Nate con las imágenes preprocesadas de Sentinel-1, utilizando dos clasificadores diferentes; Random Forest y Umbrales de Calibración.
3. Comparar la confiabilidad de las metodologías aplicadas mediante evaluación estadística para la validación de su uso en la zona de estudio.

La división de tareas por objetivos se muestra en la Tabla 1.

**Tabla 1.** División de tareas por objetivos

<b>Objetivos Específicos</b>	<b>Tareas</b>	
	<b>Angie Jiménez</b>	<b>María José Guerrero</b>
1	Preprocesar las imágenes antes y después del evento en SNAP, para un resultado de 16 escenarios por imagen.	Preprocesar las imágenes antes y después del evento en SNAP, para un resultado de 16 escenarios por imagen.
2	Procesar las imágenes en SNAP mediante el clasificador Random Forest.	Procesar las imágenes en SNAP mediante el clasificador Umbrales de Calibración.
3	Comparar la confiabilidad de las metodologías mediante índices de precisión.	Comparar la confiabilidad de las metodologías mediante índices de precisión.
Justificación del proyecto de graduación en conjunto	Comparar la confiabilidad de las metodologías y determinar cuál filtro y cuál clasificador tuvo mejor desempeño según las metodologías utilizadas.	

## 2. MARCO TEÓRICO

### 2.1. Eventos meteorológicos extremos: Inundaciones

El término de inundación se define por el IPCC (2014, p.130) como el “desbordamiento por encima de los confines normales de un arroyo u otro cuerpo de agua, o la acumulación de agua por encima de zonas que normalmente no están sumergidas”. Según la CNE (s/f), estas son causadas por precipitaciones intensas y prolongadas, las cuales pueden estar relacionadas a fenómenos atmosféricos como huracanes o tormentas tropicales.

Las inundaciones pueden promoverse por fenómenos antrópicos como el cambio de uso del suelo, alteración por construcción de infraestructura hidráulica, contaminación de ríos y extracción de materia prima de estos. En Costa Rica, estas corresponden al fenómeno natural que mayor número de emergencias genera anualmente, y la mayoría de las zonas del territorio nacional son vulnerables a sus efectos (CNE, s/f).

Las inundaciones se pueden clasificar como lentas o repentinas. Las primeras se asocian con desbordamiento lento de cuerpos de agua debido a precipitaciones de baja intensidad, pero sostenidas en el tiempo. Las súbitas o repentinas son debidas a maremotos, mareas y fenómenos de tormenta de alta intensidad y corta duración intensificadas por los vientos (CNE, s/f).

Controlar las consecuencias de las inundaciones resulta complicado debido al arrastre de sedimentos y objetos, que pueden causar desastres en las zonas urbanas o productivas (Felipe Arreguín et al., 2016). El lapso que tarde el suelo inundado, conocido como tiempo de

permanencia, también genera consecuencias socioeconómicas importantes. Este dependerá del tipo de inundación, evento hidrometeorológico y características del suelo. Un largo tiempo de permanencia, afecta negativamente la productividad agrícola de la zona (Otondo et al., s/f) y puede generar inestabilidad y debilitamiento de la infraestructura vial y urbana (Banco Internacional de Reconstrucción y Fomento, 2016).

### *2.1.1. Tormenta tropical Nate*

De los desastres naturales que ha experimentado el país en las últimas décadas, la tormenta tropical Nate se destaca como uno de los eventos de mayor afectación, la cual generó importantes pérdidas económicas en infraestructura (Núñez Chacón, 2017). Este fenómeno inició como depresión tropical en el mar Caribe el 4 de octubre del 2017 (Mora Ramírez & Rodríguez Muñoz, 2018). En el mismo día, el gobierno de la república decretó alerta roja en tres cuartas partes del país (Núñez Chacón, 2017). Al día siguiente, el IMN declaró el evento como tormenta tropical y el 6 de octubre del 2017 la tormenta continuó su trayectoria alejándose del territorio nacional. Los efectos indirectos de este evento ocasionaron: precipitaciones, de hasta 550 mm en un lapso de 24 horas; fuertes ráfagas de vientos, de 63 a 118 km/h; y fuertes oleajes en el país. Todos estos repercutieron en inundaciones, deslizamientos, pérdidas de bienes materiales y viviendas, daños y pérdidas totales de obras públicas, pérdidas agrícolas y muerte de animales y humanos (Mora Ramírez & Rodríguez Muñoz, 2018).

La tormenta tropical Nate provocó daños y pérdidas económicas en 76 cantones del país, sin embargo, las afectaciones de mayor peso se dieron en 38 cantones y 642 poblados (CNE, 2018; Vallejos Vásquez & Fonseca Bonilla, 2017). Las comunidades de mayor afectación por el evento se ubican en Guanacaste, en la zona sur y central sur. Destacándose poblados como Acosta, Aserrí, Dota, Filadelfia, Abangares, Carrillo, Tilarán, Bagaces, Cañas, Turrialba, zonas de Cartago y Puntarenas (Núñez Chacón, 2017). Muchos de los habitantes de comunidades afectadas se vieron obligados a trasladarse a refugios establecidos por los comités municipales. Servicios básicos como abastecimiento de agua potable, electricidad y telecomunicaciones fueron suspendidos debido a los daños de infraestructura ocasionados por el evento (Mora Ramírez & Rodríguez Muñoz, 2018).

## **2.2. Información de la zona de estudio**

El área analizada para el caso de estudio corresponde a la planicie inundable de la margen derecha del Río Tempisque, en Guanacaste, Costa Rica. Guanacaste corresponde a la provincia número siete de Costa Rica, se extiende por 10.140,71 kilómetros cuadrados, conteniendo una población de aproximadamente 400.000 habitantes (PROCOMER Costa Rica, 2020).

Guanacaste se caracteriza por tener dos estaciones climáticas muy bien definidas. Esta provincia es susceptible a sufrir los efectos del fenómeno El Niño Oscilación del Sur (ENOS); el cual causa tanto periodos de sequía como aumento en la intensidad de precipitación (Espinoza Rivera, 2018).

Una de las cuencas de mayor importancia de la provincia es la del Río Tempisque. En esta se han presentado destructivas inundaciones, como en 1998 debido al huracán Mitch y en el 2017 por la tormenta Nate; principalmente en las comunidades de La Guinea y Corralillo (Espinoza Rivera, 2018).

El uso de suelo en los márgenes del río Tempisque ha cambiado de manera acelerada. Esto debido principalmente a la intensificación de la ganadería y agricultura comercial, así como a la sobreexplotación maderera, lo cual ha deteriorado la cuenca después de 1950 (Salgado, 2009). Este cambio en las condiciones del suelo y el aumento pronosticado de intensidad de lluvias y tormentas debido al cambio climático en la zona (Alvarado et al., 2012), promueven inundaciones que afectan actividades productivas y áreas urbanas.

La zona por estudiar tiene un área aproximada de 463 kilómetros cuadrados. Esta contiene centros poblacionales como Palmira, Filadelfia y Belén con una población total de 18.846 habitantes (Municipalidad de Carrillo, 2020). También se encuentra el poblado Talolinga del cantón de Nicoya con una población aproximada de 4.017 personas (Núñez Arias & Marín Hernández, 2015). Así como zonas de actividades agrícolas de importancia para el país, tales como la siembra de caña de azúcar, arroz y melón (Espinoza Rivera, 2018). Estas zonas fueron declaradas como zonas en estado de emergencia por el evento por la CNE (Comisión Nacional de Emergencias [CNE], 2018).

### **2.3. Aplicación de teledetección para el análisis de inundaciones**

#### *2.3.1. Fundamentos teóricos sobre la aplicación de SAR en inundaciones*

La teledetección es la técnica que emplea sensores aéreos o colocados en plataformas espaciales, que permite obtener y darle tratamiento a datos que describen la superficie terrestre (Chuvienco, 1995). Este proceso se da por la interacción electromagnética entre la tierra y el sensor disponible. Una de las formas de clasificar los sensores es según su fuente de energía: a) sensores pasivos, los cuales reciben energía de una fuente externa como por ejemplo el sol; b) sensores activos, que tienen la facilidad de generar su propio haz de energía (Chuvienco, 1995; NASA, 2018).

Dentro de los sensores activos se encuentra SAR. La tecnología SAR funciona mediante pulsos electromagnéticos que se envían a la tierra desde el satélite. Estos pulsos son reflejados por la superficie y retornan al sensor, generando imágenes digitales del área que ilumina (Gimeno Martínez, 2019). Según indica Bhagat (2017), los resultados de las imágenes SAR van a depender de: a) las características del radar, como su longitud de onda, polarización y el ángulo de incidencia y b) las características de la superficie de interés, como constante dieléctrica, grado de aspereza y distribución de objetos sobre el área de estudio. Los radares emiten señales hacia la superficie terrestre en forma de microondas, con longitudes desde 0,3 cm a 300 cm, razón por la cual es posible generar información aún en condiciones nubosas. Las señales son retrodispersadas por la superficie y redirigidas hacia el radar.

La longitud de onda es proporcional a la capacidad de atravesar la cubierta vegetal de la superficie y según la longitud de onda se identifica una banda (Mata Muñoz, 2019). En la Tabla 2 se muestran las bandas más utilizadas (X, C, S y L) y ejemplos de aplicación según su capacidad de captar información. Por lo tanto, si un sensor posee una banda X, tendrá una menor penetración a través del medio que una banda S o L (Mata Muñoz, 2019). Esto debe ser considerado al analizar inundaciones, ya que, si la zona presenta vegetación, se recomienda emplear una banda que garantice una mayor penetración en el medio para así localizar las áreas inundadas. Mata Muñoz (2019) y Borah et al. (2018) realizaron un mapeo de inundaciones en España y la India respectivamente, para esto emplearon SENTINEL-1, el cual opera con una banda C. Por otra parte, Manavalan (2017) utilizó la banda L para el mapeo de inundaciones, lo cual permitió identificar más regiones inundadas que SAR de banda C o X. Sin embargo, la

decisión va a depender de la disponibilidad de imágenes SAR en el área de interés y la banda con que opere el radar.

**Tabla 2.** Bandas más utilizadas en SAR. Modificado de: Podest (2018b)

Designación	Longitud de onda (cm)	Frecuencia (GHz)	Ejemplo de aplicación	Capacidad de penetración
X	2,4 - 3,8	12,5 - 8	Meteorología, agricultura, uso militar	Superficie de vegetación
C	3,8 - 7,5	8 - 4	Estudio del océano, agricultura, cambios en superficie de la tierra	Vegetación, aluviión seco
L	15 - 30	2 - 1	Agricultura, silvicultura, humedad del suelo	Vegetación, suelo, nieve

De acuerdo con Mata Muñoz (2019), la polarización se define como “la dirección de propagación de la onda perpendicular a la dirección del campo eléctrico”. Esta se clasifica como HH (transmitida horizontalmente, recibida horizontalmente), HV (transmitida horizontalmente, recibida verticalmente), VH (transmitida verticalmente, recibida horizontalmente) y VV (transmitida verticalmente, recibida verticalmente). Usualmente las configuraciones HV y VH tienen una menor penetración en la superficie que HH y VV (Podest, 2018b). Por lo tanto, para superficies de vegetación inundada se recomienda la polarización HH o VV y para detectar agua abierta se recomienda HV o VH (Podest, 2019). El ángulo de incidencia se forma entre la vertical de la superficie de interés y la dirección en la que el radar emite el pulso. Conforme menor sea el ángulo de incidencia, mayor será la señal devuelta al sensor (Mata Muñoz, 2019).

Con respecto a las características de la superficie de estudio, la constante dieléctrica va a definir la reflectancia y conductividad, conforme mayor sea este valor, mayor será la reflectancia del área. Por lo tanto, la capacidad de las ondas en atravesar una superficie seca es mayor a una húmeda (Bhagat, 2017). Los mecanismos de retrodispersión que se asocian a los eventos de inundación corresponden a dispersión especular y por doble rebote. El primer mecanismo es usual en superficies planas con baja rugosidad, cuando la onda llega a la superficie, se refleja en dirección opuesta al radar (Mata Muñoz, 2019), produciendo un pixel de color gris oscuro (Podest, 2018b). El segundo mecanismo es común en áreas inundadas donde se encuentran árboles y vegetación de ribera, donde la onda rebota en el agua, choca con la vegetación y es devuelta en su mayoría al sensor (Mata Muñoz, 2019). En este caso el color del pixel es blanco (Podest, 2018b).

### 2.3.2. Características SENTINEL-1

La misión SENTINEL-1 forma parte del programa Copernicus a cargo de la ESA y la Comisión Europea. Copernicus es una iniciativa europea que tiene como fin ofrecer servicios de información sobre la superficie terrestre y medio ambiente para la gestión de riesgo. Sentinel-1 está conformado por dos satélites en órbita polar (Sentinel-1A y Sentinel-1B), los cuales operan de día y noche (ESA, s/f). Sentinel-1 genera imágenes de toda la superficie terrestre y

su ciclo de repetición orbital es de seis días. El sensor del radar opera en la banda C, por lo que las condiciones climáticas no son restrictivas, además, emite una señal con frecuencia de 5,4 GHz (ESA, s/f; Mata Muñoz, 2019). Las imágenes presentan polarización VV, VH, HH y HV. La resolución espacial es de 5 metros y su cobertura de hasta 400 kilómetros (Torres et al., 2012). De acuerdo con Mata Muñoz (2019) “el ángulo de incidencia va a depender de la distancia a la que se encuentre el sensor con respecto a la superficie y también de la geometría de la superficie”. Por lo tanto, el ángulo de incidencia no es un valor fijo, va a variar según la forma de la superficie de estudio. El sensor se encuentra aproximadamente a 693 kilómetros de la superficie terrestre (ESA, s/f).

### *2.3.3. Preprocesamiento de imágenes SAR*

Es necesario que las imágenes SAR sean calibradas y la información que contienen preprocesada (Bioresita, 2019), según las características y el tipo de análisis que se desee realizar a estas. Dentro de los preprocesamientos que se deben realizar a las imágenes SAR para analizar inundaciones están: la aplicación del archivo de órbita, reducción de ruido térmico, corrección de artefactos radiométricos en bordes de la imagen, calibración radiométrica, reducción de ruido, aplanamiento radiométrico del terreno y la calibración geométrica o topográfica (Manakos et al., 2020). Para realizar el preprocesamiento se dispone de diferentes filtros y herramientas en softwares para el preprocesamiento de imágenes SAR. La ESA desarrolló el software libre SNAP, el cual está equipado para preprocesar las imágenes y analizarlas profundamente de manera precisa (Mata Muñoz, 2019).

#### *2.3.3.1. Aplicación del archivo de órbita*

La aplicación del archivo de órbita se ejecuta debido a que los vectores de estado de órbita proporcionados en un producto SAR usualmente no son precisos. No obstante, se pueden refinar con los archivos de órbita precisos que están disponibles días o semanas después de la generación de la imagen SAR en un software de preprocesamiento. Con base en esta información, se actualizan los vectores de estado de órbita en los metadatos del producto (The Sentinel Application Platform [SNAP], 2022c).

#### *2.3.3.2. Reducción de ruido térmico*

El ruido térmico corresponde a una energía aditiva de fondo que provoca ruido de fondo en la imagen SAR (Park et al., 2018). La intensidad de la imagen de Sentinel-1 se ve perturbada por dos fuentes de ruido térmico. La primera está relacionada con el patrón de la antena y varía en dirección del alcance. El segundo se conoce como ruido festonado, el cual varía a lo largo de la dirección del azimut (Filipponi, 2019). La eliminación de ruido térmico reduce los efectos de ruido en la textura entre sub-franjas, normalizando la señal de retrodispersión dentro de toda la imagen y dando como resultado discontinuidades reducidas entre sub-franjas para escenas en modos de adquisición de múltiples franjas (Filipponi, 2019).

#### *2.3.3.3. Corrección de artefactos radiométricos en el borde de la imagen*

Es necesario corregir la hora de inicio del muestreo para compensar el cambio de la curvatura de la tierra. Al mismo tiempo, la compresión del azimut y del rango genera artefactos radiométricos en los bordes de la imagen. El algoritmo de eliminación de ruido de borde, disponible como herramienta en SNAP, se diseñó para eliminar el ruido de baja intensidad y los datos no válidos en los bordes de la escena (Filipponi, 2019).

#### 2.3.3.4. Calibración radiométrica

La calibración radiométrica consiste en generar una imagen en la que cada pixel esté relacionado con la retrodispersión de la escena, lo cual será fundamental en el análisis cuantitativo de los resultados (Podest, 2018a). El ángulo de incidencia, la pérdida de señal al propagarse y el patrón no uniforme de radiación de la antena puede afectar el valor de retrodispersión, por lo que se realiza la calibración radiométrica para disminuir esta influencia (Bioresita, 2019; Podest, 2018a). Además, esta corrección se necesita para comparar las imágenes de SAR adquiridas de sensores distintos, o adquiridas por el mismo sensor en diferentes horas o tratadas por procesadores distintos (Environmental Systems Research Institute [ESRI], 2022).

Entre las calibraciones radiométricas a considerar en el software SNAP se incluye sigma 0 y gamma 0. De acuerdo con ESRI (2022), “sigma 0 es la retrodispersión devuelta a la antena desde una unidad de área del terreno, se calibra según el ángulo de incidencia. Como las imágenes están calibradas, se pueden comparar directamente con distintas imágenes de radar capturadas por el mismo sensor o por otro”. Es por esto que muchos investigadores emplean este tipo de calibración para interpretar los valores de dispersión y analizar las propiedades de la superficie de estudio. En una calibración radiométrica sigma 0 se minimiza el impacto topográfico (ESRI, 2022).

Por otra parte, ESRI (2022) indica que “gamma 0 se utiliza para calibrar la antena, como cada celda del rango es equidistante del satélite, el rango cercano y el rango lejano son igual de brillantes, lo cual resulta útil a la hora de determinar el patrón de la antena en set de datos de salida”. Se calibra según el ángulo de incidencia local. Este proceso de calibración se basa en la relación de energía que es transmitida y recibida por el sensor, lo cual tendrá un efecto directo en el brillo de los píxeles (Jahren Petersen, 2022). Ambas calibraciones se diferencian por la intensidad máxima del brillo en las imágenes, siendo la de gamma 0 mayor a sigma 0. Si el terreno de estudio es plano, no habrá diferencia entre las calibraciones radiométricas sigma 0 y gamma 0; sin embargo, si hay topografía gamma 0 será una mejor opción, ya que hay una mayor señal devuelta al sensor (ESRI, 2022).

#### 2.3.3.5. Reducción de ruido granular

El ruido o el efecto de sal y pimienta es característico de las imágenes SAR. Esto distorsiona la información del terreno y hace que se pierda la calidad de la imagen. Las metodologías de reducción de ruido consisten en suavizar la imagen y los límites de las distintas formas representadas mediante la interpolación, evitando la pérdida de detalles de esta (Mata Muñoz, 2019).

Dentro de las técnicas para corregir el efecto sal y pimienta, se encuentran filtros que mueven una ventana sobre cada píxel, aplicando una fórmula matemática que sustituye el valor del píxel central de la ventana, un pixel a la vez a lo largo de la imagen SAR (Santoso et al., 2015). La aplicación de estas técnicas de reducción de ruido puede generar pérdida de detalle y forma de las texturas dentro de la imagen, generando errores en el procesamiento y análisis de estas. La eficiencia en la corrección de este efecto en las imágenes SAR se basa en eliminar el ruido en un área uniforme, preservando la textura de los bordes y generando buena apariencia visual sin cambiar las características (Santoso et al., 2015).

En aplicaciones de detección de inundaciones se han utilizado técnicas de preprocesamiento como el filtro Refined Lee (M. Zhang et al., 2020; Borah et al., 2018; Dhara et al., 2020), Lee (Mata Muñoz, 2019), Boxcar (W. Zhang et al., 2020) y Frost por Bioresita (2019) y Tavus et al.

(2020). Estas técnicas disminuyen el efecto de sal y pimienta y mejoran la relación señal-ruido. Sin embargo, es importante determinar cómo afecta el desempeño de los filtros de ruido a la detección de inundaciones. Santos et al. (2015) evaluaron con diferentes parámetros el desempeño de filtros para reducción de ruido, obteniendo que el mejor filtro es el que elimina el efecto de sal y pimienta, presenta bordes nítidos y preserva la textura.

Para llevar a cabo la reducción del ruido se deberá establecer el tamaño de ventana para filtrar los píxeles de la imagen. Se tendrá un menor efecto del filtro al trabajar con un tamaño de ventana más pequeño y se obtendrá una imagen más suavizada, pero con mayor distorsión y pérdida de resolución al emplear un tamaño de ventana más grande (ESRI, 2022).

### 2.3.3.5.1. Evaluación cuantitativa de la reducción de ruido granular

Algunos de los parámetros empleados para evaluar el desempeño de los filtros de reducción del ruido granular son: el error cuadrático medio (MSE), la relación señal-ruido pico (PSNR) y la diferencia promedio (AD) (Santos et al., 2015). Estos parámetros tienen como objetivo medir la eficiencia y la capacidad de los algoritmos del filtro de reducción de ruido para mejorar la información de la imagen (J. Sen Lee et al., 2015).

El MSE se utiliza para encontrar las diferencias entre la imagen original y la imagen sin ruido. El valor MSE determina el error cuadrático acumulativo entre la imagen original y filtrada. Este parámetro se calcula mediante la Ecuación 1 (Santos et al., 2015).

$$MSE = \frac{1}{MN} \sum_{j=1}^M \sum_{k=1}^N (X_{j,k} - X'_{j,k})^2 \quad (1)$$

Donde  $M$  – número de filas de la imagen ráster;  $N$  – número de columnas de la imagen ráster;  $X$  – imagen original; y  $X'$  – imagen con filtro.

Mientras más alto sea el valor de MSE implica que la imagen original y la filtrada tienden a ser cada vez más diferentes. El valor MSE más bajo es cero, y esto significa que la imagen original y la filtrada son completamente idénticas (Santos et al., 2015).

El PSNR es una relación entre la máxima potencia posible de la señal y la imagen con ruido. Es una medida del rendimiento de la reducción del ruido moteado. El PSNR se calcula a partir de la Ecuación 2 (Santos et al., 2015).

$$PSNR = 10 \log_{10} \left( \frac{(2^n - 1)^2}{MSE} \right) = 10 \log_{10} \left( \frac{255^2}{MSE} \right) \quad (2)$$

Donde  $MSE$  – error cuadrático medio.

Conforme mayor sea el valor del PSNR, mejor será la calidad de la imagen. Se producen imágenes idénticas cuando el valor de MSE es cero, el valor de PSNR se indefine (Santos et al., 2015).

Finalmente, AD es la diferencia media entre la imagen original y la filtrada dividida por el tamaño de la imagen. Se calcula mediante la Ecuación 3 (Santos et al., 2015).

$$AD = \frac{1}{MN} \sum_{j=1}^M \sum_{k=1}^N |X_{j,k} - X'_{j,k}| \quad (3)$$

Donde  $M$  – número de filas de la imagen ráster;  $N$  – número de columnas de la imagen ráster;  $X$  – imagen original; y  $X'$  – imagen con filtro.

Su valor máximo corresponde a imágenes diferentes y su valor mínimo corresponde a imágenes similares (Santoso et al., 2015).

#### 2.3.3.6. Corrección geométrica

La corrección geométrica se emplea para corregir distorsiones geométricas causadas por el rango oblicuo, la inversión del relieve, las sombras y el desplazamiento en contra del nadir. Esto con el fin de que la representación geométrica de la imagen se asemeje a las condiciones reales del terreno (Fernández-Ordoñez et al., 2020). Dicha corrección emplea un modelo de elevación digital (DEM) para corregir la ubicación de cada píxel, para esto implementa un método de ortorrectificación que geocodifica escenas SAR a partir de imágenes en geometría de radar. Además, hace uso de la información de vector de estado de órbita disponible en los metadatos, las anotaciones de tiempo de radar y los parámetros de conversión de rango de inclinación a tierra junto con los datos del DEM de referencia para derivar la información de geolocalización precisa (SNAP, 2022b).

#### 2.3.4. Procesamiento de imágenes SAR para detección de inundaciones

Para el procesamiento de los resultados se utilizan los sistemas de información geográfica (SIG) (Borah et al., 2018). Estos son herramientas que pueden manipular datos obtenidos de imágenes espaciales (Pradhan et al., 2009), y permiten mapear y georreferenciar la información obtenida del análisis previo. Se pueden encontrar tanto de acceso libre, por ejemplo, QGIS, así como software de licencia comercial como ArcGIS.

El programa SNAP dispone de un repertorio de herramientas denominado “Sentinel Toolboxes”, el cual se emplea para preprocesar y procesar imágenes SAR, esto permite darles un tratamiento completo a las imágenes y posteriormente analizar los resultados obtenidos. Además, SNAP cuenta con funciones para generar análisis multitemporales de imágenes SAR (Selmi, 2021).

El proceso para depurar y analizar imágenes SAR requiere de experiencia y entrenamiento en la interpretación de la información que contienen (Tavus et al., 2020), por esto, en la práctica se han desarrollado metodologías que lo facilitan. Dentro de las metodologías a considerar en el presente proyecto se encuentran: clasificador Random Forest (RF) y técnica de Umbrales de Calibración (UC).

##### 2.3.4.1. Clasificador Random Forest

En teledetección para la identificación de áreas inundadas se han aplicado diferentes técnicas de clasificación supervisada. Esta técnica de clasificación identifica la clase a la que pertenece cada píxel de la imagen, utilizando datos previamente identificados como muestras para encontrar datos no identificados (Avedaño et al., 2014). En este tipo de metodologías el conjunto de datos previamente identificados se conoce como datos de entrenamiento, los cuales son indispensables para el apropiado rendimiento de la clasificación. La fiabilidad de estas muestras de entrenamiento determina en gran medida la precisión de los enfoques basados en la clasificación supervisada (Kordelas et al., 2018).

Uno de los clasificadores más comunes en estos tratamientos es RF o Bosque Aleatorio. Este clasificador se basa en árboles estadísticos de predicción, los cuales consisten en algoritmos estadísticos o técnicas de aprendizaje automático que construyen modelos predictivos que

clasifican datos según las características o propiedades deseadas por el usuario (Universidad Internacional de la Rioja, 2021).

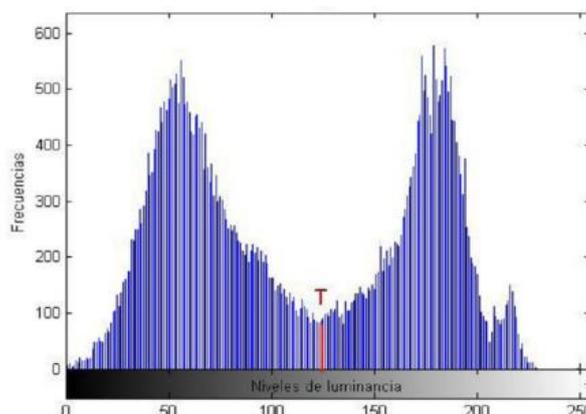
RF utiliza varios árboles de predicción, donde cada árbol sigue un enfoque diferente para la clasificación. Cada árbol clasifica los datos con sus criterios individuales, y a partir de los resultados de todos los enfoques se clasifica la imagen asignando el píxel a la clase con la máxima posibilidad (Gupta et al., 2015). Los resultados representan la aplicación estadística de muchos árboles de decisión, resultando en un modelo más preciso que el basado únicamente en un árbol de decisión (Tavus et al., 2020).

Tavus et al. (2020) utilizaron una metodología basada en el clasificador RF, donde se detectaron zonas de inundación en la ciudad Ordu de Turquía con imágenes de Sentinel-1 y Sentinel-2. Con la metodología empleada, los autores encontraron que las áreas urbanas y de suelo desnudo no podían separarse efectivamente sin el uso de imágenes ópticas, así como las áreas forestales y agrícolas. Aun así, se concluyó que las áreas inundadas se pueden mapear con el método propuesto mediante la herramienta SNAP (Tavus et al., 2020). Manakos et al. (2020) también realizaron un análisis de áreas inundación mediante Sentinel-1 y Sentinel-2, donde aplicaron una clasificación RF centrada en píxeles, la cual tuvo mejores resultados que las clasificaciones realizadas centradas en áreas mediante valores de retrodispersión.

#### 2.3.4.2. Técnica de Umbrales de Calibración

La técnica de UC o también conocida como umbralización, tiene como objetivo binarizar una imagen digital a partir de un valor de umbral, separando así el fondo y el objeto a separar (Cattaneo et al., 2011). La binarización de una imagen consiste en reducir la información de esta, de modo que solo queden dos valores, verdadero y falso. Para la identificación de zonas inundadas dichos valores corresponden a áreas inundadas y no inundadas (Guruprasad et al., 2020).

La técnica UC considerada en la presente investigación se basa en la información estadística que proporciona un histograma. Se debe definir un valor T (umbral) que permita una adecuada separación entre el fondo y el objeto. Por ejemplo, si un histograma presenta dos picos, tal como se muestra en la Figura 1, es posible separar dos regiones, por lo que el valor T corresponde al valor que se encuentra en el valle en medio de los picos, o bien, el menor valor de la frecuencia en el valle (Cattaneo et al., 2011). Sin embargo, este es un escenario ideal, usualmente las imágenes presentan histogramas sin una marcada separación y esto se debe a los cambios en la iluminación de la imagen (Cattaneo et al., 2011).



**Figura 1.** Ejemplo de técnica de UC (Cattaneo et al., 2011).

De acuerdo con Mata Muñoz (2019), este es un proceso de fácil ejecución que distingue las zonas inundadas de las que no lo están. Como ya se ha mencionado, los valores de retrodispersión de zonas inundadas permiten establecer diferencias entre otros fenómenos físicos, razón por la cual se puede establecer parámetros limitantes (Bioresita, 2019). Para establecer manualmente el umbral entre zonas inundadas se emplea el histograma característico de polarización, el cual brinda información de los píxeles de una imagen según los valores de retrodispersión. El software SNAP permite generar una nueva imagen bicolor que separa ambas zonas mediante una ecuación matemática (Aldhshan et al., 2019). Ahora bien, Mata Muñoz (2019) recomienda crear una capa en la que se ingresen polígonos en diferentes partes del área inundada para generar un histograma de dichos datos de retrodispersión y obtener un valor de umbral más preciso.

Mata Muñoz (2019), realizó un mapeo de inundaciones siguiendo la metodología de UC a partir de imágenes SAR de Sentinel-1 y la herramienta SNAP. Para esto requirió imágenes previas y posteriores al evento. Además, las imágenes presentaron polarización VV y VH. La polarización VH mostró resultados más favorables, esto debido a que generó superficies de inundación más amplias y se confirmó la idoneidad de las imágenes SAR para el mapeo de inundaciones. Por otra parte, B. Zhang et al. (2018) realizaron un mapeo de inundaciones durante un huracán en Florida siguiendo la técnica de UC. Emplearon imágenes SAR de Sentinel-1 antes, durante y después del huracán, lo cual permitió limitar la firma de retrodispersión de fondo. Los resultados mostraron efectivamente que la parte sur de Florida fue inundada en su mayoría.

### 2.3.5. *Imágenes satelitales*

Una imagen satelital se obtiene de un sensor pasivo instalado en un satélite artificial, el cual reacciona a estímulos externos y registra la energía natural que se emite o refleja desde la superficie de la tierra. La fuente de radiación más común es la luz solar reflejada desde la tierra (Zhu et al., 2017).

Planet Labs es una compañía de Estados Unidos que opera las constelaciones de imágenes satelitales PlanetScope (PS). Las imágenes se recopilan y procesan en una variedad de formatos para diferentes usos, ya sea mapeo, respuesta a desastres, agricultura de precisión o análisis de imágenes temporales para crear productos de información enriquecidos. La constelación completa de PlanetScope es de aproximadamente 130 satélites y es capaz de obtener imágenes de toda la superficie terrestre todos los días (lo que equivale a una capacidad de recolección diaria de 200 millones de km<sup>2</sup>/día) (Planet Labs, 2022a).

Los productos de PlanetScope a considerar en la presente investigación se llaman “PlanetScope Ortho Analytic 4B SR” con un nivel 3B, los cuales se caracterizan por: ser imágenes orto rectificadas, presentar reflectancia de superficie, presentar cuatro bandas (azul, verde, rojo e infrarrojo cercano), tener un encuadre basado en escenas y de proyección cartográfica (Planet Labs, 2022a).

De acuerdo con Herrera Chaves (2014), una banda en una imagen satelital es “una composición de colores de un espectro emitido por la radiación solar. Las distintas combinaciones de bandas pueden generar distintos colores a las imágenes para obtener composiciones como color verdadero, color falso, infra rojo cercano o medio” (p. 10). Lo anterior permite llevar a cabo análisis de uso de suelo, vegetación y el cálculo de índices espectrales.

### 2.3.6. Índices espectrales derivados de imágenes satelitales

Los índices espectrales se calculan utilizando una ecuación matemática que se aplica para dos o más bandas de reflectancia espectral de una imagen satelital. El índice espectral calculado es una imagen nueva que destaca características o propiedades particulares de la superficie terrestre, por ejemplo, vegetación, suelo o agua (Prasad et al., 2022).

Los índices espectrales varían desde una simple relación espectral de dos bandas hasta combinaciones más complejas de múltiples bandas. Los índices espectrales se desarrollan en función de las propiedades espectrales del objeto de interés. Por ejemplo, los índices espectrales calculados que utilizan las bandas espectrales infrarrojas de onda corta son más sensibles al contenido de agua de la vegetación, por lo que se utilizan para evaluar la disminución de la vegetación y humedad (Memon et al., 2015). Los índices espectrales relacionados con el agua se aplican ampliamente en aplicaciones agrícolas y ecológicas, incluidas las características de las masas de agua superficial, el estrés hídrico de la vegetación, la evaluación del contenido de agua del suelo y el seguimiento de los humedales (Prasad et al., 2022).

#### 2.3.6.1. Índice Diferencial de Agua Normalizado

El Índice Diferencial de Agua Normalizado (NDWI) refleja el contenido de humedad en vegetación y suelos, esto a partir de imágenes adquiridas por los sensores satelitales. Los valores obtenidos de este índice son de gran importancia en el área de ingeniería, ya que estos pueden ser aplicados a diferentes tipos de modelados, estudios predictivos y la delimitación de masas de agua (Delpino Aguayo et al., 2018). El cálculo del índice se realiza a partir de un algoritmo matemático, el cual determina la diferencia de reflectancia entre las bandas del espectro electromagnético captado por los sensores satelitales, tal como se muestra en la Ecuación 4 (Acharya et al., 2018).

$$NDWI = \frac{Verde - NIR}{Verde + NIR} \quad (4)$$

Donde *NIR* – Near InfraRed o infrarrojo cercano; y *Verde* – Banda visible del verde.

De acuerdo con The Earth Observing System [EOS] (2020) “las longitudes de onda del infrarrojo cercano maximizan la alta reflectancia de la vegetación terrestre y las zonas de suelo, mientras que minimizan la baja reflectancia de la masa de agua” (p. 1). Por otra parte, la reflectancia de la superficie del agua se maximiza por las longitudes de onda del verde visible (Delpino Aguayo et al., 2018).

Los resultados de NDWI se encuentran en el rango de -1 a 1. Los valores positivos se identifican como cuerpos de agua y los negativos (o cero) el suelo y la vegetación terrestre. Conforme más se aproxima el valor a uno, mayor es la presencia de agua (Acharya et al., 2018). Los valores de NDWI corresponden a los siguientes rangos (EOS, 2020b):

- De 0,2 a 1: superficie del agua.
- De 0,0 a 0,2: inundación o alto contenido de humedad.
- De -0,3 a 0,0: sequía moderada, superficie sin agua.
- De -1 a -0,3: sequía, superficie sin agua.

### 2.3.7. Método de validación de resultados

Algunos de los parámetros empleados para la validación de resultados son el índice  $k$  o coeficiente kappa y la medida F, estos se obtienen a partir de una matriz de confusión (Recuero, 2021). La matriz de confusión, que también se conoce como matriz de error, permite evaluar el rendimiento de un modelo de clasificación (Recuero, 2021). Las validaciones con matrices de confusión para determinación de confiabilidad en análisis de inundaciones con imágenes SAR han sido utilizadas por autores como Belmonte & Caamaño (2009), Clemente et al. (2020), Kordelas et al. (2018) y Manakos et al. (2020). Este método corresponde a una matriz cuadrada de  $n \times n$ , siendo  $n$  el número de clases. En esta se relacionan la serie de datos reales, en los cuales se consideran los datos NDWI, y los datos obtenidos de una clasificación. Las columnas conciernen a los datos supuestos como reales y las filas corresponden a los resultados de las metodologías desarrolladas, siendo los valores de la diagonal los píxeles clasificados adecuadamente (Belmonte & Caamaño, 2009).

De la matriz de confusión se obtienen los parámetros de validación como el coeficiente kappa, el cual equivale a la diferencia entre la exactitud de la clasificación con un clasificador automático y la de una clasificación correcta con un clasificador aleatorio (Belmonte & Caamaño, 2009). Dicho índice se calcula mediante la Ecuación 5 y entre más cercano sea el valor de  $k$  a uno, mayor será la confiabilidad de la metodología de clasificación.

$$k = \frac{N \sum_{i=1}^r x_{(i,i)} - \sum_{i=1}^r (x_{(i,+)}x_{(+,i)})}{N^2 - \sum_{i=1}^r (x_{(i,+)}x_{(+,i)})} \quad (5)$$

Donde  $r$  – número de filas;  $x_{(i,i)}$  – la clase observada;  $x_{(i,+)}$  –el número de datos en la fila  $i$ ;  $x_{(+,i)}$  –el número de datos en la columna  $i$ ; y  $N$  – el total de datos en la matriz.

En la Tabla 3 se muestra un ejemplo de una matriz de confusión para la validación de una clasificación.

**Tabla 3.** Ejemplo de matriz de confusión para validación de clasificación

Clases		Datos reales		Total
		A	B	
Datos deducidos	A	27	6	33
	B	4	33	37
Total		31	39	60

Otro índice de validación es la medida F. Este parámetro mide la precisión en la clasificación de dos diferentes clases, ponderando la precisión del productor y del usuario. El valor óptimo de la medida F en una clasificación es el más cercano a 1 (M. Zhang et al., 2020). La precisión del productor se relaciona con los errores de omisión presentados en la clasificación, y se obtiene de la relación entre las unidades muestreadas correctamente clasificadas y el número de unidades que pertenecen a esa categoría realmente. Respecto a los errores de comisión, estos se toman en cuenta en la precisión del usuario. Esta se obtiene de la razón entre las unidades muestreadas que fueron clasificadas correctamente y las unidades totales clasificadas esa clase (Boca & Rodríguez, s/f). La medida F, utilizada como índice de precisión para evaluar las metodologías, se calcula con la Ecuación 6.

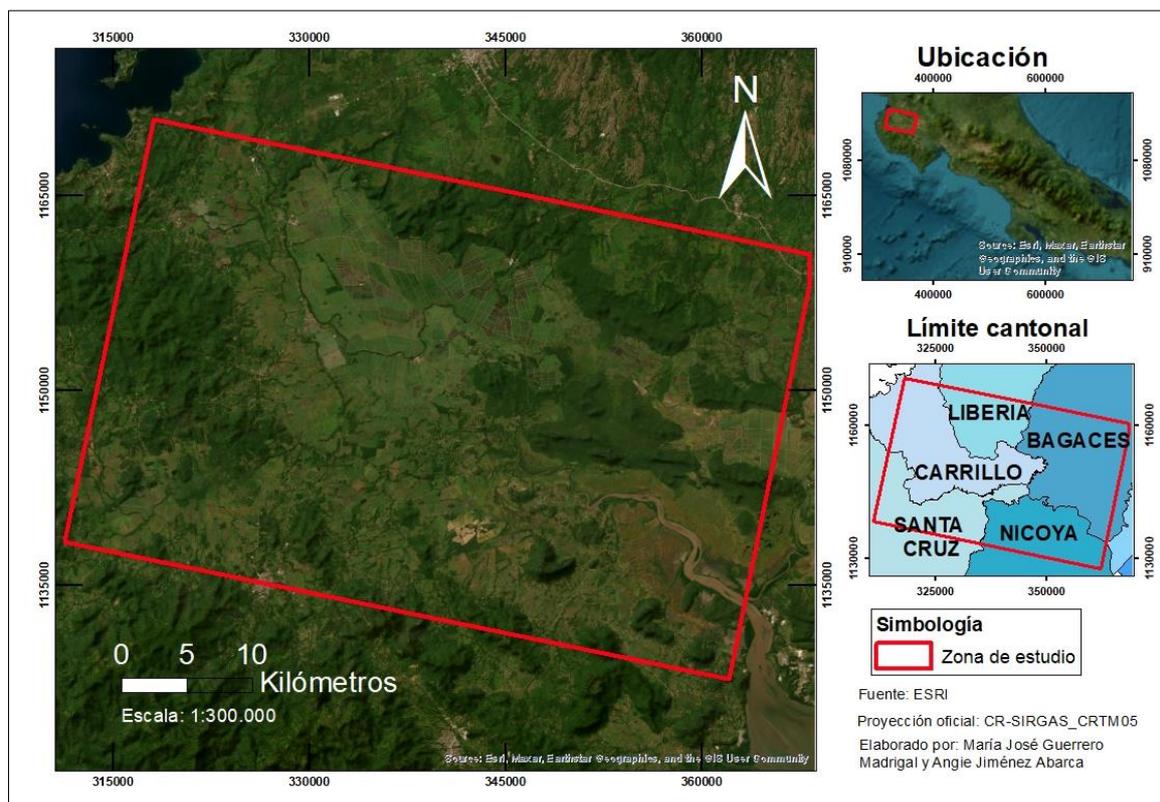
$$Medida F = 2 \cdot \frac{pr \cdot us}{pr + us} \quad (6)$$

Donde *pr* – precisión del productor o probabilidad de que un valor en una clase determinada se haya clasificado correctamente; *us* – precisión del usuario o probabilidad de que un valor predicho esté en una clase determinada realmente pertenezca a esa clase.

### 3. METODOLOGÍA

#### 3.1. Sitio de estudio

Las metodologías desarrolladas se aplicaron a un caso de estudio en la planicie inundable de la margen derecha del Río Tempisque en Guanacaste, Costa Rica (Figura 2). El área de estudio es de aproximadamente 463 km<sup>2</sup>. En esta zona se encuentran distritos del cantón de Carrillo como Palmira, Filadelfia y Belén (Municipalidad de Carrillo, 2020). También se encuentra el poblado Talolinga el cantón de Nicoya (Núñez Arias & Marín Hernández, 2015), las cuales como se mencionó anteriormente fueron seriamente afectadas por la tormenta Nate y se encuentran en cantones que fueron declarados en alerta roja ante el evento. Así como zonas agrícolas de importancia para el país, en cuales se practica la siembra de caña de azúcar, arroz y melón (Espinoza Rivera, 2018).



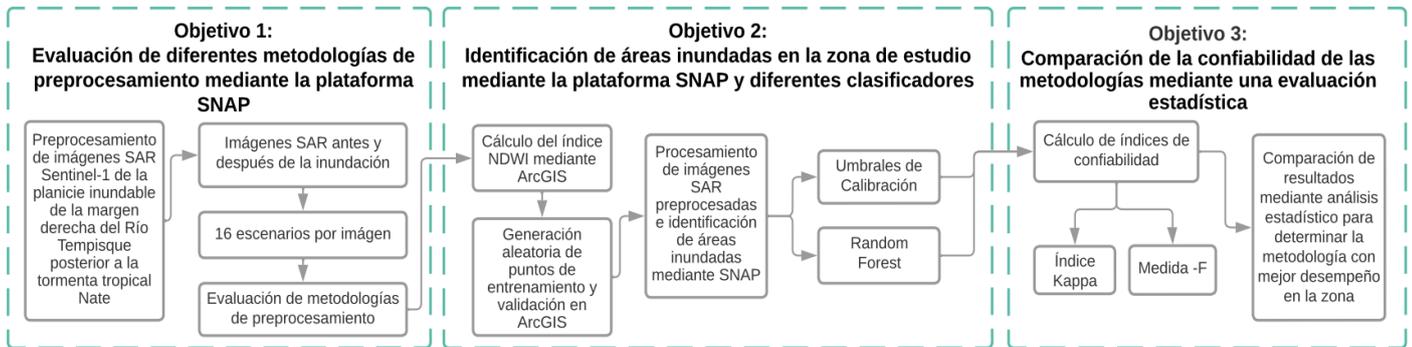
**Figura 2.** Zona de estudio, planicie inundable de la margen derecha del Río Tempisque.

#### 3.2. Métodos

Para la evaluación de las metodologías de clasificación RF y UC en la identificación de áreas inundables mediante imágenes SAR en Costa Rica, se siguieron los pasos del diagrama presentado en la Figura 3.

Inicialmente se aplicaron 16 metodologías de preprocesamiento para cada imagen SAR (objetivo específico 1), tanto antes como después del evento de inundación; además, se evaluó el desempeño de los filtros de efecto granular. Posteriormente se identificaron áreas de

inundación con los clasificadores RF y UC mediante el software SNAP para las imágenes preprocesadas posteriores al evento de inundación (objetivo específico 2). Las imágenes SAR previas al evento de inundación se emplearon para la diferenciación entre los cuerpos de agua fijos (ríos, lagos, cultivos de riego por aniego) y zonas inundadas en el cálculo de área de inundación y en la elaboración de mapas de inundación. Por último, se comparó la confiabilidad de las metodologías de procesamiento para la identificación de zonas inundadas. Lo anterior mediante índices de confiabilidad (objetivo específico 3).



**Figura 3.** Diagrama de flujo de la metodología desarrollada.

### 3.2.1. Definición de métodos

#### 3.2.1.1. Preprocesamiento de las imágenes SAR

Para llevar a cabo el objetivo específico 1 se aplicaron una serie de herramientas del programa SNAP versión 8.0 (Figura 4). El primer paso fue la aplicación del archivo de órbita, el cual es recomendado por (Organización de las Naciones Unidas [ONU], 2020), ya que proporciona una posición precisa de la imagen SAR y genera una actualización de los metadatos originales de la imagen. Esto asegura un proceso de registro espacial exitoso. Dicho archivo se descargó directamente del programa SNAP mediante la herramienta de radar “Apply Orbit File”. Esta herramienta no conlleva un parámetro extra de definición, ya que el vector del estado de órbita solicitado por SNAP es asignado por defecto y se descarga de forma automática.

Se continuó con la reducción del ruido térmico. El ruido térmico varía a lo largo de los ejes de rango y azimut, y genera cambios bruscos discontinuos en la intensidad de los límites entre franjas (Park et al., 2018). Para corregir esto se empleó la herramienta de radar “Radiometric, S-1 Thermal Noise Removal”. El parámetro de procesamiento a tomar en cuenta fue la polarización VV y VH, de las cuales Podest (2019) indica que la configuración VV detecta mejor las zonas perennes inundadas y VH la vegetación inundada.

Los artefactos radiométricos en los bordes de imágenes SAR aparecen durante la compresión de rango y azimut, y un tiempo específico de muestreo. Este tiempo corresponde al desfase entre el tiempo de inicio del pulso transmitido y el tiempo de inicio de la ventana de muestreo actual recibida. Lo anterior genera productos sin valor y píxeles con valores muy bajos que resultan imprecisos (Ali et al., 2018). Para solventar esto se empleó la herramienta de radar “Sentinel-1 TOPS, S-1 Remove GRD Border Noise”. Los parámetros de procesamiento considerados fueron: la polarización VV y VH, y el límite de margen de borde, el cual es asignado por defecto en SNAP.

El siguiente paso fue la corrección radiométrica, la cual es de gran importancia ya que se da la conversión de números digitales registrados por el sensor SAR a unidades físicas, lo cual

permite asignar valores de retrodispersión a los píxeles de la imagen. Una vez que se realiza este paso es posible llevar a cabo un análisis cuantitativo de las imágenes SAR (Jahren Petersen, 2022). Se aplicaron dos tipos de calibración radiométrica, sigma 0 y gamma 0. Lee et al. (2015) y O'Grady et al. (2014) aplicaron sigma 0 y gamma 0 para el análisis de inundaciones e indican que sigma 0 proporciona una mejor separación entre agua y la superficie terrestre. Para esto se empleó la herramienta de radar "Radiometric, Calibrate". El parámetro de procesamiento considerado fue la polarización VV y VH.

Posteriormente se realizó la calibración de efecto granular. Las imágenes SAR se caracterizan por presentar un efecto de sal y pimienta que disminuye su utilidad al reducir la capacidad de detectar objetivos en la superficie de estudio. Lo anterior dificulta la interpretación y análisis de las imágenes, razón por la cual es necesario corregir dicho efecto (Dasari et al., 2015).

En el presente proyecto se aplicaron cuatro filtros de calibración (Lee, Lee Sigma, Boxcar y Frost) mediante las herramientas de radar "Speckle Filtering". Se seleccionó la opción de un único producto ya que no se está realizando un análisis multitemporal de imágenes. Para cada uno de los filtros se seleccionaron dos tamaños de ventanas diferentes (5x5 y 7x7), siendo estos de los más frecuentes en el mapeo de inundaciones (Aldhshan et al., 2019; Borah et al., 2018; Dhara et al., 2020). La definición del tamaño de ventana de píxeles requiere de especial atención, pues con ventanas más grandes, mayor será la reducción del ruido, pero también será mayor la pérdida de definición en la imagen (Mata Muñoz, 2019). En grandes zonas de inundación con amplias planicies la resolución no es un factor importante como es en el caso de la planicie del Tempisque en Costa Rica, donde se tienen cambios importantes de topografía y se requiere de una mayor resolución.

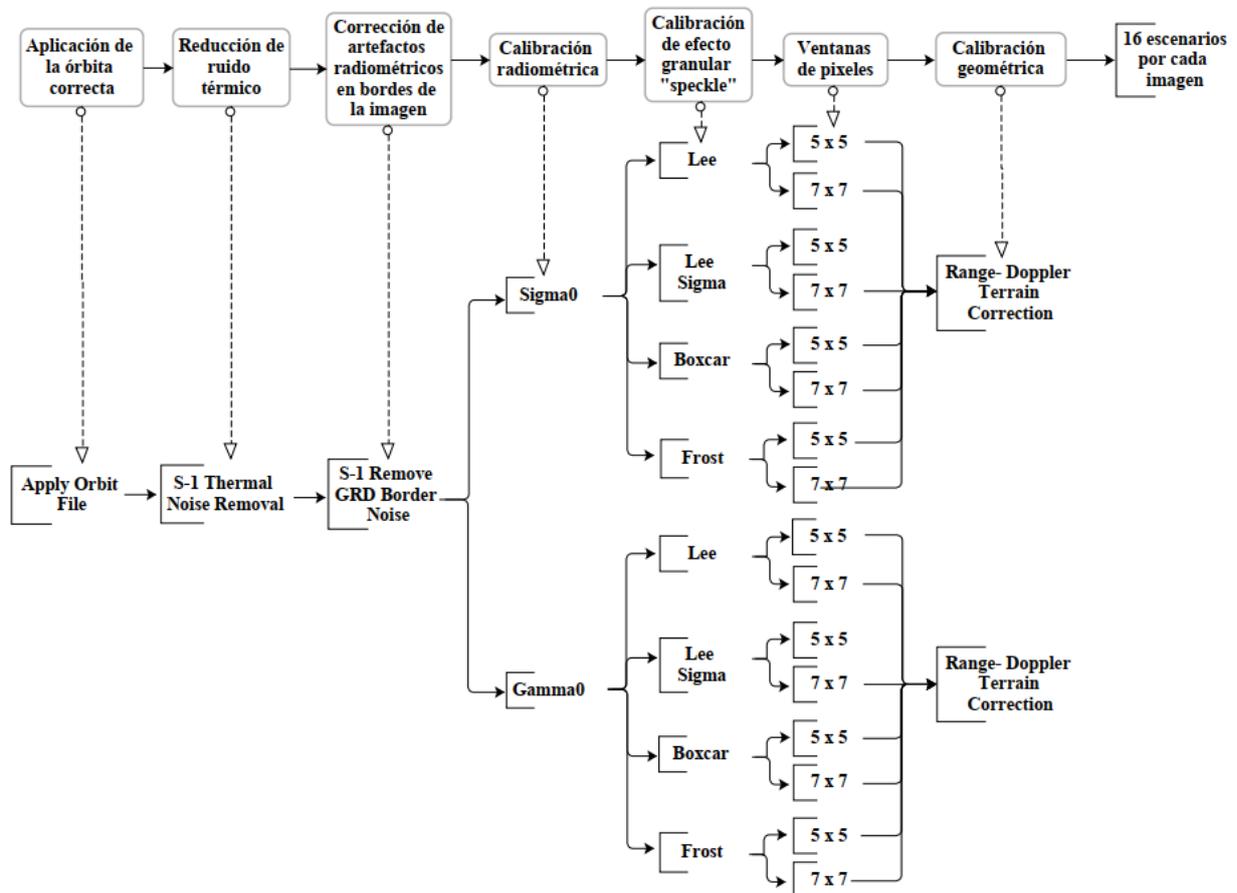
El error en las imágenes causado por el rango oblicuo, del relieve, las sombras y el desplazamiento en contra del nadir se corrigió mediante la herramienta "Range-Doppler Terrain Correction", dentro del menú de funciones geométricas para Radar contenidas en SNAP. Los parámetros de procesamiento considerados fueron: polarización, DEM, coordenadas geográficas, método de remuestreo, espaciado de píxeles, generación de mapas de ángulo de incidencia.

Para la corrección geométrica se tomó en cuenta la polarización VV y VH. Se utilizó como DEM de referencia el SRTM de un segundo de arco proporcionado por el mismo software SNAP, el cual tiene una resolución de 30 metros aproximadamente (EROS, 2018). Las coordenadas utilizadas en SNAP para corregir geométricamente las imágenes fueron las WGS84. Durante esta corrección, también se generaron los mapas del ángulo de incidencia desde el elipsoide, del ángulo de incidencia local y del ángulo de incidencia local proyectado.

El método de remuestreo utilizado para la corrección geométrica fue el de interpolación bilineal. Esta operación permitió cambiar la resolución del conjunto de datos ráster mediante el uso de métodos de interpolación según la resolución del DEM (Shen & Tan, 2020). Por esta razón, la resolución de las imágenes al finalizar el preprocesamiento resultó de 30 m. La interpolación bilineal define como valor de remuestreo el promedio ponderado de los cuatro centros de celda más cercanos. Este método aplica para datos continuos, como lo es la elevación de terreno (ESRI, 2020). No se consideraron las interpolaciones cúbicas ni las de puntos, para evitar valores asignados que estuviesen fuera del rango de datos de entrada.

Los pasos mencionados anteriormente fueron integrados en un diagrama de preprocesamiento mediante la herramienta "Graph Builder" de SNAP. El diagrama generado se aplicó a las imágenes antes (VV y VH) y después (VV y VH) del evento de inundación. Por cada imagen

se obtuvieron 16 escenarios, por lo que considerando dos imágenes antes y dos imágenes después del evento de inundación, se preprocesaron 64 escenarios en total.



**Figura 4.** Diagrama de flujo del preprocesamiento de imágenes y combinaciones desarrolladas.

Posteriormente se evaluó cuantitativamente el desempeño de los filtros de efecto granular en las imágenes SAR preprocesadas. Para esto se calcularon los parámetros MSE, PSNR y AD mediante el software Matlab 2021-b, licencia estudiantil número 17287-09987-45328-79398-67346. La licencia utilizada fue proporcionada por la Universidad de Costa Rica.

Para el cálculo del MSE se utilizó la función “immse” del paquete Image Processing, la cual calcula el error cuadrático medio entre la imagen original y la imagen filtrada (MathWorks, s/f-b). El PSNR se obtuvo mediante la función “psnr” del paquete Image Processing, el cual calcula la relación señal-ruido máxima para la imagen filtrada, con la imagen original como referencia (MathWorks, s/f-c). La AD se calculó mediante la función “imabsdiff” del paquete Image Processing. Esta función calcula la diferencia absoluta entre los píxeles de dos imágenes, generando una matriz de diferencia (MathWorks, s/f-a), para la cual posteriormente se realizó una sumatoria de estas diferencias absolutas y se obtuvo el valor de diferencia promedio.

Estas funciones se emplearon mediante el código adjunto en el Anexo 1. En este se comparan las imágenes filtradas con la imagen de referencia sin filtro en un ciclo que genera una tabla con los valores obtenidos de cada parámetro para todas las imágenes. Los parámetros fueron evaluados para los 64 escenarios obtenidos previamente, comparando las imágenes originales con sus respectivas imágenes luego de aplicar los filtros.

Finalmente se realizaron tablas comparativas en las que se muestran los resultados de los parámetros para cada uno de los escenarios planteados (Figura 4). El criterio para la selección del filtro con un mejor desempeño fue un mayor valor PSNR y menor valor de MSE y AD. Esto debido a que los valores más altos de PSNR presentan una mayor calidad de imagen, ya que se da una mejor reconstrucción durante la corrección de efecto granular (Iza et al., 2015). Por otra parte, los valores más bajos de MSE y AD indican que hay una mayor nitidez y conservación de los bordes en las imágenes. Los valores más bajos de estos parámetros se consideran más eficaces para preservar las características de las imágenes SAR (Mohan et al., 2017).

### 3.2.1.2. Procesamiento

Los parámetros de selección de zonas anegadas que se tomaron en cuenta se basaron en el valor de retrodispersión de las imágenes. La vegetación anegada presenta retrodispersión de doble rebote, lo que provoca ópticamente en la imagen SAR píxeles muy brillantes por los altos valores de retrodispersión, superiores a los -5 dB. Zonas urbanas, boscosas, superficies rugosas y con pendientes orientadas hacia el sensor, pueden causar el mismo efecto. Las zonas inundadas se pueden manifestar también en tonos oscuros con baja retrodispersión, por debajo de los -15 dB. Esto porque las superficies generan el mismo efecto espejo de las zonas de agua abierta (Mata Muñoz, 2019). En la presente investigación se determinaron únicamente las zonas inundadas que presentaron retrodispersión especular, es decir, inundación de agua abierta. No se tomarán en cuenta las áreas inundadas bajo cobertura.

La determinación de zonas inundadas se aplicó en un caso de estudio para la llanura de la margen derecha del río Tempisque en Guanacaste (Figura 1) y la tormenta tropical Nate. Para esto, se descargaron las imágenes SAR de la zona de estudio para las fechas del evento, esto a partir de la plataforma ASF, la cual ofrece imágenes de libre acceso. En la Tabla 4 se muestran las características de las imágenes SAR de Sentinel-1 a emplear para el presente proyecto.

**Tabla 4.** Características de imágenes SAR de Sentinel-1 a utilizar en el caso de estudio

<b>Imagen</b>	<b>Fecha de captura</b>	<b>Hora de captura</b>	<b>Polarización</b>	<b>Dirección de vuelo</b>
Antes del evento	30-09-2017	11:30	VV + VH	Descendiente
Después del evento	12-10-2017	11:30	VV + VH	Descendiente

Previo a la identificación de zonas inundadas, se calculó el índice NDWI mediante el software ArcGIS en cinco imágenes satelitales de PlanetScope, esto con el fin de identificar las zonas inundadas consideradas como referencia. Las imágenes satelitales tienen una resolución de 3 m, donde se pueden evidenciar las zonas inundadas con mayor eficacia. A partir de esta información se determinaron los puntos de control, de los cuales 70% fueron considerados como puntos de entrenamiento y el 30% puntos de validación. Las características de las imágenes satelitales se muestran en la Tabla 5, con las cuales se realizó un mosaico para eliminar las zonas nubosas y calcular el NDWI.

**Tabla 5.** Características de imágenes satelitales de PlanetScope a utilizar en el caso de estudio

<b>Imagen satelital</b>	<b>Nombre</b>	<b>Fecha de captura</b>	<b>Hora de captura</b>	<b>Cantidad de bandas</b>
1	PlanetScope	07-10-2017	15:29	
2	Ortho Analytic 4B SR	09-10-2017	15:28	
3		11-10-2017	15:33	4
4		12-10-2017	13:51	
5		13-10-2017	13:21	

Cada imagen satelital de PlanetScope contiene un subconjunto de imágenes separadas, por lo que se agruparon para obtener la imagen total de un día. Para esto empleó la herramienta “Mosaic to New Raster”, en la cual se consideraron parámetros como: las coordenadas, WGS84; número de bandas, 4; y tamaño de píxel, 16 bit. Las imágenes obtenidas presentan reflectancia de superficie, por lo que la corrección atmosférica no fue necesaria. La imagen obtenida del paso anterior presentó un borde negro con datos sin valor, por lo que se utilizó la herramienta “Clip” para descartarlos.

Se calculó el índice NDWI a partir de la herramienta “Raster Calculator”, el parámetro solicitado por dicha herramienta fue la Ecuación (4). Para las imágenes satelitales de PlanetScope, la banda visible del verde corresponde a la banda 2 y el infrarrojo cercano a la banda 4 (Planet Labs, 2022b). El índice NDWI se calculó para las cinco imágenes satelitales y se hicieron pruebas preliminares de procesamiento con diferentes límites de inundación. Estas pruebas fueron realizadas con los límites 0,2, 0,25, 0,3, 0,35, 0,4 y 0,5, siendo el límite de 0,35 el que menor error presentaba tanto para kappa como para la medida F en ambas metodologías de preprocesamiento. Por lo tanto, considerando la información anterior y la base de datos de EOS (2020b), se establecieron los siguientes rangos para el índice NDWI:

- De 0,35 a 1: zonas inundadas.
- De -1 a 0,35: superficie sin agua.

Los productos de las imágenes satelitales se ven afectados por la presencia de nubes, por lo que el siguiente paso fue descartar las secciones de nubes de los datos de entrenamiento y validación. Para esto se realizó una clasificación mediante la barra de herramientas “Image Classification”. Se digitalizaron y clasificaron 60 polígonos de píxeles que contenían nubes y 60 polígonos de píxeles que no contenían nubes. La herramienta “Interactive Supervised Classification” permitió crear un archivo con las dos clases. Posteriormente se empleó la herramienta “Extract by Mask” para extraer y descartar los datos de nubes.

Una vez extraídas las nubes, se generó una imagen final con la herramienta “Mosaic” del catálogo “Image Analysis” superponiendo las imágenes de los cinco días. En este procedimiento se utilizó el método de mosaico “Last”; teniendo en cuenta que las imágenes se ordenaron de las más lejanas a las más cercanas a la fecha de la imagen SAR del 12 de octubre del 2007.

Del producto final del índice NDWI, se extrajeron 10.000 puntos con la herramienta de ArcGis “Create Accuracy Points”. Se utilizó “Equalized Stratified Random” como estrategia de muestreo; donde se crean puntos aleatoriamente distribuidos dentro de cada clase, en los que cada clase tiene el mismo número de puntos. Para la separación de datos de entrenamiento y datos de validación, se dividieron los 10.000 puntos generados mediante la herramienta “Subset Features” del paquete “Geostatistical Analyst”. Estos fueron generados con 100 m de distancia

entre ellos; considerando que el tamaño de pixel de las imágenes procesadas resulta de 50 m y 70 m según el tamaño de ventana utilizado en el preprocesamiento. Los 10.000 puntos seleccionados corresponden a aproximadamente 10% de los píxeles totales de la imagen a clasificar. Se separó de forma aleatoria en un nuevo archivo el 70% de los puntos con datos de NDWI, los cuales fueron empleados para entrenamiento tanto en la clasificación mediante RF, como en la clasificación a partir de UC. Mediante la herramienta “Erase” se separó el 30% restante de los datos en un nuevo archivo, el cual se utilizó para validar los resultados de los clasificadores en el objetivo 3.

Los datos de entrenamiento, correspondientes al 70% previamente extraídos de los datos NDWI, se separaron en dos capas de puntos, como *Agua* y *No Agua*. Siendo *Agua* las zonas con índice NDWI entre 0,35 y 1, y *No Agua* las zonas con índice entre -1 y 0,35. Este procedimiento se repitió tres veces con el fin de posteriormente determinar si existe algún efecto asociado a la aleatoriedad en la selección de datos de entrenamiento en las metodologías (resultados objetivo 3).

#### 3.2.1.2.1. Técnica de Umbrales de Calibración

Para llevar a cabo la clasificación por UC se emplearon imágenes SAR preprocesadas previas y posteriores al evento de inundación (Tabla 4). Todo el procesamiento se llevó a cabo en SNAP. A nivel general, se generaron histogramas característicos de polarización para las imágenes posteriores al evento, los cuales incluyen datos de retrodispersión de zonas inundadas. Mediante dichos histogramas se determinó el umbral entre las áreas inundadas y no inundadas, este valor fue fundamental para llevar a cabo la separación de ambas áreas. Para ajustar la metodología se siguió el método de Selmi (2021), donde aleatoriamente se digitalizaron zonas inundadas mediante puntos para analizar el histograma de estas, y aumentar la precisión del umbral. Para el presente proyecto se emplearon los datos de entrenamiento previamente establecidos.

La imagen antes del evento de inundación se diferenció como “Imagen de archivo” y posterior al evento de inundación como “Imagen de crisis”. La imagen de archivo se utilizó con el fin de distinguir las zonas inundadas de cuerpos de agua como ríos, lagos y cultivos de riego por inundación.

El primer paso para la identificación de las zonas inundadas fue la transformación de datos de valores lineales a logarítmicos o decibelios, esto debido a que las imágenes SAR presentan más píxeles con valores de retrodispersión bajos que valores de retrodispersión altos. La distribución de valores de píxeles en decibelios permite tener un mayor entendimiento y manipular la información (RUS Copernicus, 2015). Para esto se empleó la herramienta “Linear to/from dB”, la cual generó automáticamente la nueva imagen.

El valor del umbral se definió según el punto en el que se generó un valle; es decir, el valor de frecuencia (píxeles) más bajo del valle, tal como se muestra en la Figura 1. Los píxeles por debajo del valor del umbral se identificaron como cuerpos de agua, estos presentan valores bajos de retrodispersión debido a la reflexión especular sobre la superficie de agua. Por otra parte, los píxeles por encima del valor del umbral se clasificaron como áreas no inundadas (Mata Muñoz, 2019).

Se generó una imagen binaria a partir de la imagen de crisis con el nombre “Superficie de Agua”, la cual incluyó: 1) áreas no inundadas, y 2) zonas inundadas y cuerpos de agua como ríos, lagos y cultivos de riego por inundación. Para esto se empleó la herramienta “Raster Band Maths”, la cual permite crear un producto con múltiples bandas basado en una expresión matemática (SNAP, 2022a). Los parámetros considerados fueron: la imagen de crisis; y la

expresión matemática de banda, la cual indica que, para el producto la banda de la imagen de crisis debe ser menor al valor del umbral. En la Ecuación (7) se muestra un ejemplo de la expresión matemática. El color de los píxeles que representan los cuerpos de agua se modificó mediante la herramienta “Color Manipulation”.

$$\text{Sigma0\_VH\_d} < -15 \quad (7)$$

Donde  $\text{Sigma0\_VH\_d}$  – nombre de la imagen de crisis;  $-15$  – valor hipotético del umbral.

Las imágenes resultantes de la clasificación en SNAP se exportaron como archivos TIF a ArcGIS. Mediante la herramienta “Reclassify” se reclasificaron las clases para que los píxeles clasificados por UC como *Agua* adoptaran el valor de “2” y los clasificados como *No Agua* adoptaran el valor de “1”. Este procedimiento se realizó para posteriormente calcular la matriz de confusión y los índices relacionados a la precisión de la técnica (ver sección 3.3).

Posteriormente se realizó la distinción de zonas de inundación y cuerpos de agua fijos previos al evento de inundación para la elaboración de los mapas de inundación (ver sección 3.2.1.2.3).

### 3.2.1.2.2. Clasificador Random Forest

Para la clasificación de zonas inundadas mediante la técnica de aprendizaje automático RF, se utilizó el software SNAP en el procesamiento de las imágenes SAR previamente preprocesadas en el objetivo 1.

Los puntos de entrenamiento generados se importaron a SNAP y se sobrepusieron a cada imagen preprocesada. Mediante la función “Random Forest” en el menú de “Raster”, dentro de las metodologías de clasificación supervisada, se clasificaron las 32 imágenes SAR preprocesadas, incluyendo tanto las imágenes con polarización VV y VH. Los parámetros tomados en cuenta dentro de la función de RF en SNAP se presentan en la Tabla 6. Los puntos de entrenamiento corresponden a las capas de puntos generados previamente con el 70% de los datos del índice NDWI en ArcGis, como se explicó anteriormente en la sección 3.2.1.2.

**Tabla 6.** Parámetros seleccionados en la clasificación supervisada con RF en SNAP

Cantidad de datos de entrenamiento	Cantidad de árboles de decisión	Vectores de entrenamiento	Bandas características
7.000	500	Agua No Agua	VH VV

Se seleccionan 7.000 datos de entrenamiento en la función de “Random Forest”, correspondientes al 70% del total de puntos generados. Se utilizaron 500 árboles de decisión para entrenar el clasificador de RF en la determinación de zonas de inundación. Este valor se seleccionó dentro del rango de cantidad de árboles óptimos para el clasificador (Espín et al., 2015).

Las imágenes resultantes de la clasificación en SNAP se exportaron como archivos TIF a ArcGIS y mediante la herramienta “Reclassify” se reclasificaron las clases para que los píxeles clasificados por RF como *Agua* adoptaran el valor de “2” y los clasificados como *No Agua* adoptaran el valor de “1”, generando una imagen binaria. Este procedimiento se realizó para posteriormente calcular la matriz de confusión y los índices relacionados a la precisión del clasificador (ver sección 3.3).

Posteriormente se realizó la distinción de zonas de inundación y cuerpos de agua fijos previos al evento de inundación para la elaboración de los mapas de inundación (ver sección 3.2.1.2.3).

### 3.2.1.2.3. Descarte de cuerpos de agua fijos previos al evento de inundación

Este procedimiento se realizó para la generación de mapas de inundación, para las imágenes resultantes previamente clasificadas tanto con UC como para las clasificadas con RF. Como se mencionó anteriormente, la imagen antes del evento de inundación se llamó “Imagen de archivo”. Esta se empleó para distinguir las zonas inundadas de cuerpos de agua como ríos, lagos y cultivos de riego por inundación.

Para llevar a cabo el descarte se creó una imagen binaria a partir de la imagen de archivo con el nombre “Agua Previa al Evento”, la cual incluyó: 1) áreas no inundadas, 2) cuerpos de agua como ríos, lagos y cultivos de riego por inundación. Se empleó la herramienta “Raster Band Maths” y los parámetros tomados en cuenta fueron la imagen de archivo y la expresión matemática de la banda. En la Ecuación (8) se muestra un ejemplo de la expresión matemática. El color de los píxeles que representan los cuerpos de agua se modificó mediante la herramienta “Color Manipulation”.

$$\text{Sigma0\_VH\_a} < -15 \quad (8)$$

Donde  $\text{Sigma0\_VH\_a}$  – nombre de la imagen de archivo;  $-15$  – valor del umbral para imagen previa al evento.

El valor hipotético del umbral se definió a partir de la técnica UC y a partir de este se clasificaron las zonas de inundación previas al evento.

Una vez obtenidas las imágenes binarias (“Superficie de Agua” y “Agua Previa al Evento”), se procedió a unir las en un mismo producto mediante la herramienta “Create Stack”. Los parámetros considerados fueron las dos imágenes binarias y el método de desplazamiento inicial. En el preprocesamiento de las imágenes SAR se aplicó el archivo de órbita correcto, por lo que se seleccionó “Orbit” como el método de desplazamiento.

Para descartar los cuerpos de agua como ríos y lagos e identificar las zonas inundadas se realizó una resta entre imágenes binarias. Como se trata de una operación aritmética de bandas, se empleó la herramienta “Raster Band Maths”. Los parámetros tomados en cuenta fueron el producto objetivo y la expresión matemática de banda. El producto objetivo corresponde al producto de la unión de ambas imágenes binarias. En la Ecuación (9) se muestra un ejemplo de la expresión matemática.

$$\text{Superficie de Agua} - \text{Agua Previa al Evento} \quad (9)$$

Una vez que se distinguieron las zonas de inundación de los cuerpos de agua fijos previos al evento de inundación, se generaron los mapas de inundación de ambas metodologías mediante el software ArcGIS.

### 3.2.1.2.4. Cálculo de áreas inundadas

Se calculó el área de inundación para dos procesamientos de la técnica UC:

- Polarización VH, calibración radiométrica Sigma 0, filtro Lee Sigma con tamaño de ventana 5x5.
- Polarización VV, calibración radiométrica Sigma 0, filtro Boxcar con tamaño de ventana 7x7.

Se calculó el área de inundación para dos procesamientos de la técnica RF:

- Polarización VH, calibración radiométrica Sigma 0, filtro Lee con tamaño de ventana 5x5.
- Polarización VV, calibración radiométrica Sigma 0, filtro Lee Sigma con tamaño de ventana 5x5.

Para el cálculo del área se empleó la herramienta “Mask Manager” del software SNAP, la cual permite crear una máscara de las zonas identificadas como inundadas, sin tomar en cuenta los cuerpos de agua fijos previos al evento de inundación. Posteriormente se empleó la herramienta “Mask Area”, la cual realiza automáticamente un recuento de los píxeles totales de la máscara y con base en el tamaño del píxel realiza el cálculo del área total de interés.

### 3.3. Análisis estadístico

Se validaron los resultados obtenidos de cada metodología a partir de la información tomada de las imágenes ópticas mediante el índice NDWI, tomando estos últimos datos de referencia como las zonas realmente inundadas (paso 3, Figura 2). La validación de estos datos se realizó mediante una matriz de confusión, tomando en cuenta el valor de kappa y la medida F.

La matriz de confusión se calculó para todas las imágenes clasificadas en el software RStudio a partir del código mostrado en el Anexo 2. El código generado lee la imagen con los valores NDWI y la capa de puntos de validación generados en ArcGIS (ver sección 3.2.1.2). Posteriormente extrae los valores de NDWI para cada punto de la capa de validación y clasifica los datos dentro del rango de 0,35 a 1 con un valor de 2, correspondientes a las superficies con agua; y clasifica los datos dentro del rango de -1 a 0,35 con un valor de 1, correspondientes a superficies sin agua. Los valores de cada punto se guardan en un vector o “Data Frame” correspondiente al archivo de validación.

Como segundo paso el código abre la imagen procesada, posteriormente clasificada con valores de 2 para superficies con agua y 1 para superficies sin agua. Posteriormente extrae los valores de la imagen procesada para cada punto de la capa de validación y los guarda en un vector o “Data Frame” correspondiente al archivo de predicción.

Por último, el código genera una matriz de confusión utilizando el vector de validación y el vector de predicción. Los resultados de esta validación para todas las imágenes fueron comparados mediante análisis de varianza (ANOVA) que se detallan en las siguientes secciones, esto con el fin determinar cuál metodología de procesamiento tuvo mejor rendimiento en la zona de estudio.

#### 3.3.1. Índice Kappa

A partir de la matriz de confusión generada en R, se calcula el valor del índice kappa para cada imagen procesada y validada con los datos del índice NDWI. La función del software R para el cálculo de la matriz, genera automáticamente el valor de kappa, el cual calcula mediante la Ecuación 5.

Se realizó una prueba ANOVA y Tukey para cada metodología de procesamiento (UC y RF) mediante el software InfoStat, con el fin de determinar si hay diferencias significativas entre las medias de los resultados del índice kappa (variable dependiente). El tamaño de muestra para las pruebas ANOVA fue de 32. Se consideraron las siguientes variables de clasificación (variables independientes): polarización (VH y VV), calibración radiométrica (Sigma 0 y Gamma 0), filtro de efecto granular (Lee, Lee Sigma, Boxcar y Frost) y el tamaño de la ventana (5x5 y 7x7).

Para la metodología UC, se establecieron las siguientes hipótesis:

- Hipótesis nula (H0): no existe diferencia significativa entre las medias del índice kappa obtenidas por UC.
- Hipótesis alternativa (H1): existe una diferencia significativa entre las medias del índice kappa obtenidas por UC.

Para la metodología RF, se establecieron las siguientes hipótesis:

- Hipótesis nula (H0): no existe diferencia significativa entre las medias del índice kappa obtenidas por RF.
- Hipótesis alternativa (H1): existe una diferencia significativa entre las medias del índice kappa obtenidas por RF.

Además, se realizó una prueba ANOVA y Tukey para determinar si hay diferencia significativa entre las medias de los resultados del índice kappa (variable dependiente) obtenidos por UC y RF (variables independientes). El tamaño de muestra fue de 64. Se establecieron las siguientes hipótesis:

- Hipótesis nula (H0): no existe diferencia significativa entre las medias del índice kappa obtenidas por UC y RF.
- Hipótesis alternativa (H1): existe una diferencia significativa entre las medias del índice kappa obtenidas por UC y RF.

En todas las pruebas realizadas el nivel de significancia fue de 0,05.

### 3.3.2. Medida F

A partir de la matriz de confusión generada en R, se calcula el valor de la medida F para cada imagen procesada y validada con los datos del índice NDWI. La función del software R para el cálculo de la matriz calcula la tasa de verdaderos positivos o sensibilidad y la tasa de verdaderos negativos o especificidad. A partir de estos valores se calcula la tasa de falsos positivos o error de usuario y la tasa de falsos negativos o error de productor; a partir de las ecuaciones 10 y 11 correspondientemente.

$$\text{Error del usuario} = 1 - \text{Sensibilidad} \quad (10)$$

$$\text{Error del productor} = 1 - \text{Especificidad} \quad (11)$$

Con estos valores se obtuvo el valor de la medida F para cada imagen procesada a partir de la ecuación 6.

Se efectuó una prueba ANOVA y Tukey para cada metodología de procesamiento (UC y RF) mediante el software InfoStat, con el fin de determinar si hay diferencias significativas entre las medias de los resultados de la medida F (variable dependiente). El tamaño de muestra para las pruebas ANOVA fue de 32. Se consideraron las siguientes variables de clasificación (variables independientes): polarización (VH y VV), calibración radiométrica (Sigma 0 y Gamma 0), filtro de efecto granular (Lee, Lee Sigma, Boxcar y Frost) y el tamaño de la ventana (5x5 y 7x7).

Para la metodología UC, se establecieron las siguientes hipótesis:

- Hipótesis nula (H0): no existe diferencia significativa entre las medias de la medida F obtenidas por UC.
- Hipótesis alternativa (H1): existe una diferencia significativa entre las medias de la medida F obtenidas por UC.

Para la metodología RF, se establecieron las siguientes hipótesis:

- Hipótesis nula (H0): no existe diferencia significativa entre las medias de la medida F obtenidas por RF.
- Hipótesis alternativa (H1): existe una diferencia significativa entre las medias de la medida F obtenidas por RF.

Además, se realizó una prueba ANOVA y Tukey para determinar si hay diferencia significativa entre las medias de los resultados de la medida F (variable dependiente) obtenidos por UC y RF (variables independientes). El tamaño de muestra fue de 64. Se establecieron las siguientes hipótesis:

- Hipótesis nula (H0): no existe diferencia significativa entre las medias de la medida F obtenidas por UC y RF.
- Hipótesis alternativa (H1): existe una diferencia significativa entre las medias de la medida F obtenidas por UC y RF.

En todas las pruebas realizadas el nivel de significancia fue de 0,05.

### 3.3.3. Efecto de aleatoriedad en datos de entrenamiento

Se generaron tres series de datos de entrenamiento de forma aleatoria en ArcGIS (ver sección 3.2.1.2) para determinar si existe una diferencia significativa entre las medias de los índices kappa y medida F (variables dependientes) obtenidos del clasificador RF. Esto con el fin de definir si la aleatoriedad puede inducir un error en la validación de resultados de ambas metodologías de procesamiento (RF y UC). Ahora bien, la aleatoriedad de los datos de entrenamiento es independiente del método de procesamiento que se evalúe, por lo tanto, únicamente se realizó la prueba ANOVA con RF. Cada serie de datos presentó una muestra de cuatro imágenes SAR, sus especificaciones de procesamiento se muestran en la Tabla 7.

**Tabla 7.** Especificaciones de las series de datos de entrenamiento generadas de forma aleatoria

Metodología de procesamiento	Calibración radiométrica	Filtro de efecto granular	Tamaño de ventana
RF	Sigma 0	Frost Lee Sigma	5x5
	Gamma 0	Lee Boxcar	7x7

Se realizó una prueba ANOVA para el índice kappa mediante el software InfoStat. Se consideró como variable de clasificación (variable independiente) el número de la serie de datos de entrenamiento. Se establecieron las siguientes hipótesis:

- Hipótesis nula (H0): no existe diferencia significativa entre las medias del índice kappa.
- Hipótesis alternativa (H1): existe una diferencia significativa entre las medias del índice kappa.

Además, se realizó una prueba ANOVA para la medida F mediante el software InfoStat. De igual forma se consideró como variable de clasificación (variable independiente) el número de la serie de datos de entrenamiento. Se establecieron las siguientes hipótesis:

- Hipótesis nula (H0): no existe diferencia significativa entre las medias de la medida F.

- Hipótesis alternativa (H1): existe una diferencia significativa entre las medias de la medida F.

En ambos casos el nivel de significancia fue de 0,05.

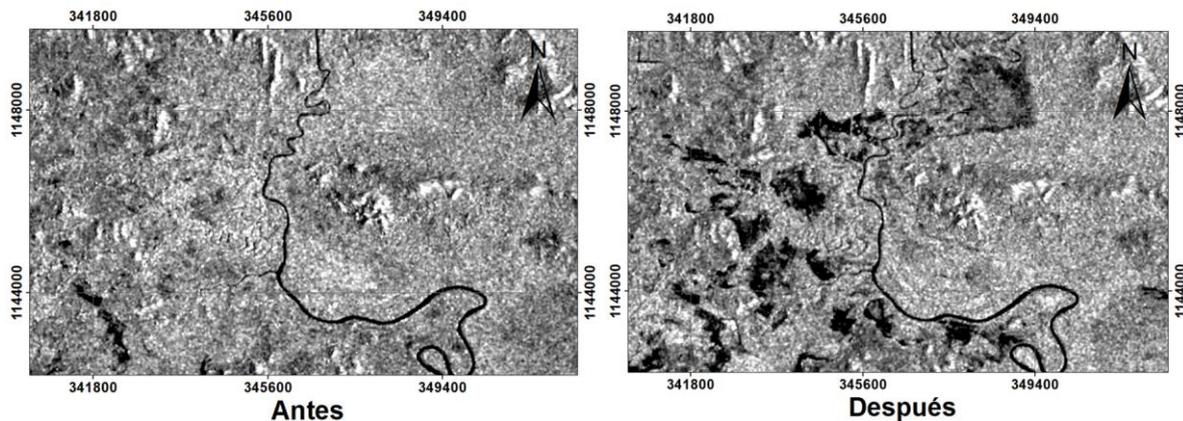
## 4. RESULTADOS Y DISCUSIÓN

### 4.1. Preprocesamiento

Como resultado del preprocesamiento se obtuvieron 32 escenarios para la imagen antes y después del evento de inundación, esto considerando las polarizaciones VH y VV, para un total de 64 escenarios. Todos los mapas de preprocesamiento se generaron bajo las coordenadas CR-SIRGAS\_CRTM05.

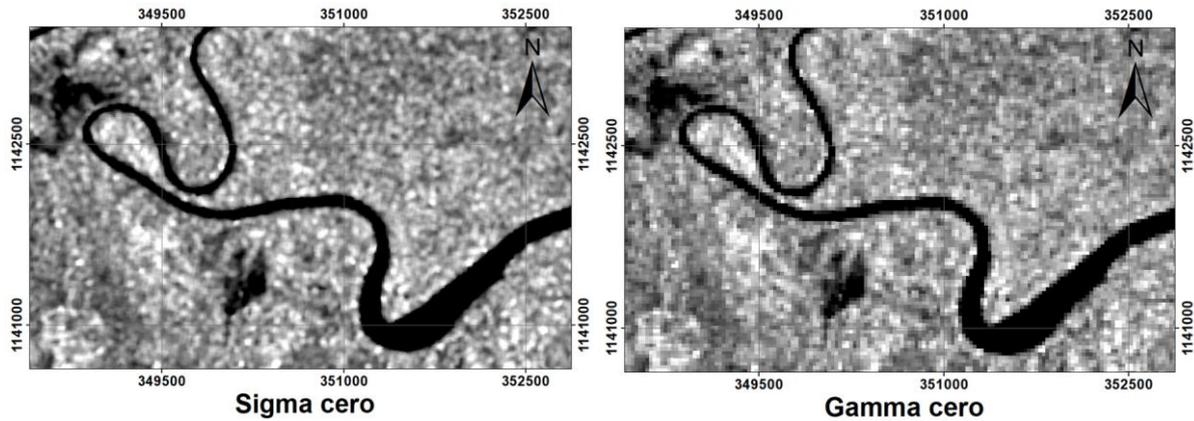
Las zonas inundadas analizadas presentaron tonos oscuros, específicamente de color negro, indicando baja retrodispersión. Los valores de intensidad se encuentran entre -22 dB a -25 dB. El mecanismo de retrodispersión asociado a los resultados es la retrodispersión especular. El haz de ondas emitidas por el radar se refleja en las zonas inundadas, estas actúan como un espejo y la señal es devuelta en dirección opuesta al sensor, razón por la cual se generan tonos oscuros y valores bajos de intensidad (Mata Muñoz, 2019).

En la Figura 5 se muestra el preprocesamiento de las imágenes antes y después del evento de inundación en un área cercana al río Tempisque. En esta es posible identificar las manchas de inundación en tonalidades oscuras.



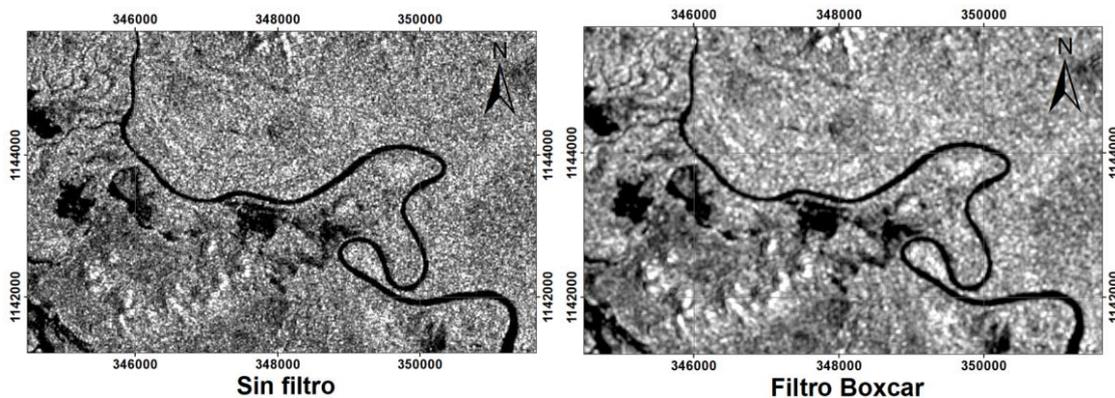
**Figura 5.** Preprocesamiento de imágenes SAR antes y después del evento de inundación (polarización VH, filtro Lee y calibración radiométrica sigma 0).

En la presente investigación se aplicaron dos tipos de calibraciones radiométricas, sigma 0 y gamma 0. Ambas calibraciones mostraron un nivel de brillo similar en las imágenes SAR (Figura 6). De acuerdo con Jahren Petersen (2022), sigma 0 es la calibración más utilizada por científicos en el preprocesamiento de imágenes SAR para su posterior análisis estadístico. Esto debido a que las imágenes calibradas pueden ser directamente comparadas con otras imágenes SAR captadas por el mismo sensor o uno diferente (ESRI, 2022). Por otra parte, la calibración radiométrica gamma 0 no es tan utilizada, esta se emplea para calibrar la antena. El proceso de calibración se basa en la relación de energía que es transmitida y recibida por el sensor, lo cual tendrá un efecto directo en el brillo de los píxeles (Jahren Petersen, 2022). Más adelante se determinará si las correcciones tienen efecto significativo en la determinación de zonas inundadas.

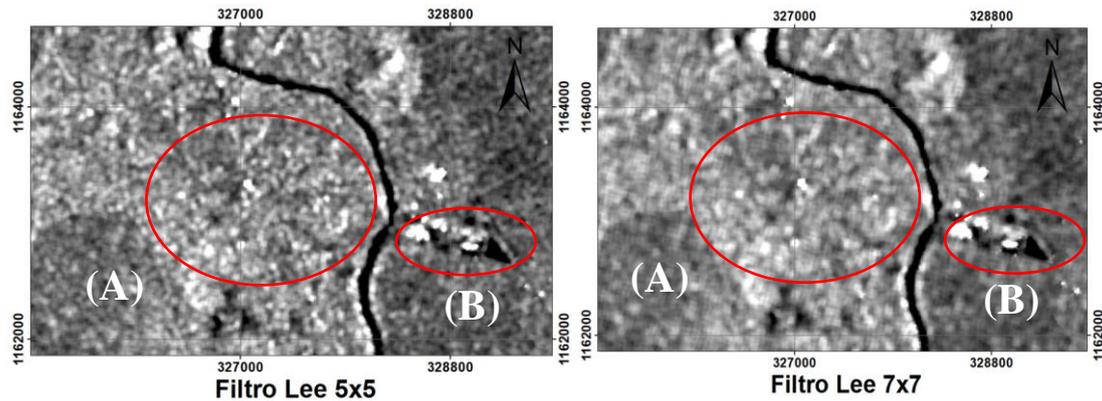


**Figura 6.** Comparación de imágenes SAR con calibración radiométrica sigma 0 y gamma 0 (después del evento de inundación, polarización VH y filtro Lee Sigma).

Los resultados de aplicar los filtros de efecto granular muestran que las imágenes SAR sin filtro tienen una menor calidad con respecto a las que sí se les aplicó. Las imágenes sin filtro presentaron el efecto de sal y pimienta característico de las imágenes SAR (Figura 7). Por otra parte, conforme mayor es el tamaño de la ventana de los diferentes filtros, mayor es el efecto de calibración de efecto granular; sin embargo, la pérdida de resolución en las imágenes es mayor. Lo anterior se puede apreciar de forma más clara en la Figura 8, en la cual se ubica el poblado de Palmira del lado oeste (A), e industrias agrícolas como la Central Azucarera Tempisque del lado este (B). Este efecto se presentó tanto en las imágenes preprocesadas con sigma 0 como con gamma 0.

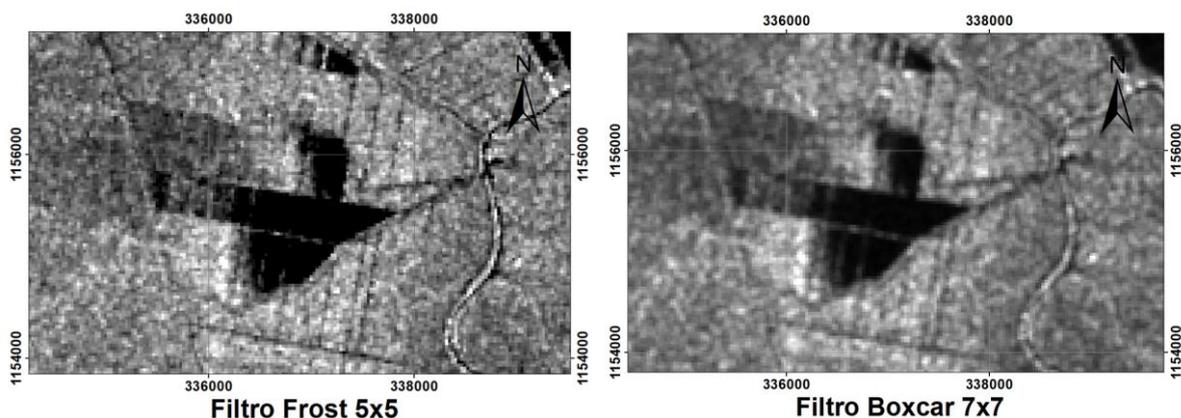


**Figura 7.** Comparación de imágenes SAR con y sin la aplicación de filtro Boxcar (después del evento de inundación, polarización VH y calibración sigma 0).



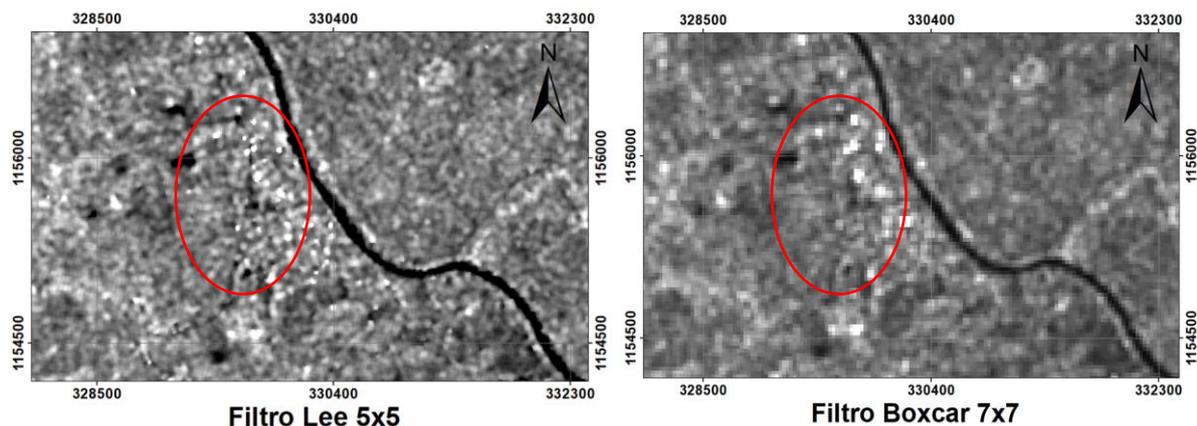
**Figura 8.** Comparación de imágenes SAR con tamaño de ventanas diferentes para el filtro Lee y Lee Sigma (después del evento de inundación, polarización VH y calibración sigma 0). Con círculo rojo se indica el poblado de Palmira (A) y la Central Azucarera Tempisque (B).

Otro aspecto importante por mencionar es la distorsión de borde, al aplicar la calibración de efecto granular se obtuvieron imágenes más suavizadas; sin embargo, estructuras lineales como carreteras y algunos tramos del río Tempisque perdieron resolución y nitidez. Este efecto se agrava con un mayor tamaño de ventana (B. Zhang et al., 2018), tal como se muestra en la Figura 9, donde se ubica una zona dedicada a la agricultura.



**Figura 9.** Comparación de distorsión de borde para el filtro Frost y Boxcar con tamaño de ventanas diferentes (después del evento de inundación, polarización VH y calibración sigma 0).

Después de aplicar los filtros de efecto granular, el tamaño de ventana que presentó una mejor resolución y nitidez a nivel visual fue 5x5. Lo anterior coincide con los resultados reportados por Mata Muñoz (2019). El filtro Boxcar con tamaño de ventana 7x7 presentó una resolución más baja a nivel visual con respecto a los demás filtros. Lo anterior se aprecia en la Figura 10, donde los píxeles más brillantes del lado oeste (en círculo rojo) representan el poblado de Filadelfia. Más adelante se determinará el desempeño de los filtros utilizados en la determinación de zonas inundadas, para conocer la relación entre el desempeño de la eliminación del ruido con la determinación de inundaciones en el caso de estudio.



**Figura 10.** Comparación de preprocesamiento con filtro Lee y Boxcar (después del evento de inundación, polarización VH y calibración sigma 0). Con círculo rojo se indica el poblado de Filadelfia.

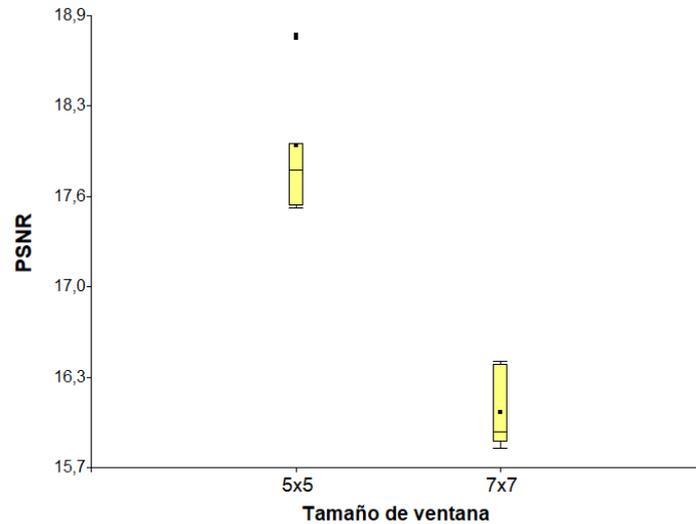
Finalmente se generaron mapas de ángulo de incidencia local, ángulo de incidencia local proyectado y ángulo de incidencia local desde el elipsoide (Anexo 3 y 4). El efecto generado por el ángulo está directamente relacionado con los valores de retrodispersión de las imágenes, ya que este modifica la señal según la geometría de la superficie y la dirección del sensor (Mata Muñoz, 2019). Conocer estos efectos ayudará en el posterior análisis del comportamiento de los valores de retrodispersión en zonas de inundación. En el Anexo 5 se presenta el diagrama de flujo generado en SNAP para llevar a cabo el preprocesamiento de forma automática.

Los resultados de la evaluación cuantitativa del desempeño de los filtros de efecto granular en las imágenes SAR después del evento de inundación (con polarización VH) se muestran en la Tabla 8.

**Tabla 8.** Parámetros de rendimiento para las imágenes SAR después del evento de inundación con polarización VH

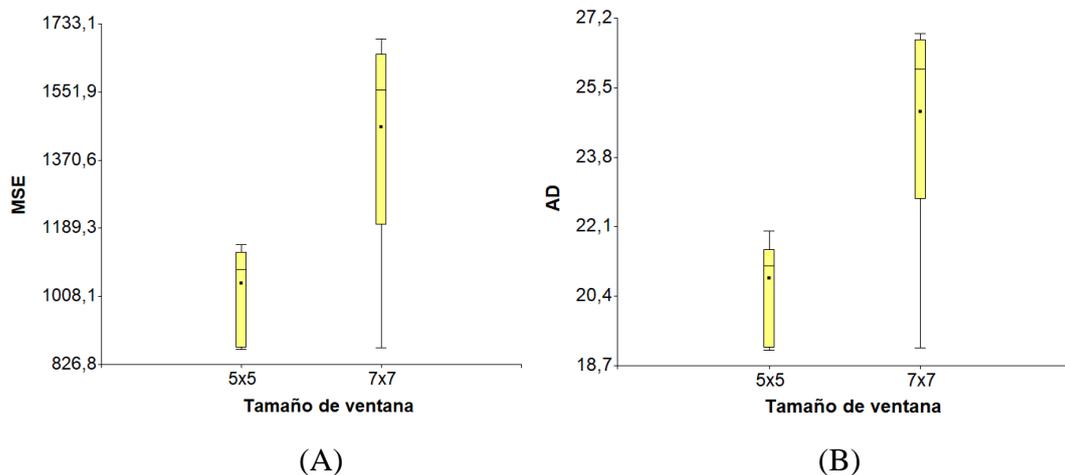
<b>Imágenes SAR después del evento de inundación con polarización VH</b>					
<b>Calibración radiométrica</b>	<b>Filtro de efecto granular</b>	<b>Tamaño de ventana</b>	<b>MSE</b>	<b>PSNR</b>	<b>AD</b>
Sigma 0	Lee	5x5	1145,91	17,54	21,98
	Lee	7x7	1651,96	15,95	26,69
	Sigma Lee	5x5	1037,05	17,97	20,78
	Sigma Lee	7x7	1474,89	16,44	25,29
	Boxcar	5x5	1125,38	17,62	21,54
	Boxcar	7x7	1691,94	15,85	26,81
	Frost	5x5	871,35	18,73	19,12
	Frost	7x7	871,35	18,73	19,12
Gamma 0	Lee	5x5	1141,86	17,55	21,94
	Lee	7x7	1641,83	15,98	26,60
	Sigma Lee	5x5	1033,27	17,99	20,74
	Sigma Lee	7x7	1469,19	16,46	25,24
	Boxcar	5x5	1120,93	17,64	21,49
	Boxcar	7x7	1674,03	15,89	26,67
	Frost	5x5	867,98	18,75	19,08
	Frost	7x7	1198,61	17,34	22,76

Se corrobora a partir de la PSNR que las imágenes filtradas con un tamaño de ventana de 5x5 presentaron una mejor calidad que las imágenes con un tamaño de ventana de 7x7 para todos los filtros utilizados (ver Figura 11). Esto debido a que las imágenes filtradas con un tamaño de ventana 5x5 presentan índices con valores mayores; los cuales representan mejores reconstrucciones en el proceso de filtrado (Iza et al., 2015).



**Figura 11.** Gráfico de cajas para PSNR con respecto al tamaño de ventanas, obtenido de InfoStat. Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de  $Q_1-1.5*RIC$  y  $Q_3+1.5*RIC$ , donde RIC es el rango inter-cuartil.

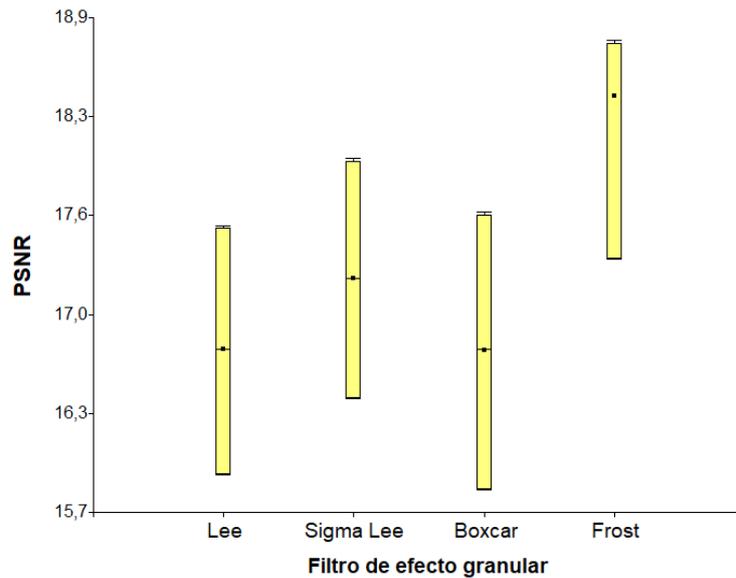
Según los valores de MSE y AD, los tratamientos con ventana de 5x5 generaron menores cambios en la información de las imágenes; esto porque presentaron valores menores en estos parámetros (ver Figura 12).



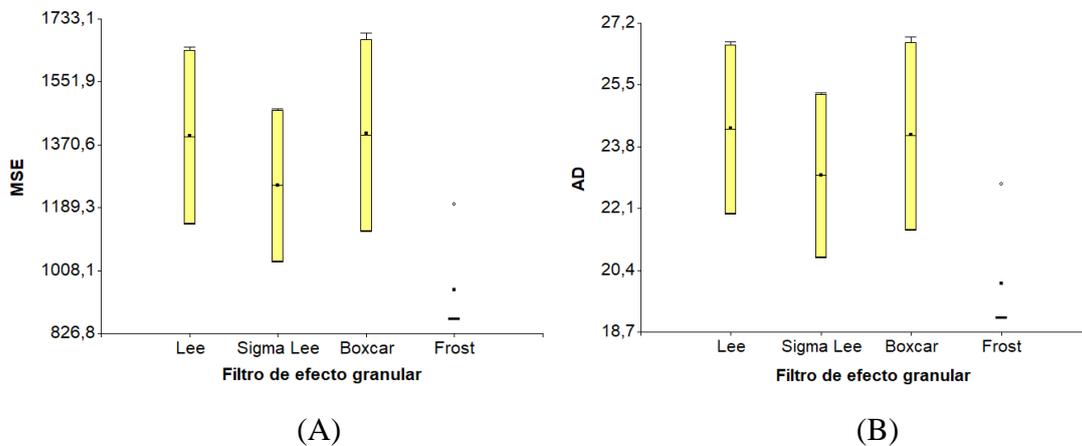
**Figura 12.** Gráfico de cajas para MSE (A) y AD (B) con respecto al tamaño de ventanas, obtenido de InfoStat. Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de  $Q_1-1.5*RIC$  y  $Q_3+1.5*RIC$ , donde RIC es el rango inter-cuartil.

El filtro con mejor desempeño fue el Frost 5x5, pues presentó valores de PSNR mayores (ver Figura 13) y valores menores de MSE y AD (ver Figura 14). Valores pequeños de MSE y AD

reflejan un filtrado con preservación de bordes en las estructuras de las imágenes (Mohan et al., 2017). En la Figura 14 se puede apreciar que los resultados de MSE y AD fueron muy precisos.



**Figura 13.** Gráfico de cajas para PSNR con respecto al filtro de efecto granular, obtenido de InfoStat. Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de  $Q_1 - 1.5 * RIC$  y  $Q_3 + 1.5 * RIC$ , donde RIC es el rango inter-cuartil.



**Figura 14.** Gráfico de cajas para MSE (A) y AD (B) con respecto filtro de efecto granular, obtenido de InfoStat. Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de  $Q_1 - 1.5 * RIC$  y  $Q_3 + 1.5 * RIC$ , donde RIC es el rango inter-cuartil.

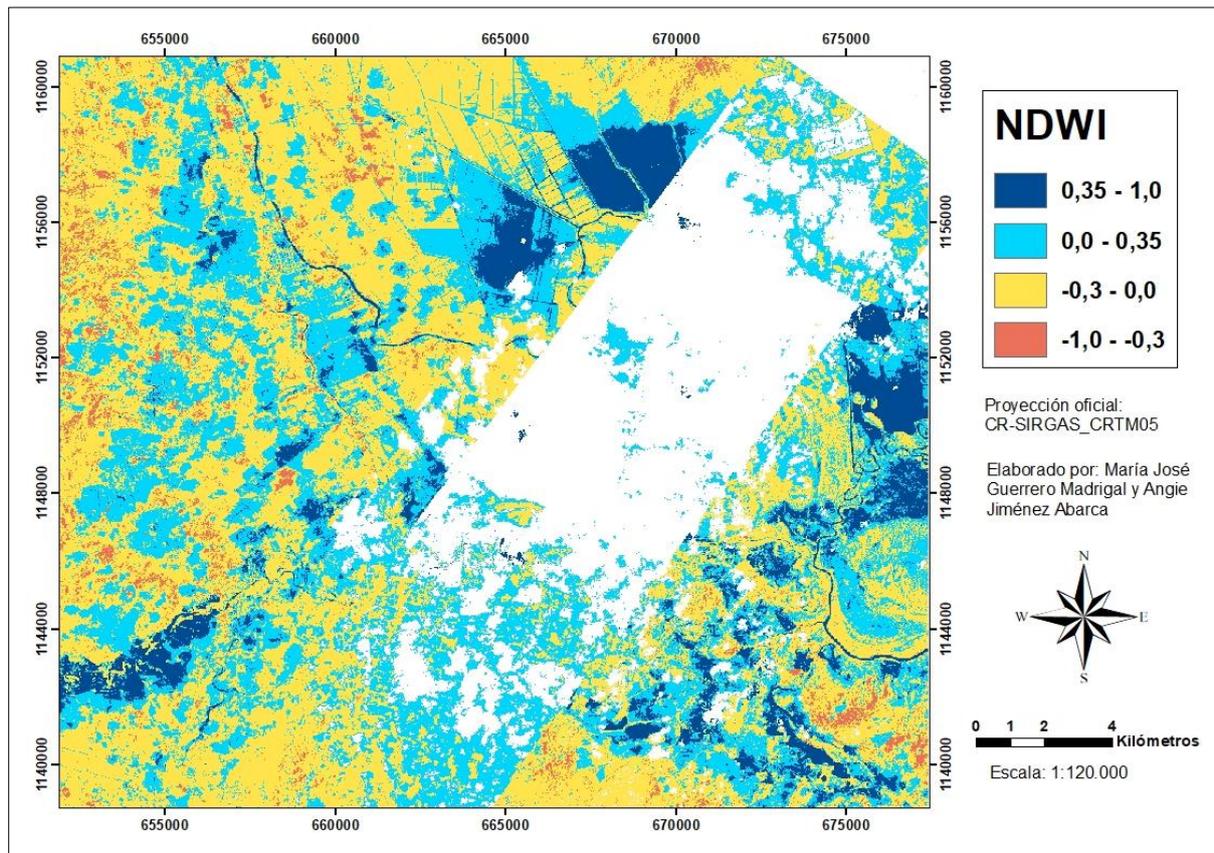
Este comportamiento es el mismo para las imágenes antes y después del evento de inundación con polarizaciones VH y VV (ver Anexos 6, 7 y 8). Estos resultados son congruentes con los presentados por Mohan et al. (2017) y Santoso et al. (2015), donde el filtro con mejor desempeño para eliminar el ruido conservando la información de las imágenes fue el Frost.

## 4.2. Procesamiento

En la Figura 11 se muestra el cálculo del índice NDWI a partir de las imágenes PlanetScope con una resolución de 3 m. En la misma se presenta una combinación de cinco imágenes satelitales de días posteriores al evento de inundación (ver Tabla 5), las cuales fueron las más

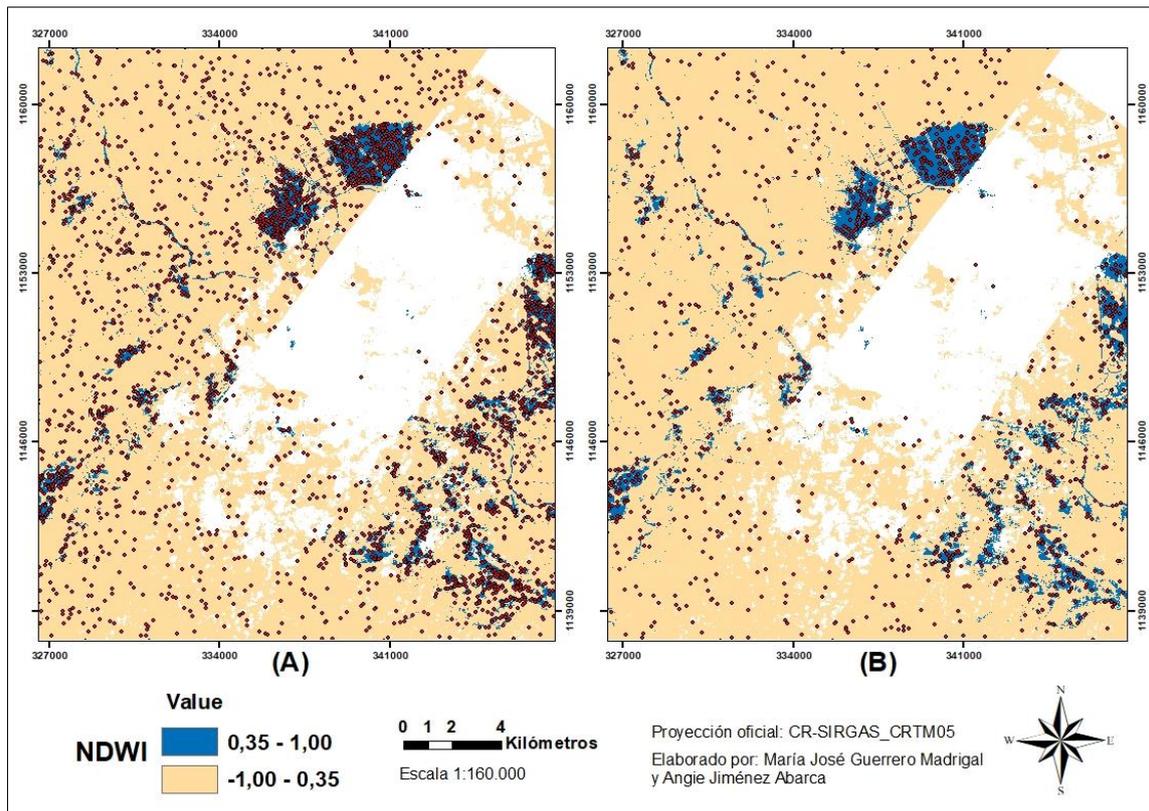
cercanas al evento y presentaron menor nubosidad. La ventana de tiempo analizada fue de 6 días. Las nubes restantes fueron descartadas debido a que se clasificaban como áreas inundadas, lo cual habría generado errores en la validación de resultados. Por lo tanto, los espacios en blanco o no datos corresponden a zonas de nubosidad.

Como se puede apreciar en la Figura 11, se presentan zonas inundadas en color azul oscuro (0,35 a 1). Algunas de estas áreas inundadas coinciden con zonas de cultivos como arroz, caña de azúcar y cítricos. Se presentan zonas con alto contenido de humedad debido a las precipitaciones del evento (0 a 0,35). Por otra parte, se identifican grandes extensiones de superficie sin contenido de agua (-1 a 0).



**Figura 11.** Cálculo del índice NDWI en la zona de estudio. Las áreas blancas representan zonas con nubes que fueron descartadas.

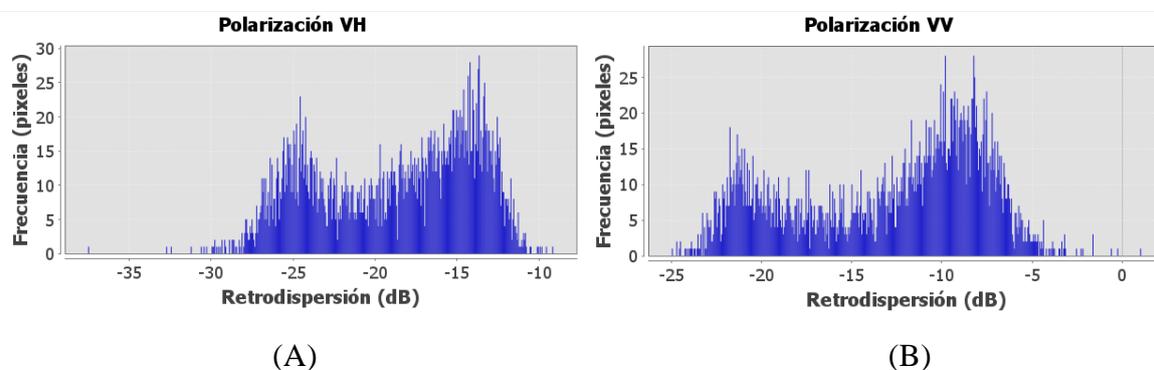
En la Figura 12 (a) se presenta el 70% de los puntos que se emplearon como datos de entrenamiento en la técnica de UC y RF. Por otra parte, en la Figura 12 (b) se muestra el 30% restante de los puntos que serán utilizados en la validación de resultados (objetivo 3). Dicho mapa considera únicamente dos categorías: zonas no inundadas (-1 a 0,35) y zonas inundadas (0,35 a 1). Las coordenadas geográficas corresponden a CR-SIRGAS\_CRTM05.



**Figura 12.** Índice NDWI (a) 70% de datos de entrenamiento, (b) 30% de datos para validación de resultados. Las áreas blancas representan zonas con nubes que fueron descartadas.

#### 4.2.1. Técnica de Umbrales de Calibración

Se procesaron 32 imágenes SAR mediante la técnica de UC, en la Figura 13 se muestran los histogramas de retrodispersión para las polarizaciones VH (A) y VV (B), los cuales presentan una distribución bimodal. La curva de zonas no inundadas (izquierda) aporta una mayor cantidad de píxeles de la imagen SAR. Por otra parte, la curva más pequeña (derecha) corresponde a los píxeles de las zonas inundadas. Entre ambas curvas se identificó el valor del umbral, el cual correspondió al valor más bajo de la frecuencia en el valle. Con base en la Figura 14 se determinó un umbral de -21 dB para la polarización VH y de -16,25 dB para VV.



**Figura 13.** Histogramas de retrodispersión a partir de datos de entrenamiento para la banda VH (A) y VV (B) (calibración radiométrica Sigma 0, Filtro Lee Sigma y tamaño de ventana 5x5), obtenidos de SNAP.

En la Tabla 9 se muestran los resultados del valor de umbral establecido para cada imagen SAR según sus especificaciones. De acuerdo con Clement et al., (2017), la polarización VH identifica un mayor rango de valores de retrodispersión en superficies de agua abierta, por lo que la polarización VV omite áreas inundadas. La calibración radiométrica sigma 0 presentó un menor umbral con respecto a gamma 0. Esto se debe a que para la calibración radiométrica gamma 0 se devuelve una mayor señal al sensor, por lo que los valores de retrodispersión son mayores. Por otra parte, sigma 0 devuelve una menor señal, por lo que los valores de retrodispersión siempre van a ser menores.

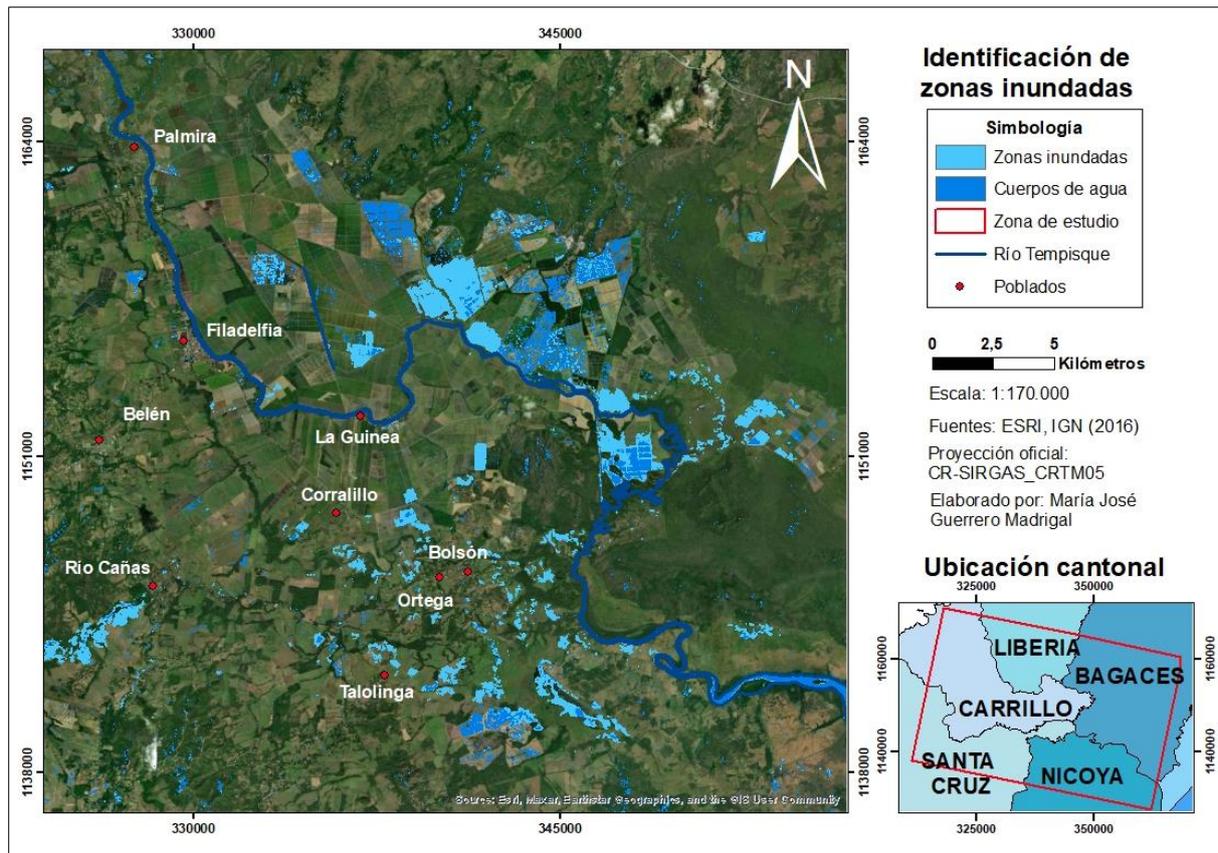
**Tabla 9.** Resultados de UC según su polarización y calibración radiométrica

<b>Polarización</b>	<b>Calibración radiométrica</b>	<b>Umbral de calibración (dB)</b>
VH	Sigma 0	-21,00
	Gamma 0	-19,50
VV	Sigma 0	-16,25
	Gamma 0	-14,20

Ahora bien, la Figura 14 muestra el mapa de inundación de la zona de estudio. Se realizó una diferenciación de los cuerpos de agua previos al evento de inundación, por ejemplo, ríos y cultivos inundados de arroz. Esto con el fin de representar con mayor exactitud las zonas de inundación. Todos los mapas de inundación de la técnica UC se generaron bajo las coordenadas CR-SIRGAS\_CRTM05.

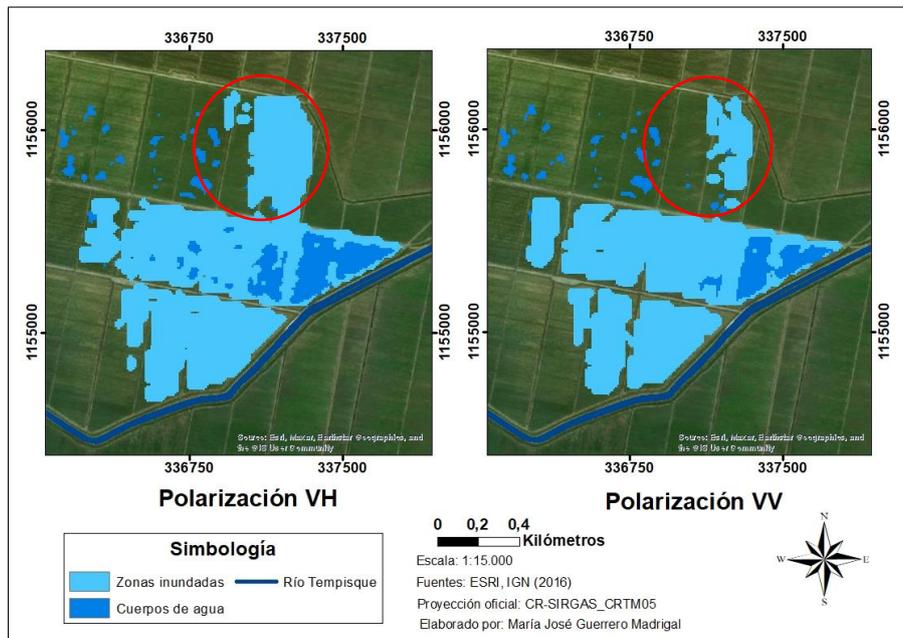
En la Figura 14 se puede apreciar que no se identificaron zonas de inundación en los distritos y poblados de la zona de estudio, esto se debe a que las imágenes SAR de la zona de estudio (ver Tabla 4) fueron capturadas en una fecha posterior a la fecha crítica de la tormenta tropical Nate. Sin embargo, sí fue posible identificar zonas inundadas en proximidades de los poblados señalados y campos agrícolas, tal como se aprecia en la parte superior derecha de la Figura 14 (simbología celeste).

Por otra parte, la presencia de cuerpos de agua previos al evento de inundación (ver Figura 14, simbología azul) en la zona agrícola, se debe al sistema de siembra de arroz en aniego de la empresa El Pelón de la Bajura. Lo anterior se corroboró mediante un historial de cultivos del DRAT del Sistema de Apoyo para la Gestión Inteligente del Recurso Hídrico, donde para el 2017 se registran cultivos de arroz anegado en la zona (Sistema de Apoyo para la Gestión Inteligente del Recurso Hídrico [SAGIRH], s/f).



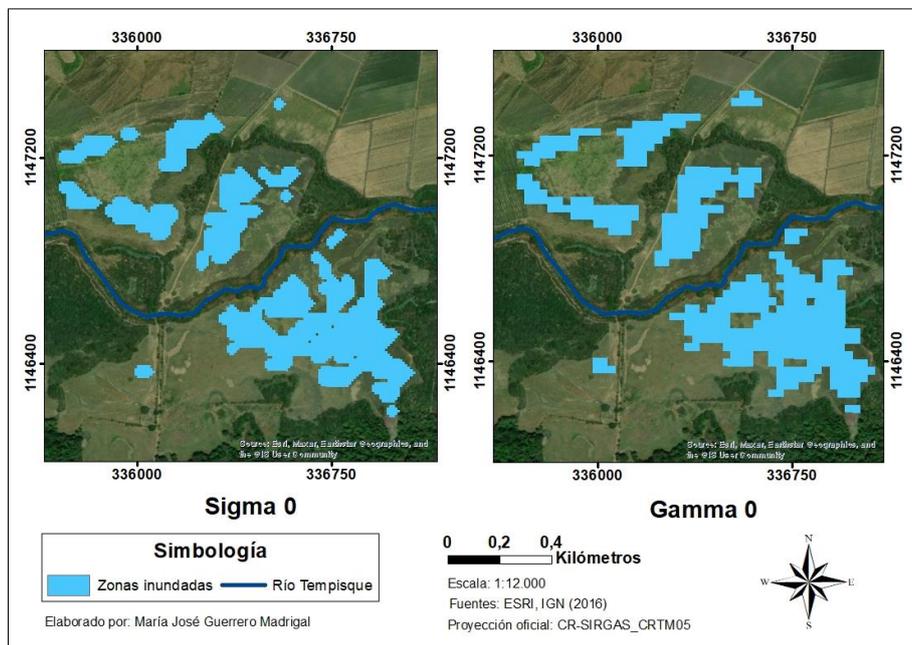
**Figura 14.** Mapa de inundación en zona de estudio mediante UC (calibración radiométrica Sigma 0, filtro Frost y tamaño de ventana 5x5).

En la Figura 15 se presentan mapas de inundación de un área de cultivos en Liberia para las polarizaciones VH y VV. Visualmente se puede apreciar que la polarización VH detectó una mayor área de inundación con respecto a VV (ver círculos rojos). De acuerdo con Clement et al. (2017) y Podest (2019), la polarización VH tiene un mejor desempeño en la identificación de zonas inundadas en agua abierta; sin embargo, aún no es posible asumir que los resultados sean correctos. Por lo que se realizó una validación en el objetivo 3 a partir del índice NDWI para confirmar la confiabilidad de dichos resultados.

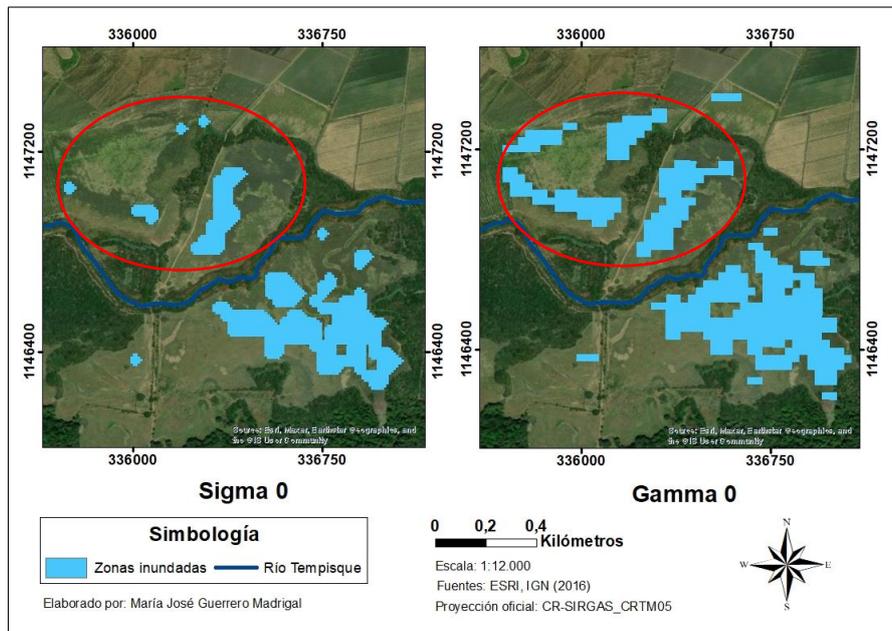


**Figura 15.** Comparación de polarización VH y VV en mapas de inundación (calibración radiométrica Sigma 0, filtro Frost y Boxcar y tamaño de ventana 5x5).

La Figura 16 muestra mapas de inundación entre Belén y Filadelfia generados con base en la calibración radiométrica sigma 0 y gamma 0. Visualmente no hay una diferencia notoria entre las zonas de inundación, esto sucede para todos los filtros aplicados, a excepción del filtro Boxcar, tal como se muestra en la Figura 17 (ver círculos rojos).

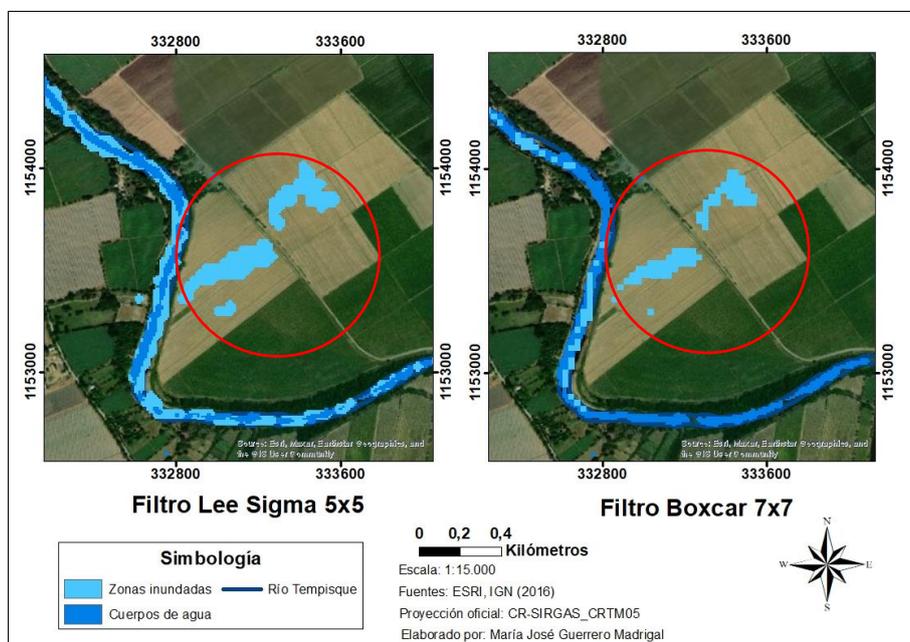


**Figura 16.** Comparación de calibración radiométrica Sigma 0 y Gamma 0 en mapas de inundación (polarización VH, filtro Lee y tamaño de ventana 5x5).



**Figura 17.** Comparación de calibración radiométrica Sigma 0 y Gamma 0 en mapas de inundación (polarización VH, filtro Boxcar y tamaño de ventana 5x5).

La Figura 18 presenta mapas de inundación entre el distrito de Liberia y Filadelfia según el filtro de efecto granular y el tamaño de ventana. Visualmente el filtro Lee Sigma 5x5 detectó una mayor área de inundación (ver círculos rojos) con respecto a Boxcar 7x7. Además, se puede apreciar que, a partir del filtro Lee Sigma se identifica el desbordamiento del río Tempisque en algunas de sus secciones. Esto se asocia a un mejor desempeño del filtro en la corrección del ruido granular, lo cual se refleja en la identificación de zonas inundadas.



**Figura 18.** Comparación de filtros de efecto granular y tamaño de ventana en mapas de inundación (polarización VH y calibración radiométrica Sigma 0).

Finalmente se calculó la extensión de la zona inundada para dos procesamientos diferentes. El primer cálculo corresponde a la imagen que visualmente presentó una mayor área de

inundación y que con base en los resultados del objetivo 1, presentó un alto rendimiento en la corrección del ruido granular. El segundo cálculo corresponde a la imagen que visualmente presentó una menor área de inundación y que tuvo mal desempeño en la corrección del ruido granular de acuerdo con los resultados del objetivo 1. En la Tabla 10 se presenta un aproximado del área de inundación en la zona de estudio. Se puede corroborar que la polarización VH sí detecta una mayor área de inundación. Cabe destacar que, para el cálculo se descartaron los cuerpos de agua fijos como ríos y la siembra de arroz en aniego. Los cálculos de áreas de la Tabla 10 resultan útiles para la toma de decisiones en situaciones de emergencia.

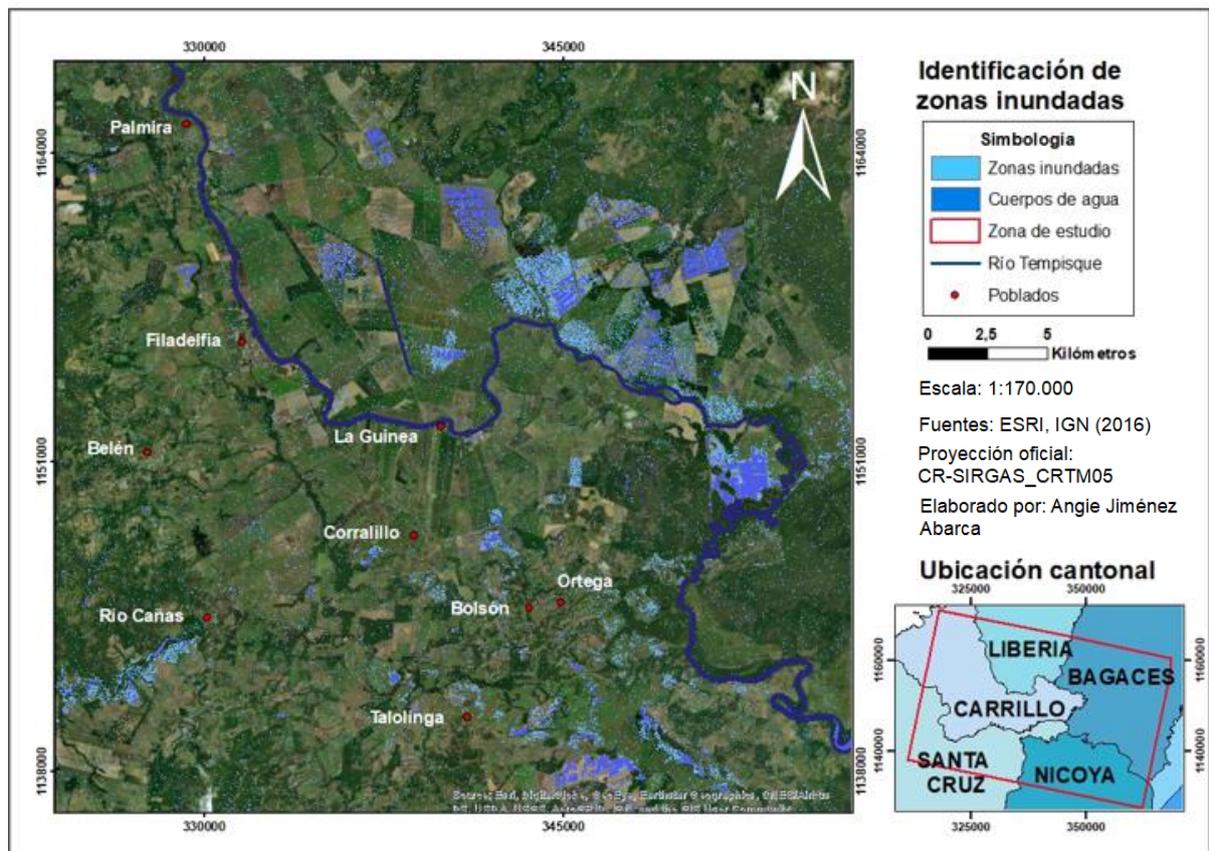
**Tabla 10.** Área aproximada de inundación en la zona de estudio mediante técnica UC (calibración radiométrica Sigma 0)

<b>Especificaciones de procesamiento</b>	<b>Píxeles totales de inundación</b>	<b>Área (km<sup>2</sup>)</b>
VH, Frost 5x5	332.522	69,880
VV, Boxcar 7x7	19.693	30,156

#### 4.2.2. Clasificador Random Forest

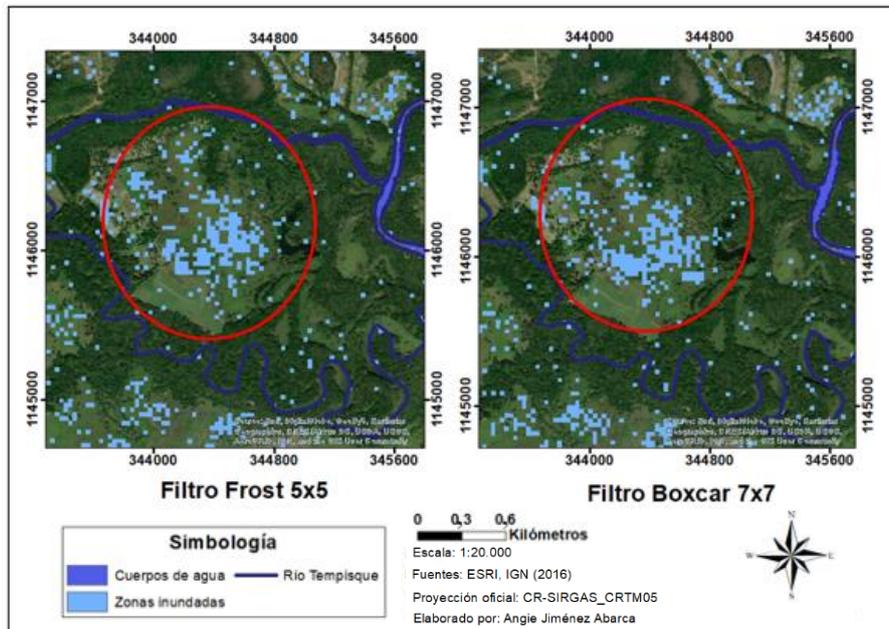
Las 16 imágenes previamente preprocesadas, correspondientes a las imágenes después del evento de inundación, se procesaron con la técnica de “Machine Learning Random Forest”, para clasificar las zonas con agua o inundación, de las zonas secas o sin presencia de agua en su superficie. En el conjunto de imágenes, se evaluaron 2 diferentes calibraciones radiométricas, Gamma 0 y Sigma 0, dos diferentes polarizaciones; VV y VH y cuatro diferentes filtros de efecto granular con dos tamaños diferentes de ventanas.

En la Figura 19 se muestra el mapa de inundación de la zona de estudio. Se realizó una diferenciación de los cuerpos de agua previos al evento de inundación, por ejemplo, ríos y cultivos inundados de arroz. Esto con el fin de representar con mayor exactitud las zonas de inundación. Todos los mapas de inundación de la técnica RF se generaron bajo las coordenadas CR-SIRGAS\_CRTM05.



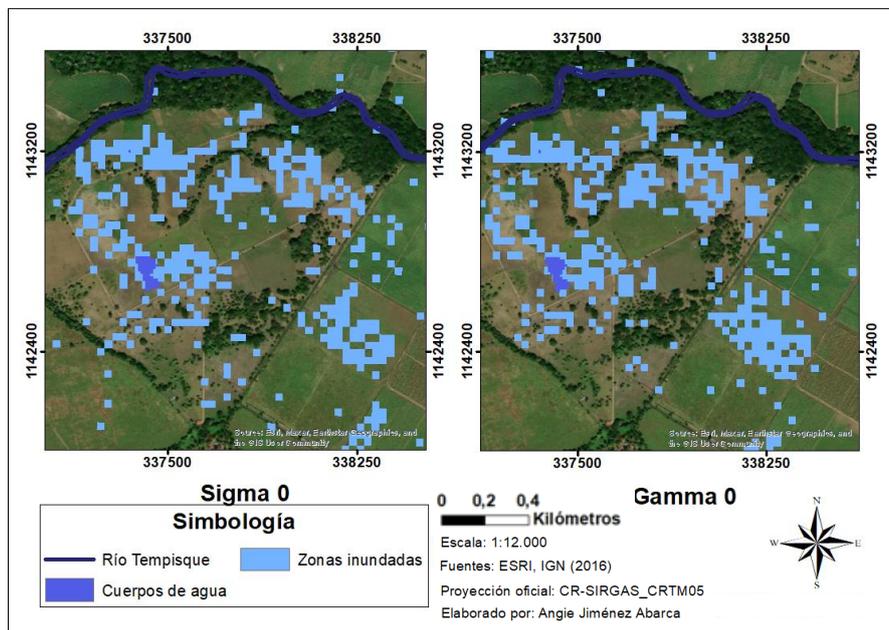
**Figura 19.** Mapa de inundación en zona de estudio mediante RF (calibración radiométrica Sigma 0, filtro Frost y tamaño de ventana 5x5).

En la Figura 20 se muestran las diferencias de los resultados según los filtros utilizados. Se puede apreciar como con el filtro de efecto granular Boxcar 7x7, el clasificador genera un resultado más ruidoso que el generado con el filtro Frost 5x5. Esto está relacionado a que, con ventanas mayores de filtrado, mayor será la eliminación de ruido o efecto de granular. En la Figura 20 también se puede observar que el filtro Frost conserva mejor los bordes en las zonas de inundación detectadas que el filtro Boxcar; como se concluyó en la evaluación de reducción de ruido granular (ver sección 4.1).



**Figura 20.** Comparación de filtros de efecto granular y tamaño de ventana en mapas de inundación (polarización VH y calibración radiométrica Sigma 0).

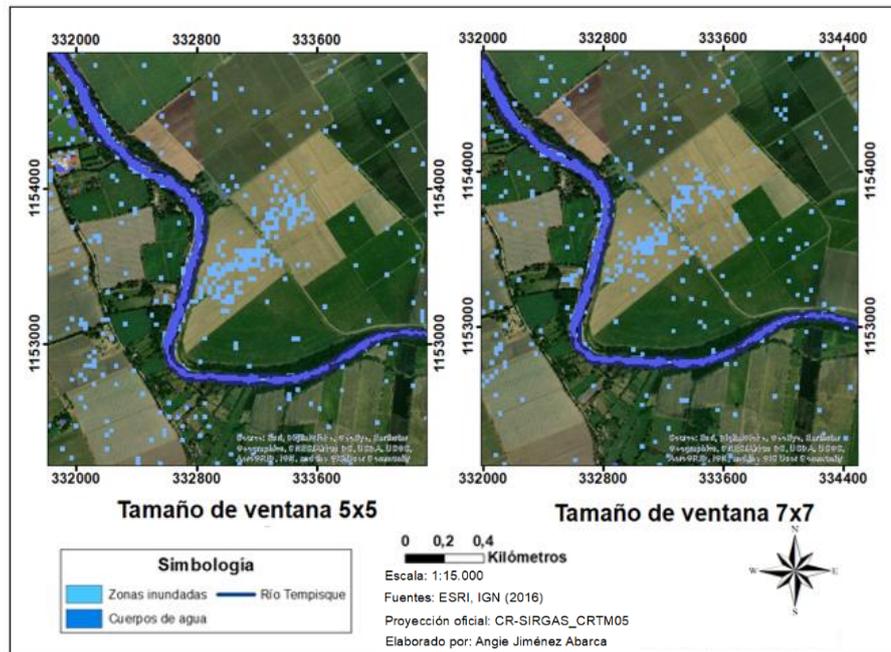
Visualmente no se aprecia diferencia entre las imágenes calibradas con Sigma 0 y las calibradas con Gamma 0. En la Figura 21 se puede observar, como la clasificación para las imágenes generadas con polarización VH, y filtro Lee 5x5, tuvieron resultados muy similares independientemente de la calibración radiométrica.



**Figura 21.** Comparación de calibración radiométrica Sigma 0 y Gamma 0 en mapas de inundación (polarización VH, filtro Lee y tamaño de ventana 5x5).

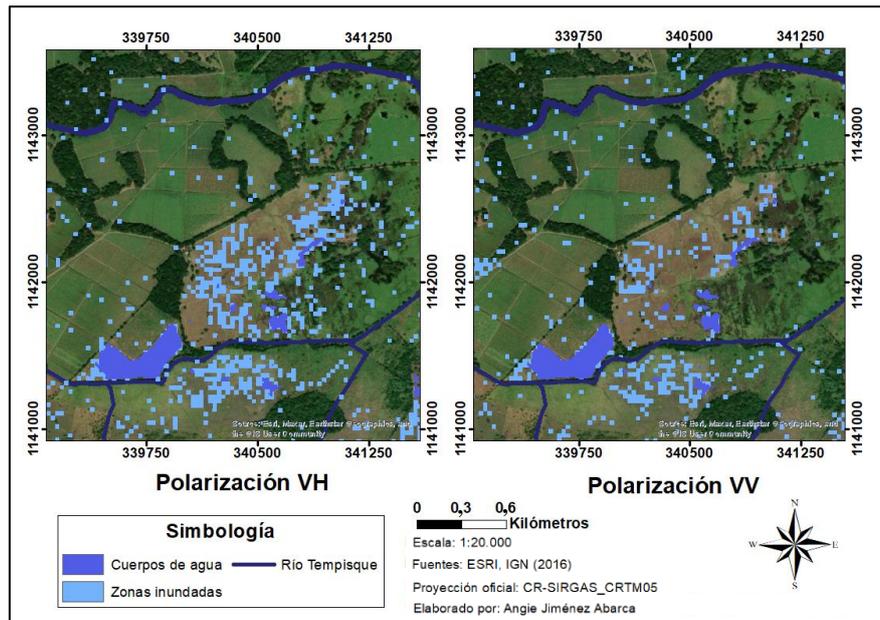
Para la banda VV, las diferencias en los resultados utilizando mismo filtro y diferente tamaño de ventana, no mostraron diferencias notables visualmente en la clasificación. En la Figura 22 se puede observar como la imagen procesada con tamaño de ventana 5x5 presenta ligeramente menos ruido que la imagen con un tamaño de ventana menor, pero no es notorio. Es importante

tener en cuenta que con la polarización VV en áreas montañosas, se presentan mayores distorsiones geométricas producidas por la geometría lateral del sensor, lo que significa que la extensión de la inundación derivada del SAR suele subestimarse en estas áreas (M. Zhang et al., 2020).



**Figura 22.** Comparación de tamaño de ventanas en filtros de ruido granular en mapas de inundación (polarización VV, filtro Lee Sigma y calibración sigma 0).

En la Figura 23 se presentan mapas con polarización VV y VH, donde se aprecian las diferencias respecto a las dos polarizaciones utilizadas. Es ligeramente notable a nivel visual como la polarización VH presenta mayor cantidad de área inundada que VV. Esto se debe a que bajo polarización VH, las características del coeficiente de retrodispersión especular debido a la inundación, son más detectadas que bajo la polarización VV. Por esto, según X. Zhang et al., (2021), para detección de inundaciones, es mejor la polarización VH en áreas con más vegetación y tipos de objetos terrestres complejos. Por lo tanto, se puede juzgar preliminarmente que en áreas con más vegetación y tipos de objetos terrestres complejos, la polarización VH es más propicia (X. Zhang et al., 2021).



**Figura 23.** Comparación de polarización VH y VV en mapas de inundación (calibración radiométrica Sigma 0, filtro Frost y tamaño de ventana 5x5).

Finalmente se calculó la extensión de la zona inundada para dos procesamientos diferentes. El primer cálculo corresponde a la imagen que visualmente presentó una mayor área de inundación. El segundo cálculo corresponde a la imagen que visualmente presentó una menor área de inundación. En la Tabla 11 se presenta un aproximado del área de inundación en la zona de estudio. Se puede corroborar que la polarización VH sí detecta una mayor área de inundación. Cabe destacar que, para el cálculo se descartaron los cuerpos de agua fijos como ríos y la siembra de arroz en aniego.

**Tabla 11.** Área aproximada de inundación en la zona de estudio mediante técnica RF (calibración radiométrica Sigma 0)

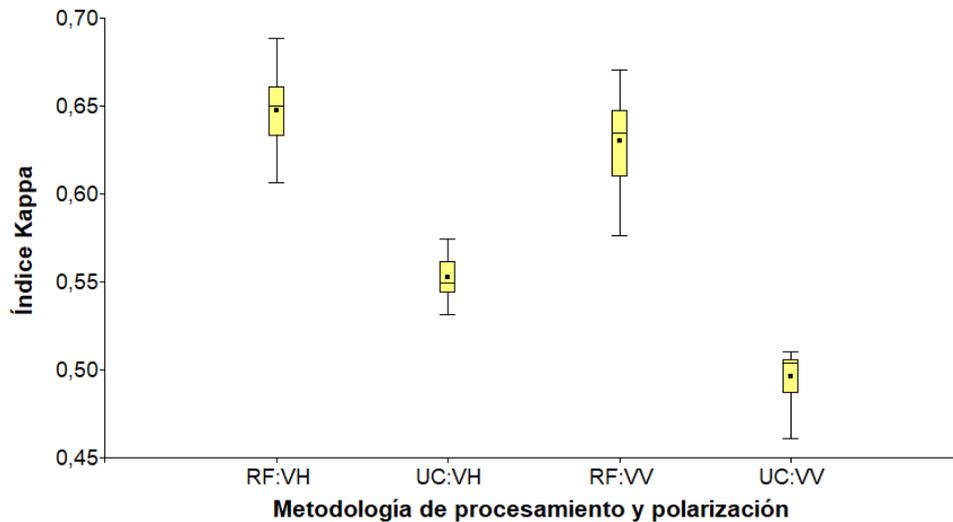
Especificaciones de procesamiento	Píxeles totales de inundación	Área (km <sup>2</sup> )
VH, Lee 5x5	123.753	73,768
VV, Lee Sigma 7x7	94.878	47,983

### 4.3. Análisis estadístico

#### 4.3.1. Índice Kappa

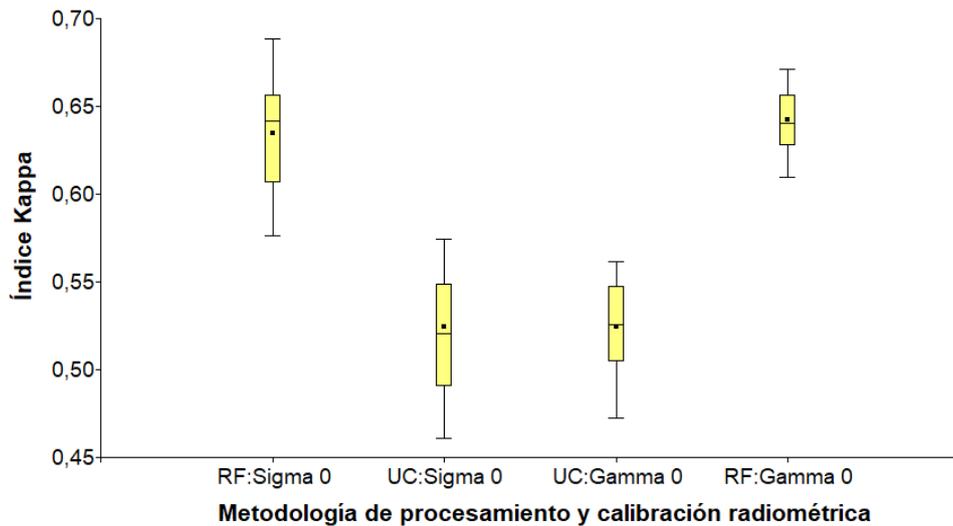
Los resultados del índice kappa de la prueba preliminar de procesamiento con el límite de inundación 0,2 se presentan en el Anexo 9, los cuales arrojaron resultados menos favorables con un kappa promedio de 0,35. Posteriormente se calculó el índice kappa con el límite de inundación 0,35, dichos resultados presentaron un mejor valor para el índice con un promedio de 0.6. Por lo que se determina que el límite de 0,35 es más favorable en este caso para la identificación de zonas inundadas con base en el índice NDWI, tal como se explicó en la sección 3.2.1.2. Los resultados de este apartado se basaron en límite 0,35.

En la Figura 24, se muestra el índice kappa de las imágenes SAR con respecto a la metodología de procesamiento y polarización. La polarización VH presenta un mayor índice con respecto a VV para ambas metodologías, lo cual coincide con Podest (2019), quien indica que la polarización VH presenta mejores resultados para detección de agua abierta. La metodología RF presentó mayores valores del índice kappa. Además, se puede apreciar que la técnica RF presenta una mayor dispersión de sus datos, mientras que UC presenta datos más concentrados.



**Figura 24.** Gráfico de cajas del índice kappa con respecto a la metodología de procesamiento y polarización, obtenido de InfoStat. Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de  $Q_1 - 1.5 \cdot RIC$  y  $Q_3 + 1.5 \cdot RIC$ , donde RIC es el rango inter-cuartil.

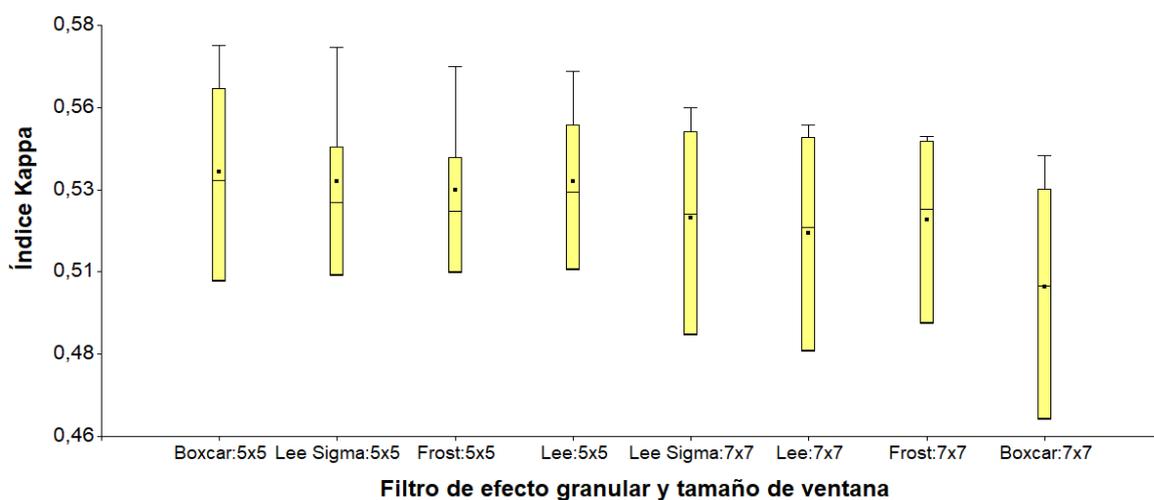
En la Figura 25 se presenta el índice kappa de las imágenes SAR con respecto a la metodología de procesamiento y la calibración radiométrica. La técnica de RF presentó un mayor índice, ambas calibraciones radiométricas presentaron medias semejantes; no obstante, Sigma 0 presenta una mayor dispersión en sus datos. Por otra parte, la técnica UC presentó un menor índice y medias semejantes para ambas calibraciones radiométricas. De igual manera, Gamma 0 presentó una menor dispersión en sus datos.



**Figura 25.** Gráfico de cajas del índice kappa con respecto a la metodología de procesamiento y calibración radiométrica, obtenido de InfoStat. Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de  $Q_1-1.5*RIC$  y  $Q_3+1.5*RIC$ , donde RIC es el rango inter-cuartil.

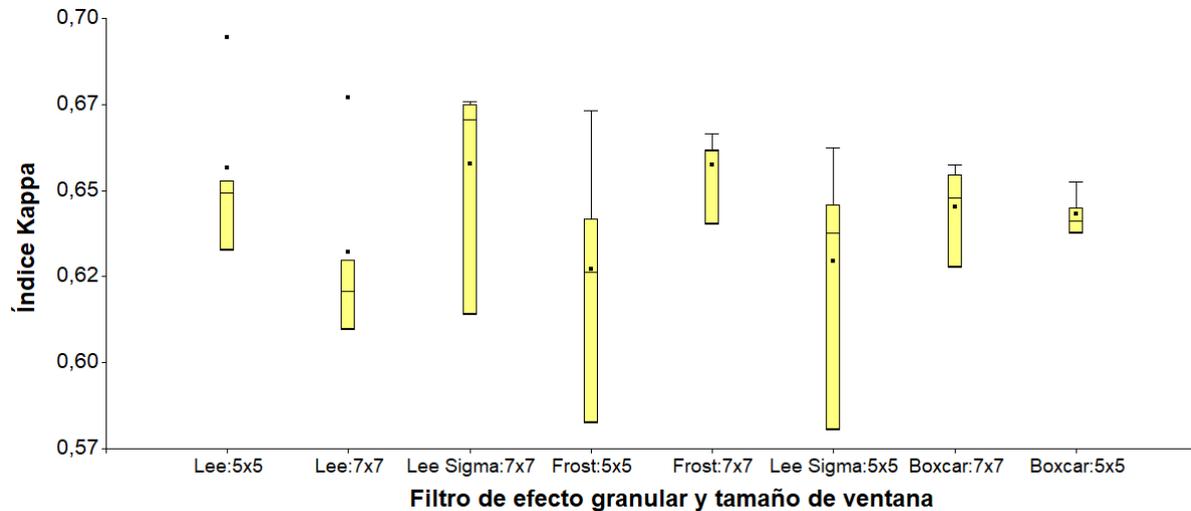
En la Figura 26 se muestra el índice kappa con respecto a los filtros de efecto granular y el tamaño de ventana para la técnica UC. El tamaño de ventana 5x5 presentó un mayor índice comparado al tamaño 7x7, lo cual coincide con los resultados obtenidos en el objetivo 1. El filtro Boxcar con tamaño de ventana 5x5 presentó el mayor promedio del índice kappa y Boxcar con tamaño de ventana 7x7 el menor.

En el objetivo 2 se determinó visualmente que el procesamiento con el filtro de efecto granular Frost y tamaño de ventana 5x5 identificó una mayor área de inundación. Por otra parte, el filtro Boxcar con tamaño de ventana 5x5, visualmente identificó un área menor. Por lo tanto, se denota la importancia del cálculo de índices de confiabilidad, ya que una metodología de procesamiento puede identificar una mayor área de inundación; sin embargo, no implica que esté correctamente identificada.



**Figura 26.** Gráfico de cajas del índice kappa con respecto al filtro de efecto granular y tamaño de ventana para la técnica UC, obtenido de InfoStat. Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de  $Q_1-1.5*RIC$  y  $Q_3+1.5*RIC$ , donde RIC es el rango inter-cuartil.

En la Figura 27, se muestra el índice kappa con respecto a los filtros de efecto granular y el tamaño de ventana para la técnica RF. A diferencia de la Figura 26, para RF se puede apreciar que no hay una diferencia marcada entre los tamaños de ventana 5x5 y 7x7. El filtro Lee con tamaño de ventana 5x5 presentó un mayor promedio del índice. Por otra parte, el filtro Frost con tamaño de ventana 5x5 presentó el menor promedio del índice.



**Figura 27.** Gráfico de cajas del índice kappa con respecto al filtro de efecto granular y tamaño de ventana para la técnica RF, obtenido de InfoStat. Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de  $Q_1 - 1.5 \cdot \text{RIC}$  y  $Q_3 + 1.5 \cdot \text{RIC}$ , donde RIC es el rango inter-cuartil.

A continuación, se presentan los resultados de las pruebas ANOVA y Tukey:

- Prueba ANOVA y Tukey del índice Kappa para metodología UC.

Los resultados de la prueba ANOVA, obtenida con el programa Infostat, para cada variable de clasificación en UC se muestran en la Tabla 12. El valor de p con base en la calibración radiométrica y filtro de efecto granular es mayor al nivel de significancia (0,05), por lo que se acepta la hipótesis nula; es decir, no existe diferencia significativa entre los resultados obtenidos a partir de la calibración radiométrica (Sigma 0 y Gamma 0), ni entre los resultados de los filtros de efecto granular (Lee, Lee Sigma, Boxcar y Frost). Esto se corrobora en la prueba Tukey de la Tabla 13 obtenida con Infostat, donde se muestra que las medias con letra en común no son significativamente diferentes.

Por otra parte, de acuerdo con la Tabla 12, el valor p según la polarización y tamaño de ventana es menor al nivel de significancia (0,05), por lo que se rechaza la hipótesis nula; es decir, existe una diferencia significativa entre los resultados según las variables de clasificación mencionadas. Los resultados de la banda VH presentaron una media mayor del índice kappa (ver Figura 24 y Tabla 13), lo cual corrobora que VH tiene una mayor utilidad en la identificación de inundaciones (Clement et al., 2017 y Podest, 2019), que en el presente proyecto corresponde a agua abierta. Por otra parte, los resultados de la variable del tamaño de ventana coinciden los resultados obtenidos en el objetivo 1 (en el cual se evalúa el desempeño de los filtros de efecto granular y el tamaño de ventana), ya que el tamaño de ventana 5x5 presentó una media mayor a 7x7. Estos resultados se corroboran en la prueba Tukey de la Tabla 13.

**Tabla 12.** Resultado del análisis de varianza SC tipo III del índice kappa para UC

Fuente de variación	SC	GL	CM	F	p
Modelo	$3,0 \times 10^{-2}$	6	$4,9 \times 10^{-3}$	43,09	<0,0001
Polarización	$3,0 \times 10^{-2}$	1	$3,0 \times 10^{-2}$	232,82	<0,0001
Calibración radiométrica	$3,6 \times 10^{-6}$	1	$3,6 \times 10^{-6}$	0,03	0,8596
Filtro de efecto granular	$3,8 \times 10^{-4}$	3	$1,3 \times 10^{-4}$	1,12	0,3582
Tamaño de ventana	$2,5 \times 10^{-3}$	1	$2,5 \times 10^{-3}$	22,32	0,0001
Error	$2,9 \times 10^{-3}$	25	$1,1 \times 10^{-4}$		
Total	$3,0 \times 10^{-2}$	31			

Suma de los cuadrados (SC), grados de libertad (GL), cuadrado medio (CM), valor F (F), valor p (p).  
n=32,  $\alpha=0,05$ .

**Tabla 13.** Resultado de prueba Tukey del índice kappa para UC

Fuente de variación		Media	n	EE		
Polarización	VV	0,50	16	$2,7 \times 10^{-3}$	A	
	VH	0,55	16	$2,7 \times 10^{-3}$		B
Calibración radiométrica	Sigma 0	0,53	16	$2,7 \times 10^{-3}$	A	
	Gamma 0	0,53	16	$2,7 \times 10^{-3}$	A	
Filtro de efecto granular	Boxcar	0,52	8	$3,8 \times 10^{-3}$	A	
	Lee	0,53	8	$3,8 \times 10^{-3}$	A	
	Frost	0,53	8	$3,8 \times 10^{-3}$	A	
	Lee Sigma	0,53	8	$3,8 \times 10^{-3}$	A	
Tamaño de ventana	7x7	0,52	16	$2,7 \times 10^{-3}$	A	
	5x5	0,53	16	$2,7 \times 10^{-3}$		B

Medias con una letra común no son significativamente diferentes ( $p > 0,05$ ).

Tamaño de muestra (n), error estándar (EE).

$\alpha=0,05$ .

- Prueba ANOVA y Tukey del índice Kappa para metodología RF.

En la Tabla 14 se presentan los resultados de la prueba ANOVA obtenida con el programa Infostat para las variables de clasificación de RF. El valor de p es mayor al nivel de significancia (0,05) para todas las variables de clasificación, por lo que se rechaza la hipótesis nula, no hay diferencia significativa entre los resultados de dichas variables. La Tabla 15 presenta los resultados de la prueba Tukey obtenida con Infostat, de la cual se corrobora que no hay diferencia significativa entre los resultados de las variables.

**Tabla 14.** Resultado del análisis de varianza SC tipo III del índice kappa para RF

Fuente de variación	SC	GL	CM	F	p
Modelo	$3,6 \times 10^{-3}$	6	$5,9 \times 10^{-4}$	0,81	0,569
Polarización	$2,4 \times 10^{-3}$	1	$2,4 \times 10^{-3}$	3,33	0,0801
Calibración radiométrica	$4,6 \times 10^{-4}$	1	$4,6 \times 10^{-4}$	0,64	0,4326
Filtro de efecto granular	$1,8 \times 10^{-5}$	3	$5,9 \times 10^{-6}$	0,01	0,9990
Tamaño de ventana	$6,5 \times 10^{-4}$	1	$6,5 \times 10^{-4}$	0,9	0,3528
Error	$2,0 \times 10^{-2}$	25			
Total	$2,0 \times 10^{-2}$	31			

Suma de los cuadrados (SC), grados de libertad (GL), cuadrado medio (CM), valor F (F), valor p (p).  
n=32,  $\alpha=0,05$ .

**Tabla 15.** Resultado de prueba Tukey del índice kappa para metodología RF

Fuente de variación		Media	n	EE	
Polarización	VV	0,63	16	0,01	A
	VH	0,65	16	0,01	A
Calibración radiométrica	Sigma 0	0,64	16	0,01	A
	Gamma 0	0,64	16	0,01	A
Filtro de efecto granular	Boxcar	0,64	8	0,01	A
	Lee	0,64	8	0,01	A
	Frost	0,64	8	0,01	A
	Lee Sigma	0,64	8	0,01	A
Tamaño de ventana	7x7	0,65	16	0,01	A
	5x5	0,64	16	0,01	A

Medias con una letra común no son significativamente diferentes ( $p > 0,05$ ).

Tamaño de muestra (n), error estándar (EE).  
 $\alpha=0,05$ .

- Prueba ANOVA y Tukey del índice Kappa para ambas metodologías UC y RF.

En la Tabla 16 se presentan los resultados de la ANOVA obtenida con el programa Infostat para ambas metodologías de procesamiento UC y RF. Para esto se tomó como base los resultados del índice kappa de cada imagen SAR. Ambas metodologías de procesamiento presentaron resultados significativamente diferentes, esto debido a que el valor de p es menor al nivel de significancia (0,05), por lo que se rechaza la hipótesis nula. La media del índice kappa obtenida por RF fue de 0,64, mientras que para que UC fue de 0,53. Lo anterior indica que, de acuerdo con el índice kappa, la metodología de RF presenta una mayor confiabilidad en sus resultados. En la prueba Tukey de la Tabla 17, obtenida de Infostat, también se puede apreciar que ambas metodologías de procesamiento son significativamente diferentes.

**Tabla 16.** Resultado del análisis de varianza SC tipo III del índice kappa para las metodologías de procesamiento UC y RF

<b>Fuente de variación</b>	<b>SC</b>	<b>GL</b>	<b>CM</b>	<b>F</b>	<b>p</b>
Modelo	0,21	1	0,21	245,54	<0,0001
Metodologías de procesamiento	0,21	1	0,21	245,54	<0,0001
Error	0,05	62	8,7 x10 <sup>-4</sup>		
Total	0,27	63			

Suma de los cuadrados (SC), grados de libertad (GL), cuadrado medio (CM), valor F (F), valor p (p). n=64,  $\alpha=0,05$ .

**Tabla 17.** Resultado de prueba Tukey del índice kappa para ambas metodologías UC y RF

<b>Metodología de procesamiento</b>	<b>Media</b>	<b>n</b>	<b>EE</b>	
UC	0,53	32	0,01	A
RF	0,64	32	0,01	B

Medias con una letra común no son significativamente diferentes ( $p > 0,05$ ).

Tamaño de muestra (n), error estándar (EE).

$\alpha=0,05$ .

En el Anexo 10 se presentan los resultados completos del índice kappa.

Con base en los resultados del índice kappa, en la Tabla 18 se presenta un resumen de las combinaciones más confiables para cada metodología de procesamiento.

**Tabla 18.** Resumen de combinaciones más confiables para metodologías de procesamiento según el índice kappa

<b>Metodología de procesamiento</b>	<b>Polarización</b>	<b>Calibración radiométrica</b>	<b>Filtro de efecto granular</b>	<b>Tamaño de ventana</b>
Random Forest	VH	Sigma 0	Lee	5x5
		Gamma 0	Lee	7x7
Umbral de Calibración	VH	Sigma 0	Boxcar	5x5
		Sigma 0	Frost	5x5

En la Tabla 19 se presenta un resumen de las combinaciones menos confiables para cada metodología de procesamiento.

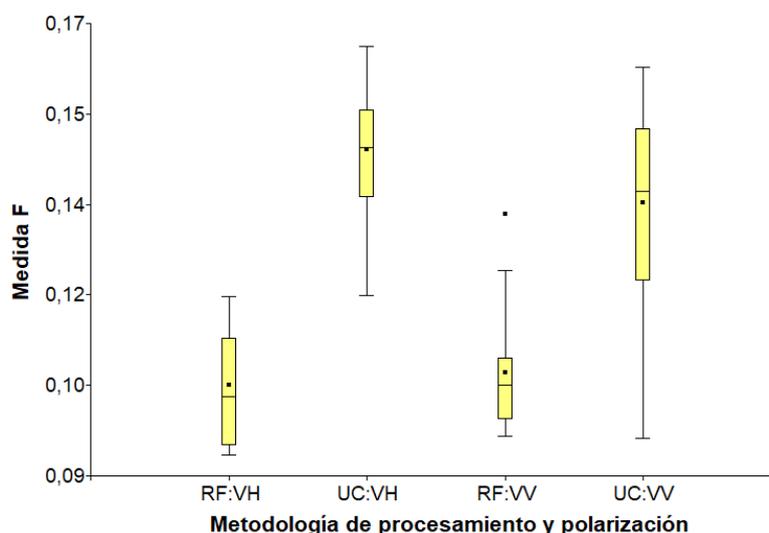
**Tabla 19.** Resumen de combinaciones menos confiables para metodologías de procesamiento según el índice kappa

Metodología de procesamiento	Polarización	Calibración radiométrica	Filtro de efecto granular	Tamaño de ventana
Random Forest	VV	Sigma 0	Lee Sigma Frost	5x5
Umbrales de Calibración	VV	Sigma 0 Gamma 0	Boxcar Boxcar	7x7

#### 4.3.2. Medida F

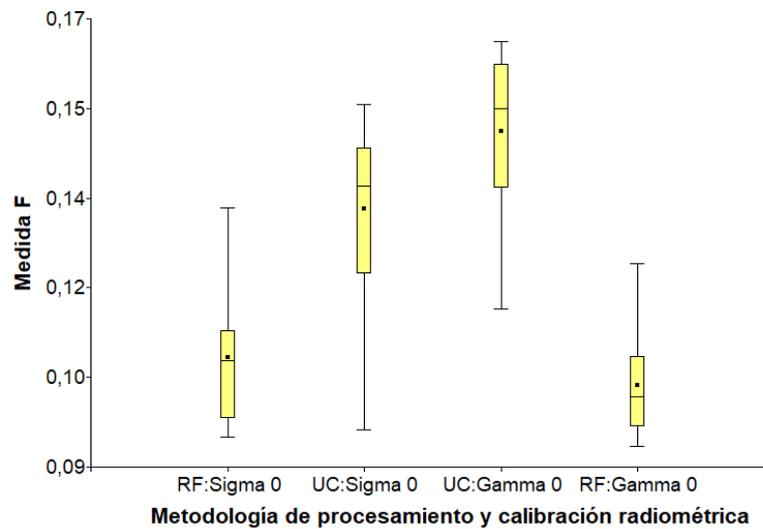
Los resultados de la medida F de la prueba preliminar de procesamiento con el límite de inundación 0,2 se presentan en el Anexo 9. Posteriormente se calculó este parámetro con el límite de inundación 0,35, dichos resultados presentaron un mejor valor de medida F. Por lo que se determina que el límite de 0,35 para la identificación de zonas inundadas con base en el índice NDWI; como se explicó en la sección 3.2.1.2. Los resultados de este apartado se basaron en límite 0,35 para el caso de estudio.

Respecto a la medida F, los resultados de la prueba estadística ANOVA realizada en Infostat, muestran que la técnica de UC tuvo mayores valores en este parámetro, lo que significa que la media armónica de la precisión y la recuperación del modelo es más confiable (M. Zhang et al., 2020) que para la técnica de RF. En la Figura 28 se presenta el gráfico de cajas de la medida F con respecto a la metodología de procesamiento y polarización, donde se puede observar también que la polarización VH tuvo mejores resultados para la técnica de UC y la polarización VV obtuvo mejores resultados para la técnica RF, esto para a la medida F.



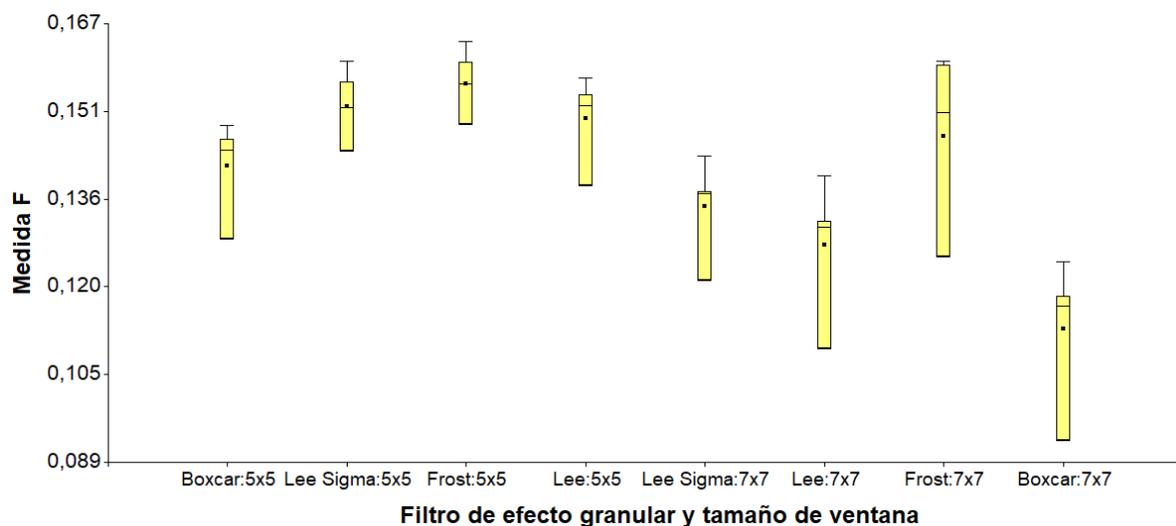
**Figura 28.** Gráfico de cajas de la medida F con respecto a la metodología de procesamiento y polarización, obtenido de InfoStat. Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de  $Q_1 - 1.5 * RIC$  y  $Q_3 + 1.5 * RIC$ , donde RIC es el rango inter-cuartil.

La calibración radiométrica influyó en los resultados de la medida F, como se muestra en la Figura 29. Se presentaron mejores valores de este parámetro para la calibración Gamma 0 utilizando la técnica de UC, mientras para RF los mejores resultados correspondieron a los preprocesados con la calibración Sigma 0.



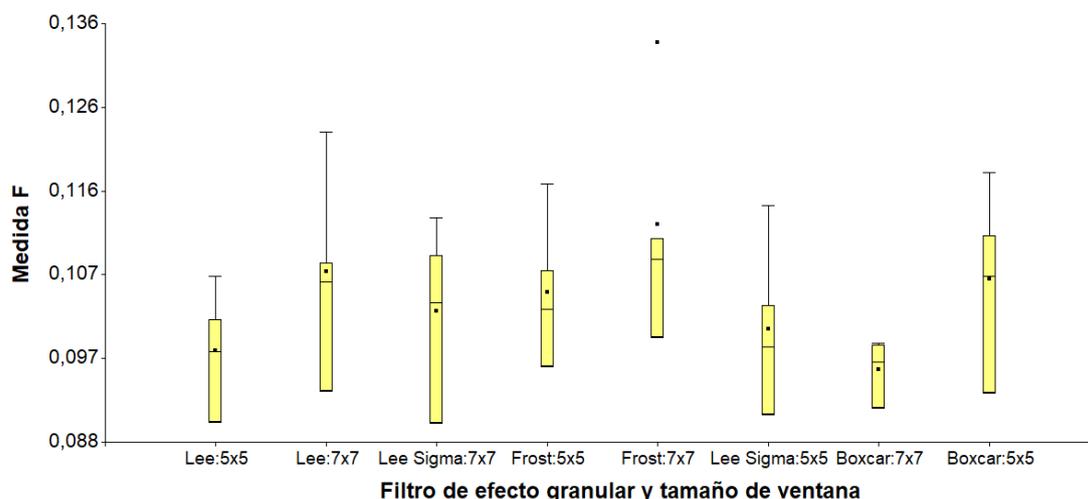
**Figura 29.** Gráfico de cajas de la medida F con respecto a la metodología de procesamiento y calibración radiométrica, obtenido de InfoStat. Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de  $Q_1 - 1.5 * RIC$  y  $Q_3 + 1.5 * RIC$ , donde RIC es el rango inter-cuartil.

En la Figura 30 se muestra la medida F con respecto a los filtros de efecto granular y el tamaño de ventana para la técnica UC. El tamaño de ventana 5x5 presentó un mayor índice con respecto al tamaño 7x7, al igual que para el índice kappa (ver sección 4.3.1). El filtro Frost 5x5 presentó el mayor promedio en la medida F y Boxcar 7x7 el menor, resultados correspondientes a los de la evaluación del rendimiento de los filtros de efecto granular (ver sección 4.1).



**Figura 30.** Gráfico de cajas de la medida F con respecto al filtro de efecto granular y tamaño de ventana para la técnica UC, obtenido de InfoStat. Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de  $Q_1 - 1.5 * RIC$  y  $Q_3 + 1.5 * RIC$ , donde RIC es el rango inter-cuartil.

En la Figura 31, se muestra la medida F con respecto a los filtros al filtro de efecto granular y el tamaño de ventana para la técnica RF. El filtro Boxcar con tamaño de ventana 7x7 presentó un menor promedio en el resultado. El mayor promedio, lo presentó Frost con tamaño de ventana 7x7.



**Figura 31.** Gráfico de cajas de la medida F con respecto al filtro de efecto granular y tamaño de ventana para la técnica RF, obtenido de InfoStat. Cajas definidas por el primer cuartil (Q<sub>1</sub>), mediana y tercer cuartil (Q<sub>3</sub>). Líneas (bigotes) definidos según criterio de Q<sub>1</sub>-1.5\*RIC y Q<sub>3</sub>+1.5\*RIC, donde RIC es el rango inter-cuartil.

A continuación, se presentan los resultados de las pruebas ANOVA y Tukey:

- Prueba ANOVA y Tukey de la Medida F para metodología UC

Los resultados de la prueba ANOVA obtenidos con el programa Infostat para cada variable de clasificación en UC se muestran en la Tabla 20. El valor de p con base en la polarización, calibración radiométrica, filtro de efecto granular y tamaño de ventana es menor al nivel de significancia (0,05), por lo que se rechaza la hipótesis nula; es decir, sí existe diferencia significativa entre los resultados obtenidos a partir de la calibración radiométrica (Sigma 0 y Gamma 0), entre las polarizaciones utilizadas (VV y VH), entre los resultados de los filtros de efecto granular (Lee, Lee Sigma, Boxcar y Frost) y entre los diferentes tamaños de ventana (5x5 y 7x7). Estos resultados se corroboran en la Tabla 21, la cual muestra los resultados de la prueba Tukey obtenidos de Infostat. De acuerdo con la Tabla 21, no existe diferencia significativa entre Lee Sigma y Lee, así como entre Lee Sigma y Frost.

**Tabla 20.** Resultado del análisis de varianza SC tipo III de la medida F para UC

Fuente de variación	SC	GL	CM	F	p
Modelo	0,01	6	1,3E-03	32,46	<0,0001
Polarización	7,4E-04	1	7,4E-04	18,18	0,0003
Calibración radiométrica	1,6E-03	1	1,6E-03	39,35	<0,0001
Filtro de efecto granular	2,5E-03	3	8,3E-04	20,53	<0,0001
Tamaño de ventana	3,1E-03	1	3,1E-03	75,67	<0,0001
Error	1,0E-03	25	4,1E-05		
Total	0,01	31			

Suma de los cuadrados (SC), grados de libertad (GL), cuadrado medio (CM), valor F (F), valor p (p). n=32,  $\alpha=0,05$ .

**Tabla 21.** Resultado de prueba Tukey de medida F para UC

Fuente de variación		Media	n	EE		
Polarización	VV	0,14	16	$1,6 \times 10^{-3}$	A	
	VH	0,15	16	$1,6 \times 10^{-3}$		B
Calibración radiométrica	Sigma 0	0,13	16	$1,6 \times 10^{-3}$	A	
	Gamma 0	0,15	16	$1,6 \times 10^{-3}$		B
Filtro de efecto granular	Boxcar	0,13	8	$2,3 \times 10^{-3}$	A	
	Lee	0,14	8	$2,3 \times 10^{-3}$		B
	Lee Sigma	0,14	8	$2,3 \times 10^{-3}$		B C
	Frost	0,15	8	$2,3 \times 10^{-3}$		C
Tamaño de ventana	7x7	0,13	16	$1,6 \times 10^{-3}$	A	
	5x5	0,15	16	$1,6 \times 10^{-3}$		B

Medias con una letra común no son significativamente diferentes ( $p > 0,05$ ).

Tamaño de muestra (n), error estándar (EE).

$\alpha=0,05$ .

- Prueba ANOVA y Tukey de la Medida F para metodología RF.

Los resultados de la prueba ANOVA obtenidos de Infostat para cada variable de clasificación en RF se muestran en la Tabla 22. El valor de p con base en la polarización, calibración radiométrica, filtro de efecto granular y tamaño de ventana es mayor al nivel de significancia (0,05), por lo que se acepta la hipótesis nula; es decir, no existe diferencia significativa entre los resultados obtenidos a partir de la calibración radiométrica (Sigma 0 y Gamma 0), entre las polarizaciones utilizadas (VV y VH), entre los resultados de los filtros de efecto granular (Lee, Lee Sigma, Boxcar y Frost) ni entre los diferentes tamaños de ventana (5x5 y 7x7). La Tabla 23 presenta los resultados de la prueba Tukey obtenidos de Infostat, los cuales indican que no existe diferencia significativa entre las variables de clasificación. Estos resultados de la medida F coinciden con los del índice kappa, ya que en ambos casos la metodología RF no presentó diferencia significativa con respecto a las variables de clasificación.

**Tabla 22.** Resultado del análisis de varianza SC tipo III de la medida F para RF

Fuente de variación	SC	GL	CM	F	p
Modelo	$5,7 \times 10^{-4}$	6	$9,5 \times 10^{-5}$	0,83	0,5545
Polarización	$4,2 \times 10^{-5}$	1	$4,2 \times 10^{-5}$	0,37	0,5484
Calibración radiométrica	$2,0 \times 10^{-4}$	1	$2,0 \times 10^{-4}$	1,77	0,1956
Filtro de efecto granular	$2,9 \times 10^{-4}$	3	$9,7 \times 10^{-5}$	0,85	0,4782
Tamaño de ventana	$3,6 \times 10^{-5}$	1	$3,6 \times 10^{-5}$	0,31	0,5812
Error	$2,9 \times 10^{-3}$	25	$1,1 \times 10^{-4}$		
Total	$3,4 \times 10^{-3}$	31			

Suma de los cuadrados (SC), grados de libertad (GL), cuadrado medio (CM), valor F (F), valor p (p).  
n=32,  $\alpha=0,05$ .

**Tabla 23.** Resultado de prueba Tukey de medida F para RF

Fuente de variación		Media	n	EE	
Polarización	VV	0,10	16	$2,7 \times 10^{-3}$	A
	VH	0,10	16	$2,7 \times 10^{-3}$	A
Calibración radiométrica	Sigma 0	0,11	16	$2,7 \times 10^{-3}$	A
	Gamma 0	0,10	16	$2,7 \times 10^{-3}$	A
Filtro de efecto granular	Boxcar	0,10	8	$3,8 \times 10^{-3}$	A
	Lee	0,10	8	$3,8 \times 10^{-3}$	A
	Frost	0,11	8	$3,8 \times 10^{-3}$	A
	Lee Sigma	0,10	8	$3,8 \times 10^{-3}$	A
Tamaño de ventana	7x7	0,10	16	$2,7 \times 10^{-3}$	A
	5x5	0,10	16	$2,7 \times 10^{-3}$	A

Medias con una letra común no son significativamente diferentes ( $p > 0,05$ ).

Tamaño de muestra (n), error estándar (EE).

$\alpha=0,05$ .

- Prueba ANOVA y Tukey de la Medida F para ambas metodologías UC y RF

A partir la prueba ANOVA obtenida de Infostat de los resultados de la medida F para todas las imágenes procesadas, se puede observar en la Tabla 24, que el valor de p para las metodologías de procesamiento es menor al nivel de significancia (0,05), por lo que se rechaza la hipótesis nula. Sí existe diferencia significativa en los resultados de medida F entre las dos técnicas de procesamiento utilizadas. En la Tabla 25 se presentan los resultados de la prueba Tukey obtenida de Infostat, en la cual también se establece una diferencia significativa de la media de la medida F para ambas metodologías, siendo mayor el valor de UC que el de RF. Al ser RF una técnica de Machine Learning, que clasifica mediante árboles de decisión, los cuáles pueden verse alterados por incongruencias en la retrodispersión debido al ruido granular o a la localización de los pixeles de entrenamiento.

**Tabla 24.** Resultado del análisis de varianza SC tipo III de la medida F para las metodologías de procesamiento UC y RF

Fuente de variación	SC	GL	CM	F	p
Modelo	0,02	1	0,02	108,83	<0,0001
Metodología de procesamiento	0,02	1	0,02	108,83	<0,0001
Error	0,01	62	$2,0 \times 10^{-4}$		
Total	0,03	63			

Suma de los cuadrados (SC), grados de libertad (GL), cuadrado medio (CM), valor F (F), valor p (p).  
n=64,  $\alpha=0,05$ .

**Tabla 25.** Resultado de prueba Tukey para ambas metodologías UC y RF

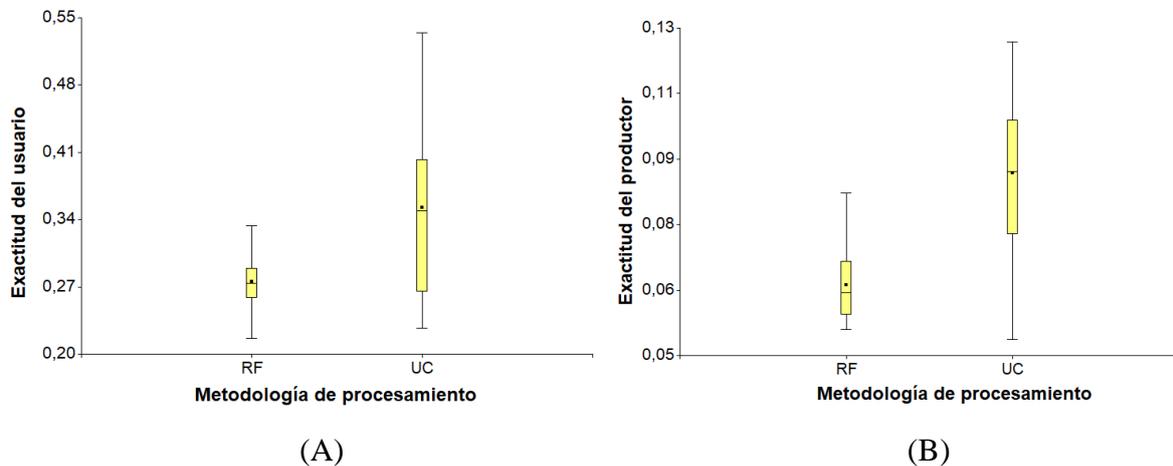
Metodología de procesamiento	Media	n	EE	
UC	0,14	32	$2,5 \times 10^{-3}$	A
RF	0,10	32	$2,5 \times 10^{-3}$	B

Medias con una letra común no son significativamente diferentes ( $p > 0,05$ ).

Tamaño de muestra (n), error estándar (EE).

$\alpha=0,05$ .

La exactitud del usuario y del productor para RF es significativamente menor que las mismas para UC, como se presenta en los gráficos de la Figura 32. Por esta razón la medida F presenta valores mayores para UC que para RF. Demostrando que UC tiene mejor confiabilidad en la clasificación según este índice. En el Anexo 10 se puede notar como la sensibilidad de RF es mucho mayor que la de UC, lo que significa baja exactitud del productor.



**Figura 32.** Gráfico de cajas para exactitud del usuario (A) y exactitud del productor (B). Cajas definidas por el primer cuartil ( $Q_1$ ), mediana y tercer cuartil ( $Q_3$ ). Líneas (bigotes) definidos según criterio de  $Q_1 - 1.5 * RIC$  y  $Q_3 + 1.5 * RIC$ , donde RIC es el rango inter-cuartil.

Con base en los resultados de la medida F, en la Tabla 26 se presenta un resumen de las combinaciones más confiables para cada metodología de procesamiento.

**Tabla 26.** Resumen de combinaciones más confiables para metodologías de procesamiento según la medida F

Metodología de procesamiento	Polarización	Calibración radiométrica	Filtro de efecto granular	Tamaño de ventana
Random Forest	VV	Sigma 0	Lee Sigma	5x5
		Gamma 0	Lee Sigma	7x7
Umbral de Calibración	VH	Gamma 0	Frost	5x5
		Gamma 0	Lee Sigma	5x5

En la Tabla 27 se presenta un resumen de las combinaciones menos confiables para cada metodología de procesamiento.

**Tabla 27.** Resumen de combinaciones menos confiables para metodologías de procesamiento según la medida F

Metodología de procesamiento	Polarización	Calibración radiométrica	Filtro de efecto granular	Tamaño de ventana
Random Forest	VH	Sigma 0	Lee Sigma Frost	7x7
Umbrales de Calibración	VV	Sigma 0 Sigma 0	Boxcar Lee	7x7

En el Anexo 10 se presentan los resultados completos de la medida F.

#### 4.3.3. Resumen de resultados del Índice Kappa y Medida F

La metodología con mejor exactitud en la detección de áreas inundadas y la posibilidad de detectar las mismas áreas con una clasificación correcta fue con el clasificador RF; utilizando polarización VH, calibración radiométrica Sigma 0, filtro de efecto granular Lee con tamaño de ventana 5x5 (ver Tabla 18). Para el clasificador de UC, la mejor metodología para detectar áreas inundadas con una clasificación correcta fue utilizando polarización VH, calibración radiométrica Sigma 0, filtro de efecto granular Boxcar con número de ventana 5x5 (ver Tabla 18).

La metodología con mejor rendimiento combinado de sensibilidad y especificidad fue con el clasificador UC; utilizando polarización VH, calibración radiométrica Gamma 0, filtro de efecto granular Frost con número de ventana 5x5 (ver Tabla 26). Para el clasificador de RF, la metodología con un mejor modelo más equilibrado respecto a la precisión de usuario y precisión de productor fue utilizando polarización VH, calibración radiométrica Sigma 0, filtro de efecto granular Lee Sigma con tamaño de ventana 7x7 (ver Tabla 26).

En este caso de estudio, la mejor polarización para detectar áreas inundadas fue VH. Así como la mejor calibración radiométrica fue con Sigma 0 y tamaño de ventana 5x5. Y los mejores filtros fueron Boxcar, Lee Sigma y Lee.

#### 4.3.4. Efecto de aleatoriedad en datos de entrenamiento

Se realizó una prueba ANOVA y Tukey para determinar si existe una diferencia significativa entre tres diferentes series de datos de entrenamiento generados de forma aleatoria, para esto se tomó como base los resultados del índice kappa y medida F de cada imagen SAR. Los resultados de este apartado se basaron en el límite de inundación 0,35 con base el índice NDWI.

Los resultados de la prueba ANOVA para el índice kappa obtenidos de Infostat se muestran en la Tabla 28. El valor de p para las series de datos es mayor al nivel de significancia (0,05), por lo que se acepta la hipótesis nula; es decir, no existe diferencia significativa entre las tres series de datos de entrenamiento generadas de forma aleatoria. La Tabla 29 presenta los resultados de la prueba Tukey obtenida de Infostat, en esta se corrobora que no existe diferencia significativa entre las tres series de datos, las cuales están conformadas por cuatro imágenes SAR preprocesadas de forma diferente.

**Tabla 28.** Resultado del análisis de varianza SC tipo III en la aleatoriedad de datos de entrenamiento del índice kappa

Fuente de variación	SC	GL	CM	F	p
Modelo	$1,0 \times 10^{-3}$	2	$5,0 \times 10^{-4}$	0,59	0,5766
Serie de datos	$1,0 \times 10^{-3}$	2	$5,0 \times 10^{-4}$	0,59	0,5766
Error	0,01	9	$8,5 \times 10^{-4}$		
Total	0,01	11			

Suma de los cuadrados (SC), grados de libertad (GL), cuadrado medio (CM), valor F (F), valor p (p). n=12,  $\alpha=0,05$ .

**Tabla 29.** Resultado de prueba Tukey en la aleatoriedad de datos de entrenamiento del índice kappa para la metodología de procesamiento

Serie de datos	Media	n	EE	
3	0,37	4	0,01	A
1	0,37	4	0,01	A
2	0,39	4	0,01	A

Medias con una letra común no son significativamente diferentes ( $p > 0,05$ ).

Tamaño de muestra (n), error estándar (EE).

$\alpha=0,05$ .

En la Tabla 30 se muestran los resultados de la prueba ANOVA para la medida F obtenidos de Infostat, el valor de p para las series de datos es mayor al nivel de significancia (0,05), por lo que se acepta la hipótesis nula, no hay diferencia significativa entre las series de datos generados aleatoriamente. En la Tabla 31 se presentan los resultados de la prueba Tukey obtenidos de Infostat, en la cual se confirma que no hay diferencias significativas entre las series de datos de entrenamiento.

**Tabla 30.** Resultado del análisis de varianza SC tipo III en la aleatoriedad de datos de entrenamiento de la medida F

Fuente de variación	SC	GL	CM	F	p
Modelo	$5,0 \times 10^{-4}$	2	$2,5 \times 10^{-4}$	1.09	0,3757
Serie de datos	$5,0 \times 10^{-4}$	2	$2,5 \times 10^{-4}$	1.09	0,3757
Error	$2,1 \times 10^{-3}$	9	$2,5 \times 10^{-4}$		
Total	$2,6 \times 10^{-3}$	11			

Suma de los cuadrados (SC), grados de libertad (GL), cuadrado medio (CM), valor F (F), valor p (p). n=12,  $\alpha=0,05$ .

**Tabla 31.** Resultado de prueba Tukey en la aleatoriedad de datos de entrenamiento de la medida F para la metodología de procesamiento

Serie de datos	Media	n	EE	
1	0,11	4	0,01	A
2	0,13	4	0,01	A
3	0,12	4	0,01	A

Medias con una letra común no son significativamente diferentes ( $p > 0,05$ ).

Tamaño de muestra (n), error estándar (EE).  $\alpha=0,05$ .

A partir de los resultados obtenidos de las pruebas ANOVA, se definió que solo se realizaría el procesamiento de imágenes SAR mediante las metodologías de UC y RF a partir de una serie de datos de entrenamiento (70%) y validación (30%). La aleatoriedad en la generación de datos de entrenamiento y validación no es una fuente de variación en los resultados de la presente investigación.

## 5. CONCLUSIONES

- A partir de la evaluación de las metodologías de preprocesamiento, se concluye que la metodología que presentó un mejor rendimiento en la corrección del ruido granular para la polarización VH es el filtro Frost, con tamaño de ventana de 5x5 y calibración radiométrica Gamma 0. Con medidas de MSE, PSNR y AD de 868,0, 18,7 y 19,1 respectivamente. Mientras el desempeño más bajo lo presentó el filtro Boxcar con tamaño de ventana de 7x7 y calibración radiométrica Sigma 0. Con medidas de MSE, PSNR y AD de 1691,9, 15,8 y 26,8 respectivamente.
- La metodología de preprocesamiento que presentó un mejor rendimiento en la corrección del ruido granular para la polarización VV es el filtro Frost, con tamaño de ventana de 5x5 y calibración radiométrica Sigma 0. Con medidas de MSE, PSNR y AD de 602,6, 20,3 y 15,4 respectivamente. Mientras el desempeño más bajo lo presentó el filtro Boxcar con tamaño de ventana de 7x7 y calibración radiométrica Sigma 0. Con medidas de MSE, PSNR y AD de 1264,8, 17,1 y 22,5 respectivamente
- Con respecto a la técnica UC, se calculó un área de 69,880 km<sup>2</sup> y 30,432 km<sup>2</sup> para el procesamiento más y menos confiable, respectivamente según el objetivo 1. Mientras para RF, se calculó un área de 73,768 km<sup>2</sup> y 47,983 km<sup>2</sup> para el procesamiento más y menos confiable, respectivamente según el objetivo 1.
- La metodología de RF presentó una mayor confiabilidad en sus resultados del índice kappa con respecto a UC, esto debido a que presentó una media mayor del índice (0,64). Lo que significa que RF resultó con mejor exactitud en la detección de áreas inundadas y la posibilidad de detectar las mismas áreas con una clasificación correcta; esto con una polarización VV, calibración radiométrica Sigma 0 y filtro Lee Sigma con tamaño de ventana 5x5. Para el clasificador de UC, la mejor metodología para detectar áreas inundadas con una clasificación correcta, fue utilizando polarización VH, calibración radiométrica Sigma 0, filtro de efecto granular Boxcar con número de ventana 5x5.
- La metodología de UC presentó una mayor confiabilidad en sus resultados de la medida F con respecto a RF, esto debido a que presentó una media mayor de la medida F (0,14). Lo que significa que el mayor rendimiento combinado de sensibilidad y especificidad fue con el clasificador UC; utilizando polarización VH, calibración radiométrica Gamma 0, filtro de efecto granular Frost con número de ventana 5x5. Por otra parte, para RF el procesamiento con mayor confiabilidad presentó polarización VV, calibración Sigma 0 y filtro de efecto granular Lee Sigma con tamaño de ventana 5x5.
- La mejor polarización para detectar áreas inundadas fue VH. Así como la mejor calibración radiométrica fue con Sigma 0 y tamaño de ventana 5x5. Y los mejores filtros fueron Boxcar, Lee Sigma y Lee.

- Los resultados de la evaluación del preprocesamiento no fueron correspondientes con la evaluación de las clasificaciones, ya que los filtros con mejor rendimiento en la eliminación del efecto sal y pimienta tuvieron bajos índices kappa en la clasificación de inundaciones. Esto se puede deber a que la eliminación del efecto sal y pimienta disminuya la eficiencia de los clasificadores utilizados durante la detección de inundación.
- El efecto de ruido granular en las imágenes SAR conduce a errores en la clasificación de zonas inundadas que realmente no lo están; es decir, genera falsos negativos y falsos positivos en el modelo. Este fenómeno se observó en todas las metodologías utilizadas.
- Las inundaciones generadas debido a la tormenta tropical Nate tuvieron un tiempo de permanencia de al menos 6 días en la zona de estudio, ya que se detectaron zonas inundadas en la zona 6 días después del evento.
- El clasificador de UC presenta mayor facilidad de uso y rapidez en la generación de resultados, por lo que se recomienda para análisis y toma de decisiones durante los eventos hidrometeorológicos. RF tiene potencial de ser un clasificador más robusto con mayor precisión, pero al depender de la calidad en el tratamiento de los datos de entrenamiento y de las variables de aprendizaje automático, se recomienda para análisis posteriores a los eventos.

## **6. RECOMENDACIONES**

- Se recomienda tomar en cuenta el efecto de las ciudades, en este caso las zonas urbanas correspondieron a un porcentaje despreciable de la imagen completa, razón por la cual se descartó su efecto. Esto no significa que estos no sean significativos en otra zona o análisis diferente; por lo que se recomienda descartar las zonas urbanas del análisis previo a la clasificación, con datos confiables correspondientes al uso del suelo de la zona.
- Antes de llevar a cabo una evaluación de clasificadores para la identificación de inundaciones se recomienda verificar la disponibilidad y accesibilidad de imágenes satelitales del sitio de estudio en la fecha de interés. Además, verificar que la imagen satelital no presente una alta nubosidad, ya que podría inducir a errores en la verificación de resultados.
- Desarrollar la metodología de preprocesamiento y procesamiento del presente proyecto en un área de estudio diferente y bajo un evento hidrometeorológico con diferentes características. Esto con el fin de emplear imágenes SAR que hayan sido capturadas en fechas más cercanas al evento y que por ende detecten mayores áreas de inundación que puedan ser de utilidad para las entidades encargadas de la gestión del riesgo en el país. Además, para realizar una comparación entre el desempeño de las metodologías de preprocesamiento y procesamiento.
- Replicar esta investigación empleando datos de topografía LiDAR de la zona de estudio en la corrección geométrica del preprocesamiento, esto con el fin de comparar los resultados de las investigaciones y determinar si hay una mejoría y/o diferencia significativa en el rendimiento de las metodologías de estudio.

- Para análisis en vegetación inundada, se recomienda el uso de RF, pues la retrodispersión generada en estas condiciones (doble rebote) es más alta que el umbral seleccionado con el clasificador UC. Lo que genera un enmascaramiento de las zonas inundadas vegetadas con zonas de alta retrodispersión como zonas urbanas.
- Se recomienda generar investigaciones variando la cantidad de árboles de decisión en el clasificador RF, para determinar si lo recomendado en la bibliografía (500 árboles de decisión) es lo correspondiente para la detección de inundación en la zona de estudio ya que la cantidad de clases es pequeña (inundado, no inundado). Esto mejoraría la eficiencia del algoritmo, reduciendo los tiempos de ejecución.
- Para obtener una mejor aproximación de las áreas de inundación se recomienda emplear imágenes SAR más cercanas al evento de inundación.

## 7. REFERENCIAS

- Acharya, T. D., Subedi, A., & Lee, D. H. (2018). Evaluation of Water Indices for Surface Water Extraction in a Landsat 8 Scene of Nepal. *Sensors* 2018, Vol. 18, Page 2580, 18(8), 2580. <https://doi.org/10.3390/S18082580>
- Agencia Espacial Europea. (s/f). *Sentinel-1*. Recuperado el 11 de julio de 2021, a partir de <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-1>
- Alaska Satellite Facility. (2021). *Sentinel-1*. <https://asf.alaska.edu/data-sets/sar-data-sets/sentinel-1/sentinel-1-about/>
- Aldhshan, S. R. S., Zubair Mohammed, O., & Mohd Shafri, H. Z. (2019). Flash flood area mapping using sentinel-1 SAR data: A case study of eight upazilas in Sunamganj district, Bangladesh. *IOP Conference Series: Earth and Environmental Science*, 357(1), 0–15. <https://doi.org/10.1088/1755-1315/357/1/012034>
- Ali, I., Cao, S., Naeimi, V., Paulik, C., & Wagner, W. (2018). Methods to Remove the Border Noise From Sentinel-1 Synthetic Aperture Radar Data: Implications and Importance For Time-Series Analysis. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(3), 777–786. <https://doi.org/10.1109/JSTARS.2017.2787650>
- Aon Benfield Corporation. (2022). *2021 Weather, Climate and Catastrophe Insight*. <https://www.aon.com/getmedia/1b516e4d-c5fa-4086-9393-5e6afb0eeded/20220125-2021-weather-climate-catastrophe-insight.pdf.aspx>
- Avedaño, J., Parra, J., Plazas, P., & Bayona, J. F. (2014). Segmentación y clasificación de imágenes SAR en zonas de inundación en Colombia, una herramienta computacional para prevención de desastres. *Revista Facultades de Ingeniería, Universidad Antonio Nariño*, 4(8), 24–38.
- Banco Internacional de Reconstrucción y Fomento. (2016). *Notas Técnicas: Riesgo de inundaciones en redes viales*. <https://n9.cl/lu0jf>
- Belmonte, I., & Caamaño, S. (2009). *Una aplicación basada en imágenes SAR para el monitoreo y prevención de inundaciones en Argentina [Tesis de Maestría]*. Universidad Nacional de Córdoba.
- Bhagat, V. (2017). Space borne Active Microwave Remote Sensing of Soil Moisture: A Review. *Remote Sensing of Land*, 1(1), 53–86. <https://doi.org/10.21523/GCJ1.17010104>
- Bioresita, F. (2019). *Use of multi-source image time series for surface water mapping* [Tesis Doctoral]. University of Strasbourg.
- Boca, T., & Rodríguez, G. (s/f). *Métodos estadísticos de la evaluación de la exactitud de productos derivados de sensores remotos*. [https://inta.gob.ar/sites/default/files/script-tmp-inta-mtodos\\_est\\_sensores.pdf](https://inta.gob.ar/sites/default/files/script-tmp-inta-mtodos_est_sensores.pdf)
- Borah, S. B., Sivasankar, T., Ramya, M. N. S., & Raju, P. L. N. (2018). Flood inundation mapping and monitoring in Kaziranga National Park, Assam using

- Sentinel-1 SAR data. *Environmental Monitoring and Assessment*, 190(9), 1–11. <https://doi.org/10.1007/s10661-018-6893-y>
- Castro Gómez, A. (2020). *Mapeo de zonas inundadas con Sentinel-1 en SNAP (método del valor umbral)*. [https://eo4society.esa.int/wp-content/uploads/2021/11/ESA\\_Mapeo-inundacion\\_SNAP.pdf](https://eo4society.esa.int/wp-content/uploads/2021/11/ESA_Mapeo-inundacion_SNAP.pdf)
- Cattaneo, C. A., Larcher, I., Ruggeri, A. I., Herrera, A. C., BIASONI, E. M., Möller, O., Signorelli, J. W., Storti, M. A., & Rosario, A. (2011). Métodos de umbralización de imágenes digitales basados en entropía de Shannon y otros. *Mecánica Computacional*, XXX, 2785–2805.
- Chuvieco, E. (1995). *Fundamentos de teledetección* (2a ed.). RIALP S.A.
- Clement, M. A., Kilsby, C. G., & Moore, P. (2017). Multi-temporal synthetic aperture radar flood mapping using change detection. *Journal of Flood Risk Management*, 11(2), 152–168. <https://doi.org/10.1111/jfr3.12303>
- Clemente, J. P., Fontanelli, G., Ovando, G. G., Roa, Y. L. B., Lapini, A., & Santi, E. (2020). Google Earth Engine: Application Of Algorithms For Remote Sensing Of Crops In Tuscany (Italy). *2020 IEEE Latin American GRSS & ISPRS Remote Sensing Conference (LAGIRS)*, 195–200. <https://doi.org/10.1109/LAGIRS48042.2020.9165561>
- Comisión Nacional de Emergencias. (2018). *Plan general de la emergencia ante la situación provocada por la tormenta tropical Nate: decreto de emergencia N°40677*. [https://www.cne.go.cr/recuperacion/declaratoria/planes/Plan General de la Emergencia 40677.pdf](https://www.cne.go.cr/recuperacion/declaratoria/planes/Plan%20General%20de%20la%20Emergencia%2040677.pdf)
- Comisión Nacional de Prevención de Riesgos y Atención de Emergencias. (s/f). *Deslizamientos, inundaciones, sismos*. [https://www.cne.go.cr/reduccion\\_riesgo/informacion\\_educativa/recomendaciones\\_consejos/documentos/Folleto Deslizamientos.pdf](https://www.cne.go.cr/reduccion_riesgo/informacion_educativa/recomendaciones_consejos/documentos/Folleto_Deslizamientos.pdf)
- Dasari, K., Anjaneyulu, L., Jayasri, P. V., & Prasad, A. (2015). Importance of speckle filtering in image classification of SAR data. *International Conference on Microwave, Optical and Communication Engineering (ICMOCE)*, 349–352. <https://doi.org/10.1109/ICMOCE.2015.7489764>
- Delpino Aguayo, M. A., Portillo Sosa, V., & Mora Stanley, C. R. (2018). Evaluación de índices espectrales derivados de sensores remotos para la caracterización de ambientes de humedales. *Simpósio de Geotecnologías No Pantanal*, 112–121.
- Dhara, S., Dang, T., Parial, K., & Lu, X. X. (2020). Accounting for Uncertainty and Reconstruction of Flooding Patterns Based on Multi-Satellite Imagery and Support Vector Machine Technique: A Case Study of Can Tho City, Vietnam. *Water*, 12(1593). <https://doi.org/10.3390/w12061543>
- Earth Resources Observation and Science (EROS) Center. (2018). *Shuttle Radar Topography Mission (SRTM) 1 Arc-Second Global*. <https://www.usgs.gov/centers/eros/science/usgs-eros-archive-digital-elevation-shuttle-radar-topography-mission-srtm-1>
- Environmental Systems Research Institute. (2020). *Difference between Nearest Neighbor, Bilinear Interpolation and Cubic Convolution?* FAQ: What Is the

- Difference between Nearest Neighbor, Bilinear Interpolation and Cubic Convolution? <https://support.esri.com/en/technical-article/000005606>
- Environmental Systems Research Institute. (2022). *Calibración radiométrica de Sentinel-1*. <https://desktop.arcgis.com/es/arcmap/latest/manage-data/raster-and-images/sentinel-1-radiometric-calibration.htm>
- Espín, N., Castillo, F., García, F., & Sarría, F. (2015). Comparación de Métodos de Clasificación de Imágenes de Satélite. *Boletín de La Asociación de Geógrafos Españoles*, 67, 327–347.
- Fernández-Ordoñez, Y. M., Soria-Ruiz, J., Leblon, B., Macedo-Cruz, A., Ramírez Guzmán, M. E., & Escalona-Maurice, M. (2020). Imágenes de radar para estudios territoriales, caso: inundaciones en Tabasco con el uso de imágenes SAR Sentinel-1A y Radarsat-2. *Revista Internacional de Estadística y Geografía*, 11(1).
- Filipponi, F. (2019). *Sentinel-1 GRD Preprocessing Workflow*. 11. <https://doi.org/10.3390/ecrs-3-06201>
- Gimeno Martínez, N. (2019). *¿Qué es un SAR?* Instituto Nacional de Técnica Aeroespacial. [https://www.inta.es/INTA/es/blogs/ceit/BlogEntry\\_1554121012176#](https://www.inta.es/INTA/es/blogs/ceit/BlogEntry_1554121012176#)
- Grupo Intergubernamental de Expertos sobre el Cambio Climático. (2014). *Quinto Informe de Evaluación*. [https://www.ipcc.ch/site/assets/uploads/2018/02/SYR\\_AR5\\_FINAL\\_full\\_es.pdf](https://www.ipcc.ch/site/assets/uploads/2018/02/SYR_AR5_FINAL_full_es.pdf)
- Guillén Rivera, S. (2022). *Evaluación de la oferta hídrica dentro del esquema de producción de arroz para la época de invierno en la empresa agrícola El Pelón de la Bajura* [Tesis de Licenciatura]. [Tecnológico de Costa Rica].
- Gupta, S., Singh, D., Singh, K. P., & Kumar, S. (2015). An efficient use of random forest technique for SAR data classification. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2015-Novem, 3286–3289. <https://doi.org/10.1109/IGARSS.2015.7326520>
- Guruprasad, P., Mahalingpur, K., & Manjesh, T. (2020). *Overview of different thresholding methods in image processing*. [https://www.researchgate.net/publication/342038946\\_OVERVIEW\\_OF\\_DIFFERENT\\_THRESHOLDING\\_METHODS\\_IN\\_IMAGE\\_PROCESSING](https://www.researchgate.net/publication/342038946_OVERVIEW_OF_DIFFERENT_THRESHOLDING_METHODS_IN_IMAGE_PROCESSING)
- Herrera Chaves, M. (2014). *Análisis de los cambios de uso de suelo y su respuesta hidrológica de los años 2000 a 2020 en la cuenca de los ríos Quebradas Seca y Bermudez* [Tesis de Licenciatura]. Universidad de Costa Rica.
- Instituto Meteorológico Nacional. (2016). *Huracán Otto Informe técnico*. <https://www.imn.ac.cr/documents/10179/20909/Informe+IMN+Huracán+Otto>
- Iza, S. I., Siti, N. S., Muzaimi, M., & Sailudin, D. (2015). Denoising Performances of Fundamental Filters for T2-Weighted MRI Images. *Procedia Computer Science*, 60, 760–768. <https://doi.org/10.1016/j.procs.2015.08.231>

- Jahren Petersen, S. (2022). *High-resolution soil moisture retrieval using sentinel-1 data for monitoring regenerative agricultural practices a feasibility study from Alentejo, Portugal*.  
<https://run.unl.pt/bitstream/10362/134627/1/TGEO0278.pdf>
- Kordelas, G. A., Manakos, I., Aragonés, D., Díaz-Delgado, R., & Bustamante, J. (2018). Fast and Automatic Data-Driven Thresholding for Inundation Mapping with Sentinel-2 Data. *Remote Sensing*, 10(910).  
<https://doi.org/10.3390/rs10060910>
- Kussul, N., Shelestov, A., & Skakun, S. (2011). Flood Monitoring from SAR Data. *NATO Science for Peace and Security Series C: Environmental Security*, 97, 19–29. [https://doi.org/10.1007/978-90-481-9618-0\\_3](https://doi.org/10.1007/978-90-481-9618-0_3)
- Lee, H., Yuan, T., Jung, H. C., & Beighley, E. (2015). Mapping wetland water depths over the central Congo Basin using PALSAR ScanSAR, Envisat altimetry, and MODIS VCF data. *Remote Sensing of Environment*, 159, 70–79.  
<https://doi.org/10.1016/J.RSE.2014.11.030>
- Lee, J. Sen, Ainsworth, T. L., Wang, Y., & Chen, K.-S. (2015). Polarimetric SAR Speckle Filtering and the Extended Sigma Filter. *IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING*, 55(3), 1150–1160.
- Manakos, I., Kordelas, G. A., & Marini, K. (2020). Fusion of Sentinel-1 data with Sentinel-2 products to overcome non-favourable atmospheric conditions for the delineation of inundation maps. *European Journal of Remote Sensing*, 53(sup2), 53–66. <https://doi.org/10.1080/22797254.2019.1596757>
- Manavalan, R. (2017). SAR image analysis techniques for flood area mapping - literature survey. *Earth Sci Inform*, 10, 1–14. <https://doi.org/10.1007/s12145-016-0274-2>
- Martínez Blanco, A., Soto Villalobos, L., Gutiérrez, H., Vásquez Rodríguez, A., & Corrales Nuñez, A. (2022). *Community Perspectives: Loss and Damage in Cahuita, Costa Rica, is a publication from the series: Climate Justice in Latin America; by La Ruta del Clima Association with the support of Brot für die Welt* (1a ed.). La Ruta del Clima.
- Mata Muñoz, M. (2019). *Monitorización de inundaciones mediante Radar SAR (SENTINEL-1)* [Tesis de Maestría]. Universidad de Alcalá.
- MathWorks. (s/f-a). *Absolute difference of two images*. Recuperado el 21 de junio de 2022, a partir de <https://la.mathworks.com/help/images/ref/imabsdiff.html>
- MathWorks. (s/f-b). *Error cuadrático medio*. Recuperado el 15 de junio de 2022, a partir de <https://la.mathworks.com/help/images/ref/immse.html>
- MathWorks. (s/f-c). *Peak signal-to-noise ratio (PSNR)*. Recuperado el 15 de junio de 2022, a partir de <https://la.mathworks.com/help/images/ref/psnr.html>
- Memon, A. A., Muhammad, S., Rahman, S., & Haq, M. (2015). Flood monitoring and damage assessment using water indices: A case study of Pakistan flood-2012. *The Egyptian Journal of Remote Sensing and Space Science*, 18(1), 99–106. <https://doi.org/10.1016/J.EJRS.2015.03.003>

- Mohan, S., Nikam, B. R., Aggarwal, S. P., Thakur, P. K., Krishna, Y. V. N., & Kingma, N. (2017). Evaluation of Adaptive Filters for Speckle Reduction in RISAT-1 Data for Flood Mapping. *Asian Journal of Geoinformatics*, 17(2), 12–24.
- Mora Ramírez, S., & Rodríguez Muñoz, G. (2018). *Situación de la afectación y daños causados por la Tormenta Nate al Sector Agropecuario y necesidades prioritarias: Decreto Ejecutivo N ° 40677-MP*.
- National Aeronautics Space Administration. (2018). *Fundamentals of Remote Sensing: Satellites, Sensors, Data, Tools for Land Management and Wildfire Applications*. <https://appliedsciences.nasa.gov/join-mission/training/english/arset-fundamentals-remote-sensing>
- Núñez Chacón, M. (2017). Secuelas de tormenta Nate en el país tardarán años en resolverse. *Semanario Universidad*. <https://n9.cl/lgs2i>
- Oficina de las Naciones Unidas para la Reducción del Riesgo de Desastres. (2020). *Inventario histórico de desastres: base de datos Costa Rica*. DesInventar Sendai. <https://db.desinventar.org/DesInventar/profiletab.jsp?countrycode=cria&continue=y>
- O'Grady, D., Leblanc, M., & Bass, A. (2014). The use of radar satellite data from multiple incidence angles improves surface water mapping. *Remote Sensing of Environment*, 140, 652–664. <https://doi.org/10.1016/J.RSE.2013.10.006>
- Organización de las Naciones Unidas. (2020). *Mudslides and Associated Flood Detection Using Sentinel-1 Data*. <https://www.un-spider.org/advisory-support/recommended-practices/mudslides-flood-sentinel-1/step-by-step>
- Otondo, J., Melani, E., Casal, A., Coria, J., Martinefsky, M., & Némoz, J. (s/f). *Las inundaciones, los pastizales y los suelos*. [https://inta.gob.ar/sites/default/files/script-tmp-inta\\_-\\_inundaciones\\_-\\_pastizales\\_-\\_suelos\\_-\\_cuenca\\_de.pdf](https://inta.gob.ar/sites/default/files/script-tmp-inta_-_inundaciones_-_pastizales_-_suelos_-_cuenca_de.pdf)
- Park, J. W., Korosov, A. A., Babiker, M., Sandven, S., & Won, J. S. (2018). Efficient Thermal Noise Removal for Sentinel-1 TOPSAR Cross-Polarization Channel. *IEEE Transactions on Geoscience and Remote Sensing*, 56(3), 1555–1565. <https://doi.org/10.1109/TGRS.2017.2765248>
- Pizarro, Y., & Marchena, J. (2008). Inundaciones en el río Tempisque: historia y percepciones sociales (1900-2007). *Revista de Ciencias Ambientales*, 36(2), 19. <https://doi.org/10.15359/rca.36-2.3>
- Planet Labs. (2022a). *Planet Scope Product Specifications*. [https://assets.planet.com/docs/Planet PSScene Imagery Product Spec letter screen.pdf](https://assets.planet.com/docs/Planet_PSScene_Imagery_Product_Spec_letter_screen.pdf)
- Planet Labs. (2022b). *Understanding PlanetScope Instruments*. <https://developers.planet.com/docs/apis/data/sensors/>
- Podest, E. (2018a). Conceptos Básicos del Radar de Apertura Sintética. En *La Teledetección por Radar y sus Aplicaciones para la Tierra, el Agua y Desastres* (p. 51). National Aeronautics Space Administration.

<https://arset.gsfc.nasa.gov/sites/default/files/disasters/SAR-17/Session1-SAR-Spanish.pdf>

- Podest, E. (2018b). *SAR para el mapeo de suelos y cultivos*. National Aeronautics Space Administration. <https://arset.gsfc.nasa.gov/disasters/webinars/intro-SAR>
- Podest, E. (2019). *SAR para desastres y aplicaciones hidrológicas*. <https://appliedsciences.nasa.gov/join-mission/training/english/arset-fundamentals-remote-sensing>
- Pradhan, B., Shafiee, M., & Pirasteh, S. (2009). Maximum flood prone area mapping using RADARSAT images and GIS: Kelantan river basin. *Revista Internacional de Geoinformática*, 5(2).
- Prasad, A. D., Ganasala, P., Hernández-Guzmán, R., & Fathian, F. (2022). Remote sensing satellite data and spectral indices: an initial evaluation for the sustainable development of an urban area. *Sustainable Water Resources Management*, 8(1), 1–16. <https://doi.org/10.1007/S40899-022-00607-2/TABLES/11>
- PROCOMER Costa Rica. (2020, octubre 6). *Guanacaste, la costa dorada del Pacífico Norte*. <https://www.procomer.com/noticia/exportador-noticia/blog-guanacaste-la-costa-dorada-del-pacifico-norte/>
- Recuero, P. (2021). *Cómo interpretar la matriz de confusión*. Recuperado el 11 de julio de 2021, a partir de <https://empresas.blogthinkbig.com/como-interpretar-la-matriz-de-confusion-ejemplo-practico/>
- Retana, J. (2012). Eventos hidrometeorológicos extremos lluviosos en Costa Rica desde la perspectiva de la adaptación al cambio en el clima. *Revista de Ciencias Ambientales*, 44(2), 5–16. <https://doi.org/http://dx.doi.org/10.15359/rca.44-2.1>
- Rodríguez, S. (2018). *Las cicatrices después de Nate en Corralillo, Guanacaste*. Ojo al Clima. <https://ojoalclima.com/las-cicatrices-despues-de-nate-en-corrallillo-guanacaste/>
- RUS Copernicus. (2015). *Flood Monitoring With Sentinel-1 Using S-1 Toolbox - January 2015, Malawi*. [https://rus-copernicus.eu/portal/wp-content/uploads/library/education/training/HAZA01\\_FloodMapping\\_Malawi.pdf](https://rus-copernicus.eu/portal/wp-content/uploads/library/education/training/HAZA01_FloodMapping_Malawi.pdf)
- Salgado, D. (2009). Inundaciones y gestión del riesgo de desastres. Retos para su reducción y mitigación. *Ambientico*. [https://www.ambientico.una.ac.cr/wp-content/uploads/tainacan-items/5/19973/191\\_7-11.pdf](https://www.ambientico.una.ac.cr/wp-content/uploads/tainacan-items/5/19973/191_7-11.pdf)
- Santoso, A. W., Pebrianti, D., Bayuaji, L., & Zain, J. M. (2015a). Performance of various speckle reduction filters on Synthetic Aperture Radar image. *2015 4th International Conference on Software Engineering and Computer Systems, ICSECS 2015: Virtuuous Software Solutions for Big Data*, 11–14. <https://doi.org/10.1109/ICSECS.2015.7333103>
- Scarpino, S., Albano, R., Cantisani, A., Mancusi, L., Sole, A., & Milillo, G. (2018). Multitemporal SAR data and 2D hydrodynamic model flood scenario dynamics

- assessment. *ISPRS International Journal of Geo-Information*, 7(3), 1–24. <https://doi.org/10.3390/ijgi7030105>
- Selmi, L. (2021). *Flood mapping using the Sentinel-1 imagery and the ESA SNAP S1 Toolbox*. [https://rus-copernicus.eu/portal/wp-content/uploads/library/education/training/HAZA01\\_FloodMapping\\_Malawi.pdf](https://rus-copernicus.eu/portal/wp-content/uploads/library/education/training/HAZA01_FloodMapping_Malawi.pdf)
- Shen, J., & Tan, F. (2020). Effects of DEM resolution and resampling technique on building treatment for urban inundation modeling: a case study for the 2016 flooding of the HUST campus in Wuhan. En *Natural Hazards* (Vol. 104, Issue 1). Springer Netherlands. <https://doi.org/10.1007/s11069-020-04198-z>
- Suárez, G., Hori, T., Alva, V., Guerrero, R., Balcazar, F., Aguirre, M., Baruzzi, M., Lozano, R., Bayona, M., Ortiz, S., Pérez, S., Greco, S., Valle, Y., & Chávez, E. (s/f). *Programa de emergencia en respuesta a la tormenta tropical Nate*. <https://repositorio-snp.mideplan.go.cr/handle/123456789/174?locale-attribute=es>
- Tavus, B., Kocaman, S., Nefeslioglu, H. A., & Gokceoglu, C. (2020). A fusion approach for flood mapping using sentinel-1 and sentinel-2 datasets. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 43(B3), 641–648. <https://doi.org/10.5194/isprs-archives-XLIII-B3-2020-641-2020>
- The Earth Observing System. (2020). *Índice De Agua De Diferencia Normalizada*. NASA. <https://eos.com/es/make-an-analysis/ndwi/>
- The Sentinel Application Platform. (2022a). *Help - Band Maths Operator*.
- The Sentinel Application Platform. (2022b). *Help - Range Doppler Terrain Correction Operator*.
- The Sentinel Application Platform. (2022c). *Help - S-1 GRD Border Noise Removal*.
- Torres, R., Snoeij, P., Geudtner, D., Bibby, D., Davidson, M., Attema, E., Potin, P., Rommen, B. Ö., Floury, N., Brown, M., Traver, I. N., Deghaye, P., Duesmann, B., Rosich, B., Miranda, N., Bruno, C., L'Abbate, M., Croci, R., Pietropaolo, A., ... Rostan, F. (2012). GMES Sentinel-1 mission. *Remote Sensing of Environment*, 120, 9–24. <https://doi.org/10.1016/j.rse.2011.05.028>
- Universidad Internacional de la Rioja. (2021). Árboles de decisión: qué son y cuál es su uso en Big Data. *UNIR Revista: Ingeniería y Tecnología*. <https://www.unir.net/ingenieria/revista/arboles-de-decision/>
- Valencia, M. (2022). New Report Details Dire Climate Impacts in Latin America and the Caribbean. *Convención Marco de Las Naciones Unidas Sobre El Cambio Climático*. <https://unfccc.int/news/new-report-details-dire-climate-impacts-in-latin-america-and-the-caribbean>
- Vallejos Vásquez, S., Esquivel Valverde, L., & Hidalgo Madrigal, M. (2012). *Histórico de desastres en Costa Rica*. Comisión Nacional de Prevención de Riesgos y Atención de Emergencias. <https://www.bvs.sa.cr/ambiente/4923.pdf>

- Vallejos Vásquez, S., & Fonseca Bonilla, W. (2017). Tormenta tropical Nate y su paso por Costa Rica. *Revista En Torno a La Prevención*, 19, 29–37. <http://revistaentorno.desastres.hn/pdf/spa/doc1903/doc1903-contenido.pdf>
- Zhang, B., Wdowinski, S., Oliver-Cabrera, T., Koirala, R., Jo, M. J., & Osmanoglu, B. (2018). Mapping the extent and magnitude of sever flooding induced by hurricane irma with multi-temporal sentinel-1 SAR and inSAR observations. *Remote Sensing and Spatial Information Science*. <https://doi.org/10.5194/isprs-archives-XLII-3-2237-2018>
- Zhang, M., Chen, F., Liang, D., Tian, B., & Yang, A. (2020). Use of sentinel-1 grd sar images to delineate flood extent in Pakistan. *Sustainability (Switzerland)*, 12(14), 1–19. <https://doi.org/10.3390/su12145784>
- Zhang, W., Hu, B., & Brown, G. S. (2020). Automatic Surface Water Mapping Using Polarimetric SAR Data for Long-Term Change Detection. *Water*, 12(872), 872. <https://doi.org/10.3390/w12030872>
- Zhu, L., Suomalainen, J., Liu, J., Hyypä, J., Kaartinen, H., & Haggren, H. (2017). A Review: Remote Sensing Sensors. En *Multi-purposeful Application of Geospatial Data*. InTech. <https://doi.org/10.5772/intechopen.71049>

## 8. ANEXOS

### Anexo 1. Código de Matlab generado para calcular los parámetros de desempeño de los filtros de efecto granular

```
%Se llaman las imagenes preprocesadas
file_filter = fullfile('C:\Users\angie\Desktop\TESIS\TIFF\D_VV_SIGMA');
dirOutput_1 = dir(fullfile(file_filter, 'D*')); %las imagenes preprocesadas inician con la
letra D
dirOutput_ref = dir(fullfile(file_filter, '1*')); %las imagen de referencia inicia con el
numero 1
filter_names = {dirOutput_1.name}'; %se crea una matriz con los nombres de las imagenes
preprocesadas
filter_ref = {dirOutput_ref.name}'; %se crea una matriz con el nombre de la imagen de
referencia
numFrames = numel(filter_names);

%Se llama la imagen de referencia
ref_nonfilter = imread(filter_ref{1});
%% Ciclo MSE

M = imread(filter_names{1});
MSE_tab = zeros([8 2]);
MSE_tab(1,2) = 1;

for p = 1:6
    M = imread(filter_names{p});
    MSE = immse(ref_nonfilter,M);
    MSE_tab(p,:) = [MSE,p];
end

%% Ciclo PSNR

PS = imread(filter_names{1});
PSNR_tab = zeros([8 2]);
PSNR_tab(1,2) = 1;

for p = 1:6
    PS = imread(filter_names{p});
    PSNR = psnr(ref_nonfilter,PS);
    PSNR_tab(p,:) = [PSNR,p];
end

%% Ciclo AD

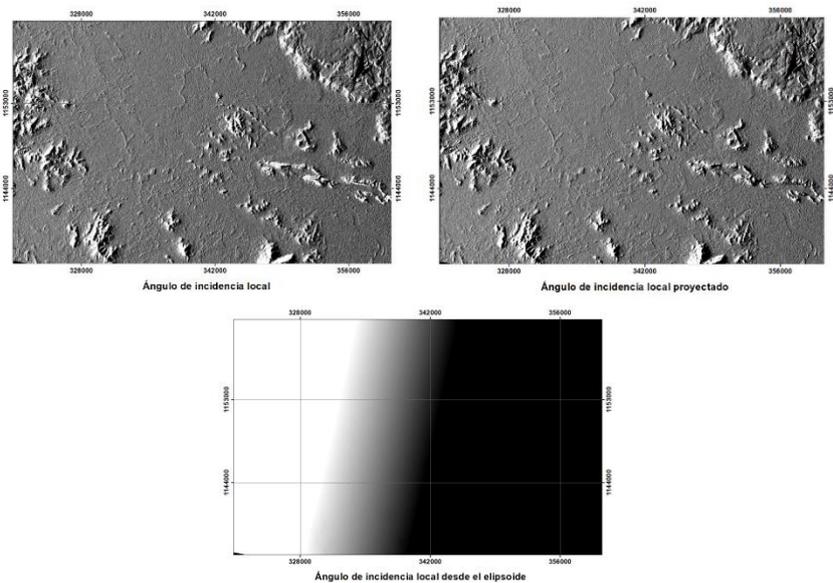
A = imread(filter_names{1});
AD_tab = zeros([8 2]);
AD_tab(1,2) = 1;

for p = 1:6
    A = imread(filter_names{p});
    AD = imabsdiff(ref_nonfilter,A);
    AD_tab(p,:) = [sum(AD, 'all'),p];
end
```

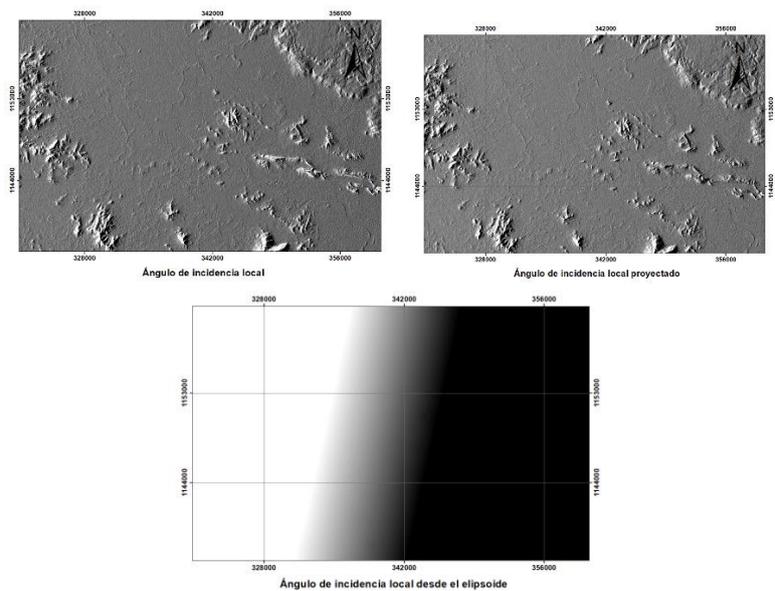
## Anexo 2. Código de RStudio generado para calcular la matriz de confusión de las imágenes clasificadas

```
1  ## Instalar/Abrir librerías
2  rm(list = ls())
3  library(terra)
4  #install.packages("inflection")
5  #install.packages("randomForest")
6  #install.packages("caret")
7  library(inflection)
8  library(sf)
9  library(randomForest)
10 library(ggplot2)
11 library(lattice)
12 library(caret)
13
14 ## Clasificación de imagen NDWI en Agua/No Agua
15 #Leer imagen NDWI
16 NDWI <- rast("NDWI_recorte.tif")
17 names(NDWI) <- "NDWI"
18 plot(NDWI)
19 head(NDWI)
20
21 #Leer puntos de validación (30% de los puntos generados)
22 CLC.poly.AOI <- st_read("test_1.shp")
23 CLC.poly.AOI <- st_transform(CLC.poly.AOI, crs(NDWI))
24 plot(NDWI)
25 plot(CLC.poly.AOI,add=T)
26
27 #Extraer puntos de NDWI
28 Pts.train.sample.500.xy = st_coordinates(CLC.poly.AOI) [,1:2]
29 ind2.points = extract(NDWI,Pts.train.sample.500.xy)
30 ind2.points$class <- as.factor(CLC.poly.AOI$GrndTruth)
31 NDWI.df <- as.data.frame(ind2.points)
32
33 #Eliminar los puntos que incluyen NA values en NDWI
34 head(NDWI.df)
35 POSNA<-which(is.na(NDWI.df[,1]))
36 if (length(POSNA>0)){
37   NDWI.df<-NDWI.df[-POSNA,]
38 }
39 NDWI.df
40
41 #Clasificación basada en reglas de NDWI
42 NDWI2.df <- NDWI.df
43 NDWI2.df[NDWI2.df > 0.2] = 2 #Agua
44 NDWI2.df[NDWI2.df <= 0.2 ] = 1 #NoAgua
45 head(NDWI2.df)
46 NDWI2.df$NDWI <- as.factor(NDWI2.df$NDWI)
47
48 ## Clasificar imagen procesada
49 #Leer Imagen Procesada
50 IP <- rast("F_VH_RF_3_rec.tif") #debe venir previamente clasificada en 1-2.
51 names(IP) <- "IP"
52 head(IP)
53 plot(IP)
54
55 #Leer puntos de validación
56 CLC.poly.AOI_2 <- st_read("test_1.shp")
57 CLC.poly.AOI_2 <- st_transform(CLC.poly.AOI_2, crs(IP))
58 plot(IP)
59 plot(CLC.poly.AOI_2,add=T)
60
61 #Extraer puntos de imagen procesada
62 Pts2.train.sample.500.xy = st_coordinates(CLC.poly.AOI_2) [,1:2]
63 ind.points = extract(IP,Pts2.train.sample.500.xy)
64 ind.points$class <- as.factor(CLC.poly.AOI_2$GrndTruth)
65 IP.df <- as.data.frame(ind.points)
66
67 #Eliminar los puntos que incluyen NA values
68 head(IP.df)
69 POSNA<-which(is.na(IP.df[,1]))
70 if (length(POSNA>0)){
71   IP.df<-IP.df[-POSNA,]
72 }
73 IP.df
74
75 IP2.df <- IP.df
76 IP2.df$IP <- as.factor(IP2.df$IP)
77
78 #Revisar formato de datos
79 typeof(IP2.df$IP)
80 class(IP2.df$IP)
81 typeof(NDWI2.df$NDWI)
82 class(NDWI2.df$NDWI)
83
84 ## Calcular la matriz de confusión en las muestras de validación
85 matrice.confusion.final<-confusionMatrix(IP2.df$IP,NDWI2.df$NDWI)
86 matrice.confusion.final
```

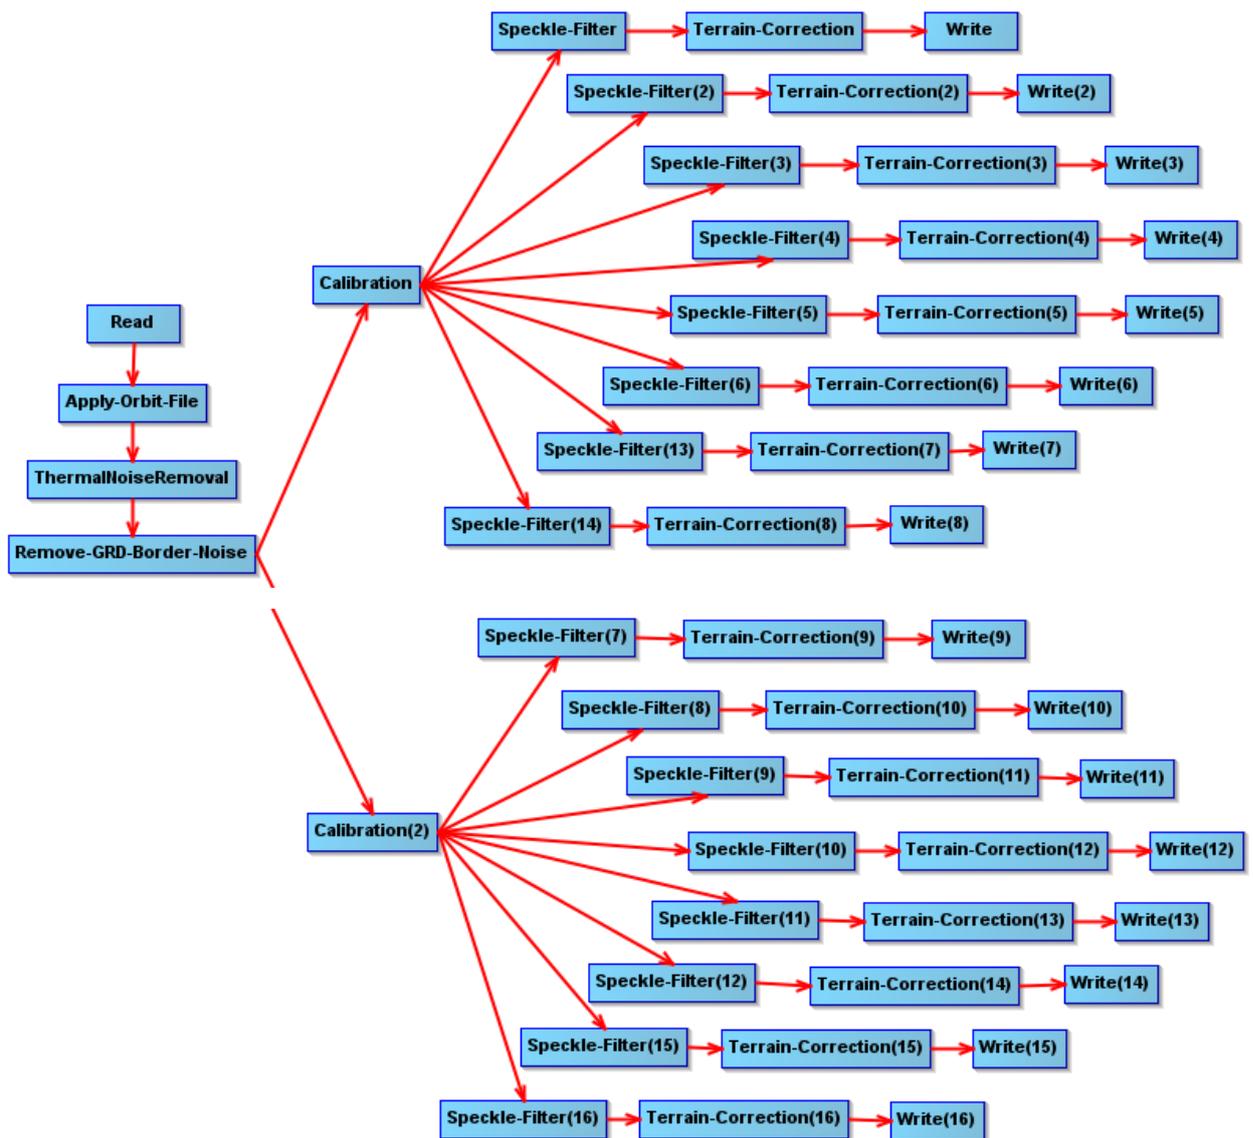
### Anexo 3. Mapas de ángulo de incidencia para las imágenes antes del evento de inundación



### Anexo 4. Mapas de ángulo de incidencia para las imágenes después del evento de inundación



Anexo 5. Diagrama de flujo generado por la herramienta “Graph Builder” de SNAP



**Anexo 6.** Parámetros de rendimiento para las imágenes SAR después del evento de inundación con polarización VV.

<b>Imágenes SAR después del evento de inundación con polarización VV</b>					
<b>Calibración radiométrica</b>	<b>Filtro de efecto granular</b>	<b>Tamaño de ventana</b>	<b>MSE</b>	<b>PSNR</b>	<b>AD</b>
Sigma 0	Lee	5x5	843,18	18,87	18,13
	Lee	7x7	1212,44	17,29	21,94
	Sigma Lee	5x5	769,36	19,27	17,38
	Sigma Lee	7x7	1089,72	17,76	21,11
	Boxcar	5x5	838,41	18,90	18,01
	Boxcar	7x7	1264,77	17,11	22,46
	Frost	5x5	602,58	20,33	15,36
	Frost	7x7	801,41	19,09	17,92
Gamma 0	Lee	5x5	829,47	18,94	17,97
	Lee	7x7	1201,41	17,33	21,84
	Sigma Lee	5x5	745,66	19,41	17,09
	Sigma Lee	7x7	1109,84	17,68	21,35
	Boxcar	5x5	857,74	18,80	18,24
	Boxcar	7x7	1264,05	17,11	22,44
	Frost	5x5	619,84	20,21	15,59
	Frost	7x7	822,05	18,98	18,18

**Anexo 7.** Parámetros de rendimiento para las imágenes SAR antes del evento de inundación con polarización VH.

<b>Imágenes SAR antes del evento de inundación con polarización VH</b>					
<b>Calibración radiométrica</b>	<b>Filtro de efecto granular</b>	<b>Tamaño de ventana</b>	<b>MSE</b>	<b>PSNR</b>	<b>AD</b>
Sigma 0	Lee	5x5	947,18	18,37	19,46
	Lee	7x7	1441,84	16,54	24,42
	Sigma Lee	5x5	923,66	18,48	19,23
	Sigma Lee	7x7	1300,12	16,99	23,23
	Boxcar	5x5	1013,72	18,07	20,08
	Boxcar	7x7	1521,87	16,31	24,98
	Frost	5x5	721,41	19,55	17,05
	Frost	7x7	972,49	18,25	20,05
Gamma 0	Lee	5x5	1067,43	17,85	21,48
	Lee	7x7	1412,59	16,63	24,52
	Sigma Lee	5x5	906,11	18,56	19,00
	Sigma Lee	7x7	1166,85	17,46	21,90
	Boxcar	5x5	1102,61	17,71	21,74
	Boxcar	7x7	1494,39	16,39	25,17
	Frost	5x5	933,78	18,43	20,33
	Frost	7x7	854,80	18,81	18,69

**Anexo 8.** Parámetros de rendimiento para las imágenes SAR antes del evento de inundación con polarización VV.

<b>Imágenes SAR antes del evento de inundación con polarización VV</b>					
<b>Calibración radiométrica</b>	<b>Filtro de efecto granular</b>	<b>Tamaño de ventana</b>	<b>MSE</b>	<b>PSNR</b>	<b>AD</b>
Sigma 0	Lee	5x5	899,59	18,59	19,19
	Lee	7x7	1248,05	17,17	22,50
	Sigma Lee	5x5	745,52	19,41	17,24
	Sigma Lee	7x7	1118,47	17,64	21,61
	Boxcar	5x5	924,31	18,47	19,39
	Boxcar	7x7	1299,96	16,99	22,90
	Frost	5x5	568,49	20,58	15,15
	Frost	7x7	866,88	18,75	19,09
Gamma 0	Lee	5x5	600,75	20,34	15,25
	Lee	7x7	1216,68	17,28	22,99
	Sigma Lee	5x5	573,89	20,54	14,69
	Sigma Lee	7x7	769,03	19,27	17,06
	Boxcar	5x5	619,03	20,21	15,45
	Boxcar	7x7	1262,87	17,12	23,35
	Frost	5x5	604,14	20,32	16,04
	Frost	7x7	574,82	20,54	15,06

## Anexo 9. Resultados de análisis estadístico con umbral de 0,2 del índice NDWI (objetivo 3).

Polarización	Calibración radiométrica	Filtro de efecto granular	Tamaño de ventana	Metodología de procesamiento	Índice Kappa	Parámetro Sensibilidad	Parámetro Especificidad	Exactitud del usuario	Exactitud del productor	Medida F
VH	Gamma 0	Frost	7x7	RF	0,422	0,734	0,689	0,311	0,266	0,287
VH	Gamma 0	Lee Sigma	5x5	RF	0,405	0,736	0,670	0,330	0,264	0,293
VH	Sigma 0	Lee	5x5	RF	0,402	0,722	0,680	0,320	0,279	0,298
VH	Sigma 0	Boxcar	7x7	RF	0,402	0,716	0,686	0,314	0,284	0,298
VH	Sigma 0	Lee Sigma	5x5	RF	0,399	0,726	0,673	0,327	0,274	0,298
VH	Sigma 0	Frost	7x7	RF	0,399	0,709	0,690	0,310	0,291	0,300
VH	Sigma 0	Lee	7x7	RF	0,394	0,722	0,673	0,327	0,279	0,301
VV	Sigma 0	Lee Sigma	5x5	RF	0,394	0,722	0,673	0,327	0,279	0,301
VH	Gamma 0	Boxcar	7x7	RF	0,394	0,711	0,683	0,317	0,289	0,302
VH	Gamma 0	Lee Sigma	7x7	RF	0,391	0,697	0,694	0,306	0,303	0,305
VH	Sigma 0	Boxcar	5x5	RF	0,389	0,716	0,673	0,327	0,284	0,304
VH	Gamma 0	Boxcar	5x5	RF	0,389	0,697	0,692	0,308	0,303	0,306
VH	Sigma 0	Lee Sigma	7x7	RF	0,388	0,695	0,693	0,307	0,305	0,306
VH	Gamma 0	Lee	5x5	RF	0,384	0,697	0,687	0,313	0,303	0,308
VH	Gamma 0	Frost	5x5	RF	0,384	0,713	0,673	0,327	0,287	0,306
VH	Sigma 0	Frost	5x5	RF	0,377	0,944	0,664	0,336	0,056	0,096
VH	Gamma 0	Lee	7x7	RF	0,375	0,690	0,685	0,315	0,310	0,313
VV	Sigma 0	Frost	5x5	RF	0,361	0,704	0,658	0,343	0,296	0,318
VV	Sigma 0	Lee Sigma	7x7	RF	0,337	0,682	0,655	0,345	0,318	0,331
VV	Sigma 0	Lee	7x7	RF	0,336	0,690	0,646	0,354	0,310	0,330
VV	Sigma 0	Boxcar	5x5	RF	0,335	0,685	0,650	0,350	0,315	0,331
VV	Gamma 0	Lee Sigma	7x7	RF	0,334	0,675	0,659	0,341	0,325	0,333
VV	Gamma 0	Lee	7x7	RF	0,327	0,690	0,638	0,362	0,310	0,334
VV	Gamma 0	Frost	7x7	RF	0,327	0,681	0,646	0,354	0,319	0,336
VV	Gamma 0	Lee	5x5	RF	0,326	0,682	0,645	0,355	0,318	0,336
VV	Sigma 0	Lee	5x5	RF	0,322	0,663	0,659	0,341	0,337	0,339
VV	Gamma 0	Frost	5x5	RF	0,313	0,655	0,658	0,342	0,346	0,344
VV	Gamma 0	Boxcar	7x7	RF	0,310	0,667	0,642	0,358	0,333	0,345
VV	Gamma 0	Lee Sigma	5x5	RF	0,308	0,688	0,620	0,380	0,312	0,342
VV	Gamma 0	Boxcar	5x5	RF	0,301	0,652	0,648	0,352	0,348	0,350
VV	Sigma 0	Frost	7x7	RF	0,294	0,659	0,635	0,365	0,341	0,352
VV	Sigma 0	Boxcar	7x7	RF	0,293	0,655	0,639	0,362	0,346	0,353
VH	Sigma 0	Frost	5x5	UC	0,417	0,829	0,825	0,175	0,171	0,173
VH	Gamma 0	Frost	5x5	UC	0,417	0,992	0,429	0,571	0,008	0,016
VH	Gamma 0	Frost	7x7	UC	0,416	0,995	0,425	0,576	0,005	0,009
VH	Gamma 0	Lee Sigma	5x5	UC	0,408	0,995	0,417	0,583	0,005	0,011
VH	Gamma 0	Lee	5x5	UC	0,406	0,995	0,414	0,586	0,005	0,009
VH	Sigma 0	Lee Sigma	5x5	UC	0,401	0,997	0,408	0,592	0,003	0,007
VH	Sigma 0	Lee	5x5	UC	0,400	0,996	0,408	0,592	0,004	0,008
VH	Gamma 0	Boxcar	5x5	UC	0,386	0,996	0,394	0,606	0,004	0,008
VH	Sigma 0	Boxcar	5x5	UC	0,379	0,996	0,387	0,614	0,004	0,008
VH	Gamma 0	Lee Sigma	7x7	UC	0,362	0,997	0,369	0,631	0,003	0,007

VV	Gamma 0	Frost	5x5	UC	0,362	0,993	0,372	0,628	0,007	0,013
VV	Gamma 0	Frost	7x7	UC	0,360	0,995	0,369	0,631	0,005	0,011
VV	Gamma 0	Lee Sigma	5x5	UC	0,355	0,994	0,365	0,635	0,006	0,012
VH	Sigma 0	Frost	7x7	UC	0,353	0,997	0,360	0,640	0,003	0,005
VH	Gamma 0	Lee	7x7	UC	0,348	0,997	0,355	0,645	0,003	0,007
VV	Gamma 0	Lee	5x5	UC	0,347	0,994	0,356	0,644	0,006	0,012
VH	Sigma 0	Lee Sigma	7x7	UC	0,340	1,000	0,346	0,654	0,000	0,001
VV	Sigma 0	Frost	5x5	UC	0,338	0,996	0,345	0,655	0,004	0,008
VV	Gamma 0	Boxcar	5x5	UC	0,329	0,995	0,338	0,662	0,005	0,011
VH	Sigma 0	Lee	7x7	UC	0,328	0,997	0,334	0,666	0,003	0,005
VV	Sigma 0	Lee Sigma	5x5	UC	0,328	0,997	0,335	0,665	0,003	0,007
VV	Sigma 0	Lee	5x5	UC	0,318	0,997	0,325	0,675	0,003	0,007
VH	Gamma 0	Boxcar	7x7	UC	0,308	0,997	0,315	0,685	0,003	0,007
VV	Gamma 0	Lee Sigma	7x7	UC	0,306	0,995	0,314	0,686	0,005	0,011
VV	Sigma 0	Boxcar	5x5	UC	0,296	0,997	0,303	0,698	0,003	0,007
VH	Sigma 0	Boxcar	7x7	UC	0,293	0,997	0,299	0,701	0,003	0,005
VV	Gamma 0	Lee	7x7	UC	0,289	0,995	0,297	0,703	0,005	0,011
VV	Sigma 0	Frost	7x7	UC	0,287	0,998	0,292	0,708	0,002	0,004
VV	Sigma 0	Lee Sigma	7x7	UC	0,280	0,999	0,284	0,716	0,001	0,001
VV	Sigma 0	Lee	7x7	UC	0,258	0,999	0,262	0,738	0,001	0,001
VV	Gamma 0	Boxcar	7x7	UC	0,255	0,995	0,263	0,737	0,005	0,009
VV	Sigma 0	Boxcar	7x7	UC	0,225	0,999	0,228	0,772	0,001	0,001

**Anexo 10.** Resultados de análisis estadístico con umbral de 0,35 del índice NDWI (objetivo 3).

Polarización	Calibración radiométrica	Filtro de efecto granular	Tamaño de ventana	Metodología de procesamiento	Índice Kappa	Parámetro Sensibilidad	Parámetro Especificidad	Exactitud del usuario	Exactitud del productor	Medida F
VH	Sigma 0	Lee	5x5	RF	0,693	0,940	0,779	0,221	0,060	0,094
VH	Gamma 0	Lee	7x7	RF	0,675	0,945	0,739	0,269	0,097	0,143
VV	Sigma 0	Lee Sigma	7x7	RF	0,674	0,945	0,735	0,246	0,106	0,148
VH	Sigma 0	Lee Sigma	7x7	RF	0,673	0,946	0,731	0,232	0,113	0,152
VH	Gamma 0	Frost	5x5	RF	0,671	0,939	0,754	0,253	0,107	0,150
VV	Sigma 0	Frost	7x7	RF	0,665	0,943	0,729	0,274	0,102	0,149
VH	Gamma 0	Lee Sigma	7x7	RF	0,664	0,931	0,770	0,294	0,056	0,093
VH	Gamma 0	Lee Sigma	5x5	RF	0,660	0,944	0,720	0,317	0,066	0,109
VV	Gamma 0	Frost	7x7	RF	0,660	0,935	0,750	0,309	0,069	0,113
VH	Sigma 0	Frost	7x7	RF	0,659	0,947	0,710	0,307	0,094	0,143
VH	Gamma 0	Boxcar	7x7	RF	0,656	0,940	0,727	0,261	0,113	0,157
VV	Sigma 0	Boxcar	7x7	RF	0,652	0,943	0,712	0,263	0,075	0,117
VV	Sigma 0	Lee	5x5	RF	0,651	0,945	0,706	0,301	0,086	0,133
VH	Sigma 0	Boxcar	5x5	RF	0,651	0,939	0,722	0,269	0,054	0,090
VH	Gamma 0	Lee	5x5	RF	0,644	0,929	0,747	0,265	0,055	0,091
VV	Gamma 0	Lee Sigma	5x5	RF	0,644	0,938	0,718	0,278	0,061	0,100
VV	Gamma 0	Boxcar	5x5	RF	0,643	0,941	0,708	0,269	0,070	0,111
VV	Gamma 0	Frost	5x5	RF	0,640	0,937	0,716	0,299	0,059	0,099
VH	Sigma 0	Boxcar	7x7	RF	0,639	0,941	0,702	0,288	0,057	0,095
VH	Gamma 0	Frost	7x7	RF	0,638	0,933	0,724	0,336	0,060	0,102
VV	Sigma 0	Boxcar	5x5	RF	0,636	0,930	0,731	0,328	0,089	0,140
VH	Gamma 0	Boxcar	5x5	RF	0,636	0,926	0,743	0,338	0,072	0,118
VV	Gamma 0	Lee	5x5	RF	0,631	0,943	0,683	0,290	0,053	0,090
VV	Gamma 0	Lee	7x7	RF	0,628	0,935	0,704	0,340	0,085	0,136
VH	Sigma 0	Lee Sigma	5x5	RF	0,628	0,925	0,737	0,271	0,057	0,094
VV	Gamma 0	Boxcar	7x7	RF	0,626	0,934	0,706	0,253	0,071	0,111
VV	Gamma 0	Lee Sigma	7x7	RF	0,612	0,920	0,729	0,253	0,117	0,160
VH	Sigma 0	Lee	7x7	RF	0,610	0,934	0,683	0,355	0,081	0,132
VH	Sigma 0	Frost	5x5	RF	0,609	0,940	0,664	0,317	0,057	0,096
VV	Sigma 0	Lee	7x7	RF	0,608	0,931	0,691	0,328	0,091	0,143
VV	Sigma 0	Frost	5x5	RF	0,581	0,928	0,662	0,263	0,115	0,160
VV	Sigma 0	Lee Sigma	5x5	RF	0,579	0,914	0,699	0,380	0,075	0,125
VH	Sigma 0	Boxcar	5x5	UC	0,577	0,903	0,731	0,251	0,122	0,164
VH	Sigma 0	Lee Sigma	5x5	UC	0,576	0,895	0,754	0,407	0,069	0,119
VH	Sigma 0	Frost	5x5	UC	0,570	0,887	0,768	0,351	0,101	0,157
VH	Sigma 0	Lee	5x5	UC	0,569	0,893	0,747	0,397	0,084	0,138
VH	Gamma 0	Boxcar	5x5	UC	0,564	0,898	0,727	0,261	0,056	0,092
VH	Gamma 0	Lee Sigma	7x7	UC	0,558	0,906	0,693	0,297	0,065	0,106
VH	Gamma 0	Lee	5x5	UC	0,552	0,887	0,739	0,280	0,056	0,093
VH	Gamma 0	Lee	7x7	UC	0,552	0,911	0,672	0,282	0,062	0,102
VH	Sigma 0	Lee Sigma	7x7	UC	0,550	0,915	0,660	0,345	0,104	0,160

VH	Gamma 0	Frost	7x7	UC	0,549	0,883	0,747	0,363	0,098	0,154
VH	Sigma 0	Lee	7x7	UC	0,548	0,919	0,645	0,378	0,093	0,149
VH	Sigma 0	Frost	7x7	UC	0,547	0,909	0,672	0,230	0,069	0,107
VH	Gamma 0	Lee Sigma	5x5	UC	0,545	0,885	0,737	0,271	0,080	0,123
VH	Gamma 0	Boxcar	7x7	UC	0,543	0,925	0,620	0,257	0,074	0,115
VH	Gamma 0	Frost	5x5	UC	0,542	0,878	0,750	0,292	0,060	0,099
VH	Sigma 0	Boxcar	7x7	UC	0,533	0,931	0,593	0,384	0,090	0,146
VV	Gamma 0	Lee Sigma	5x5	UC	0,511	0,899	0,649	0,274	0,060	0,098
VV	Sigma 0	Lee	5x5	UC	0,511	0,916	0,603	0,294	0,066	0,108
VV	Gamma 0	Frost	5x5	UC	0,509	0,896	0,656	0,390	0,089	0,144
VV	Gamma 0	Lee	5x5	UC	0,507	0,902	0,637	0,246	0,062	0,098
VV	Sigma 0	Frost	5x5	UC	0,507	0,907	0,622	0,353	0,103	0,160
VV	Gamma 0	Boxcar	5x5	UC	0,507	0,910	0,616	0,284	0,064	0,104
VV	Sigma 0	Lee Sigma	5x5	UC	0,506	0,912	0,610	0,426	0,076	0,129
VV	Gamma 0	Frost	7x7	UC	0,505	0,897	0,647	0,276	0,067	0,107
VV	Sigma 0	Boxcar	5x5	UC	0,504	0,924	0,574	0,251	0,065	0,103
VV	Gamma 0	Lee Sigma	7x7	UC	0,499	0,918	0,585	0,415	0,082	0,137
VV	Gamma 0	Lee	7x7	UC	0,493	0,924	0,562	0,439	0,076	0,130
VV	Sigma 0	Frost	7x7	UC	0,491	0,927	0,551	0,449	0,073	0,126
VV	Sigma 0	Lee Sigma	7x7	UC	0,487	0,930	0,539	0,461	0,070	0,121
VV	Sigma 0	Lee	7x7	UC	0,482	0,939	0,512	0,489	0,062	0,109
VV	Gamma 0	Boxcar	7x7	UC	0,473	0,935	0,509	0,491	0,065	0,115
VV	Sigma 0	Boxcar	7x7	UC	0,461	0,949	0,461	0,539	0,051	0,093