



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO
PROGRAMA DE MAESTRÍA Y DOCTORADO EN INGENIERÍA
INGENIERÍA ELÉCTRICA – PROCESAMIENTO DIGITAL DE SEÑALES

DETECCIÓN Y SEGMENTACIÓN DE HIELO *FRAZIL/PANCAKE* BASADA EN
SUPERPIXELES Y LA TRANSFORMADA DE HERMITE USANDO IMÁGENES
SAR

TESIS
QUE PARA OPTAR POR EL GRADO DE:
MAESTRA EN INGENIERÍA

PRESENTA:
ING. VIVIAN PAOLA TRIANA GALEANO

TUTOR PRINCIPAL
DR. BORIS ESCALANTE RAMÍREZ
FACULTAD DE INGENIERÍA

CIUDAD DE MÉXICO. ENERO 2017

JURADO ASIGNADO:

Presidente: Dra. LUCÍA MEDINA GÓMEZ
Secretario: Dr. PABLO ROBERTO PÉREZ ALCÁZAR
Vocal: Dr. BORIS ESCALANTE RAMÍREZ
1^{er}. Suplente: Dr. JESÚS SAVAGE CARMONA
2^d o. Suplente: Dr. FERNANDO ARÁMBULA COSÍO

Lugar o lugares donde se realizó la tesis: POSGRADO DE INGENIERÍA

TUTOR DE TESIS:

Dr. BORIS ESCALANTE RAMÍREZ

FIRMA

“Corre riesgos: si ganas, serás dichoso; si pierdes, serás sabio.”

— Peter Kreeft

Agradecimientos

Al Profe Boris Escalante por permitirme ser parte del LAPI y por el apoyo brindado durante la maestría.

A mi mami quien siempre me apoya incondicionalmente a pesar de mis momentos de locura.

A mi loco papi que es mi mejor ejemplo de altruismo.

A Martín que desde que llegó a mi vida siempre me hace enojar.

A mi familia, en especial a mi abuelito a quien admiro y adoro.

A mis amigos y compañeros del LAPI: Jimena, Erik, Leiner, Lorena, gracias por el apoyo y compañía durante el tiempo de realización de mi tesis.

A Edgar y Erika por los buenos momentos y la bonita amistad que siempre me han dado.

A Uriel por las valiosas enseñanzas tanto a nivel personal como académico, así como la grata amistad.

A Germán por toda la paciencia para conmigo, la compañía para comer, los momentos que finge escucharme y por ser un cuidador de gatos bueno y amoroso.

A mis compañeros y amigos de generación por ser tan amables y haberme acompañado gratamente en este proceso de formación.

A mis profesores y jurados quienes compartieron el conocimiento y aportaron críticas en el proceso de formación como maestra.

A la señora Araceli por haberme brindado cariño y la mejor casa para vivir durante la maestría.

Al Consejo Nacional de Ciencia y Tecnología (CONACYT) por el apoyo económico brindado durante mis estudios.

Contenido

| | |
|---|-----|
| Agradecimientos | III |
| Lista de Figuras..... | VII |
| 1. Introducción | 1 |
| 1.1. Motivación | 1 |
| 1.2. Descripción de la tesis..... | 3 |
| 2. Hielo <i>Frazil/Pancake</i> e Imágenes SAR | 5 |
| 2.1. Hielo <i>Frazil/Pancake</i> | 5 |
| 2.2. Radar de Apertura Sintética | 7 |
| 2.3. Misión Sentinel-1 | 9 |
| 2.4. Revisión literaria..... | 9 |
| 3. Metodología | 13 |
| 3.1. Transformada de Hermite..... | 14 |
| 3.1.1. Transformada Polinomial | 14 |
| 3.1.2. Transformada de Hermite Cartesiana Unidimensional..... | 15 |
| 3.1.3. Transformada de Hermite Cartesiana Bidimensional | 17 |
| 3.1.4. Transformada de Hermite Rotada..... | 19 |
| 3.2. Algoritmo de Filtrado | 19 |
| 3.2.1. Filtrado basado en la Transformada de Hermite | 20 |
| 3.3. Algoritmo de Segmentación..... | 21 |
| 3.3.1. Superpíxeles - SLIC..... | 22 |
| 3.3.2. Descripción de texturas con la Transformada de Hermite | 24 |
| 3.4. Evaluación Cuantitativa de la Segmentación | 25 |
| 3.4.1. Error de Clasificación..... | 25 |
| 3.4.2. Error de área | 26 |
| 3.4.3. Índice DICE..... | 26 |
| 4. Pruebas y Resultados | 29 |
| 4.1.1. Filtrado | 29 |

| | |
|---------------------------------------|----|
| 4.1.2. Segmentación..... | 31 |
| 5. Conclusiones y Trabajo Futuro..... | 35 |
| 5.1. Conclusiones..... | 35 |
| 5.2. Trabajo Futuro..... | 36 |
| Referencias..... | 39 |

Lista de Figuras

| | |
|---|----|
| Figura 2.1. Campo de hielo Pancake en una suspensión de hielo Frazil . | 6 |
| Figura 2.2. Zona de hielo Frazil/Pancake en una imagen SAR de Sentinel-1 (polarización HH) tomada sobre Greenland – Diciembre 4 de 2014, de acuerdo al análisis visual de un experto en hielo Frazil/Pancake. | 6 |
| Figura 2.3. Esquema de observación de un sistema RADAR [15]. | 8 |
| Figura 3.1. Esquema general que ilustra la metodología planteada. | 13 |
| Figura 3.2. Transformada Polinomial [40]. | 15 |
| Figura 3.3. Coeficientes de la Transformada de Hermite cartesiana con orden máximo de descomposición 2. | 18 |
| Figura 3.4. Coeficientes de la Transformada de Hermite Rotada con orden máximo de descomposición 2. | 18 |
| Figura 3.5. Esquema general de filtrado [42]. | 20 |
| Figura 4.1. Subimagen SAR Sentinel-1 polarización HH, corregida radiométricamente, tomada sobre Greenland – 4 diciembre 2014. Derecha: Imagen sin filtrar, con presencia de Speckle. Izquierda: Imagen filtrada usando el algoritmo basado en la Transformada de Hermite. | 30 |
| Figura 4.2. Histogramas de la subimagen sin filtrar (a) e histograma de la subimagen filtrada (b). | 30 |
| Figura 4.3. Superpíxeles obtenidos como resultado de pre-segmentación. | 31 |
| Figura 4.4. Comparación de contornos resultado de la segmentación con el algoritmo propuesto (color verde) y dos marcaciones manuales de referencia (color rojo). | 32 |

Figura 4.5. Contorno de la segmentación obtenida puesto sobre la subimagen con el objetivo de realizar inspección visual para evaluación cualitativa de los resultados..... 33

Figura 4.6. Máscaras correspondientes a la marcación manual de referencia (a), (b) y máscara resultado de la segmentación lograda con el algoritmo propuesto (c)..... 34

1.Introducción

1.1.Motivación

La observación, monitoreo y análisis de hielo marino es de vital importancia debido a que este impone restricciones en el tráfico marítimo, sirve como indicador climático, juega un rol importante en la exploración y explotación de recursos marinos; además de ser un aislante efectivo entre el océano y la atmósfera, restringiendo el intercambio de calor, masa y componentes químicos [1]. La presencia de hielo marino reduce considerablemente la radiación solar que absorbe la superficie de la Tierra y en zonas de latitudes altas es importante la observación de éste para realizar pronósticos del clima.

Los sistemas de Radar de Apertura Sintética – SAR se presentan como la mejor opción para llevar a cabo las tareas de observación en las zonas de hielo marino, debido a la capacidad que estos poseen para obtener imágenes en casi cualquier condición atmosférica y cualquier hora del día, ya que son sistemas activos; es decir, poseen una fuente de radiación propia, y trabajan en la banda de microondas del espectro electromagnético cuya radiación puede penetrar lluvias y nubes [2]. Uno de los principales retos a la hora de analizar imágenes obtenidas con sistemas SAR es el fenómeno conocido como *Speckle*, inherente a la formación de la imagen, que agrega una degradación a la misma, modelándose como un tipo de ruido multiplicativo, y dificulta las tareas de detección, segmentación [2], clasificación [3] y análisis.

Desde el lanzamiento del primer satélite con sensor SAR para monitoreo de la superficie de la Tierra en 1978, gran cantidad de imágenes se encuentran disponibles para ser analizadas y extraer información relevante para diversos estudios relacionados con cambio climático, navegación marítima, vigilancia y seguridad marítima. Por estas razones, y dada la complejidad del análisis de dichas imágenes, científicos alrededor del mundo han estudiado, desarrollado e implementado técnicas que permiten la interpretación de información y el análisis de los distintos fenómenos a partir de este tipo de imágenes.

El problema de detección de hielo marino a partir de imágenes SAR ha sido abordado desde diferentes perspectivas, las cuales van desde el uso de información de niveles de gris combinado con análisis de texturas, hasta información adicional como cartas de

concentración de hielo para mejorar las tasas de clasificación. Aunque los resultados reportados con anterioridad han sido considerados como aceptables, diversos autores, como [4], sugieren que el problema de detección y análisis de hielo marino a partir de imágenes SAR sigue siendo un campo de estudio que requiere ser explorado y optimizado, especialmente para la automatización y discriminación de fronteras entre diferentes tipos de hielo.

El hielo *Frazil/Pancake* es un tipo de hielo marino que resulta del proceso de enfriamiento en superficies con condiciones turbulentas, asociadas con el viento y campos de olas [5]. Pequeños cristales de hielo *Frazil* se congelan juntos para formar una especie de hielo que tiene forma de pastel, con los bordes elevados por las interacciones entre ellos, el cual se llama hielo *Pancake*. Estos pasteles se transportan juntos en una base de hielo *Frazil*, de ahí el nombre hielo *Frazil/Pancake*. Autores como [6] [7] han señalado la importancia de este tipo de hielo como componente de la criósfera y la influencia que tiene el espesor de estos hielos en el flujo de calor y sal a la superficie del océano. Estudios sobre la dispersión de olas en campos de hielo *Frazil/Pancake* se consideran relevantes para obtener medidas de espesor de hielos, como lo señala [8], motivo por el cual surge la necesidad de detectar este hielo en las imágenes SAR.

La detección y segmentación de áreas donde se presenta hielo de tipo *Frazil/Pancake* en imágenes SAR, obtenidas por la misión Sentinel-1, es el principal objetivo de esta Tesis, para lo cual se propone el uso de la Transformada de Hermite como herramienta útil para la reducción de *Speckle* y la descripción de texturas, así como una etapa de pre-segmentación basada en Superpíxeles. La Transformada de Hermite, como modelo matemático con funciones de análisis similares a derivadas de Gaussianas, ha sido utilizada para el análisis de imágenes debido a la relación que guardan las derivadas de Gaussianas con los campos receptivos del sistema de visión de algunos mamíferos [9]. Trabajos como el desarrollado en [10] demuestran la utilidad de esta Transformada en la clasificación y segmentación de texturas. Además, en [11] [12] se utiliza la Transformada de Hermite para tareas de reducción de ruido y en [13] se encuentra que los algoritmos de filtrado basados en transformadas polinomiales presentan buen desempeño, comparado con otras técnicas, para la preservación de información en imágenes SAR. La obtención de superpíxeles usando el algoritmo SLIC [14] se propone gracias a la capacidad que posee de obtener segmentos que se adhieren a los bordes de la imagen y se evitan las formas similares a bloques dadas por el uso de ventanas cuadradas en la segmentación. Los resultados de este trabajo serán usados para llevar a cabo estudios posteriores como el planteado en [8].

1.2. Descripción de la tesis

En el Capítulo 2 se explican las principales ideas relacionadas con hielo *Frazil/Pancake* y las características que lo representan en imágenes SAR. Así mismo, se expone la teoría relacionada con la formación de una imagen de Radar de Apertura Sintética de tal manera que se puedan entender las diferentes perspectivas desde las cuales se ha abordado el problema de observación de hielo marino usando sensores SAR, lo cual, hace referencia al tema de discusión en la última sección de este Capítulo. La metodología propuesta para detectar hielo *Frazil/Pancake* en imágenes SAR se presenta en el Capítulo 3. En el Capítulo 4 se dan a conocer y se analizan los resultados de la segmentación. En el Capítulo 5 se presentan las conclusiones y trabajo futuro.

2. Hielo *Frazil/Pancake* e Imágenes SAR

La representación en mapas temáticos de áreas con diversos tipos de hielo marino es de vital importancia para aplicaciones como navegación marítima, estudios ambientales y de cambio climático, así como pronósticos de clima. Las imágenes SAR han sido usadas en la mayoría de los trabajos relacionados con zonas polares gracias a la ventaja que ofrecen de obtener información en casi cualquier condición atmosférica, haciendo posible la obtención de mapas con importante distinción entre los diversos tipos de hielo marino y mar abierto. Hielo *Frazil/Pancake*, considerado como un tipo especial de hielo marino, cuya detección, a partir de imágenes SAR obtenidas con la misión Sentinel-1, es el principal objetivo de este trabajo.

2.1. Hielo *Frazil/Pancake*

El hielo *Pancake* es el resultado de un proceso de congelación que tiene lugar en condiciones turbulentas de la superficie, típicamente asociadas con viento y oleaje. Bajo estas condiciones, el producto inicial de congelamiento en la superficie del mar es hielo *Frazil*, una suspensión de pequeños cristales orientados aleatoriamente, que dan al mar una apariencia grasosa o cremosa [5].

A medida que la congelación continúa y la densidad de la suspensión *Frazil* incrementa, se alcanza un punto de transición en el cual los cristales *Frazil* se congelan juntos en pequeños pasteles, con el tamaño de cada pastel controlado por ondas inducidas por la compresión cíclica de la suspensión. Las colisiones entre pasteles vecinos fuerzan al hielo *Frazil* sobre los bordes de los pasteles, los cuales se levantan para dar a la superficie una apariencia de *pancake*, de ahí el nombre de hielo *Pancake* [5]. Dichos *pancakes* se mezclan y transportan unos sobre otros, llegando a congelarse juntos, aumentando el espesor normal del hielo, con el hielo *Frazil* actuando como “pegamento”. En la Figura 2.1 se muestra una fotografía de un campo de hielo *Frazil/Pancake*, donde se puede observar la forma similar a *pancakes* que presenta.

Al inicio de la formación, los *pancake* pueden ser de solo unos pocos centímetros o decenas de centímetros de diámetro, pero estos crecen gradualmente en diámetro y espesor

debido a una mayor acumulación de la matriz de *Frazil* que los rodea. Eventualmente, los *pancakes* pueden alcanzar de 3 a 5 m en diámetro y 50 a 70 cm de espesor con toda la estructura de hielo compuesta por cristales de origen *Frazil* [7].



Figura 2.1. Campo de hielo *Pancake* en una suspensión de hielo *Frazil* 1.

El hielo *Pancake* tiene apariencia brillante en imágenes SAR debido a la retrodispersión desde los bordes levantados de los *pancakes*, mientras el hielo *Frazil* presenta una apariencia oscura debido a la repulsión de las ondas de alta frecuencia que presenta este tipo de hielo, como se menciona en [7]. En la Figura 2.2 se observa la zona donde se presenta hielo *Frazil/Pancake*, en una imagen SAR de Sentinel-1 con polarización HH. Se puede observar la apariencia mezclada entre brillantes y oscuros para la zona de hielo *Frazil/Pancake*, como se describió.

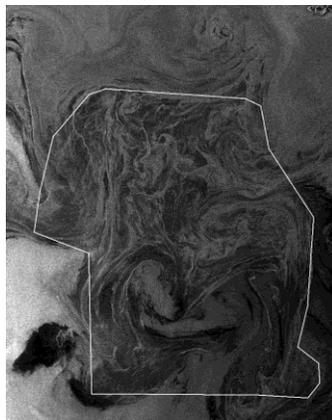


Figura 2.2. Zona de hielo *Frazil/Pancake* en una imagen SAR de Sentinel-1 (polarización HH) tomada sobre *Greenland* – Diciembre 4 de 2014, de acuerdo al análisis visual de un experto en hielo *Frazil/Pancake*.

¹ Imagen obtenida [En línea]. Disponible en: http://icestories.exploratorium.edu/dispatches/wp-content/uploads/2008/04/ice_pancakeice2.jpg . [Último acceso: 3 noviembre 2016].

2.2. Radar de Apertura Sintética

Un sistema RADAR (*Radio Detection And Ranging*) de imágenes es aquel sistema activo, que genera de manera controlada la radiación requerida para iluminar la escena, el cual emplea radiación coherente (paquetes de onda con igual longitud de onda e igual fase) en la región de microondas para formar una imagen [15]. Como resultado de la interferencia constructiva y destructiva de los pulsos coherentes del sistema RADAR, se produce una degradación en la imagen conocida como *Speckle*, que se modela como ruido multiplicativo, y da a la imagen una apariencia granular como “*salt and pepper*”. Existen diversos métodos digitales para reducción de *Speckle* como el filtro de Lee multiplicativo [16], filtro de Frost [17], filtros basados en Transformadas Polinomiales [12], entre otros; así como la técnica conocida como *Multilook*, considerado como un método de naturaleza física, que permite la reducción del *Speckle* realizando el promedio de una secuencia de imágenes de la misma zona tomadas en tiempos diferentes, las cuales deben ser co-registradas debido a los cambios en la geometría de iluminación que se producen por las variaciones en la órbita del satélite [15].

En la generación de la imagen SAR se pueden utilizar varios esquemas de polarización debido al uso de radiación coherente. Cuando la radiación se transmite con polarización horizontal del campo eléctrico y los pulsos retrodispersados son medidos en polarización vertical, se dice que se tiene un esquema de polarización HV. Otras combinaciones de polarización posibles son HH (transmisión horizontal-recepción horizontal), VV (transmisión vertical-recepción vertical) y VH. Con cada esquema de polarización se observan diferentes aspectos de brillantez y textura de la escena, es decir, aspectos que pudieran no ser visibles en el esquema HH podrían distinguirse en el esquema VV [15].

La imagen de RADAR se obtiene midiendo los pulsos retrodispersados por la escena. El Sistema Radar de Apertura Sintética tiene en cuenta el efecto de corrimiento *Doppler* debido al desplazamiento relativo entre la antena y un punto en la escena. Los valores de rango, amplitud, fase y corrimiento *Doppler* de la señal retrodispersada en un intervalo determinado se registran para formar la imagen.

A continuación, se presentan algunos conceptos básicos relacionados con la geometría de formación de la imagen. Ver Figura 2.3.

- Ángulo de *Squint*, η . Ángulo formado por la trayectoria de desplazamiento y el haz de radiación.
- Rango, R . Distancia de la antena a la escena.

- Dirección de azimuth. Dirección de desplazamiento de la antena. Es perpendicular a la dirección del rango.
- Ángulo de depresión, β . Inclinación del haz hacia la escena.

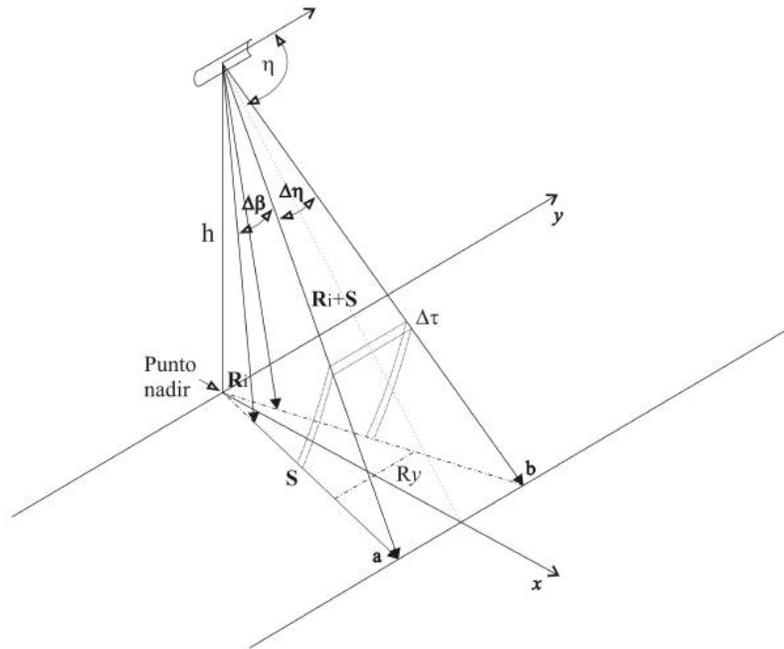


Figura 2.3. Esquema de observación de un sistema RADAR [15].

Un concepto importante en la teoría de imágenes SAR es la sección diferencial de dispersión σ_0 , que representa la fracción de radiación reemitida en dirección del receptor del sistema RADAR. Esta sección diferencial depende de parámetros tanto de la escena (rugosidad de la superficie, constante dieléctrica, coeficiente de dispersión volumétrica, entre otros) como del sistema de observación [15]. Dentro de los parámetros del sistema de observación de los cuales depende σ_0 se encuentra el ángulo de incidencia, el cual hace que se obtenga una imagen más brillante en aquellas zonas donde la pendiente del terreno y el ángulo de depresión hacen que el ángulo de incidencia sea pequeño².

² Para información detallada sobre geometría de formación de una imagen SAR y aspectos teóricos al respecto, ver [15], [51].

2.3. Misión Sentinel-1

Sentinel-1 es una constelación de dos satélites desarrollados por la Agencia Espacial Europea – ESA (por las siglas en inglés) con el objetivo principal de monitorear el suelo y los océanos. Cada satélite consta de un sensor de Radar de Apertura Sintética – SAR con banda de operación C, frecuencia de 5.405 GHz y ciclo de repetición de 12 días (por satélite) con 175 órbitas. La resolución espacial varía desde 5x5m en modo *Strip Map*, hasta 25x100 m en modo *Extra-Wide Swath*. La primera parte de la constelación fue lanzada en abril de 2014, denominada Sentinel-1A, mientras que la segunda parte, Sentinel-1B, fue puesta en órbita en abril de 2016 [18]. Información obtenida con esta misión se encuentra disponible en el portal ESA Copernicus Sentinel Scientific Data Hube³, donde se pueden encontrar productos de nivel cero de procesamiento, nivel 1 y nivel 2. En este trabajo se utilizan productos de nivel 1, lo cuales han sido sometidos a proceso de georreferenciación, *multi-looking*, y la información de la fase no está disponible. La resolución de pixel es aproximadamente cuadrada y el espacio entre pixeles también. Presenta reducción de *Speckle* a costo de una reducción en la resolución geométrica. La calibración radiométrica se puede realizar con el *Toolbox SNAP* disponible en el portal *step science toolbox exploitation platform*⁴ de la Agencia Espacial Europea.

2.4. Revisión literaria

Diferentes sensores satelitales SAR para la observación de los océanos han sido puestos en órbita desde el lanzamiento del primer satélite SeaSat (1978), que proveía imágenes de alta resolución. Le han seguido misiones como ERS-1 y ERS-2, RADARSAT-1 y RADARSAT-2, ENVISAT-ASAR, TerraSAR, y la más reciente misión puesta en órbita Sentinel-1, cuyas imágenes son usadas en este trabajo. Con las imágenes obtenidas con estos satélites se han realizado diferentes esfuerzos para implementar algoritmos que permitan la detección de zonas con diferentes tipos de hielo marino y con ello realizar estudios posteriores como estudios de concentración de hielo [6] [19] [20], medidas de espesor de los mismos [7] [8], dispersión de olas en campos de hielo marino [8], y clasificación de éste [21]. La importancia de los algoritmos automáticos radica en la gran cantidad de imágenes que deben ser procesadas, el trabajo que conlleva realizar la identificación manual [2] [4] y la precisión y robustez en la misma [22].

³ ESA Copernicus Sentinel Scientific Data Hube. [En línea]. Disponible en: <https://scihub.copernicus.eu/dhus/#/home>. [Último acceso: 15 noviembre 2016].

⁴ *step science toolbox exploitation platform*. [En línea]. Disponible en: <http://step.esa.int/main/toolboxes/snap/>. [Último acceso: 15 noviembre 2016].

Dentro de las técnicas más empleadas para la segmentación y clasificación de hielo marino a partir de imágenes SAR se encuentran aquellas basadas en texturas. Matrices de co-ocurrencias -GLCM [4] [21] [23] [24] [25] [26], Campos Aleatorios de Markov – MRF [3] [4] [27] [24] [28] y Filtros de Gabor [24] [29]. La combinación con información adicional, como cartas de concentración de hielo [26], se ha hecho para mejorar los resultados en la distinción de las diversas clases de hielo. El uso de imágenes con diferente polarización y el aprovechamiento de las características reflejadas en cada tipo de polarización también ha sido estudiado y reportado en la literatura, ya que permite reducir ambigüedades en la interpretación [23] [30] [31] [32]. Algunos estudios sugieren que las mejores polarizaciones para detectar y clasificar el hielo marino son HH y HV [30], polarizaciones que se usan en la misión Sentinel-1. En este trabajo se usa la banda HH debido a que permite mejores resultados que los encontrados usando la banda HV, aunque se reconoce que la polarización HV es menos sensible al ángulo de incidencia [30] y podría ser usada para mejorar resultados de segmentación, así como la realización de correcciones de ángulo de incidencia HH [23] [21] [30], en trabajos futuros.

Diversos estudios han reafirmado la importancia de tener en cuenta la textura y no sólo el nivel de gris a la hora de analizar las imágenes [25] [33], así como la importancia del filtrado para disminuir la tasa de error en la clasificación [2] [3]. Dentro de las técnicas de filtrado empleadas se encuentra el filtro de mediana [34], el Lee adaptivo, el Frost y el método de difusión anisotrópica [2], así como filtros basados en transformadas polinomiales [12] [13]. Sin embargo, pocos trabajos realizan comparaciones de técnicas de filtrado y el aporte en la mejora de la clasificación [2] [13] [35]. En [13] se reporta buen desempeño de los filtros basados en transformadas polinomiales en el análisis de imágenes SAR comparado con filtros de difusión anisotrópica, y, tanto en [2] como en [35], se consideran aceptables el desempeño de filtros como Lee y Frost.

Los principales tipos de hielo marino que se han estudiado y logrado identificar a partir de imágenes SAR, de acuerdo a la nomenclatura de la Organización Meteorológica Mundial – WMO⁵, son hielo multi-año, de primer-año, nuevo hielo, además de mar abierto. Algunos trabajos se concentran en la distinción entre hielo marino en general y mar abierto [23] [36] [37], mientras que otros se enfocan en clasificar los distintos tipos de hielo [3] [4] [22] [24]. Uno de los principales problemas reportados es el inconveniente para discriminar entre hielo grasoso, pequeños témpanos y mar abierto [24] [26] [36] [38], y la mezcla de varios tipos de hielo en zonas de hielo marginal – MIZ [21], donde se encuentra la mayor cantidad de hielo *Frazil/Pancake*. Estos trabajos plantean como retos la mejora en la determinación de la frontera entre mar abierto y nuevo hielo, sin embargo, para las

⁵ World Meteorological Organization. Agencia de la ONU especializada en meteorología, hidrología operativa y ciencias geofísicas relacionadas. [En línea]. Disponible en: <http://www.wmo.int/>. [Último acceso: 12 octubre 2016].

aplicaciones que se plantearon no lo consideraron un problema importante. Pero, teniendo en cuenta que el hielo *Frazil/Pancake* es un tipo de hielo nuevo, se tiene el reto de mejorar dichos resultados de frontera. Otro de los inconvenientes que estos estudios plantean es la limitación de la validación de los algoritmos a imágenes obtenidas con un sensor específico, ya sea RADARSAT-2, ENVISAT. En [37] se utiliza un algoritmo similar al planteado en [21] pero haciendo ajustes para el uso en imágenes de la misión Sentinel-1A, siendo uno de los pocos trabajos que por primera vez usan estas imágenes y, aunque reporta resultados aceptables en la distinción de varios tipos de hielo, no hace reconocimiento de hielo *Frazil/Pancake*, y sugiere que las imágenes obtenidas con Sentinel-1 presentan grandes desafíos a la hora de clasificar hielo marino, tanto por la dependencia del ángulo de incidencia que se presenta en la polarización HH, como el ruido térmico en la polarización HV.

3. Metodología

El esquema de segmentación propuesto en este trabajo se basa en la descripción de texturas usando la Transformada de Hermite y una etapa de pre-segmentación con superpíxeles – SLIC para detectar zonas de hielo *Frazil/Pancake*, a partir de imágenes SAR obtenidas con la misión Sentinel-1. En la Figura 3.1 se presenta el diagrama de flujo del sistema propuesto, reconociendo tres etapas importantes. En la primera etapa se realiza un pre-procesamiento de la señal que incluye la remoción del ruido térmico y la calibración radiométrica, así como el filtrado para reducir *Speckle*. En la segunda etapa se selecciona la ventana de la imagen que concentra el área de hielo *Frazil/Pancake*, esto a criterio del experto y realizándose de forma manual. Esta ventana es submuestreada utilizando un filtro gaussiano, reduciendo la resolución espacial. A partir de esta subimagen se calculan los superpíxeles y utilizando la Transformada de Hermite Rotada se obtienen los coeficientes representativos de la imagen. Se obtiene un vector de características por cada superpíxel, teniendo en cuenta los coeficientes de mayor energía (ver sección 3.3.2). En la tercera etapa se realiza la clasificación de los vectores de características obteniéndose una máscara binaria que permite etiquetar los píxeles de la región de interés como pertenecientes o no a una zona de hielo *Frazil/Pancake*. Por último, se realiza una evaluación de la segmentación utilizando como referencia la marcación manual realizada por un experto en hielo *Frazil/Pancake*.

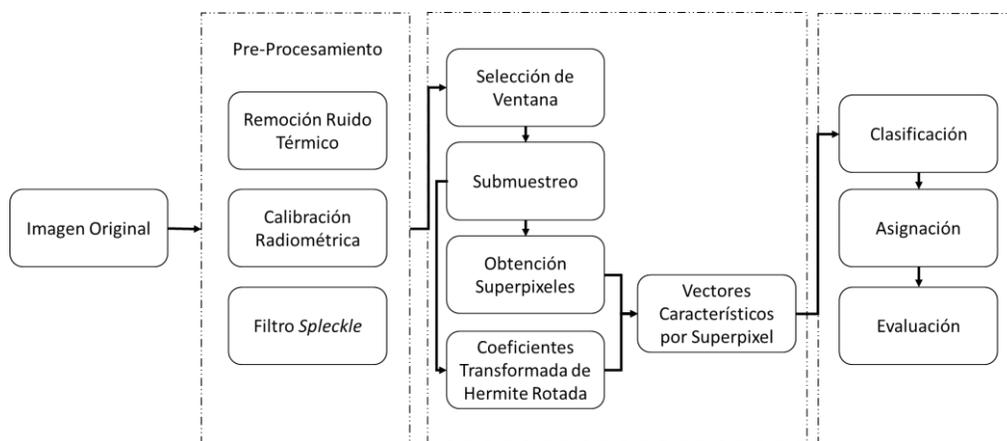


Figura 3.1. Esquema general que ilustra la metodología planteada.

3.1. Transformada de Hermite

La transformada de Hermite es una herramienta de análisis de imágenes que se aproxima al modelo de visión de algunos mamíferos, la cual tiene la capacidad de detectar y extraer estructuras visualmente importantes en una imagen, como son bordes y texturas, tal como se demuestra en [39]. Esta técnica de descomposición local fue introducida por Martens [40] al campo de procesamiento digital de imágenes y utiliza funciones elementales similares a las derivadas de Gaussianas, las cuales, según Young [9], presentan similitud con la forma de los campos receptivos de células simples en primates [41].

Diversos autores han utilizado la transformada de Hermite para diferentes aplicaciones, entre las cuales se encuentran la reducción de ruido [11], la fusión de imágenes [12], la segmentación [42], la clasificación [41], la codificación de imagen [43], el análisis de texturas [10], entre otras.

3.1.1. Transformada Polinomial

Una transformada polinomial es una técnica de representación de señales basada en aproximaciones polinomiales dentro de una ventana local. Una señal de entrada $L(x)$ se localiza multiplicándola por una función ventana $V(x)$ y se proyecta en polinomios ortogonales con funciones base $G_n(x)$, donde n es el grado del polinomio, las cuales son ortonormales con respecto a $V^2(x)$ [40].

$$L_n(kT) = \int_{-\infty}^{\infty} L(x) \cdot G_n(x - kT) V^2(x - kT) dx \quad (3.1)$$

La ecuación 3.1 se conoce como la Transformada Polinomial Directa, la cual mapea la señal de entrada $L(x)$ en los coeficientes $L_n(kT)$, los cuales se pueden obtener convolucionando la señal de entrada $L(x)$ con **funciones de análisis (o funciones filtro) $D_n(x)$** seguido de un submuestreo en múltiplos de T .

$$D_n(x) = G_n(-x) V^2(-x) \quad (3.2)$$

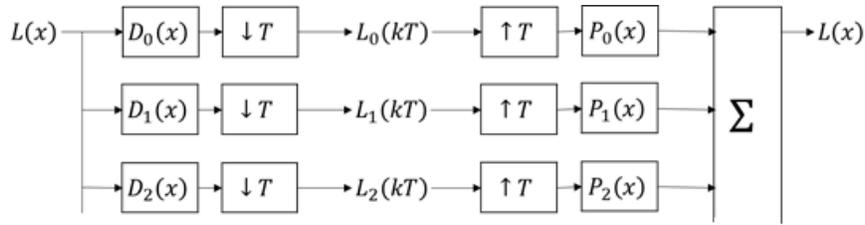


Figura 3.2. Transformada Polinomial [40].

La Figura 3.2 ilustra el proceso de obtención de la Transformada Polinomial Directa e Inversa. Esta última permite la reconstrucción de la señal de entrada a partir de la interpolación de los coeficientes $L_n(kT)$ con **funciones de síntesis** $P_n(x)$ y la suma sobre todos los órdenes n , de acuerdo con la ecuación 3.3.

$$L(x) = \sum_{n=0}^{\infty} \sum_k L_n(kT) \cdot P_n(x - kT) \quad (3.3)$$

Donde,

$$P_n(x) = \frac{G_n(x)V(x)}{W(x)} \quad (3.4)$$

3.1.2. Transformada de Hermite Cartesiana Unidimensional

La función ventana es uno de los parámetros libres en una transformada polinomial. La transformada de Hermite es una transformada polinomial con función ventana Gaussiana [43] con un factor de normalización tal que $V^2(x)$ tiene energía unitaria, ecuación 3.5 [40], y cuyos polinomios ortogonales asociados corresponden a los polinomios de Hermite, los cuales están dados por la fórmula de Rodrigues, ecuación 3.6 [41].

$$V(x) = \frac{1}{\sqrt{\sqrt{\pi}\sigma}} \cdot e^{-x^2/2\sigma^2} \quad (3.5)$$

$$H_n(x) = (-1)^n e^{x^2} \frac{d^n e^{-x^2}}{dx^n}, \quad n = 0,1,2, \dots \quad (3.6)$$

Dada las funciones de análisis de la ecuación 3.2 y los polinomios de Hermite de la ecuación 3.6, así como la función ventana de la ecuación 3.5, se obtienen las **funciones de análisis de Hermite** como se muestra en la ecuación 3.7.

$$D_n(x) = \frac{(-1)^n}{\sqrt{2^n n!}} \cdot \frac{1}{\sigma\sqrt{\pi}} H_n\left(\frac{x}{\sigma}\right) e^{-x^2/\sigma^2} \quad (3.7)$$

La **función de síntesis de Hermite** está dada por la ecuación 3.8, donde la función de ponderación $w(x)$ es la indicada por la ecuación 3.9. Si $w(x) = 1$ para valores de muestreo del parámetro $\tau < 2$, la función de síntesis es igual a la función de Hermite de orden n . Esto implica que es un eigenvalor de la ecuación de un oscilador armónico simple.

$$P_n(x) = \frac{T}{\sqrt{2^n n!}} \cdot \frac{1}{\sigma\sqrt{2\pi}} H_n\left(\frac{x}{\sigma}\right) \frac{e^{-x^2/\sigma^2}}{w(x)} \quad (3.8)$$

$$w(x) = 1 + 2 \sum_{k=1}^{\infty} \exp\left[-\frac{1}{2}\left(k\frac{2\pi\sigma}{T}\right)^2\right] \cdot \cos\left(k\frac{2\pi x}{T}\right) \quad (3.9)$$

3.1.3. Transformada de Hermite Cartesiana Bidimensional

Las funciones de análisis y síntesis de la transformada de Hermite unidimensional poseen la propiedad de ser espacialmente separables y rotacionalmente simétricas. Debido a esto, dichas funciones se pueden generalizar al caso bidimensional, como se muestra en la ecuación 3.10, donde $n - m$ denota el orden de análisis en la dirección x , mientras que m corresponde a la dirección y [40].

$$D_{n-m,m}(x,y) = D_{n-m}(x)D_m(y) \quad (3.10)$$

La descomposición de una imagen $L(x,y)$ se puede calcular usando como base las funciones de análisis en dos dimensiones de la ecuación 3.10, como una convolución de la señal de entrada con dichas funciones, seguida de un submuestreo en las direcciones horizontal y vertical, de tal manera que:

$$L_{n-m,m}(x_0,y_0) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} L(x,y) \cdot D_{n-m,m}(x_0 - x, y_0 - y) dx dy \quad (3.11)$$

Para $n = 0, 1, \dots, \infty$ y $m = 0, \dots, n$.

La imagen sintetizada se obtiene con el proceso de interpolación de la transformada inversa, como en la ecuación 3.12 [11].

$$L(x,y) = \sum_{n=0}^{\infty} \sum_{m=0}^n \sum_{(x_0,y_0) \in S} L_{n-m,m}(x_0,y_0) P_{n-m,m}(x - x_0, y - y_0) \quad (3.12)$$

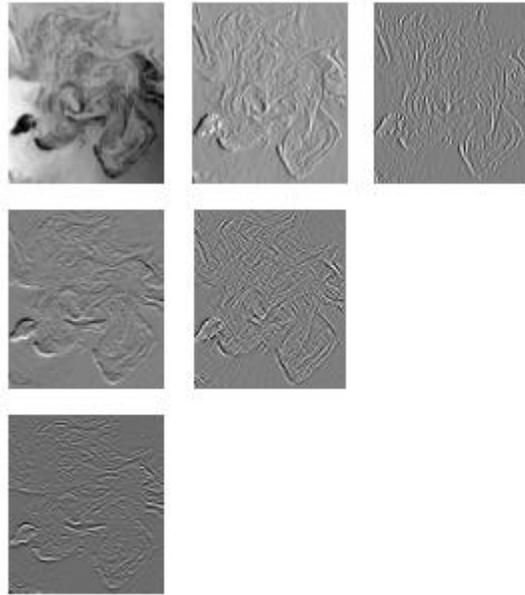


Figura 3.3. Coeficientes de la Transformada de Hermite cartesiana con orden máximo de descomposición 2.

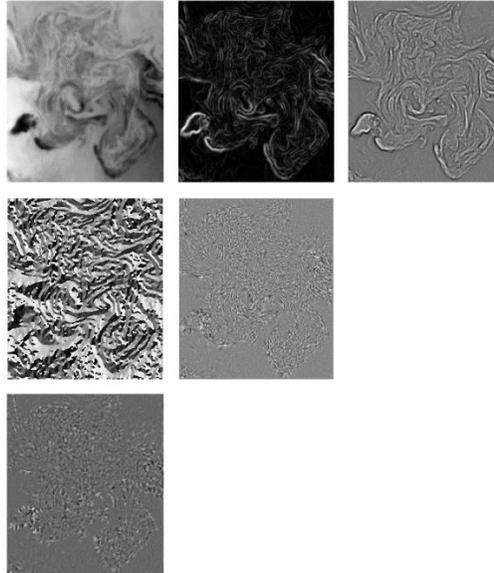


Figura 3.4. Coeficientes de la Transformada de Hermite Rotada con orden máximo de descomposición 2.

3.1.4. Transformada de Hermite Rotada

La transformada de Hermite Rotada, dada por la ecuación 3.13, se basa en la idea de los filtros con orientación arbitraria sintetizados como una combinación lineal de un conjunto de filtros base [44]. Tomando combinaciones lineales de los filtros cartesianos de orden n se pueden construir versiones rotadas de un filtro de orden n , debido a las propiedades de las funciones de análisis de Hermite [39].

$$L^{\theta}_{n-m,m}(x, y, \theta) = \sum_{k=0}^n L_{n-k,k}(x, y) \alpha_{n-k,k}(\theta) \quad (3.13)$$

Donde $\alpha_{n-m,m}(\theta)$ son las funciones angulares cartesianas de orden n definidas en la ecuación 3.14, con C_n^m correspondiente a la versión binomial de una función Gaussiana [41].

$$\alpha_{n-m,m}(\theta) = \sqrt{C_n^m} \cos^{n-m}(\theta) \sin^m(\theta) \quad (3.14)$$

La transformada de Hermite tiene la ventaja de que se puede lograr una compresión muy eficiente de la energía por medio de la rotación adaptiva de la transformada [39]; de esta manera se maximiza la detección de patrones sobre una dirección local θ [41]. En [39] se propone estimar θ usando $\tan \theta = L_{0,1}/L_{1,0}$.

3.2. Algoritmo de Filtrado

La coherencia de la radiación utilizada en los sistemas de Radar de Apertura Sintética – SAR produce una degradación en la imagen, inherente a la formación de la misma, la cual es conocida como *Speckle*. Este tipo de degradación es modelado como ruido de carácter

multiplicativo, dependiente de la señal de radar [15]. La existencia de *Speckle* dificulta aún más la tarea de modelar los coeficientes de retrodispersión en imágenes SAR de hielo marino [3] y degrada los detalles de la imagen con una posible disminución en la separación entre las distintas clases de hielo [38], complicando los procesos automáticos de segmentación y clasificación [13].

Diferentes técnicas de filtrado pretenden reducir el *Speckle*, pero para hacer uso de éstas se debe considerar la posibilidad de una disminución en los detalles de textura y de difuminación de las fronteras entre regiones de hielo [3].

3.2.1. Filtrado basado en la Transformada de Hermite

El algoritmo de filtrado utilizado para reducir el *Speckle* en las imágenes SAR, se basa en la descomposición mediante la transformada de Hermite. De acuerdo con [45], donde se comparan diferentes técnicas de filtrado para reducción de *Speckle* (Filtro Lee, Wiener, Difusión anisotrópica, Bayesiano), el mejor desempeño (en cuanto relación señal a ruido y coeficiente de correlación) se obtuvo con la estrategia implementada en [12]. Teniendo en cuenta que la transformada de Hermite es un caso especial de transformada polinomial, los resultados de desempeño concuerdan con lo obtenido en [13], donde se concluye que el mejor método de filtrado para imágenes SAR, de acuerdo a una evaluación subjetiva, es el basado en transformadas polinomiales.

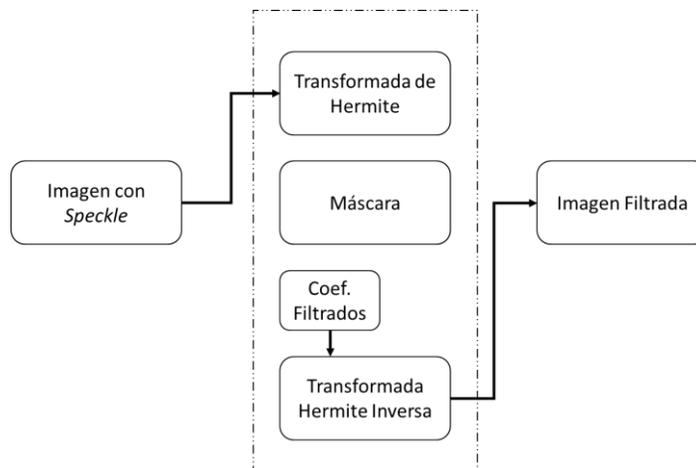


Figura 3.5. Esquema general de filtrado [42].

Como se muestra en la Figure 3.5, a partir de la imagen original se obtienen los coeficientes de la transformada de Hermite. Luego se construye una máscara de energía por medio de la umbralización de la energía de los coeficientes de primer orden $E_1 = L_{0,1}^2 + L_{1,0}^2$. Los coeficientes de Hermite se filtran teniendo en cuenta la máscara de energía obtenida, exceptuando al coeficiente de orden cero, y a partir de los coeficientes filtrados se calcula la transformada Hermite inversa para obtener una imagen con reducción significativa de *Speckle* y preservación de bordes y texturas [12].

Teniendo en cuenta que una imagen SAR de amplitud de un *look* tiene una distribución Rayleigh y relación señal a ruido – SNR de aproximadamente 1.9131 y que, en general, la SNR de una imagen SAR *multi-look* no cambia sobre la imagen completa, además, $SNR_{Nlooks} = 1.9131\sqrt{N}$ [12]; entonces, el umbral para cada punto de la imagen se puede obtener como:

$$T(x, y) = \frac{2\vartheta(x, y) \ln\left(\frac{1}{P_R}\right) L_{0,0}^2(x, y)}{AN} \quad (3.15)$$

Donde $\vartheta(x, y) = |R_L(x, y) * D_{1,0}(x, y) * D_{0,1}(x, y)|_{x=y=0}$, R_L es la función de autocorrelación de L ; P_R es la probabilidad (porcentaje) de ruido que se desea dejar en la imagen; $L_{0,0}^2$ es el coeficiente de orden cero; A es la relación señal a ruido y N es el número de *looks* de la imagen. De esta manera se obtiene la máscara de energía M que se aplica a los coeficientes para realizar la reconstrucción a partir de los coeficientes obtenidos [45].

$$F_{n-m,m} = L_{n-m,m} * M \quad (3.16)$$

3.3. Algoritmo de Segmentación

El proceso de segmentación se realiza en dos etapas. La primera etapa es la pre-segmentación de la imagen en superpíxeles, segmentos perceptualmente significativos, reduciendo la complejidad del análisis de texturas posterior [46]. En la segunda etapa se obtienen los vectores de características para cada superpíxel utilizando descriptores sobre los coeficientes de mayor energía de la transformada de Hermite Rotada.

3.3.1. Superpíxeles - SLIC

Los Superpíxeles son conjuntos de píxeles vecinos similares, [47] tanto en intensidad como en ubicación, agrupados en regiones perceptualmente significativas, las cuales pueden ser usadas para reemplazar la estructura rígida de la cuadrícula de píxeles [14].

Simple Linear Iterative Clustering (SLIC) es el algoritmo propuesto en [48] para generar *Superpíxeles* visualmente compactos y casi uniformes, el cual se utiliza en este trabajo como un paso de pre-segmentación. SLIC se basa en una versión local del agrupamiento k-medias y, como se reporta en [14], presenta mejor desempeño comparado con otras técnicas para obtener superpíxeles, en cuanto a la adherencia a los bordes, rapidez de cálculo, eficiencia de memoria y simplicidad de uso, características importantes cuando los superpíxeles se utilizan como un paso de pre-procesamiento [14].

SLIC presenta cuatro etapas importantes: inicialización, asignación, actualización y post-procesamiento.

- **Inicialización**

En esta etapa k centros de clúster son muestreados en una rejilla regular espaciada S píxeles, siendo k el número deseado de superpíxeles, aproximadamente iguales en tamaño, y $S = \sqrt{N/k}$, con N igual al número de píxeles de la imagen.

Los centros de clúster se mueven a ubicaciones semilla correspondientes a una posición de menor gradiente en una vecindad de 3×3 con el objetivo de evitar centrar un superpíxel en un borde y reducir la posibilidad de “sembrar” un superpíxel con un píxel de ruido [14].

- **Asignación**

Después de la inicialización de los centros de clúster, cada píxel i es asociado a el centro de clúster más cercano en una región de búsqueda de $2S \times 2S$ alrededor del centro de superpíxel. Para esto, se introduce una medida de distancia D , que permite determinar el centro de clúster más cercano para cada píxel [14].

La medida de distancia D se define como:

$$D = \sqrt{d_c^2 + \left(\frac{d_s}{S}\right)^2 m^2} \quad (3.17)$$

Donde, m permite dar un peso a la importancia relativa entre similitud en nivel de gris y proximidad espacial. Si m es grande, la proximidad espacial es más importante y se obtienen superpíxeles más compactos. Si m es pequeña, los superpíxeles se adhieren mejor a los bordes de la imagen pero son menos regulares en tamaño y forma.

Para imágenes en escala de grises, con posición de píxel (x, y) y nivel de intensidad l , se definen d_c y d_s como:

$$d_c = \sqrt{(l_j - l_i)^2} \quad (3.18)$$

$$d_s = \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2} \quad (3.19)$$

- **Actualización**

Después de que cada píxel fue asociado con el centro de clúster más cercano, los centros de clúster se ajustan para que sean el vector medio $[l, x, y]$ de todos los píxeles pertenecientes a dicho clúster y se calcula un error residual E entre las nuevas ubicaciones de centro de clúster y las previas.

Las etapas de asignación y actualización se repiten iterativamente hasta que el error converge, definiendo un umbral.

- **Post-procesamiento**

Por último, es necesario realizar un post-procesamiento para forzar conectividad debido a que al final del proceso algunos píxeles permanecen aislados. Usando un algoritmo

de componentes conectadas, estos pixeles aislados son asignados al centro de clúster más cercano [14].

3.3.2. Descripción de texturas con la Transformada de Hermite

Como se argumenta en [41], la Transformada de Hermite Rotada es adecuada para la extracción de características de texturas invariantes a la rotación como son energía y estadísticos de segundo orden. Los estadísticos que se extraen de los coeficientes con mayor contenido de energía de la transformada de Hermite Rotada, es decir, los coeficientes $L_{n,0}^\theta$, son media, desviación estándar, entropía y *Skewness*, definidos como:

- Media

$$\mu = \frac{1}{HxW} \sum_{w=1}^W \sum_{h=1}^H L_{n,0}^\theta \quad (3.20)$$

- Desviación estándar

$$\sigma = \sqrt{\frac{1}{HxW - 1} \sum_{w=1}^W \sum_{h=1}^H [L_{n,0}^\theta - \mu]^2} \quad (3.21)$$

- Entropía

$$H = - \sum_{w=1}^W \sum_{h=1}^H L_{n,0}^\theta * \log(L_{n,0}^\theta) \quad (3.22)$$

- *Skewness*: es una medida de asimetría de los datos alrededor de la media muestral. Cuando los datos se distribuyen más a la izquierda que a la derecha de la media *Skewness* es negativa. En caso contrario, *Skewness* es

positiva. Para una distribución de los datos perfectamente simétrica, *Skewness* es cero.

$$skew = \frac{1}{(HxW)\sigma^3} \sum_{w=1}^W \sum_{h=1}^H [L_{n,0}^{\theta} - \mu]^3 \quad (3.23)$$

El vector de características para cada superpixel se define concatenando los cuatro estadísticos anteriores, calculados sobre los coeficientes con mayor energía de la transformada de Hermite Rotada. Adicionalmente, se incluye información sobre el nivel de gris que se obtiene como la media del coeficiente de orden cero (promedio) por cada superpixel. Por lo tanto, el vector de características para cada segmento (superpixel) puede ser escrito como en ecuación 3.24, hasta el orden de análisis con que se calcula la Transformada.

$$\vec{v} = [\mu_{0,0}, \mu_{1,0}, \sigma_{1,0}, H_{1,0}, skew_{1,0}, \mu_{2,0}, \sigma_{2,0}, H_{2,0}, skew_{2,0}, \dots] \quad (3.24)$$

3.4. Evaluación Cuantitativa de la Segmentación

Aunque algunos trabajos utilizan cartas de hielo marino [26] [49] [50] como referencia para la validación de la clasificación, para este trabajo se usa la marcación manual hecha por expertos en hielo *Frazil/Pancake* para realizar la evaluación. Además, no se han reportados trabajos realizados con imágenes obtenidas con la misión Sentinel-1 para la detección de hielo *Frazil/Pancake*, por lo cual sólo se usa la validación con la marca del experto.

3.4.1. Error de Clasificación

El error de clasificación es una métrica clásica en segmentación, que cuantifica el número total de píxeles que fueron incorrectamente asignados al área de interés o al fondo

en la imagen de prueba con respecto a la cantidad de píxeles en la zona de interés marcada por el experto.

$$EC(\%) = 100 \frac{|F_0 \cap B_T| + |B_0 \cap F_T|}{|F_0|} \quad (3.25)$$

Donde $|F_0 \cap B_T|$ representa el número de falsos negativos (píxeles incorrectamente asignados a fondo) y $|B_0 \cap F_T|$ representa el número de falsos positivos (píxeles incorrectamente asignados a zona de interés).

3.4.2. Error de área

El error de área mide la diferencia entre la imagen de referencia y la imagen segmentada, expresada como porcentaje respecto al área de referencia.

$$EA(\%) = 100 \left| \frac{|F_0| - |F_T|}{|F_0|} \right| \quad (3.26)$$

Donde $|X|$ representa el tamaño del conjunto X.

3.4.3. Índice DICE

El índice DICE es una medida de similitud entre dos objetos, definida como la intersección entre los 2 objetos, segmentado y referencia, sobre la media del conjunto combinado. Este índice está definido entre 0 y 1, indicando mayor similitud entre conjuntos cuando se acerca a 1.

$$DICE = \frac{2 \cdot |F_0 \cap F_T|}{|F_0| + |F_T|} \quad (3.27)$$

Donde F_0 es el conjunto de píxeles marcado por el experto como zona de interés y F_T es el conjunto de píxeles segmentados con el método a prueba.

4. Pruebas y Resultados

Dos imágenes Sentinel-1A, nivel 1 GRD-EW (*Ground Range Detected-Extra Wide*), resolución media (40 m x 40 m), polarización HH, adquiridas sobre la región de *Greenland* en noviembre 29 y diciembre 4 de 2014, fueron usadas para probar el algoritmo. La calibración radiométrica se realizó en el *Toolbox* SNAP de la Agencia Espacial Europea, usando:

$$\sigma_0 = \frac{DN^2}{A_{dn}^2 K} \sin \alpha \quad (4.1)$$

Donde α es ángulo incidente local, DN es el número digital del pixel (valor de amplitud tomado directamente del archivo de medidas), A_{dn} y K son constantes de calibración⁶.

Se usaron ventanas de la imagen que contenían hielo *Frazil/Pancake*, seleccionadas por inspección visual.

4.1.1. Filtrado

Para reducir el *Speckle*, que como se observa en Figura 4.1 derecha, está presente en las imágenes originales calibradas radiométricamente, se utilizó el algoritmo de filtrado propuesto en [12], obteniéndose una imagen con zonas más homogéneas y sin apariencia granular propia del *Speckle*, Figura 4.1 izquierda.

⁶ Radiometric Calibration of S-1 Level-1 Products Generated by the S-1 IPF. Documento. [En línea]. Disponible en: <https://sentinel.esa.int/documents/247904/685163/S1-Radiometric-Calibration-V1.0.pdf>. [Último acceso: 15 noviembre 2016].



Figura 4.1. Subimagen SAR Sentinel-1 polarización HH, corregida radiométricamente, tomada sobre Greenland – 4 diciembre 2014. Derecha: Imagen sin filtrar, con presencia de *Speckle*. Izquierda: Imagen filtrada usando el algoritmo basado en la Transformada de Hermite.

Al observar el histograma de la imagen original sin filtrar, Figura 4.2 (a), se puede comprobar que posee una forma de distribución Rayleigh, como se esperaba de la teoría expuesta en la sección 3.2.1, con lo cual se evidencia que el algoritmo de filtrado basado en la Transformada de Hermite es una técnica apropiada para reducir el *Speckle* en las imágenes de interés de este trabajo.

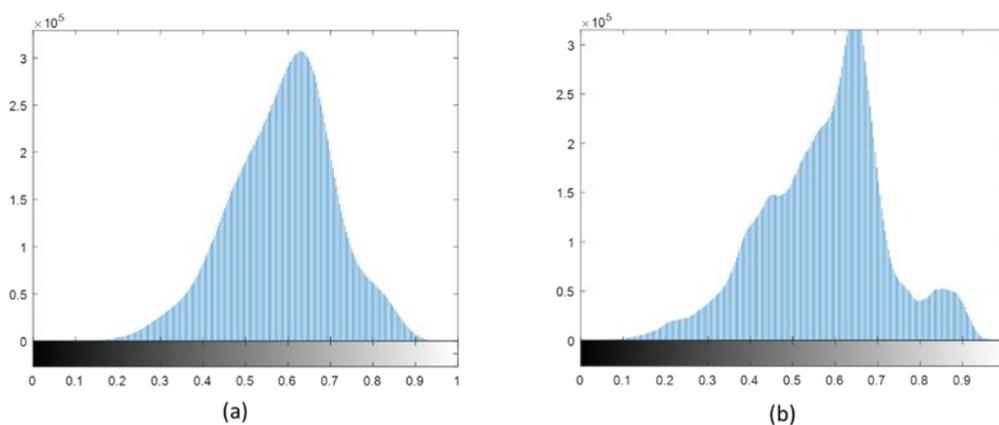


Figura 4.2. Histogramas de la subimagen sin filtrar (a) e histograma de la subimagen filtrada (b).

4.1.2. Segmentación

Para obtener los superpíxeles, regiones perceptualmente significativas, se usó el algoritmo SLIC, el cual se expuso en la sección 3.3.1. El resultado de la pre-segmentación se muestra en Figura 4.3, en la cual se observa cómo se obtienen segmentos que dividen la imagen en ventanas no rectangulares que se adhieren a los bordes de las diferentes regiones de la imagen. Por cada uno de los superpíxel se calcula un vector de características, y como resultado de la clasificación de estos, se obtiene el contorno mostrado en Figura 4.4 con color verde.

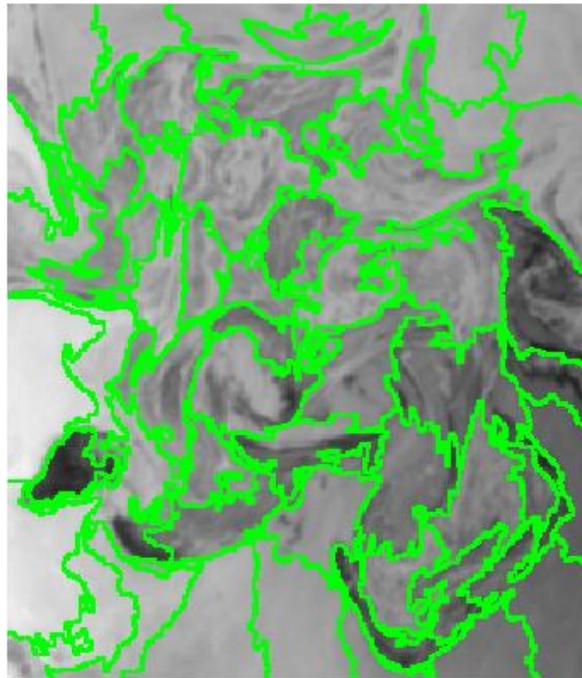


Figura 4.3. Superpíxeles obtenidos como resultado de pre-segmentación.

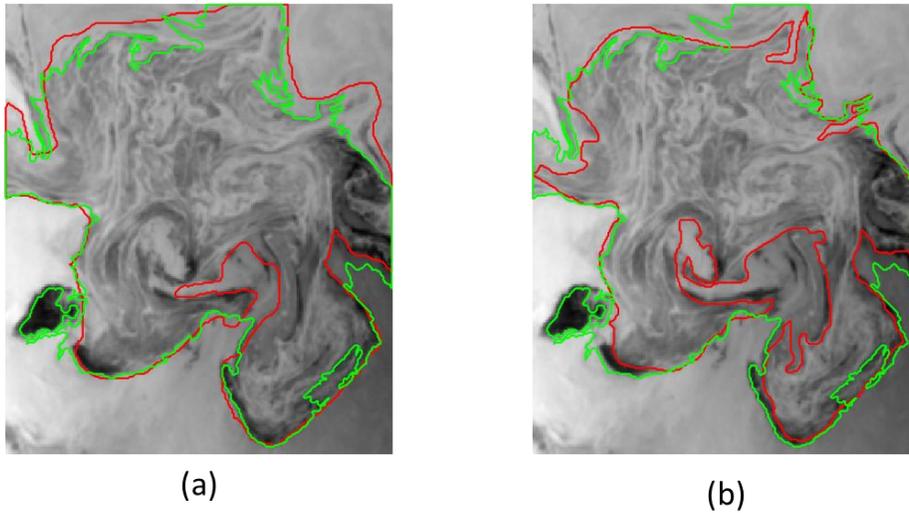


Figura 4.4. Comparación de contornos resultado de la segmentación con el algoritmo propuesto (color verde) y dos marcaciones manuales de referencia (color rojo).

En la Tabla 4.1 se muestran los resultados de las comparaciones cuantitativas realizadas con dos referencias marcadas por el experto. En ella se encuentra que los errores en cuanto a la clasificación de píxeles son relativamente altos (hasta aproximadamente 30%) y una similitud baja con respecto a la referencia. Sin embargo, si se hace una interpretación visual de los resultados obtenidos, cotejando con la subimagen, Figura 4.5, se puede observar que los resultados obtenidos no distan de lo que el ojo humano puede reconocer. Por lo tanto, se pueden considerar como aceptables los resultados obtenidos basados en una evaluación cualitativa, que depende de la interpretación del experto.

Cabe resaltar que la evaluación cuantitativa realizada se hizo con referencia a la marcación manual realizada por el experto. Debido a la complejidad para realizar dicha marcación pixel por pixel, la región de interés no está perfectamente delimitada por lo que el ojo humano puede interpretar. Sin embargo, para la aplicación de interés, donde se usarán estos resultados, dicha marcación es considerada aceptable, por lo cual se puede decir que, a pesar de tener errores numéricos y porcentaje de similitud que distan del 0% y el 100%, respectivamente, el resultado obtenido de la segmentación con el algoritmo propuesto puede ser considerado para los estudios de interés.

Tabla 4.1. Resultados de la evaluación cuantitativa de la segmentación obtenida y la marcación manual del experto como referencia.

| | EC (%) | EA (%) | DICE |
|------------------|--------|--------|--------|
| Referencia No. 1 | 17.88 | 2.82 | 0.9093 |
| Referencia No. 2 | 31.36 | 22.50 | 0.8590 |

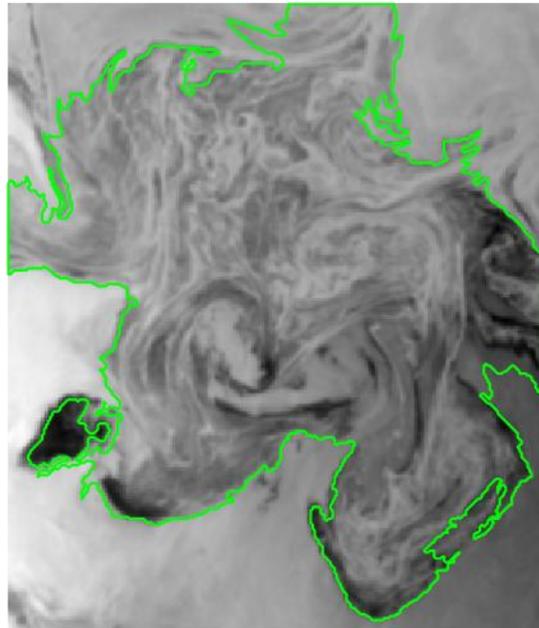


Figura 4.5. Contorno de la segmentación obtenida puesto sobre la subimagen con el objetivo de realizar inspección visual para evaluación cualitativa de los resultados.

En Figura 4.7 se muestran las máscaras de referencia (marcación manual del experto) (a),(b) y de segmentación obtenida con el algoritmo propuesto (c).



(a)



(b)



(c)

Figura 4.6. Máscaras correspondientes a la marcación manual de referencia (a), (b) y máscara resultado de la segmentación lograda con el algoritmo propuesto (c).

5. Conclusiones y Trabajo Futuro

5.1. Conclusiones

En este trabajo se presentó un algoritmo de segmentación basado en el cálculo de superpíxeles y descripción de texturas usando la transformada de Hermite, para la detección de regiones con presencia de hielo *Frazil/Pancake* en imágenes SAR obtenidas con la misión Sentinel-1. Este tipo de hielo marino es considerado importante por la influencia que tiene en la criósfera. Para lograr el objetivo, la imagen original fue corregida radiométricamente, así como filtrada para reducir el *Speckle*. Posteriormente, se redujo la resolución espacial utilizando un filtro Gaussiano, dado que la estructura del hielo *Frazil/Pancake* puede ser observada a menor resolución que la de la imagen original. A partir de esta imagen submuestreada se obtuvieron los superpíxeles y se calcularon los coeficientes de la Transformada de Hermite Rotada. Por cada superpíxel se generó un vector de características con los descriptores de media, desviación estándar, entropía. Además, se incluyó información del nivel promedio de gris en dicho vector. De la clasificación de los vectores y la asignación de una de dos clases (hielo *Frazil/Pancake* – zona de no interés) se obtuvo una máscara binaria la cual delimita, con cierta incertidumbre, la zona de presencia de hielo *Frazil/Pancake* en la imagen.

Se realizó una evaluación de los resultados utilizando como referencia la marcación manual hecha por un experto en hielo *Frazil/Pancake*. Esta evaluación cuantitativa arrojó errores de clasificación de píxeles de alrededor del 27% y errores de área de 14% en promedio. En cuanto a similitud, se utilizó el índice Dice, obteniéndose un porcentaje de similitud de entre 85% y 90%. Sin embargo, aunque los resultados cuantitativos son considerados aceptables para la aplicación de estudio de dispersión de olas en campos de hielo *Frazil/Pancake*, una inspección visual de la imagen y el resultado de la segmentación permite apreciar como el contorno de la segmentación delimita los bordes de la frontera entre la región de hielo *Frazil/Pancake* y las demás zonas en la imagen, lo cual podría considerarse como un aporte y referencia para trabajos futuros que intenten mejorar los problemas de detección de frontera entre mar abierto y hielo de tipo nuevo, que, como se

vio en la revisión literaria, es uno de los principales retos a alcanzar en este campo. No obstante, esta idea sigue siendo subjetiva y requiere ser estudiada y validada, utilizando información adicional como datos de concentración, observaciones *in situ*, y con otro tipo de sensores, como se realiza en algunos de los trabajos revisados, información con la que no se cuenta para este trabajo.

Se requiere de la selección de una ventana que contenga hielo *Frazil/Pancake* lo cual limita la automatización que es uno de los principales retos planteados en la literatura dada la cantidad y complejidad de imágenes que deben ser procesadas manualmente.

El algoritmo sólo fue probado con 2 imágenes de la misma zona, mismo modo de observación del satélite, y cuando el hielo *Frazil/Pancake* está completamente formado. Sin embargo, no es posible asegurar la consistencia del algoritmo. Para esto se debería probar con más imágenes en diferentes zonas donde se presenta este tipo de hielo y en diferente etapa de formación del mismo.

5.2. Trabajo Futuro

La polarización HH presenta una dependencia del ángulo de incidencia, que aunque se corrige en la calibración radiométrica, estudios como [37] sugieren una corrección de ángulo diferente a la aplicada con SNAP y que podría ayudar a mejorar resultados.

Trabajos encontrados en la revisión literaria sugieren las ventajas de usar las dos polarizaciones HH y HV que están disponibles en Sentinel-1, teniendo en cuenta que la polarización HV no presenta una dependencia considerable del ángulo de incidencia a diferencia de la polarización HH, mientras que esta última es menos sensible al ruido térmico que se manifiesta en HV como franjas en la imagen. Estos efectos no se corrigen totalmente con el proceso implementado en SNAP pero [37] sugiere que es posible realizarlos con la información auxiliar que acompaña a cada imagen.

Una clasificación supervisada podría ayudar a mejorar los resultados. Además, pruebas del algoritmo con imágenes obtenidas con otros sensores SAR serían útiles a la hora

de hacer una comparación de los resultados del algoritmo propuesto con otros trabajos encontrados en la literatura.

Referencias

- [1] S. Sandven y O. M. Johannessen, «Sea Ice Monitoring by Remote Sensing,» de *Remote Sensing of the Marine Environment - Manual of Remote Sensing*, Maryland, USA, J. Gower, 2006, p. 338.
- [2] T.-J. Kwon, J. Li y A. Wong, «ETVOS: An Enhanced Total Variation Optimization Segmentation Approach for SAR Sea-Ice Image Segmentation,» *IEEE Transactions on Geoscience and Remote Sensing*, vol. 51, nº 2, pp. 925-934, 2013.
- [3] Q. Yu y D. A. Clausi, «SAR Sea-Ice Image Analysis Based on Iterative Region Growing Using Semantics,» *IEEE Transactions on Geoscience and Remote Sensing*, vol. 45, nº 12, pp. 3919-3931, 2007.
- [4] P. Maillard, D. A. Clausi y H. Deng, «Operational Map-Guided Classification of SAR Sea Ice Imagery,» *IEEE Transactions on Geoscience and Remote Sensing*, vol. 43, nº 12, pp. 2940-2951, 2005.
- [5] P. Wadhams, F. Parmiggiani y G. De Carolis, «The Use of SAR to Measure Ocean Wave Dispersion in Frazil-Pancake Icefields,» *Journal of Physical Oceanography*, vol. 32, nº 6, pp. 1721-1746, 2002.
- [6] L. Wang, K. A. Scott, L. Xu y D. A. Clausi, «Sea Ice Concentration Estimation During Melt from Dual-Pol SAR Scenes Using Deep Convolutional Neural Networks: A Case Study,» *IEEE Transactions on Geoscience and Remote Sensing*, vol. 54, nº 8, pp. 4524-4533, 2016.
- [7] P. Wadhams y B. Holt, «Waves in Frazil and Pancake Ice and Their Detection in Seasat Synthetic Aperture Radar Imagery,» *Journal of Geophysical Research*, vol. 96, nº C5, pp. 8835-8852, 1991.
- [8] P. Wadhams, F. F. Parmiggiani, G. d. Carolis, D. Desiderio y M. J. Doble, «SAR imaging of wave dispersion in Antarctic pancake ice and its use in measuring ice thickness,» *Geophysical Research Letters*, vol. 31, pp. L15305 1-5, 2004.

- [9] R. A. Young, «Orthogonal basis functions for form vision derived from eigenvector analysis,» *ARVO Abstracts Association for Research in Vision and Ophthalmology*, p. 22, 1978.
- [10] A. Estudillo Romero, B. Escalante Ramírez y J. Savage Carmona, «Texture analysis based on the Hermite transform for image classification and segmentation,» *Optics, Photonics, and Digital Technologies for Multimedia Applications*, vol. 8436 of Proceedings of the SPIE, pp. 843619-1 - 843619-12, 2012.
- [11] B. Escalante Ramírez y J.-B. Martens, «Noise Reduction in Computerized Tomography Images by Means of Polynomial Transforms,» *Journal of Visual Communication and Image Representation*, vol. 3, nº 3, pp. 272-285, 1992.
- [12] B. Escalante Remírez y A. López Caloca, «The Hermite Transform: An Efficient Tool for Noise Reduction and Image Fusion in Remote-Sensing,» de *Signal Image Processing for Remote Sensing*, Taylor and Francis, 2006, pp. 537-555.
- [13] B. Escalante Ramírez y J. Lira Chávez, «Performance-oriented analysis and evaluation of modern adaptive speckle reduction techniques in SAR images,» de *Proceedings of SPIE*, 1996.
- [14] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua y S. Süsstrunk, «SLIC superpixels compared to state-of-the-art superpixel methods,» *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 34, nº 11, pp. 2274-2282, 2012.
- [15] J. Lira Chávez, Tratamiento digital de imágenes multiespectrales, Ciudad de México: Universidad Nacional Autónoma de México, 2010.
- [16] J. S. Lee, «Refined Filtering of Image Noise Using Local Statistics,» *Computer Graphics and Image Processing*, vol. 15, p. 380 – 389, 1981.
- [17] V. S. Frost, J. A. Stiles, . K. Shanmugan y J. Holtzman, «A Model for Radar Images and its Applications to Adaptive Digital Filtering of Multiplicative Noise,» *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vols. %1 de %2PAMI-4, p. 157 – 165, 1982.
- [18] E. S. Agency, «ESA Earth Online - Mission,» [En línea]. Available: <https://earth.esa.int/web/guest/missions/esa-operational-eo-missions/sentinel-1>. [Último acceso: 25 Marzo 2016].
- [19] J. Karvonen, «Baltic Sea Ice Concentration Estimation Based on C-Band HH-Polarized SAR Data,» *IEEE Journal of Selected Topics in Applied Earth Observations and REMote Sensing*, vol. 5, nº 6, pp. 1874-1884, 2012.
- [20] W. Aldenhoff, A. Berg y L. E. Eriksson, «Sea Ice Concentration Estimation from Sentinel-1 Synthetic Aperture Radar Images over the Fram Strait,» de *IGARSS IEEE*, 2016.

- [21] N. Y. Zakhvatkina, V. Y. Alexandrov, O. M. Johannessen, S. Sandven y I. Y. Frolov, «Classification of Sea Ice Types in ENVISAT Synthetic Aperture Radar Images,» *IEEE Transactions on Geoscience and Remote Sensing*, vol. 51, nº 5, pp. 2587-2600, 2013.
- [22] Q. Yu y D. A. Clausi, «Filament Preserving Model (FPM) Segmentation Applied to SAR Sea-Ice Imagery,» *IEEE Transactions on Geoscience and Remote Sensing*, vol. 44, nº 12, pp. 3687-3694, 2006.
- [23] N. Zakhvatkina, A. Korosov, S. Muckenhuber, S. Sandven y M. Babiker, «Operational algorithm for ice/water classification on dual-polarized RADARSAT-2 images,» *Cryosphere Discussions*, vol. 131, pp. 1-22, 2016.
- [24] D. A. Clausi, «Comparison and Fusion of Co-occurrence, Gabor and MRF Texture Features for Classification of SAR Sea-Ice Imagery,» *Atmosphere-Ocean*, vol. 39, nº 3, pp. 183-194, 2001.
- [25] L.-K. Soh y C. Tsatsoulis, «Texture Analysis of SAR Sea Ice Imagery Using Gray Level Co-occurrence Matrices,» *IEEE Transactions on Geoscience and Remote Sensing*, vol. 37, nº 2, pp. 780-795, 1999.
- [26] H. Liu, H. Guo y L. Zhang, «SVM-Based Sea Ice Classification Using Textural Features and Concentration From RADARSAT-2 Dual-Pol ScanSAR Data,» *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 8, nº 4, pp. 1601-1613, 2015.
- [27] W. Yang, C. He, Y. Cao, H. Sun y X. Xu, «Improved Classification of SAR Sea Ice Imagery Based on Segmentation,» de *IEEE International Symposium on Geoscience & Remote Sensing*, 2006.
- [28] S. Ochilov y D. A. Clausi, «Operational SAR Sea-Ice Image Classification,» *IEEE Transactions on Geoscience and Remote Sensing*, vol. 50, nº 11, pp. 4397-4408, 2012.
- [29] D. A. Clausi, «Improved Texture Recognition of SAR Sea Ice Imagery by Data Fusion of MRF Features with Traditional Methods,» de *Scanning the Present & Resolving the Future. Proceedings IEEE 2001 International Geoscience & Remote Sensing Symposium*, 2001.
- [30] K. C. Partington, J. D. Flach, D. Barber, D. Isleifson, P. J. Meadows y P. Verlaan, «Dual-Polarization C-Band Radar Observations of Sea Ice in the Amundsen Gulf,» *IEEE Transactions on Geoscience and Remote Sensing*, vol. 48, nº 6, pp. 2685-2691, 2010.
- [31] S. V. Nghiem y C. Bertoia, «Study of MultiPolarization C-Band Backscatter Signatures for Arctic Sea Ice Mapping with Future Satellite SAR,» *Canadian Journal of Remote Sensing*, pp. 387-402, 2001.

- [32] F. Lang, J. Yang, D. Li, L. Zhao y L. Shi, «Polarimetric SAR image Segmentation Using Statistical Region Merging,» *IEEE Geoscience and Remote Sensing Letters*, vol. 11, nº 2, pp. 509-513, 2014.
- [33] D. Barber y E. F. LeDrew, «SAR Sea Ice Discrimination Using Texture Statistics,» *Photogram Eng. Remote Sensing*, vol. 57, nº 4, pp. 385-395, 1991.
- [34] T. Bamidele Ijtona , J. Ren y P. B. Hwang, «SAR Sea Ice Image Segmentation Using Watershed with Intensity-based Region Merging,» de *IEEE International Conference on Computer and Information Technology*, 2014.
- [35] R. C. P. Marques, E. A. Carvalho y R. C. S. Costa, «Filtering effects on SAR images segmentation,» *Lecture Notes in Computer Science*, vol. 3124, pp. 1041-1046, 2004.
- [36] S. Leigh, Z. Wang y D. A. Clausi, «Automated Ice-Water Classification Using Dual Polarization SAR Satellite Imagery,» *IEEE Transactions on Geoscience and Remote Sensing*, vol. 52, nº 9, pp. 5529-5539, 2014.
- [37] A. A. Korosov y J.-W. Park, «Very High Resolution Classification on Sentinel-1A Data using Segmentation and Texture Analysis,» de *Proc. of European Space Agency Living Planet Symposium*, 2016.
- [38] F. Li, D. A. Clausi, L. Wang y L. Xu, «A Semi-supervised Approach for Ice-water Classification Using Dual-Polarization SAR Satellite Imagery,» de *IEEE International Symposium on Antennas & Propagation & USNC/URSI National Radio Science Meeting*, 2015.
- [39] A. M. van Dijk y J.-B. Martens, «Image representation and compression with steered Hermite transforms,» *Signal Processing*, vol. 56, nº 1, pp. 1-16, 1997.
- [40] J.-B. Martens, «The Hermite Transform - Theory,» *IEEE Transactions on Acoustics, Speech and Signal Processing*, vol. 38, nº 9, pp. 1595-1606, 1990.
- [41] A. Estudillo Romero y B. Escalante Ramírez, «Rotation-invariant texture features from the steered Hermite Transform,» *Pattern Recognition Letters*, vol. 32, nº 16, pp. 2150-2162, 2011.
- [42] L. Vargas Quintero, B. Escalante Ramírez, L. Camargo Marín, M. Guzmán Huerta, F. Arámbula Cosío y H. Borboa Olivares, «Left ventricle segmentation in fetal echocardiography using a multi-texture active appearance model based on the steered Hermite transform,» *Computer Methods & Programs in Biomedicine*, vol. 137, pp. 231-245, 2016.
- [43] J.-B. Martens, «The Hermite Transform - Applications,» *IEEE Transactions on Acoustics, Speech and Signal Processing*, vol. 38, nº 9, pp. 1607-1618, 1990.

- [44] W. Freeman y E. Adelson, «The design and use of steerable filters,» *IEEE Transactions and Pattern Analysis and Machine Intelligence* , vol. 13, nº 9, pp. 891-906, 1991.
- [45] L. Vargas Quintero, B. Escalante Ramírez, L. Camargo Marín, M. Guzmán Huerta, F. Arámbula Cosío y H. Borboa, «Shape extraction in fetal ultrasound images using a Hermite-based filtering approach and a Point Distribution Model,» de *Optics, Photonics and Digital Technologies for Imaging Applications IV*, 2016.
- [46] R. Nava y J. Kybic, «Supertexton-Based segmentation in early Drosophila oogenesis,» de *IEEE International Conference on Image Processing (ICIP)*, 2015.
- [47] E. Akyilmaz y U. Leloglu, «Segmentation of SAR images using similarity ratios for generating and clustering superpixels,» *Electronics Letters* , vol. 52, nº 8, pp. 654-656, 2016.
- [48] R. Achanta , A. Shaji, K. Smith, A. Lucchi, P. Fua y S. Sússtrunk, «SLIC superpixels,» EPFL Technical Report 149300, 2010.
- [49] J. Karvonen, M. Similä y M. Mäkynen, «Open Water Detection from Baltic Sea Radarsat-1 SAR Imagery,» *IEEE Geoscience and Remote Sensing Letters*, vol. 2, nº 3, pp. 275-279, 2005.
- [50] M. -A. N. Moen, A. P. Doulgeris, S. N. Anfinson, A. H. H. Renner, N. Hughes, S. Gerland y T. Eltoft, «Comparison of feature based segmentation of full polarimetric SAR satellite sea ice images with manually drawn ice charts,» *The Cryosphere Discuss*, vol. 7, pp. 1693-1705, 2013.
- [51] J. C. Curlander y R. N. Mcdonough, *Synthetic Aperture Radar : Systems and Signal Processing*, New York: Wiley, 1991.