



UNIVERSIDAD NACIONAL DE COLOMBIA

Clasificación automática de los estados de desarrollo del arroz a partir de imágenes de RADARSAT-2

Jorge Arturo Quiñones Serrano

Universidad Nacional de Colombia
Facultad de Ingeniería, Maestría en Automatización Industrial
Bogotá, Colombia
2011

Clasificación automática de los estados de desarrollo del arroz a partir de imágenes de RADARSAT-2

Jorge Arturo Quiñones Serrano

Tesis presentada como requisito parcial para optar al título de:
Magister en Ingeniería. Automatización Industrial

Director:

Flavio Augusto Prieto Ortiz Ph.D.

Línea de Investigación: Visión por computador

Procesamiento digital de imágenes

Grupo de Investigación: GAUNAL

Universidad Nacional de Colombia

Facultad de Ingeniería, Maestría en Automatización Industrial.

Bogotá, Colombia

2011

Dedico éste trabajo a mis tesoros: Candelaria Sofia, Camilo Ernesto y Ana Mercedes, mis hijos. De igual manera a mi compañera de siempre Dioselina y a mi solidaria madre Elsa.

Si los rostros cambiaban de aspecto, según les diese la luz desde arriba o desde abajo, ¿qué era en realidad un rostro? ¿Qué eran las cosas?

William Golding^a

...la manera en que vemos nuestra imagen reflejada, desde ángulos cambiantes, nos permite hacer correcciones, resaltar lo que nos gusta y eliminar lo que nos desagrada. La cámara es una clase de ojo distinta, un ojo que ve un millón de partículas de plata sobre negro, pero no los viejos recuerdos que atesora el corazón de una persona.

Amy Tan^b

En la visión, el cerebro recibe una serie de señales a lo largo del nervio óptico, señales que no forman el tipo de imagen que aceptaríamos en nuestros televisores. Hay una mancha ciega en el punto en que el nervio óptico se conecta a la retina, y la única zona de nuestro campo de visión que goza de buena resolución es un área estrecha de aproximadamente un grado de ángulo visual alrededor del centro de la retina, un área del orden del ancho de la imagen del pulgar cuando tenemos el brazo alargado. Así pues, los datos brutos enviados al cerebro constituyen una imagen mal pixelada con un agujero en su centro. Afortunadamente, el cerebro humano procesa dichos datos, combinando los de cada ojo y colmando los vacíos mediante la hipótesis de que las propiedades visuales de los lugares contiguos son semejantes e interpolándolas. Además, lee una disposición bidimensional de datos de la retina y crea la impresión de un espacio tridimensional.

Stephen Hawkinh^c

^aGolding, William. El Señor de las Moscas. Literatura. Alianza Editorial. 2009. Reflexiones del personaje Ralph. Página 96.

^bTan, Amy. Los Cien Sentidos secretos. Editorial Planeta S.A. 1996. Página 275.

^cHawking, Stephen y Mlodinow, Leonard. El Gran Diseño. Crítica. 2010. Página 55.

Agradecimientos

Agradecemos al Instituto Geografico Agustín Codazzi por facilitarnos datos que fueron de suma importancia para la realización de éste trabajo. En especial a la ingeniera Elena Posada, directora del Grupo de Percepción Remota del IGAC, de quien recibe valiosos aportes para comprender la magnitud del problema y detalles técnicos.

Resumen

Las imágenes de radar se utilizan tanto para la identificación, como para el seguimiento del crecimiento y la medición de las superficies destinadas a los diferentes cultivos. En éste trabajo, utilizamos una imagen de radar capturada por el satélite RADARSAT-2 en el mes de febrero de 2009, para implementar un sistema de clasificación automática de los estados de desarrollo del cultivo de arroz. Debido a que las imágenes presentan un ruido de moteado característico, en la primera parte del proyecto, realizamos un estudio comparativo de varios métodos propuestos en la literatura para filtrar imágenes con ruido *speckle*. Adicionalmente, proponemos un método original de ventana adaptativa para el filtrado y desarrollamos un filtro que combina la media, la moda y la mediana, el cual dio buenos resultados. Seguidamente implementamos tres clasificadores, el clasificador Bayesiano; el clasificador Fuzzy c-mean y el Perceptrón Multicapa, para segmentar y clasificar las imágenes filtradas. Desarrollamos un clasificador mixto utilizando los resultados de los tres clasificadores, el cual nos dio, luego de la evaluación, exactitud mayor al 94 %. El sistema se implementó utilizando la librería OpenCV en una plataforma de Ubuntu.

Palabras clave: Estado de desarrollo, arroz, imágenes de radar, ruido *speckle*, ventana adaptativa, filtro, red neuronal artificial, momentos de Hu.

Abstract

Radar images are used for the identification, growth control of crops and the measurement of the areas destined for crops. In this work we used a radar image captured by the RADARSAT-2 satellite in February 2009 to implement an automatic classification system for the stages of development of rice crops. Due to the characteristic speckle noise present in the images, in the first part of the project we made a comparative study of several methods that are proposed in the literature to filter images with speckle noise. Additionally we propose an original adaptive window for the filtering and we developed a filter that combines the arithmetic mean, the mode and the median which gave good results. Next we implemented three classifiers, Bayesian classifier; Fuzzy c-mean classifier and the Multilayer Perceptron classifier in order to segment and classify the filtered images. We developed a mixed classifier using the results of the three classifiers which after the evaluation gave exactness greater than 94 %. This system was implemented using the OpenCV library used in an Ubuntu platform.

Keywords: rice, speckle noise, invariant moments of Hu.

Contenido

Agradecimientos	ix
Resumen	xi
Lista de símbolos	xv
1. Introducción	1
2. Formación de Imágenes SAR	3
2.1. Introducción	3
2.2. Configuración geométrica de los sistemas SAR	4
2.3. Imágenes SAR complejas	5
2.3.1. Polarización en un sistema de radar	6
2.3.2. Descomposición de Pauli	9
3. Eliminación de ruido Speckel	11
3.1. Introducción	11
3.2. Filtros de ruido <i>speckle</i>	11
3.2.1. Filtro de Media	12
3.2.2. Filtro Moda	12
3.2.3. Filtro Mediana	12
3.2.4. Filtro M3	13
3.2.5. Filtro de Lee	13
3.2.6. Filtro de Kuan	14
3.2.7. Filtro Gamma	15
3.2.8. Filtro de Frost	15
3.2.9. Filtro de Oddy	16
3.2.10. Filtro Promedio Geométrico.	16
3.3. Filtro propuesto MediaModaNá.	16
3.4. Técnica propuesta para el tamaño adaptativo de la ventana.	17
3.4.1. Introducción.	17
3.4.2. Región de interés y su perímetro.	17
3.4.3. Similitud de las regiones.	18
3.4.4. Métrica utilizada.	19

3.4.5. Umbral utilizado.	19
3.5. Criterios de evaluación.	19
3.6. Resultado del filtrado	21
3.6.1. Introducción.	21
3.6.2. Imágenes sintéticas.	22
3.6.3. Imágenes de radar.	31
4. Segmentación, clasificación y evaluación de resultados	35
4.1. Introducción	35
4.2. Vector de características.	35
4.3. Clasificador Bayesiano	39
4.3.1. Teorema de Bayes	39
4.4. Clasificador Fuzzy c-means.	39
4.5. Redes Neuronales Artificiales. El Perceptrón Multicapa.	41
4.6. Evaluación de resultados.	45
4.7. Segmentación de imágenes reales de RADARSAT-2.	51
5. Conclusiones	54
5.1. Introducción	54
5.2. Conclusiones generales	54
5.3. Resultados del filtrado de las imágenes con ruido <i>speckle</i>	55
5.4. Resultados de la segmentación y la clasificación.	56
6. Futuros trabajos.	57
7. Anexo 1. Gráficas	58
7.1. Introducción	58
8. Anexo 2. Tablas I.	68
8.1. Introducción	68
9. Anexo 3. Pseudocódigos.	88
9.1. Introducción	88
10. Anexo 4. Momentos.	91
10.1. Momentos en una dimensión	91
10.2. Momentos invariantes 2D	92
11. Anexo 5. Evaluación del Clasificador binario.	94
11.1. Clasificador binario.	94
11.2. Matriz de confusión.	94

12. Anexo 6. Tablas II	96
13. Bibliografía	102

Lista de símbolos

Símbolos con letras latinas

Símbolo	Término	Relación
$B(x, y)$	Perímetro de la ventana $W(x,y)$.	
$f(x, y)$	Píxel (x,y) de la imagen filtrada.	
\bar{f}	Media, imagen filtrada en ventana de tamaño $N \times N$.	
$g(k, l)$	Píxel (k,l) de la imagen ruidosa.	
\bar{g}	Media, imagen ruidosa en ventana de tamaño $N \times N$.	
I	Nivel de gris.	
k	Coordenada x imagen ruidosa.	
l	Coordenada y imagen ruidosa.	
n	Ruido multiplicativo.	$g(k, l) = n(k, l)z(k, l)$
N	Tamaño de la ventana.	
$P(I)$	Probabilidad.	
$W(x, y)$	Ventana de tamaño $N \times N$ centrada en (x,y)	
$z(k, l)$	Píxel (k,l) de la imagen original.	

Símbolos con letras griegas

Símbolo	Término
σ_f	Desviación estándar de la imagen filtrada.
σ_g	Desviación estándar de la imagen ruidosa.
σ_n	Desviación estándar del ruido.
σ_0	Radar backscattering coefficient.

Abreviaturas

Abreviatura	Término
-------------	---------

CSA	Agencia Espacial Canadiense
EEI	Edge Enhancing Index EEI
IGAC	Instituto Geográfico Agustín Codazzi
MDA	MacDonald Dettwiler
OpenCV	Open Source Computer Vision Library
PolSARPro	The Polarimetric SAR Data Processing and Educational Tool
RMSE	Root Mean Square Error
SAR	Synthetic Aperture Radar
SNR	Signal to Noise Ratio

1 Introducción

Gracias a un convenio entre el Instituto Geográfico Agustín Codazzi (IGAC) y el Centro Canadiense de Percepción Remota fue posible obtener las imágenes de radar que se utilizaron en el presente estudio. El IGAC empleando imágenes de RADARSAT-2 se encuentra en el proceso de desarrollar metodologías y validar las imágenes tanto para el seguimiento del cultivo de arroz como de vegetación de páramo y de bosques tropicales [1].

Nuestro proyecto nace de la necesidad de contar con un sistema automático que permita realizar la clasificación de los estados de desarrollo del cultivo de arroz, utilizando diferentes técnicas de filtrado y de clasificación. Tomamos de la literatura especializada diversos algoritmos para eliminar el ruido *speckle*. Las técnicas de filtrado investigadas se basan en análisis estadísticos de los valores de intensidad de cada píxel en las regiones de estudio, y para evaluar el rendimiento de dichos algoritmos empleamos cuatro criterios: la relación señal a ruido (SNR); el índice de mejora de contornos (EEI), el error cuadrático medio (RMSE) y el tiempo de ejecución.

En la presente investigación, el proceso de segmentación y clasificación lo integramos en uno sólo utilizando técnicas clásicas con el clasificador Bayesiano, y técnicas de inteligencia artificial, aplicando los clasificadores Fuzzy c-mean y redes neuronales artificiales.

El sistema de clasificación automático de los estados de desarrollo del cultivo de arroz, desarrollado en el presente estudio, puede servir como apoyo a empresas e instituciones nacionales del sector agropecuario para la toma de decisiones, ya que, las imágenes de radar permiten identificar los cultivos que hay en la superficie de la Tierra y posibilitan hacer un seguimiento del crecimiento de los mismos [2]. Además, las imágenes SAR permiten medir el área destinada a los diferentes plantíos y posibilitan estimar la productividad de las áreas agrícolas. Ello facilita la aplicación de manejos en forma diferencial, de acuerdo con las condiciones de cada sitio de interés dentro de la unidad agrícola.

Las imágenes de radar son una importante herramienta para capturar información de la superficie de la Tierra, y son, en sí mismas, una forma distinta de ver la realidad. Gracias a las características que posee las ondas de radar, es posible adquirir información independientemente de las condiciones atmosféricas y de la hora del día, éste hecho nos brinda una inmensa posibilidad de estudiar amplias zonas de nuestro país.

Como primer objetivo nos plantemos reducir eficientemente el ruido presente en las imágenes SAR, las cuales, debido a la interferencia de las ondas reflejadas por la superficie de la Tierra, manifiestan un ruido de apariencia granular conocido como *speckle*. Para cumplir con éste objetivo, realizamos una evaluación del desempeño de doce filtros utilizando los cuatro crite-

rios mencionados anteriormente. Adicionalmente, proponemos un nuevo método de filtrado y un novedoso algoritmo de ventana adaptativa.

Como segundo objetivo buscamos características que nos permitieran segmentar y clasificar las imágenes. Utilizamos información de la magnitud y la fase de los campos eléctricos, con las diferentes polarizaciones, para generar una imagen en la composición de Pauli. Utilizando características de color en dicha imagen, entrenemos los clasificadores antes mencionados.

Nos planteamos como tercer objetivo la evaluación de los clasificadores utilizando los coeficientes estadísticos de la sensibilidad, la especificidad y la exactitud. Además, evaluamos un clasificador mixto que integra los tres clasificadores antes mencionados utilizando criterios probabilísticos y de votación.

El estudio realizado se basó exclusivamente en una imagen cedida por el IGAC que fue capturadas por el sensor RADARSAT-2 en el distrito de riego de Saldaña, Tolima, el día 26 de febrero de 2009. Se generó una imagen con el software PolSARPro en la composición de Pauli con una resolución de 3572×5938 píxeles. Al ser la imagen de gran tamaño se extrajeron trece imágenes de menor resolución. Al seleccionar regiones más pequeñas, de la imagen original, se tuvo como criterio elegir zonas donde se observara la presencia de los cultivos de arroz. Es decir, se trató por un lado de tomar regiones donde existiera cultivos de arroz y por otra, que dichas imágenes no tuvieran una resolución muy grande, ésto debido a la limitada capacidad de cómputo del equipo utilizado. Debido a la presencia de los sembrados de arroz entre los dos canales del río Saldaña, ésta fue la zona escogida para seleccionar las imágenes de menor resolución. Se extrajeron: dos (2) imágenes con resolución de 1100×600 píxeles; siete (7) imágenes de 1500×600 píxeles y cuatro (4) imágenes con resolución de 800×800 píxeles. Todas las imágenes se procesaron utilizando la librería OpenCV, trabajando en C++ y empleando una plataforma en Ubuntu.

El presente documento se encuentra organizado de la siguiente manera: en el Capítulo 1 discutimos brevemente el mecanismo de formación de las imágenes SAR; en el Capítulo 2 describimos los filtros utilizados para eliminar el ruido *speckle*, evaluamos los mismos y presentamos resultados del filtrado; en el Capítulo 3 analizamos los clasificadores empleados y finalmente en el Capítulo 4, presentamos las conclusiones.

2 Formación de Imágenes SAR

2.1. Introducción

El sistema de imágenes del radar de apertura sintética (SAR), es un sistema activo que opera en la región de las microondas del espectro electromagnético, usualmente entre las bandas P y Ka (ver Tabla 2-1). Este usualmente está montado en una plataforma en movimiento, una aeronave o un satélite, y opera con geometría de barrido explorando a un solo lado con una iluminación perpendicular a la dirección de vuelo. Este sistema ilumina la superficie de la Tierra con pulsos de microondas y recibe las ondas electromagnéticas reflejadas de la región examinada. El sistema SAR procesa las señales para sintetizar una imagen en dos dimensiones con alta resolución espacial utilizando todas las señales recibidas.

Haciendo un estudio del eco se extrae información de los objetos con los que interactúa la radiación. El sensor SAR al recoger información de un objeto en diferentes posiciones de su trayectoria imita una antena de mayor tamaño a la que realmente transporta. Al tener una antena virtual de mayor tamaño, la ganancia y la directividad son mayores, logrando mejor resolución espacial (resolución acimutal).

Como todo radar, el dispositivo SAR mide el tiempo que demoran las ondas electromagnéticas emitidas en volver a la antena transmisora y con éste se determina la distancia a los objetos. Adicionalmente los campos eléctricos transmitidos tienen polarización lineal tanto horizontal como vertical y el eco recibido por el radar posee información de la respuesta del blanco a la ondas polarizadas incidentes.

En si mismo un radar lo que captura son datos y sólo luego de un procesado de la información, el sistema SAR obtiene imágenes bidimensional en falso color de la superficie iluminada. Los datos reportados por el sensor poseen información tanto de la magnitud del campo polarizado como de su fase relativa. Existen varias posibilidades de combinación de las magnitudes y las fases de las señales recibidas para la formación de las imágenes bidimensionales.

El sistema SAR opera independientemente de la radiación solar y puede capturar imágenes ya sea de día o de noche. Adicionalmente, como opera en la región de las microondas evita los efectos de las nubes, niebla, lluvias y humo en las imágenes resultantes [3, 4, 5].

Tabla 2-1: Bandas de la región de microondas

Región	Longitud de onda $\Delta\lambda$ (cm)	Región	Longitud de onda $\Delta\lambda$ (cm)
Microondas	0.1 a 100	Banda Ku	1.67 a 2.50
Banda Q	0.10 a 0.27	Banda X	2.50 a 3.75
Banda W	0.27 a 0.40	Banda C	3.75 a 7.50
Banda V	0.40 a 0.75	Banda S	7.50 a 15.0
Banda Ka	0.75 a 1.11	Banda L	15.0 a 30.0
Banda K	1.11 a 1.67	Banda P	30.0 a 100.0

2.2. Configuración geométrica de los sistemas SAR

Una descripción sencilla de un sistema de captura de imágenes SAR monoestático, consiste en un pulso de microondas transmitido, una antena que se utiliza tanto para la transmisión como para la recepción, y una unidad receptora. Los sistemas SAR están montados en una plataforma en movimiento y operan con una geometría de barrido a un solo lado, como se ilustra en la Figura 2-1.

El sistema de captura de imágenes SAR se encuentra a una altura H y se mueve a una velocidad \vec{V}_{SAR} . La antena está orientada perpendicular a la dirección de vuelo, llamada *acimut* (y). El rayo de la antena es dirigido con una inclinación adecuada (θ_0) hacia la tierra. El eje radial o la línea de vista del radar es llamado *rango de inclinación* (r). El área cubierta por el haz de la antena en las direcciones del *rango del terreno* (x) y el acimut se conoce como la *huella de la antena*. El área escaneada por el haz de la antena se conoce como la *franja del radar*. La huella del radar se define por la apertura de la antena (θ_x, θ_y) y está dada por la Ecuación 2-1.

$$\theta_x \approx \frac{\lambda}{L_x}; \quad \theta_y \approx \frac{\lambda}{L_y} \quad (2-1)$$

donde L_x y L_y corresponden a las dimensiones físicas de la antena y λ es la longitud de onda correspondiente a la señal transmitida.

En la Figura 2-2 (a) y 2-2 (b), se puede observar el rango Δx y el acimut Δy . Una expresión aproximada para la franja Δx y para la franja acimutal Δy , se observa en la Ecuación 2-2.

$$\Delta X \approx \frac{R_0 \theta_x}{\cos \theta_0}; \quad \Delta Y \approx R_0 \theta_y \quad (2-2)$$

donde R_0 es la distancia entre el radar y el centro de la huella. R_{MIN} y R_{MAX} representan el *rango cercano* (punto más cercano al nadir), y el *rango lejano* respectivamente.

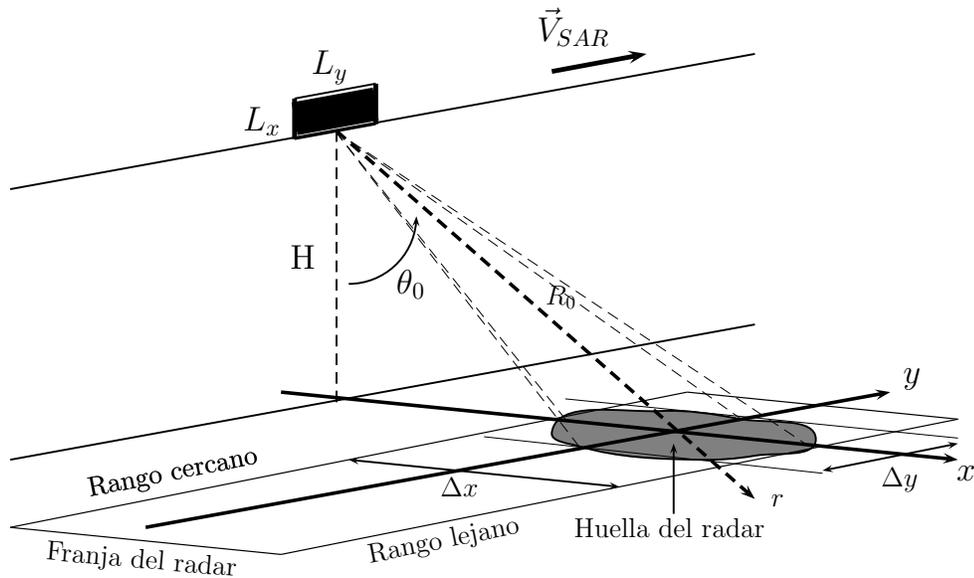


Figura 2-1: Geometría SAR.

2.3. Imágenes SAR complejas

Una onda electromagnética viajera puede interactuar con algún objeto que se encuentre en su camino. Debido a ésta interacción parte de la energía de la onda es absorbida por el objeto mientras que la restante es nuevamente re-irradiada como una nueva onda electromagnética. Debido a la interacción con el objeto, las propiedades de la onda reflejada difieren de la onda incidente. Cada píxel de una imagen SAR tiene información de la amplitud y la fase del campo eléctrico re-irradiado, asociada con la reflectividad de los objetos presentes en la zona iluminada. Es decir, se representa cada píxel por un número complejo que posee magnitud y fase¹, como muestra la Ecuación 2-3.

$$z = r e^{j\theta} \quad (2-3)$$

Donde la magnitud (r), está relacionada con la magnitud del campo eléctrico y la fase (θ), con el corrimiento de la onda recibida respecto al campo transmitido (ver Figura 2-3). Es importante anotar que la reflectividad de la superficie iluminada, es una función de los parámetros del radar (frecuencia f , polarización, ángulo de incidencia θ_i) y de las características de la superficie explorada (topografía, ángulo de incidencia local, propiedades dieléctricas del medio, humedad, etc.).

¹El símbolo j se llama unidad imaginaria, y se define como $j = \sqrt{-1}$.

2.3.1. Polarización en un sistema de radar

La polarización es una propiedad importante de las ondas electromagnéticas y se refiere a la alineación y regularidad de los campos eléctricos y magnéticos que componen la onda, en el plano perpendicular a la dirección de propagación (ver Figura 2-4). La polarización de una onda es la figura geométrica determinada por el extremo del vector que representa al campo eléctrico en función del tiempo, en una posición dada (ver Figura 2-5 (a), (b) y (c)). Para ondas con variación sinusoidal dicha figura es en general una elipse [6, 7].

Se denota las polarizaciones lineales de la onda transmitida y recibida por un par de símbolos. Un sistema de radar puede tener los siguientes canales:

- * HH para transmisión horizontal y recepción horizontal.
- * VV para transmisión vertical y recepción vertical.
- * HV para transmisión horizontal y recepción vertical.
- * VH para transmisión vertical y recepción horizontal.

Un sistema de radar puede tener diferentes niveles de complejidad en la polarización:

- Polarización simple: HH o VV, o HV o VH.
- Doble polarización: HH y HV, VV y VH o HH y VV.
- Cuatro polarizaciones: HH, VV, HV y VH.

El satélite RADARSAT-2 que fue lanzado en diciembre de 2007 por un convenio entre la Agencia Espacial Canadiense y la industria (MacDonald Dettwiler), posee las cuatro polarizaciones [8]. Es decir, el sistema de radar transmite y recibe todas las combinaciones de ondas polarizadas simultáneamente, produciendo un completo grupo de datos polarimétricos (HH, HV, VV y VH).

El satélite de observación de la Tierra RADARSAR-2 es una buena fuente de datos para las aplicaciones comerciales y para investigaciones en percepción remota. Éste suministra información para aplicaciones de vigilancia costera, marina y de embarcaciones; seguridad; monitoreo de las estaciones de energía nuclear; monitoreo de derrames de aceite; campos de viento; manejo o administración de desastres; silvicultura y es una herramienta importante para la agricultura e hidrología, entre muchas otras más. Algunas características del satélite se pueden leer en la Tabla 2-2.

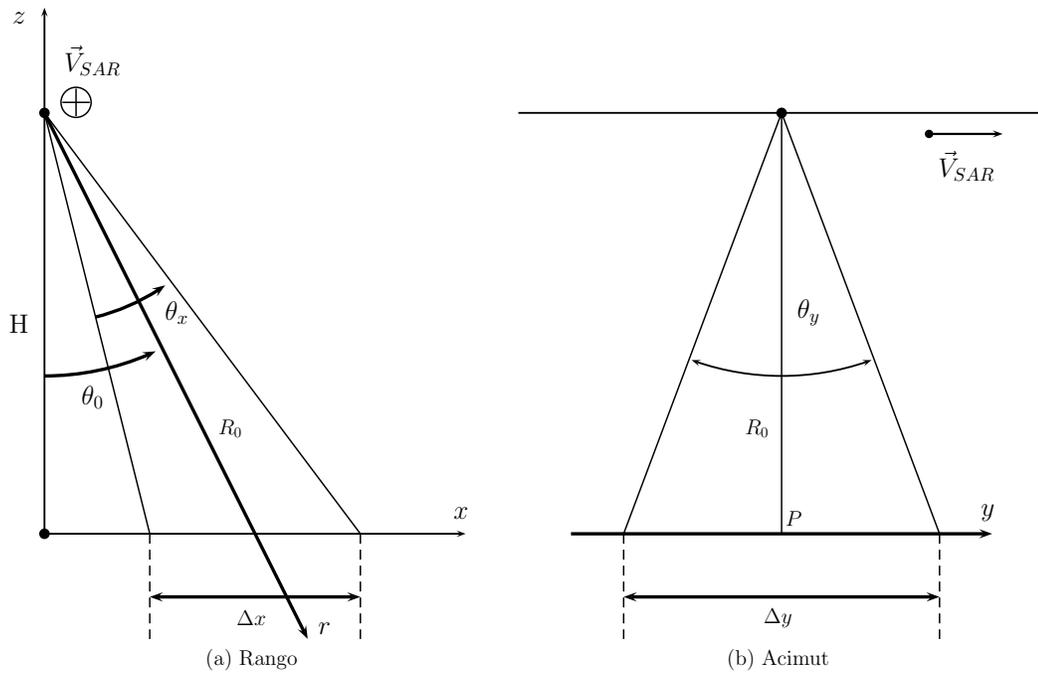


Figura 2-2: Rango y acimut

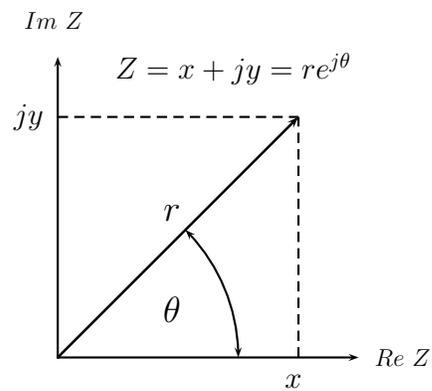


Figura 2-3: Número complejo. Magnitud y fase.

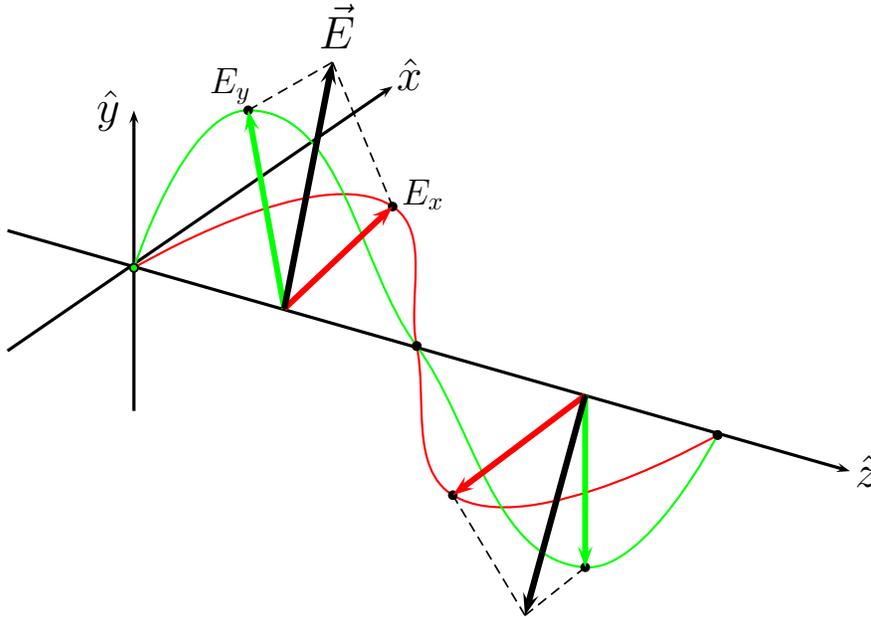


Figura 2-4: Onda viajera

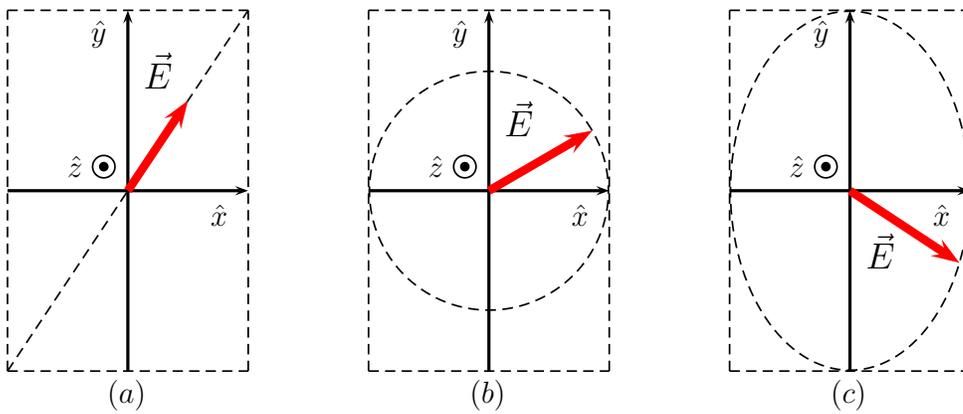


Figura 2-5: (a) Polarización lineal. (b) Polarización Circular. (c) Polarización elíptica.

Tabla 2-2: Características RADARSAT-2.

Característica	Valores
Resolución espacial	1 a 100 metros
Polarización	HH, HV, VH y VV
Ángulo de incidencia	20° a 41°
Dirección de visión	Visión derecha e izquierda
Masa de lanzamiento	2280 kg
Dimensiones de la antena SAR	15 m x 1.5 m
Cobertura	20 km a 500 km
Vida útil	7 años
Altitud	800 km
Ciclo de repetición	383 órbitas en 24 días
Frecuencia de imágenes	Banda C. 5.405 GHz

2.3.2. Descomposición de Pauli

Como se ha mencionado anteriormente, el satélite RADARSAT-2 captura información del eco en las cuatro polarizaciones, es decir: HH, HV, VV y VH. Cada uno de estos canales representa un número complejo (ver Ecuación 2-3), que posee información de la magnitud del campo eléctrico y de la fase relativa. La imagen generada con el software PolSARpro² que se utilizó en la presente investigación, se construyó en la composición de Pauli, la cual utiliza el siguiente código de colores: rojo, $|HH - VV|$; verde, $|HV|$ y azul $|HH + VV|$. La Figura 2-6 presenta una imagen real capturada por el satélite RADARSAT-2 en el municipio de Saldaña, Tolima, construida en la composición de Pauli. En dicha imagen se puede observar regiones con un color marcado que utilizaremos más adelante en la clasificación, además, es característico un ruido granular en todas las zonas de la misma. Debido a la presencia de ruido en las imágenes de radar, es obligatorio filtrarlas para poder realizar la segmentación y clasificación. El capítulo siguiente lo dedicaremos al estudio de varios filtros encontrados en la literatura para eliminar el ruido granular presente en las imágenes.

²PolSARpro es un programa especializado tanto en el procesamiento de datos SAR (radar de apertura sintética) polarimétrico como interferométrico y SAR polarimétrico-interferométrico. PolSARpro es desarrollado por la Agencia Espacial Europea.

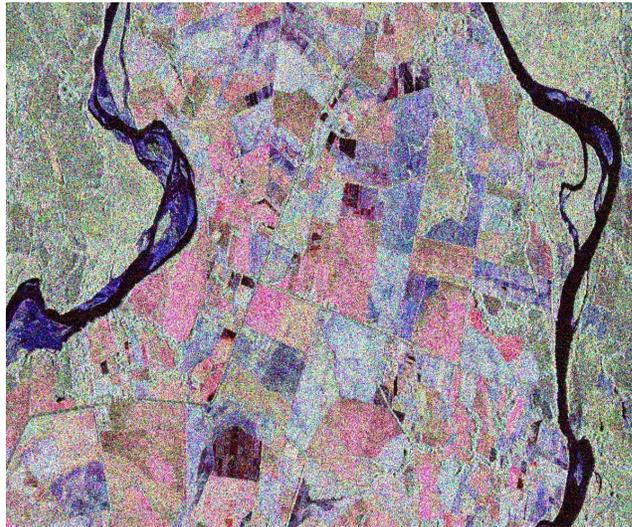


Figura 2-6: Imagen de RADARSAT-2, Saldaña.

3 Eliminación de ruido Speckel

3.1. Introducción

En el éste capítulo realizamos una discusión de varios filtros propuestos en la literatura para eliminar el ruido granular presente en las imágenes SAR. Utilizamos cuatro criterios para evaluar el desempeño del cada filtro al procesar imágenes sintéticas con diferentes porcentajes de ruido e imágenes reales. En ésta sección presentamos nuestra propuesta de filtro, el filtro MediaModaNa y un método novedoso de ventana adaptativa. Realizamos gráficas con los resultados y presentamos un análisis de los mismos.

Debido a la interferencia de las señales las imágenes de radar se manifiestan ruidosas, con un ruido de apariencia granular conocido como *speckle*. En los sistemas SAR, las ondas electromagnéticas dispersadas por los numerosos elementos en la superficie terrestre interfieren mutuamente, llegando a producir tanto interferencia constructiva como destructiva.

El ruido *speckle* tiene las características de un ruido multiplicativo aleatorio donde sus efectos son más pronunciados en áreas de alta intensidad que en áreas de baja intensidad [53]. Sea $g(k, l)$ un píxel de la imagen corrompida con un ruido multiplicativo n , tal que:

$$g(k, l) = n(k, l)z(k, l) \quad (3-1)$$

Aquí, $g(k, l)$ representa la intensidad (o la magnitud) del píxel (k, l) en la imagen SAR, $z(k, l)$ es la reflectividad de la superficie y $n(k, l)$ es la secuencia de ruido aleatorio blanco que obedece a una distribución normal con media $\bar{n} = 1$ y una varianza dada por σ_n^2 . Para estimar la desviación estándar del ruido sobre una región homogénea de la imagen, Lee [54] y Su [24] ha utilizado la expresión 4-25.

$$\sigma_n = \frac{\sigma_g}{\bar{g}} \quad (3-2)$$

En la práctica \bar{g} y σ_g , la media y la desviación estándar de la imagen ruidosa, se estiman localmente dentro de una ventana de dimensión finita. La desviación estándar del ruido σ_n son entradas para los filtros o bien se pueden estimar sobre una región uniforme en la imagen.

3.2. Filtros de ruido speckle

De entre las posibles estrategias de filtrado de *speckle*, se consideran algunas que se basan en calcular el nivel de intensidad de cada píxel a partir de las estimaciones de una serie

de estadísticos locales. A la hora de evaluar dichos estadísticos, el tamaño de la ventana de procesamiento debe ser una solución de compromiso entre la precisión de la estimación y la variabilidad de la propia imagen. En zonas homogéneas, ventanas grandes permiten realizar estimaciones precisas con un número elevado de muestras, pero en zonas heterogéneas la utilización de ventanas grandes engloba propiedades estadísticas de la imagen diferentes, que no serán útiles para el procesamiento del píxel objeto de estudio. Por ésta razón en la Sección 3,3 presentamos una novedosa propuesta de ventana adaptativa

3.2.1. Filtro de Media

Es un filtro pasa bajos básico, el cual reemplaza el píxel central (x, y) en una ventana $W(x, y)$ de tamaño $N \times N$, por el promedio de los píxeles dentro de la ventana. La media aritmética es el valor obtenido al sumar todos los datos y dividir el resultado entre el número total de datos (ver Ecuación 3-3).

$$f(x, y) = \underset{(k,l) \in W(x,y)}{\text{media}} [g(k, l)] \quad (3-3)$$

Donde $f(x, y)$ es la salida del filtro, y es la estimación de la imagen sin ruido. $g(k, l)$ representa el valor de la imagen original o ruidosa. En general, el filtro de media degrada los detalles finos y la textura de la imagen [65].

3.2.2. Filtro Moda

El filtro Moda se basa en el examen del histograma, el cual representa la frecuencia relativa o probabilidad $p(I_i)$, con la que cada color o nivel de gris I_i , aparece en la imagen. El histograma de una imagen es una función discreta que se define como muestra la Ecuación 3-4.

$$p(I_i) = \frac{n_i}{MN} \quad (3-4)$$

Donde MN es el número de píxeles en la imagen y n_i es el número de píxeles en el nivel de intensidad I_i .

El filtro Moda, halla la función de probabilidades $p(I_i)$ en una ventana de tamaño $N \times N$, la cual se va deslizando por toda la imagen. A continuación determinamos el máximo de la función $p(I_i)$ y se halla el nivel de gris I_m correspondiente con éste máximo. Paso siguiente, se asigna el valor I_m al píxel central (x, y) de la ventana de estudio. Es necesario aclarar que cada canal de la imagen es procesado independientemente.

3.2.3. Filtro Mediana

El filtro Mediana (ver Ecuación 3-5), es un filtro paso bajo no lineal. El valor del píxel central es reemplazado por la mediana del conjunto de píxeles contenidos en cada ventana.

La mediana es el valor que ocupa el lugar central de todos los datos cuando éstos están ordenados de menor a mayor.

$$f(x, y) = \underset{(k,l) \in W(x,y)}{\text{mediana}} [g(k, l)] \quad (3-5)$$

3.2.4. Filtro M3

El filtro M3 es un híbrido entre los filtros de media y mediana (ver Ecuación 3-6). El píxel central en la ventana de estudio es remplazado por el máximo valor entre la media y la mediana.

$$f(x, y) = \underset{(k,l) \in W(x,y)}{\text{máx}} \{ \text{mediana} [g(k, l)], \text{media} [g(k, l)] \} \quad (3-6)$$

3.2.5. Filtro de Lee

El filtro de Lee [54, 16, 15, 12, 66] usa estadísticas locales como la media y la desviación estándar en una ventana de tamaño fijo, para determinar pesos adecuados para suavizar la imagen. El modelo multiplicativo del ruido *speckle* se aproxima por un modelo lineal. El algoritmo de filtrado está dado por la Ecuación 3-7.

$$f(x, y) = \bar{g} + k_{xy} [g(x, y) - \bar{g}] \quad (3-7)$$

Donde \bar{g} es el valor de la media estimada a partir de los píxeles vecinos de la ventana de procesado y k_{xy} es el parámetro adaptativo que se ajusta para cada píxel según la ecuación 3-8.

$$k_{xy} = \frac{\sigma_g^2}{\sigma_g^2 + (\sigma_n \bar{g})^2} \quad (3-8)$$

donde σ_g^2 es la estimación de la varianza de $g(k, l)$ en la ventana del proceso y σ_n es la desviación estándar del ruido. En relación a este último parámetro, existen valores estándar para diferentes tipos de imágenes, también puede utilizarse un valor normalizado igual a la unidad.

En una región homogénea la salida del filtro es un promedio lineal de los píxeles de su vecindad, mientras que en regiones extremadamente heterogéneas, la salida puede llegar a ser el mismo valor del píxel de entrada.

Filtro de Lee mejorado

El filtro de Lee fue mejorado por Lopes et al. [62, 66] dividiendo la zona de estudio en tres clases de áreas. La primera clase corresponde a regiones homogéneas en las cuales el ruido puede ser eliminado utilizando un filtro pasa bajo. La segunda clase corresponde a regiones heterogéneas en la que el ruido se reduce preservando la textura. Y la tercera clase es la que

contiene puntos aislados donde el filtro debe preservar el valor observado. El filtro de Lee mejorado está dado por:

$$f(x, y) = \begin{cases} \bar{g}, & \text{si } C_I \leq C_n \\ g(k, l)S_{kl} + \bar{g}(1 - S_{kl}), & \text{si } C_n \leq C_I < C_{max} \\ g(x, y), & \text{si } C_I \geq C_{max} \end{cases} \quad (3-9)$$

La función de peso S_{kl} está dada por:

$$S_{kl} = exp \left\{ \frac{-K(C_I - C_n)}{C_{max} - C_I} \right\} \quad (3-10)$$

donde K es el factor de amortiguamiento y C_{max} es el máximo coeficiente de variación de ruido.

Donde C_n y C_I están definidos de la siguiente manera:

$$C_n = \frac{\sigma_n}{\bar{n}}, \quad C_I = \frac{\sigma_g}{\bar{g}} \quad (3-11)$$

El valor del coeficiente de amortiguamiento depende de la imagen sin filtrar y usualmente requiere experimentos de ensayo y error para determinar el mejor valor.

3.2.6. Filtro de Kuan

El filtro Kuan [17, 56, 57, 62] se basa en un criterio de mínimo error cuadrático medio (Minimum Mean Square Error, MMSE). Una primera estimación del MMSE se desarrolla para un modelo aditivo de ruido, $g = z + n$. El modelo multiplicativo del ruido entonces se considera de la siguiente forma, $g(k, l) = z(k, l) + [n(k, l) - 1]z(k, l)$. El filtro de Kuan viene dada por la Ecuación 3-12.

$$f(x, y) = \bar{g} + \left\{ \frac{\sigma_0^2 [g(x, y) - \bar{g}]}{\sigma_0^2 + \frac{[\bar{g}^2 + \sigma_0^2]}{L}} \right\} \quad (3-12)$$

Donde σ_0 esta dada por la Ecuación 3-13.

$$\sigma_0^2 = \frac{L\sigma_g^2 - \bar{g}^2}{L + 1} \quad (3-13)$$

Siendo σ_g^2 la estimación de la varianza de la imagen original en la ventana determinada; σ_0^2 es la estimación de la varianza de la imagen sin ruido y L es la relación al cuadrado entre las estimaciones de la media y la desviación estándar de la imagen total. El filtro propuesto por Kuan (Ecuación 3-12) puede considerarse como una generalización del filtro propuesto por Lee (Ecuación 3-7). El filtro Kuan es óptimo cuando la escena y las intensidades detectadas tienen una distribución Gaussiana.

3.2.7. Filtro Gamma

EL filtro Gamma está basado en un análisis Bayesiano de las propiedades estadísticas de la imagen. Para ello, se supone que tanto la reflectividad radar como el ruido *speckle* siguen una distribución Gamma. El filtro Gamma está dado por la Ecuación 3-14.

$$f(x, y) = \left[\frac{(\alpha - L - 1) \bar{g} + \sqrt{\bar{g}^2 (\alpha - L - 1)^2 + 4\alpha L g(x, y) \bar{g}}}{2\alpha} \right] \quad (3-14)$$

donde α esta definida como:

$$\alpha = \frac{L + 1}{\left[L \left(\frac{\sigma_g}{\bar{g}} \right)^2 - 1 \right]} \quad (3-15)$$

3.2.8. Filtro de Frost

El filtro Frost es un filtro adaptativo de Wiener que realiza una convolución de los valores de los píxeles dentro de una ventana de tamaño fijo con una respuesta de impulso exponencial m dada por:

$$m = \exp[-K C_y d(t_0, t)] \text{ con } C_y = \frac{\sigma_g}{\bar{g}} \quad (3-16)$$

donde K es un parámetro del filtro que representa su valor de amortiguación, $t_0 = (k, l)$ representa la localización del píxel procesado y $d(t_0, t)$ es la distancia medida desde la localización del píxel $t = (x, y)$ al $t_0 = (k, l)$ (ver Ecuación 3-17).

$$d(t_0, t) = \sqrt{(x - k)^2 + (y - l)^2} \quad (3-17)$$

La estimación del píxel en t viene dada por la ecuación 3-18, donde g_i son los valores de la imagen ruidosa en las posiciones de la ventana de convolución y m_i los coeficientes de la convolución.

$$f(x, y) = \frac{g_1 m_1 + g_2 m_2 + \dots + g_n m_n}{m_1 + m_2 + \dots + m_n} \quad (3-18)$$

Filtro de Frost mejorado

El filtro de Frost fue modificado y mejorado por Lopes et al. [62, 66] de la misma manera de como mejoró el filtro de Lee. El modelo para mejorar el filtro de Frost se formula de la siguiente manera:

$$m = \exp[-K \text{func}(C_I(t))|t|] \quad (3-19)$$

donde $func(C_I(t))$ es una función hiperbólica de C_I definida como:

$$func(C_I(t)) = \begin{cases} 0, & \text{si } C_I(t) \leq C_n \\ \frac{(C_I(t) - C_n)}{(C_{max} - C_I(t))}, & \text{si } C_n \leq C_I < C_{max} \\ \infty, & \text{si } C_I \geq C_{max} \end{cases} \quad (3-20)$$

3.2.9. Filtro de Oddy

Se trata de un filtro de media cuya forma de la ventana varía de acuerdo con la estadística local. La evaluación se hace localmente sobre una ventana de vecindad 3×3 donde se obtiene $m = \frac{1}{8} \sum_k \sum_l |g(k, l) - \bar{g}|$. La evaluación se realiza mediante:

$$f(x, y) = \bar{g} \quad \text{si } m < \alpha \bar{g}; \quad f(x, y) = \frac{\sum_k \sum_l D_{kl} g(k, l)}{\sum_k \sum_l D_{kl}} \quad \text{si } m > \alpha \bar{g}. \quad (3-21)$$

siendo α un parámetro del filtro, y $D_{kl} = 1$ si $|g(k, l) - \bar{g}| \leq m$ y $D_{kl} = 0$ en cualquier otro caso.

Para utilizar el filtro de Oddy con ventanas mayores de 3×3 modificamos el valor de m definiendolo de la siguiente manera $m = \frac{1}{N^2 - 1} \sum_k \sum_l |g(k, l) - \bar{g}|$, donde N es el tamaño de la ventana.

3.2.10. Filtro Promedio Geométrico.

Este filtro reemplaza la intensidad del píxel central por la raíz del producto de los píxeles de la ventana [68]. El filtro Promedio Geométrico se define según la Ecuación 3-22.

$$f(x, y) = \left[\prod_{(k,l) \in W(x,y)} g(k, l) \right]^{\frac{1}{N^2}} \quad (3-22)$$

Donde N es el tamaño de la ventana.

3.3. Filtro propuesto MediaModaN.

Buscando tomar lo mejor del filtro de media; de igual manera del filtro moda y del filtro mediana, en esta investigación proponemos el filtro Mediamodana (Filtro MMN), el cual reemplaza el píxel central (x, y) en una ventana $W(x, y)$ de tamaño $N \times N$, por el promedio entre la Media, la Moda y la Mediana (ver Ecuación 3-23).

$$f(x, y) = \left(\frac{Media + Moda + Mediana}{3} \right) \quad (3-23)$$

3.4. Técnica propuesta para el tamaño adaptativo de la ventana.

3.4.1. Introducción.

El objetivo del filtrado es eliminar el ruido multiplicativo que presentan las imágenes SAR. Como se ha mencionado, en regiones homogéneas conviene utilizar ventanas de filtrado grandes, pero en las fronteras es aconsejable ventanas pequeñas. Dependiendo de las propiedades estadísticas de la región de estudio y su perímetro definimos un algoritmo que adapta la ventana de filtrado de una manera optima. En esta sección se presenta la técnica propuesta de ventana adaptativa que se basa en compara la región de interés, la ventana $W(x, y)$ con su perímetro $B(x, y)$. Si la región de interés es similar al perímetro el tamaño de la ventana de filtrado se incrementa a $N + 2$, de lo contrario, se reduce el tamaño de la ventana a $N - 2$ y se compara nuevamente con su perímetro (en el Anexo 3 Sección 9, se presenta el pseudocódigo de la función `Altura_Ventana`, la cual calcula el nuevo tamaño de la ventana para el filtro adaptativo). Para cada pixel procesado se determina el valor optimo de la ventana antes de aplicar una técnica de filtrado en particular. En cada iteración se determina el tamaño optimo de la ventana de filtrado el cual puede resultar siendo $N + 2$, N o $N - 2$. A continuación describimos paso a paso y en detalle la técnica propuesta para adaptar la ventana de filtrado.

3.4.2. Región de interés y su perímetro.

En ésta propuesta de ventana adaptativa, definimos la región de interés y su perímetro como se observa en la Figura 3-1 (a) y (b) respectivamente. Representamos como $W(x, y)$ la ventana de tamaño $N \times N$ con centro en las coordenadas (x, y) . En el algoritmo propuesto el valor mínimo de N_{min} y máximo N_{max} son de 3 y 11 respectivamente, es decir, la ventana de tamaño más pequeño fue de 3×3 y la de mayor tamaño de 11×11 . La región de interés $W(x, y)$ está representada por la Ecuación 3-24.

$$W(x, y) = \left\{ (k, l) \mid x - \frac{(N-1)}{2} \leq k \leq x + \frac{(N-1)}{2}, y - \frac{(N-1)}{2} \leq l \leq y + \frac{(N-1)}{2} \right\} \quad (3-24)$$

Los píxeles de la frontera de la región de interés, son utilizados para tomar la decisión del próximo tamaño de ventana. Representaremos como $B(x, y)$ la zona del perímetro de la ventana, definido como muestra la Ecuación 3-25.

$$B(x, y) = A_1 \cup A_2 \cup A_3 \cup A_4 \quad (3-25)$$

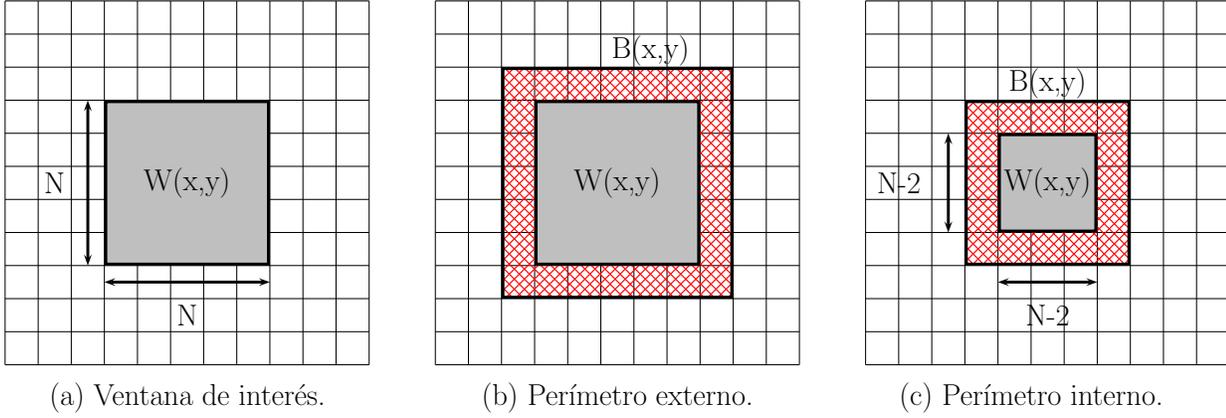


Figura 3-1: Ventana de interés y perímetro.

Donde A_1 es la región que contiene los píxeles de la frontera en la parte superior de la ventana $W(x, y)$ definido como dice la Ecuación 3-26.

$$A_1(x, y) = \left\{ (k, l) \mid x - \frac{(N+1)}{2} \leq k \leq x + \frac{(N+1)}{2} \text{ para } l = y + \frac{(N+1)}{2} \right\} \quad (3-26)$$

Siendo A_2 la región que contiene los píxeles de la frontera en la parte inferior de la ventana $W(x, y)$ definido como dice la Ecuación 3-27.

$$A_2(x, y) = \left\{ (k, l) \mid x - \frac{(N+1)}{2} \leq k \leq x + \frac{(N+1)}{2} \text{ para } l = y - \frac{(N+1)}{2} \right\} \quad (3-27)$$

De igual manera, A_3 contiene los píxeles de la frontera al lado izquierdo de la ventana $W(x, y)$ definido como dice la Ecuación 3-28.

$$A_3(x, y) = \left\{ (k, l) \mid y - \frac{(N-1)}{2} \leq l \leq y + \frac{(N-1)}{2} \text{ para } k = x - \frac{(N+1)}{2} \right\} \quad (3-28)$$

Y finalmente A_4 , que contiene los píxeles de la frontera al lado derecho de la ventana $W(x, y)$ definido como dice la Ecuación 3-29.

$$A_4(x, y) = \left\{ (k, l) \mid y - \frac{(N-1)}{2} \leq l \leq y + \frac{(N-1)}{2} \text{ para } k = x + \frac{(N+1)}{2} \right\} \quad (3-29)$$

3.4.3. Similitud de las regiones.

En nuestro caso, utilizamos los momentos estadísticos para establecer la equivalencia de las distribuciones de probabilidades de las dos regiones. Si los momentos de las regiones $W(x, y)$ y $B(x, y)$ son iguales, entonces éstas deben tener la misma distribución de probabilidades. Para determinar que tan similares son las zonas utilizamos los momentos invariantes de Hu (ver Anexo 4 en la Sección 10). Es decir, hallamos los siete momentos invariantes de Hu para la ventana $W(x, y)$ y también para el perímetro $B(x, y)$. Utilizamos la métrica dada en la Ecuación 3-30 para comparar los momentos y determinar que tan parecidas son las regiones.

3.4.4. Métrica utilizada.

Como mencionamos anteriormente, luego de hallar los momentos invariantes de Hu, utilizamos una métrica para comparar las regiones. La métrica implementada es la que muestra la Ecuación 3-30.

$$d(W, B) = \sum_{i=1}^7 |m_i^W - m_i^B| \quad (3-30)$$

Donde m_i^W y m_i^B se definen según las Ecuaciones 3-31 y 3-32 respectivamente.

$$m_i^W = \text{sign}(h_i^W) \log(h_i^W) \quad (3-31)$$

$$m_i^B = \text{sign}(h_i^B) \log(h_i^B) \quad (3-32)$$

Donde h_i^W y h_i^B son los momentos de Hu de la ventana $W(x, y)$ y del perímetro $B(x, y)$ respectivamente.

3.4.5. Umbral utilizado.

Para determinar el umbral óptimo utilizamos una función de compromiso la cual se presenta más adelante (ver Sección 3.6.2). Nuestro estudio mostró que los mejores resultados se obtienen cuando el umbral es de 0,10; en consecuencia éste fue el valor utilizado para determinar la similitud de las regiones. Es decir si $d(W, B) < 0,1$ asumimos que las regiones son iguales, de lo contrario son diferentes. Si las regiones $W(x, y)$ y $B(x, y)$ son similares, el tamaño de la ventana aumenta a $N + 2$ y se desliza la ventana. Si las regiones son diferentes, el tamaño de la ventana se reduce a $N - 2$ y se repite todo el proceso descrito anteriormente (ver Figura 3-1 (c)). Como mencionamos anteriormente, la ventana más pequeña que se utilizó fue $N_{min} = 3$ y la máxima $N_{max} = 11$. En la Figura 3-2 se dibujan valores del tamaño de ventana para un número limitado de iteraciones. En dicha figura se observa como el tamaño de la ventana cambia de una iteración a la siguiente dependiendo de las características estadísticas de cada ventana.

3.5. Criterios de evaluación.

Existen varias maneras de evaluar cuantitativamente el filtrado de imágenes de acuerdo a diferentes criterios tales como la reducción de ruido, la preservación de contornos, la preservación de ciertas características y el tiempo de ejecución [59, 60]. Se debe tener presente que los resultados de las diversas maneras de evaluar el filtrado de las imágenes pueden ser contradictorias.

De los criterios que encontramos reportados en la literatura [60] escogimos solo cuatro: la

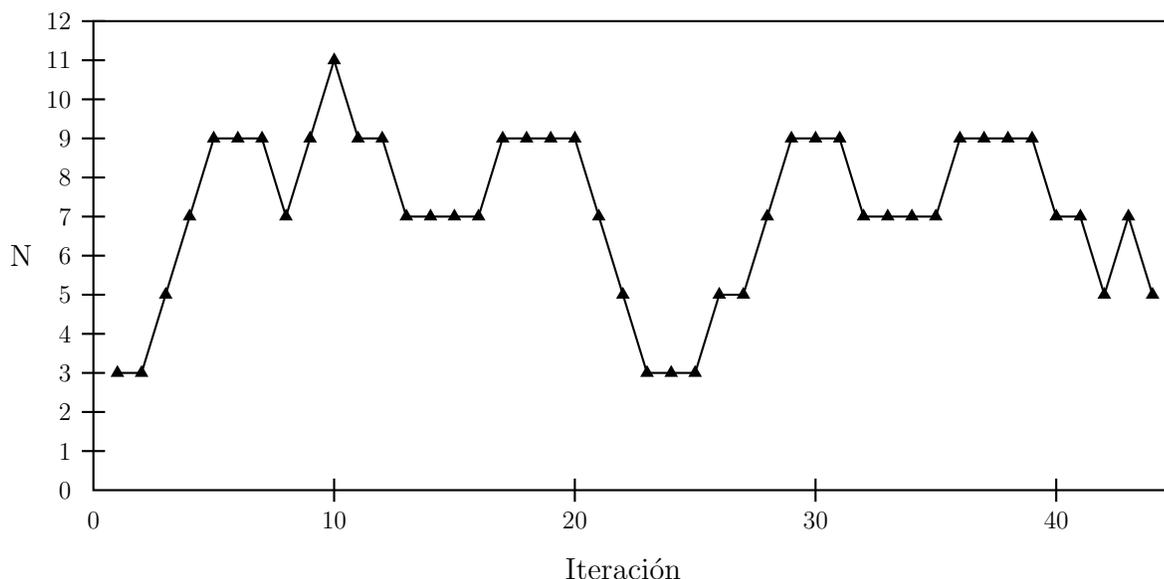


Figura 3-2: Tamaño de ventana vs iteración.

relación señal a ruido (SNR); el índice de mejora de contornos (EEI), el error cuadrático medio (RMSE) y el tiempo de ejecución. Utilizamos estos criterios porque no están correlacionados.

Relación señal a ruido (SNR).

El parámetro SNR (Signal to Noise Ratio), se define como el cociente entre la media de los niveles digitales y su desviación estándar para la imagen filtrada $f(x, y)$ [60]. (Ver Ecuación 3-33).

$$SNR = \frac{\bar{f}}{\sigma_f} \quad (3-33)$$

En la práctica la media \bar{f} , y la desviación estándar σ_f , de la imagen filtrada, se estiman localmente dentro de una ventana de dimensión finita.

Índice de mejora de contornos (EEI).

El índice de mejora de contornos (Edge Enhancing Index EEI), indica que tanto un filtro puede conservar las áreas de los contornos y se define como muestra la Ecuación 3-34.

$$EEI = \frac{\sum |f(a) - f(b)|}{\sum |g(a) - g(b)|} \quad (3-34)$$

Dónde $f(a)$ y $f(b)$ son los valores filtrados de los píxeles a cada lado del contorno, y $g(a)$ y $g(b)$ los valores originales de los correspondientes píxeles. Los valores de EEI normalmente son menores que uno y los valores grandes indican mejor capacidad de preservar los contornos.

Error cuadrático medio (RMSE).

El error cuadrático medio (Root Mean Square Error RMSE), se ha utilizado también como una medida estadística para evaluar el rendimiento de los filtros [68], definido según la Ecuación 3-35.

$$RMSE = \sqrt{\frac{\sum_k \sum_l [z(k, l) - f(k, l)]^2}{N^2}} \quad (3-35)$$

En éste índice se compara la imagen original $z(k, l)$, sin ruido multiplicativo, y la imagen filtrada $f(k, l)$. Entendiendo que entre menor sea el valor del RMSE, la imagen filtrada se asemeja más a la imagen original.

Tiempo de ejecución.

Se mide el tiempo que demora cada filtro en procesar la imagen sintética de prueba (imagen de 400×400 píxel). Los tiempos se interpretan comparativamente y no de una manera absoluta. Se utiliza la librería OpenCv para implementar los filtros, sobre una plataforma de Ubuntu. Se implementó todo en un equipo Intel(R) Pentium(R) Dual CPU T2390 @ 1.86GHz, con 2,5 GB de memoria RAM.

3.6. Resultado del filtrado

3.6.1. Introducción.

Para medir el rendimiento de los filtros, se utilizaron imágenes sintéticas con cinco porcentajes de ruido multiplicativo, lo que significa que se construyeron imágenes con ruido del 5 %, 10 %, 20 %, 30 % y del 40 % (ver Figura 3-3). Cada una de estas imágenes se procesaron con doce filtros y sus variantes, incluido el filtro MediaModaNu (MMN) propuesto. En la primera parte, el tamaño de la ventana de filtrado se mantuvo constante y esta fue siempre cuadrada de dimensión $N \times N$ (ver Figura 3-1 (a)). Se utilizaron ventanas de tamaño $N = 3$, $N = 5$, $N = 7$, $N = 9$ y $N = 11$. Cada imagen sintética se procesó con todos los tamaños de ventana. Luego se procesaron todas las imágenes con todos los filtros utilizando la técnica propuesta de ventana adaptativa.

Para evaluar el desempeño de los filtros utilizamos los cuatro indicadores mencionados anteriormente, es decir: la relación señal a ruido (SNR), el índice de mejora de contornos (EEI), el error cuadrático medio (RMSE) y el tiempo de ejecución de cada filtro. En nuestra investigación para calcular el valor del error cuadrático medio (RMSE), comparamos la imagen filtrada con la imagen original sin ruido multiplicativo, lo que nos definía el criterio que entre menor fuera éste índice, la imagen filtrada se asemejaba más a la imagen original. Como los índices que miden el desempeño son contradictorios definimos una función de compromiso (ver Tabla 3-1 y 8-11), que considere el mejor rendimiento de cada indicador. La función

de compromiso considera tres índices solamente, tomando los valores máximos de cada uno para normalizar los resultados.

Debido al volumen de los resultados presentamos en ésta sección algunas gráficas solamente; las demás gráficas y tablas se encuentran en el Anexo 1 (Sección 7) y el Anexo 2 (Sección 8) respectivamente. Como un ejemplo de los resultados del filtrado, en la Figura 7-1 se presentan imágenes filtradas con varios filtros utilizando una ventana fija de tamaño $N = 11$. A continuación presentamos un análisis de los resultados teniendo en cuenta las imágenes sintéticas y luego las imágenes reales de radar.

3.6.2. Imágenes sintéticas.

Efecto del porcentaje de ruido.

En este apartado presentamos los resultados del efecto del porcentaje de ruido en el filtrado de las imágenes sintéticas.

- El valor de índice SNR decae fuertemente cuando aumenta el ruido en las imágenes. Es decir, el rendimiento de los filtros disminuye al aumentar el porcentaje de ruido en las imágenes (ver Figura 3-4, 7-2 y 7-3). En ésta etapa el tamaño de la ventana se mantuvo constante y se representa gráficamente con símbolos diferentes, esto quiere decir: ventanas de tamaño de 3×3 se graficaron utilizando un triangulo relleno; ventanas de tamaño de 5×5 se graficaron utilizando un cuadrado relleno; ventanas de tamaño de 7×7 se graficaron utilizando un circulo relleno; ventanas de tamaño de 9×9 se graficaron utilizando un pentágono relleno y ventanas de tamaño de 11×11 se graficaron utilizando un rombo relleno.
- El índice de mejora de contornos sufre una pequeña variación al incrementarse el contenido de ruido en la imagen, tendiendo a aumentar el valor de IEE al aumentar el porcentaje de ruido (ver Figura 3-5, 7-4 y 7-5).
- El incremento en el porcentaje de ruido ocasiona un aumento del error cuadrático medio. El valor de RMSE sufre un incremento fuerte al aumentar el contenido de ruido de las imágenes (ver Figura 3-6, 7-6 y 7-7).
- El tiempo que tardan los filtros en procesar las imágenes no se ve afectado al variar el contenido de ruido en las mismas (ver Figura 3-7 y 7-8).

Efecto del tamaño de la ventana.

A continuación presentamos el impacto del tamaño de la ventana de filtrado en el desempeño de los filtros.

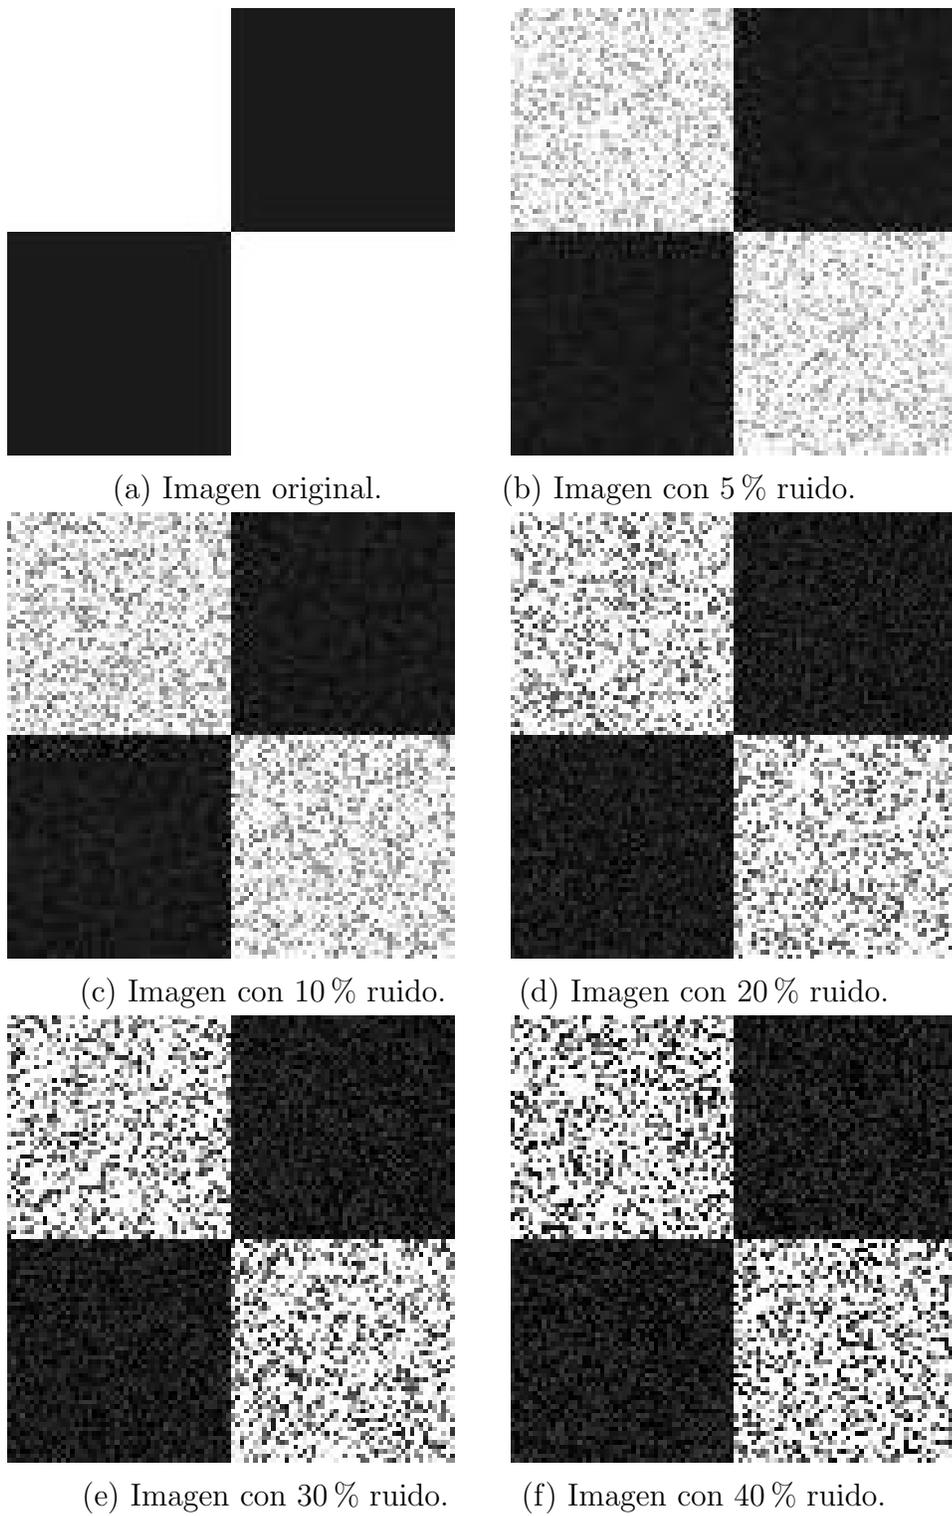


Figura 3-3: Zoom imágenes sintéticas con diferentes porcentajes de ruido multiplicativo.

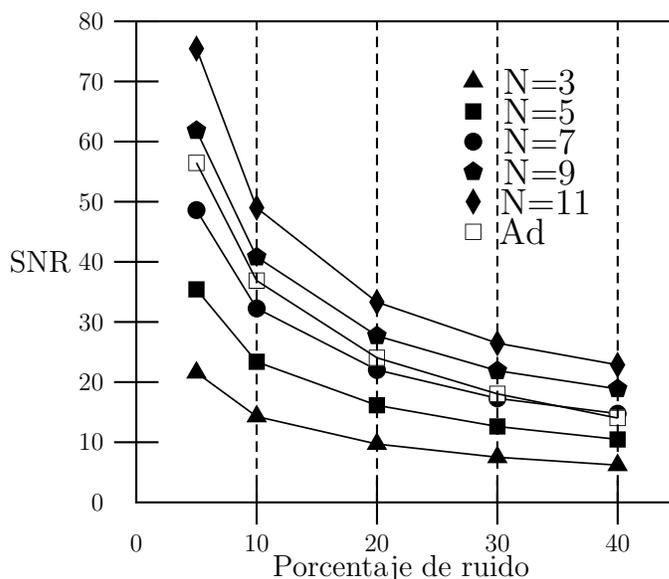


Figura 3-4: SNR vs Ruido. Filtro de Lee $\sigma_n = 6$.

- El tamaño de la ventana de proceso tiene un efecto significativo en el desempeño de los filtros. Se observa que al aumentar N el índice SNR mejora notoriamente. Los mejores valores de SNR se obtuvieron cuando el tamaño de la ventana fue de once, es decir para $N = 11$ (ver Figura 3-4, 7-2 y 7-3). Esto nos indica que entre mayor sea el tamaño de la ventana de proceso, se obtiene mejores resultados en las regiones homogéneas.
- Al elevar el tamaño de la ventana de proceso el índice de mejora de los contornos EEI, disminuye (ver Figuras 3-5, 7-4 y 7-5). Los mejores valores del índice EEI se encontraron para ventanas de tamaño tres ($N = 3$). Al incrementar el tamaño de la ventana de proceso los contornos se van degradando, siendo el mejor tamaño de ventana precisamente la ventana más pequeña utilizada.
- Un aumento de la ventana de proceso ocasiona el incremento del error cuadrático medio RMSE (ver Figura 3-6, 7-6 y 7-7). Para todos los porcentajes de ruido en las imágenes los mejores resultados se obtienen para $N = 3$. Aclaremos que en nuestro caso se comparó la imagen filtrada con la imagen sin ruido original sintética.
- Al incrementar el tamaño de la ventana de proceso el tiempo que tardan los filtros en procesar las imágenes se ve aumentado (ver Figura 3-7 y 7-8). El mejor desempeño con respecto al tiempo de procesado se encontró para ventanas de tamaño tres, es decir para $N = 3$.

Adicionalmente se elaboraron cinco (5) imágenes con ruido multiplicativo con media de uno (1) y porcentaje de ruido de 30 %. La Tabla 12-7 presenta los resultados promedios de la evaluación de dichas imágenes para el filtro de Lee. En las Figuras 7-12, 7-13 y 7-14 se

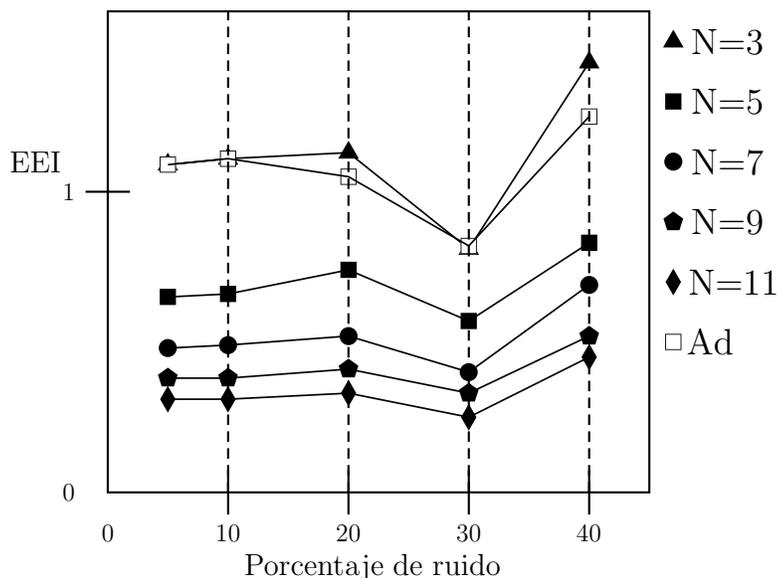


Figura 3-5: EEI vs Ruido. Filtro de Lee $\sigma_n = 6$.

representa la información de la Tabla 12-7. En la Figura 7-12 se observa que a medida que aumentamos el tamaño de la ventana de proceso el valor de índice SNR aumenta de una manera casi lineal. En la Figura 7-13 se aprecia que a medida que aumenta el tamaño de la ventana de filtrado el índice EEI disminuye; y en la Figura 7-14 se observa que a medida que aumenta el tamaño de la ventana de filtrado el índice RMSE aumenta. Estos resultados corroboran el comportamiento descrito en el apartado anterior. Asimismo se aprecia que el mejor desempeño en el filtrado, se obtiene al aplicar el método propuesto en éste trabajo de ventana adaptativa.

Efecto del tamaño de ventana adaptativo.

El filtrado con ventana adaptativa se simboliza en las gráficas con un cuadrado vacío. En todos los casos de filtrado con ventana adaptativa se utilizó la técnica propuesta. En las Figura 3-4, 7-2 y 7-3, se puede observar que el índice SNR con ventana adaptativa posee un desempeño por encima del 60 %, esto tomando como el 100 % del rendimiento para ventanas de tamaño $N = 11$. Es decir, como el rendimiento del filtrado con el algoritmo de ventana adaptativa está por encima del filtrado con $N = 7$ y por debajo del filtrado con ventana $N = 9$, es que afirmamos que su rendimiento es superior al 60 %. Con nuestra propuesta de ventana adaptativa se logra que el índice EEI este por encima del 80 % y para determinados porcentajes de ruido alcanza el valor máximo, es decir el 100 % (Figuras 3-5, 7-4, 7-5). De igual manera, utilizando la técnica propuesta de ventana adaptativa se logra valores de RMSE por encima del 80 % y para varios valores de porcentaje de ruido en la imagen se obtienen desempeños superiores al 100 % (3-6, 7-6, 7-7). Para todos los filtros, el tiempo de proceso se incrementa en un orden de magnitud al utilizar la ventana adaptativa; éste

Tabla 3-1: Definición de la Función de compromiso. Filtro Lee $\sigma_n = 6$.

% ruido	Función		
5	$F_5 =$	$\frac{100}{3}$	$* \left[\left(\frac{SNR}{75,47} \right) + \left(\frac{EEI}{1,09} \right) + \left(\frac{24,37}{RMSE} \right) \right]$
10	$F_{10} =$	$\frac{100}{3}$	$* \left[\left(\frac{SNR}{48,99} \right) + \left(\frac{EEI}{1,11} \right) + \left(\frac{31,28}{RMSE} \right) \right]$
20	$F_{20} =$	$\frac{100}{3}$	$* \left[\left(\frac{SNR}{33,30} \right) + \left(\frac{EEI}{1,13} \right) + \left(\frac{41,66}{RMSE} \right) \right]$
30	$F_{30} =$	$\frac{100}{3}$	$* \left[\left(\frac{SNR}{26,48} \right) + \left(\frac{EEI}{0,81} \right) + \left(\frac{50,01}{RMSE} \right) \right]$
40	$F_{40} =$	$\frac{100}{3}$	$* \left[\left(\frac{SNR}{22,87} \right) + \left(\frac{EEI}{1,43} \right) + \left(\frac{56,35}{RMSE} \right) \right]$

comportamiento se debe al número de rutinas adicionales que realiza el algoritmo en la comparación de las regiones.

Función de compromiso.

Debido a que los índices que miden el desempeño de los filtros son contradictorios definimos una función de compromiso que considera tres de ellos (SNR, EEI y RMSE). La contradicción la observamos cuando al aumentar el tamaño de la ventana de proceso el índice SNR aumenta pero el indicador EEI disminuye y el valor del índice RMSE aumenta. Al definir la función que aparece en la Tabla 3-1 buscamos un compromiso entre los indicadores ponderando los tres índices simultáneamente con el objetivo de obtener el mejor rendimiento en el filtrado, es decir, buscamos un tamaño de ventana que nos de una buena relación señal a ruido y que al mismo tiempo preserve los contornos y posea un valor mínimo en el error cuadrático medio. La función de compromiso se normalizó teniendo presente los diferentes tamaños de ventana y porcentajes de ruido en la imágenes sintéticas. En la normalización se tomó el valor máximo para la relación señal a ruido y el índice de mejora de contornos. Por el contrario, se seleccionó el menor valor del error cuadrático medio (ver Tabla 3-1 y 8-11). En la definición de la función de la Tabla 3-1 se utilizó el criterio que entre mayor sea la función de compromiso, mejor es el desempeño del filtro. El valor máximo de la función según la definición realizada fue de 100. Con el criterio propuesto en ésta investigación, es decir, utilizando la función de compromiso, observamos que el rendimiento de los filtros mejora cuanto se utiliza la técnica propuesta de ventana adaptativa. La función de compromiso reporta valores superiores al utilizar la técnica propuesta de ventana adaptativa en comparación con el filtrado utilizando ventana de tamaño fijo (ver Tabla 3-2 y 8-12).

- Umbral y similitud de las regiones. Para determinar la similitud de las regiones, en el algoritmo de ventana adaptativa, utilizamos un umbral específico. Empleamos la

Tabla 3-2: Función de compromiso. Filtro Lee $\sigma_n = 6$.

% ruido	Función. $N = 3$	Función. $N = 11$	Función. Adaptativa
5	$F_5 = 76,19$	$F_5 = 67,32$	$F_5 = 88,85$
10	$F_{10} = 69,01$	$F_{10} = 64,03$	$F_{10} = 83,97$
20	$F_{20} = 76,37$	$F_{20} = 73,36$	$F_{20} = 89,68$
30	$F_{30} = 76,12$	$F_{30} = 75,36$	$F_{30} = 92,09$
40	$F_{40} = 75,68$	$F_{40} = 76,35$	$F_{40} = 86,22$

Tabla 3-3: Definición de la Función de compromiso dos.

$$F_2 = \left[\left(\frac{SNR * EEI}{RMSE} \right) \right]$$

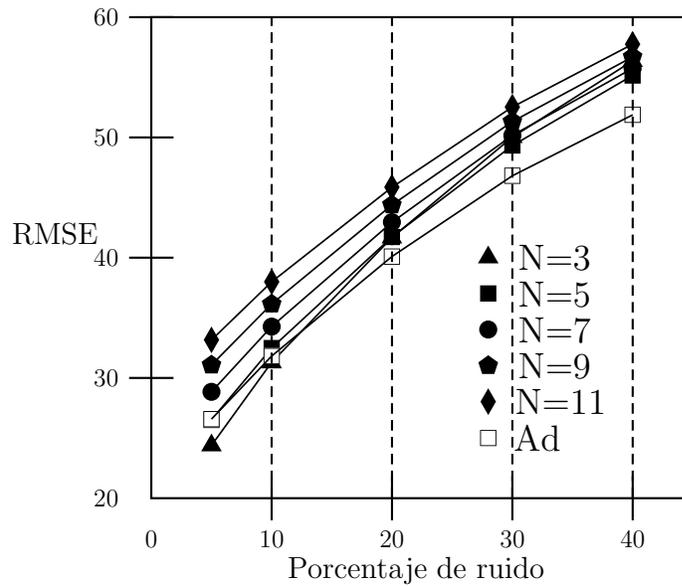
función de compromiso, definida en la Tabla **3-1**, para evaluar el desempeño del umbral al adaptar la ventana de filtrado. El criterio fue buscar el umbral, mediante su variación en el rango de 0.02 a 0.3 con paso de 0.05, tal que se produjera el más alto desempeño, este último definido por la función de compromiso. Es de anotar que el más alto valor en la función de compromiso, maximiza los índices de medición del desempeño de los filtros. En las Figura **3-8** y **7-9** se observa el efecto de variar el umbral de decisión ($0,02 \leq u \leq 0,30$) sobre la función de compromiso. Umbrales pequeños hacen más exigentes el criterio de similitud llevando hacia ventanas cercanas a la mínima, y por el contrario, umbrales grandes flexibilizan el criterio de decisión permitiendo ventanas más cerca de la máxima. Nuestro estudio muestra que el mejor desempeño de la función se obtiene cuando el umbral es de 0, 1 (ver Figura **3-8** y **7-9**), ésto debido a que el valor de la función de compromiso es mayor para dicho valor, siendo un punto de equilibrio para el tamaño de la ventana.

Resultados Generales en imágenes sintéticas.

Para poder comparar el desempeño de todos los filtros, de manera absoluta, definimos otra función de compromiso ponderando tres índices (SNR, EEI y RMSE). La función de compromiso dos (ver Tabla **3-3**), asume que el mejor desempeño es cuando el valor de SNR es máximo, al igual que el índice EEI y por el contrario considera que el valor de RMSE debe ser mínimo. Los cálculos confirman que la propuesta de filtrado con ventana adaptativa brinda mejores resultados (ver Tabla **3-4**), y adicionalmente expresan que el filtro MMN tiene un buen desempeño.

Tabla 3-4: Función de compromiso dos. Filtro Frost. $k=0.03$.

% ruido	$N = 3$	$N = 5$	$N = 7$	$N = 9$	$N = 11$	Adaptativa
5	$F_5 = 0,96$	$F_5 = 0,86$	$F_5 = 0,80$	$F_5 = 0,75$	$F_5 = 0,70$	$F_5 = 2,44$
10	$F_{10} = 0,50$	$F_{10} = 0,47$	$F_{10} = 0,45$	$F_{10} = 0,42$	$F_{10} = 0,39$	$F_{10} = 1,33$
20	$F_{20} = 0,26$	$F_{20} = 0,28$	$F_{20} = 0,26$	$F_{20} = 0,25$	$F_{20} = 0,23$	$F_{20} = 0,64$
30	$F_{30} = 0,12$	$F_{30} = 0,14$	$F_{30} = 0,13$	$F_{30} = 0,14$	$F_{30} = 0,12$	$F_{30} = 0,51$
40	$F_{40} = 0,15$	$F_{40} = 0,15$	$F_{40} = 0,18$	$F_{40} = 0,16$	$F_{40} = 0,17$	$F_{40} = 0,25$

**Figura 3-6:** RMSE vs Ruido. Filtro de Lee $\sigma_n = 6$.

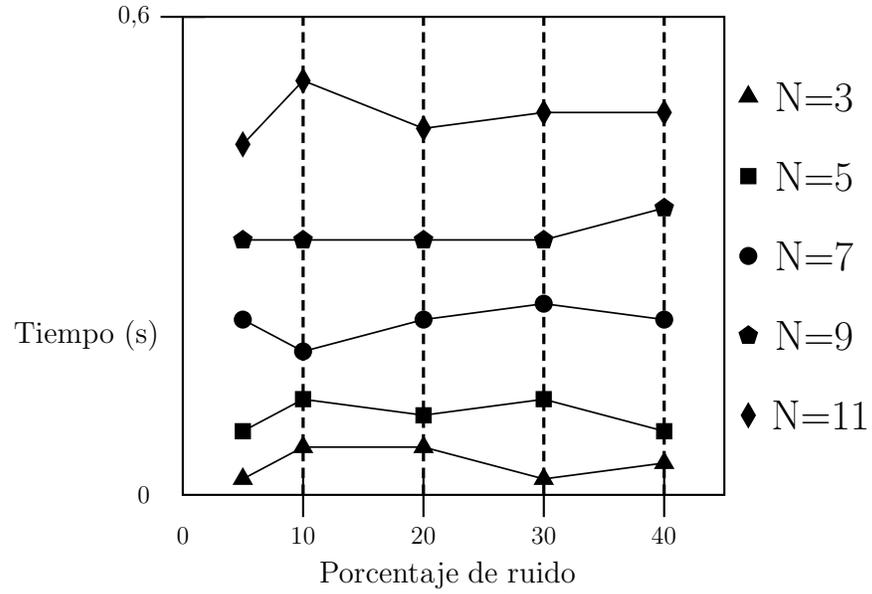


Figura 3-7: Tiempo vs Ruido. Filtro de Lee $\sigma = 6$.

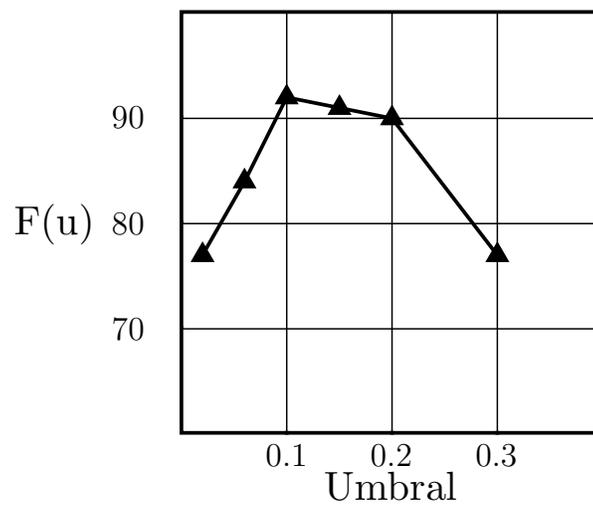
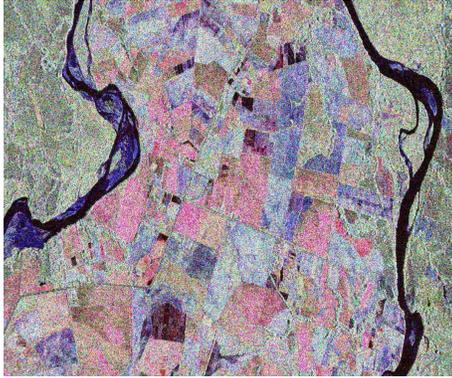
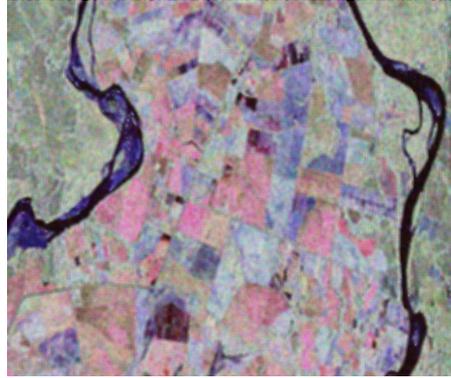


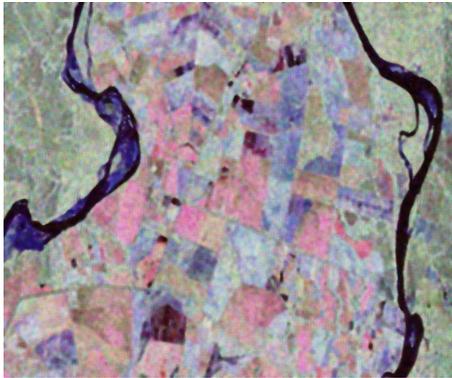
Figura 3-8: Función de Compromiso vs Umbral. Filtro de Lee $\sigma_n = 6$.



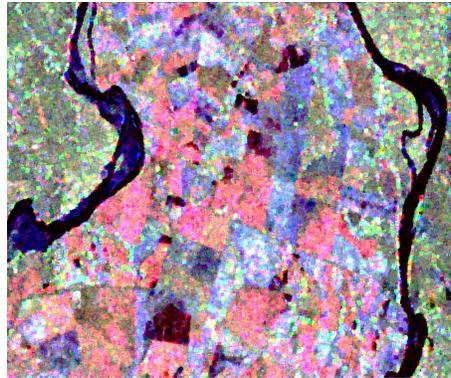
(a) Distrito de Riego Saldaña (Tolima).



(b) Filtro Lee. Ventana adaptativa.



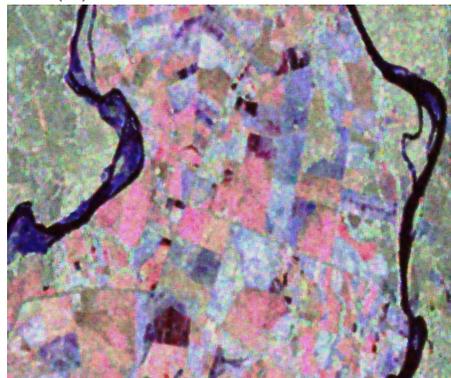
(c) Filtro Mediana. Ventana adaptativa.



(d) Filtro Moda. Ventana adaptativa.



(e) Filtro Frost. Ventana adaptativa.



(f) Filtro MMN. Ventana adaptativa.

Figura 3-9: Imágenes filtradas Municipio de Saldaña (Tolima).

3.6.3. Imágenes de radar.

La imagen utilizada en éste trabajo fue capturada por el satélite RADARSAT-2 en el Distrito de Riego de Saldaña, Tolima, el día 26 de febrero de 2009. Se utilizó el paquete PolSARpro para generar la imagen en la composición de Pauli. La imagen utilizada es de polarización múltiple (polarizaciones HH, HV, VH y VV) y de gran tamaño (3572×5938 píxeles), por esta razón se generaron varias imágenes de menor resolución para el estudio. Al seleccionar regiones más pequeñas, de la imagen original, se tuvo como criterio elegir zonas donde se observara la presencia de los cultivos de arroz. Es decir, se trató por un lado de tomar regiones donde existiera cultivos de arroz y por otra, que dichas imágenes no tuvieran una resolución muy grande, ésto debido a la limitada capacidad de computo del equipo utilizado. Debido a la presencia de los sembrados de arroz entre los dos canales del río Saldaña, ésta fue la zona escogida para seleccionar las imágenes de menor resolución. Se extrajeron: dos (2) imágenes con resolución de 1100×600 píxeles; siete (7) imágenes de 1500×600 píxeles y cuatro (4) imágenes con resolución de 800×800 píxeles.

En el municipio de Saldaña la actividad agropecuaria es la base de la economía, siendo la principal actividad la agricultura. Las tierras planas e irrigadas se usan para la siembra del cultivo más importante de la zona; el arroz. En el municipio existe el Distrito de riego del río Saldaña, el cual se bifurca en dos canales que se dirigen a los municipios de Saldaña y Purificación [69]. En la Figura 3-9 (a) se presenta una imagen SAR del Distrito de Riego del río Saldaña. En dicha Figura aparece una zona dedicada totalmente al cultivo del arroz. La región escogida se encuentra encerrada entre los dos canales del río Saldaña y en ella aparecen plantíos de arroz en diferentes etapas de desarrollo. La imagen presenta un alto contenido de ruido multiplicativo y zonas diferenciadas por un marcado color. La imagen de la Figura 3-9 (a) tiene una resolución de 1670×1390 píxeles.

El único índice que utilizamos para monitorear el desempeño de los filtros en las imágenes de radar fue la relación señal a ruido, SNR, debido a que las fronteras en una imagen real no son bien definidas y que además no contamos con una imagen sin ruido para medir el error cuadrático medio. Tomamos una región que consideramos homogénea, para comparar los resultados. La zona escogida se encuentra en el estado 3 de desarrollo de los cultivos de arroz; es decir, son cultivos con aproximadamente 25 días de sembrados, según estados fenomenológicos de desarrollo definidos por la ingeniera Posada¹ [1]. En la Figura 3-10 (a) se presenta la región seleccionada para evaluar el desempeño de los filtros, la cual presenta alto contenido de ruido multiplicativo, dicha imagen tiene una resolución de 57×57 píxeles. La misma región se presenta filtrada en las Figuras 3-10 (b), (c), (d), (e) y (f); en éstas se observa un buen desempeño del filtro de Lee, mediana y MediaModaN, los cuales logran homogeneizar la zona de prueba. Los resultados muestran que al utilizar nuestra propuesta

¹Elena Posada. Ingeniera Forestal. Instituto Geográfico Agustín Codazzi, IGAC. Centro de Investigación y Desarrollo en Información Geográfica, CIAF. Coordinadora del grupo de Percepción Remota y Aplicaciones Geográficas.

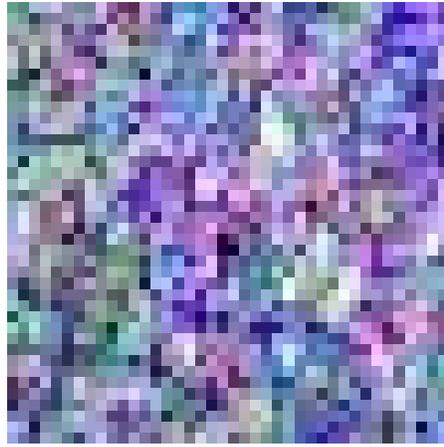
Tabla 3-5: SNR. Imagen de Radar. Clase 3.

Filtro	SNR		
	Canal 1	Canal 2	Canal 3
Original	3.99	2.73	2.79
Lee	13.52	13.90	11.29
Mediana	12.66	12.87	10.66
Frost	13.50	13.86	11.27
MediaModaN	7.98	9.02	8.73
Moda	4.31	3.66	3.99
Gamma	5.68	4.12	4.73
Geométrico	4.18	3.12	3.83

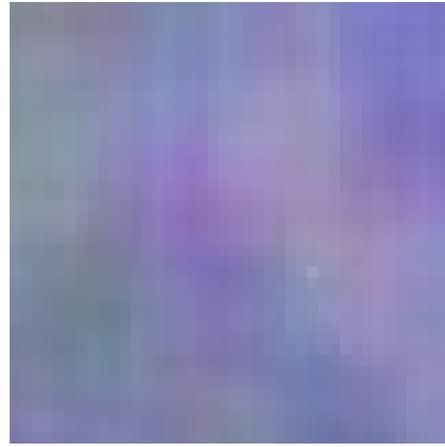
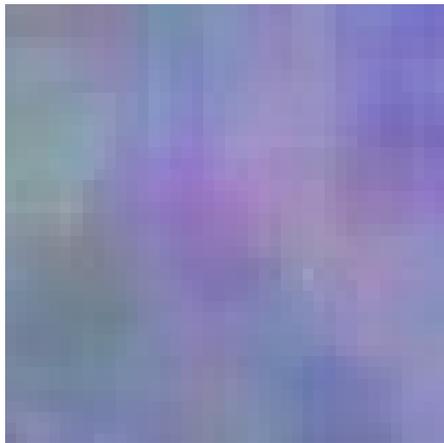
de ventana adaptativa, los mejores desempeños los tiene los filtros de Lee, Frost, Mediana y MediaModaN (ver Tabla 3-5).

En las Figuras 3-9 (b), (c), (d), (e) y (f) se muestran la image SAR filtrada con los filtros de Lee, Mediana, Moda, Frost y MediaModaN respectivamente. Se puede observar en las mismas una fuerte disminución del ruido multiplicativo presentando zonas mucho más homogéneas. De igual manera realizamos un estudio comparativo de los histogramas de la región de estudio los cuales se presentan en las Figuras 3-11 y 7-10. En la Figura 3-11 (a), (b) y (c) se presenta el histograma por canal para la región de estudio. Se observa que los valores están bastante dispersos y que tienen una distribución lejana de una gaussiana. En la Figura 3-11 (d), (e) y (f) se presenta el histograma de la región de estudio luego de ser filtrada utilizando el filtro de Lee. Se observa que los valores están más concentrados al rededor de un valor central, es decir que el filtro logra eliminar esos valores extremos y suaviza la región. En la Figura 3-11 (g), (h) y (i) se presentan los resultados del filtrado utilizando el filtro de mediana. Se observa también una eliminación fuerte de valores extremos y un agrupamiento del histograma con una distribución mucho más parecida a la distribución gaussiana.

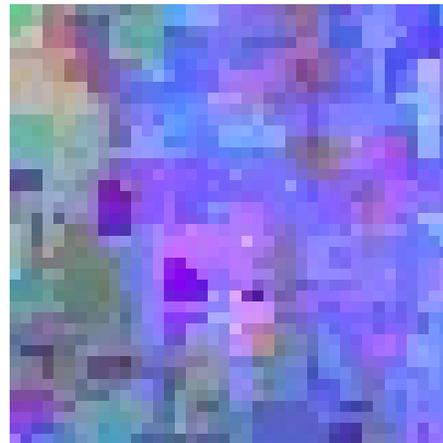
En el siguiente capítulo se presentan los clasificadores utilizados para la segmentación y clasificación de las imágenes SAR y la evaluación de los mismos.



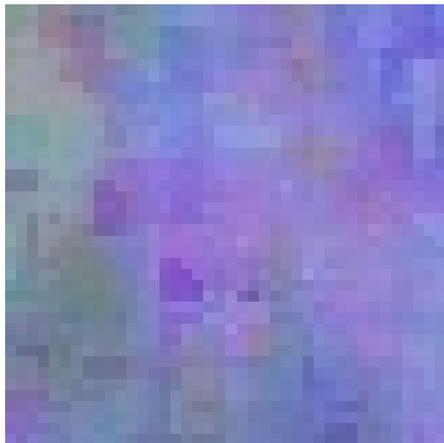
(a) Imagen original.

(b) Filtro Lee $\sigma_n = 6$.

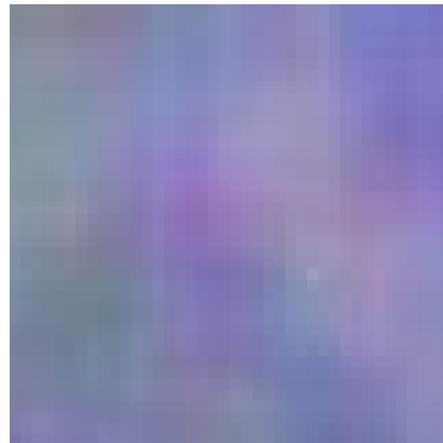
(c) Filtro Mediana.



(d) Filtro Moda.



(e) Filtro MediaModaN.a.



(f) Filtro Frost.

Figura 3-10: Imagen filtrada de radar. Clase 3.

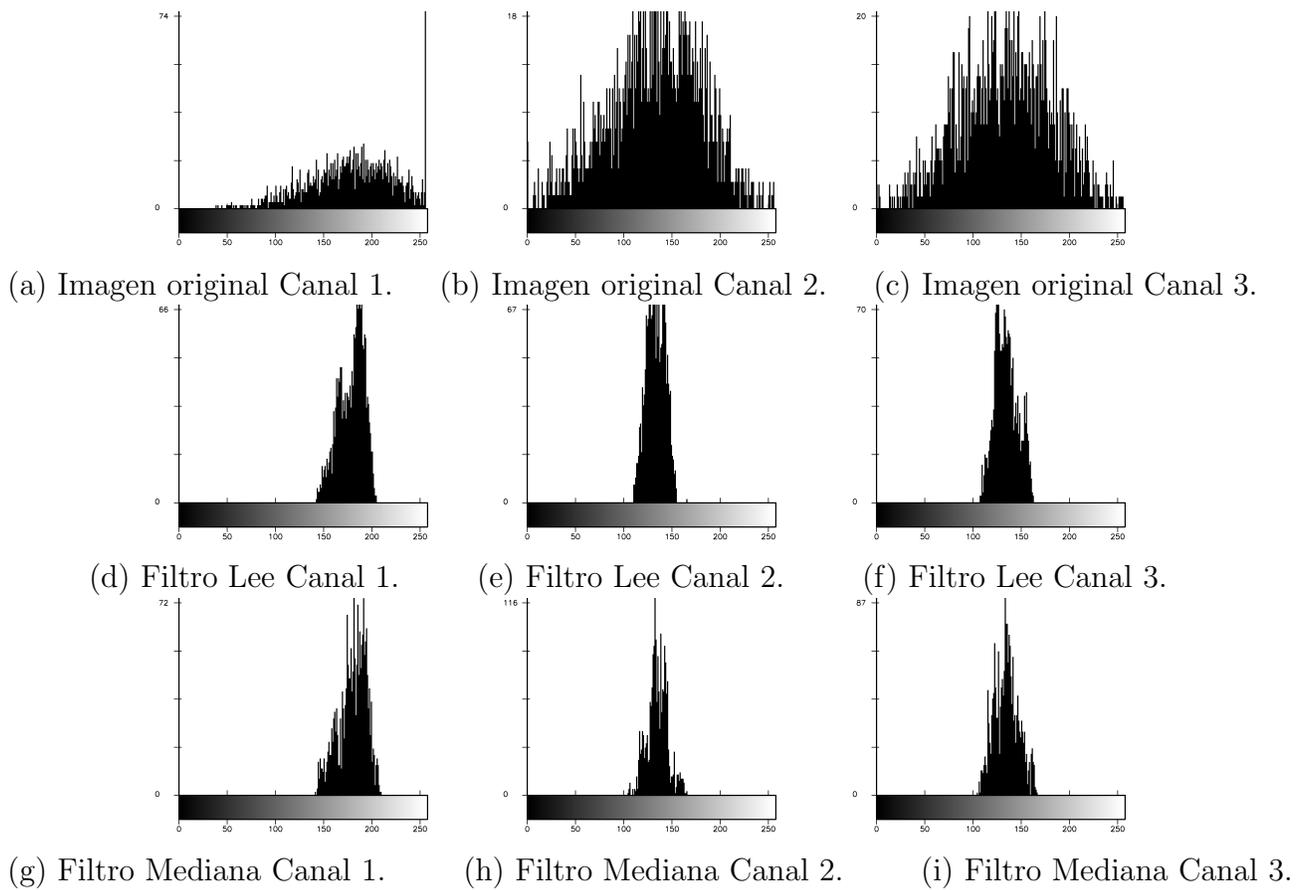


Figura 3-11: Histogramas. Clase 3. Parte I.

4 Segmentación, clasificación y evaluación de resultados

4.1. Introducción

En el presente capítulo presentamos las técnicas utilizadas para realizar la segmentación y clasificación de las imágenes SAR estudiadas. Mostramos los resultados y evaluamos los mismos utilizando tres coeficientes estadísticos: la sensibilidad, la especificidad y la exactitud. En el proceso de segmentación y clasificación de los estados de desarrollo del cultivo de arroz, se utilizaron cinco clases con base en un estudio en el que se generó una librería de patrones pictórico-morfológicos de diferentes estados de desarrollo y actividad del arroz, a partir de las imágenes de radar del satélite RADARSAT-2 [1]. Se incluye adicionalmente una sexta clase relacionada con pastizales. Las clases definidas y el código de colores utilizado se especifican en la Figura 4-1 y en la Tabla 4-1 respectivamente. Para la definición de las clases el experto realizó una visita a la zona cultivada en el municipio de Saldaña y georeferenció los diferentes estados de desarrollo del arroz. Con la información de campo, el experto determinó, en la imagen SAR, las clases asociándolas a diferentes matices de colores.

Todas las imágenes empleadas se filtraron con los tres filtros que dieron mejor desempeño (el filtro Lee, Mediana y MediaModaNá) según resultados de Capítulo 2 (Sección 3), y en todos ellos se utilizó la técnica propuesta de ventana adaptativa.

4.2. Vector de características.

Dado que fue posible diferenciar visualmente las unidades a clasificar, las características que se utilizaron, para conformar el vector de entrada a los clasificadores, se basaron en criterios de color. En la Figura 4-1 se muestran encerradas entre cuadrados cinco zonas asociadas con las clases definidas por un experto en este tipo de imágenes. Adicionalmente, se presenta una sexta clase propuesta en esta investigación relacionada con pastizales. El área resaltada en la Figura 4-1 referenciada como: *Clase 1* (terreno en soca) presenta un color azul claro; *Clase 2* (terreno preparado antes de la siembra) se presenta oscura debido al alto contenido de agua; *Clase 3* (cultivos con 25 días de sembrado) se manifiesta con un color azul oscuro; *Clase 4* (cultivos con 50 días de sembrados) se observa con un color rojo claro; *Clase 5* (cultivos con 75 días de sembrados) presenta un color verde-rojo y la *Clase 6* (pastizales) se manifiesta

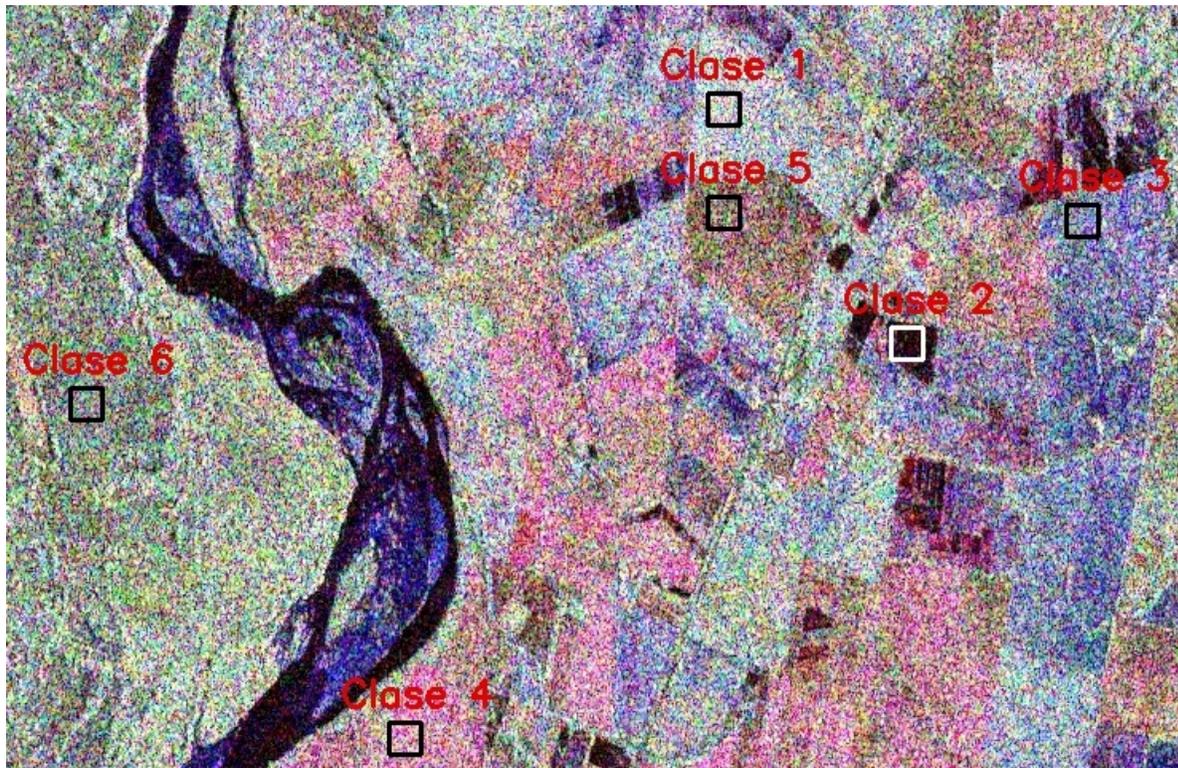


Figura 4-1: Estados de desarrollo del arroz. Clases.

Tabla 4-1: Estados de desarrollo del cultivo de arroz y código de colores.

Clase	Estado de desarrollo	Color
C_1	Terreno en soca (brote de la cosecha).	
C_2	Terreno preparado antes de la siembra.	
C_3	Cultivo con 25 días de sembrado.	
C_4	Cultivo con 50 días de sembrado.	
C_5	Cultivo con más de 75 días de sembrado.	
C_6	Pastizales.	

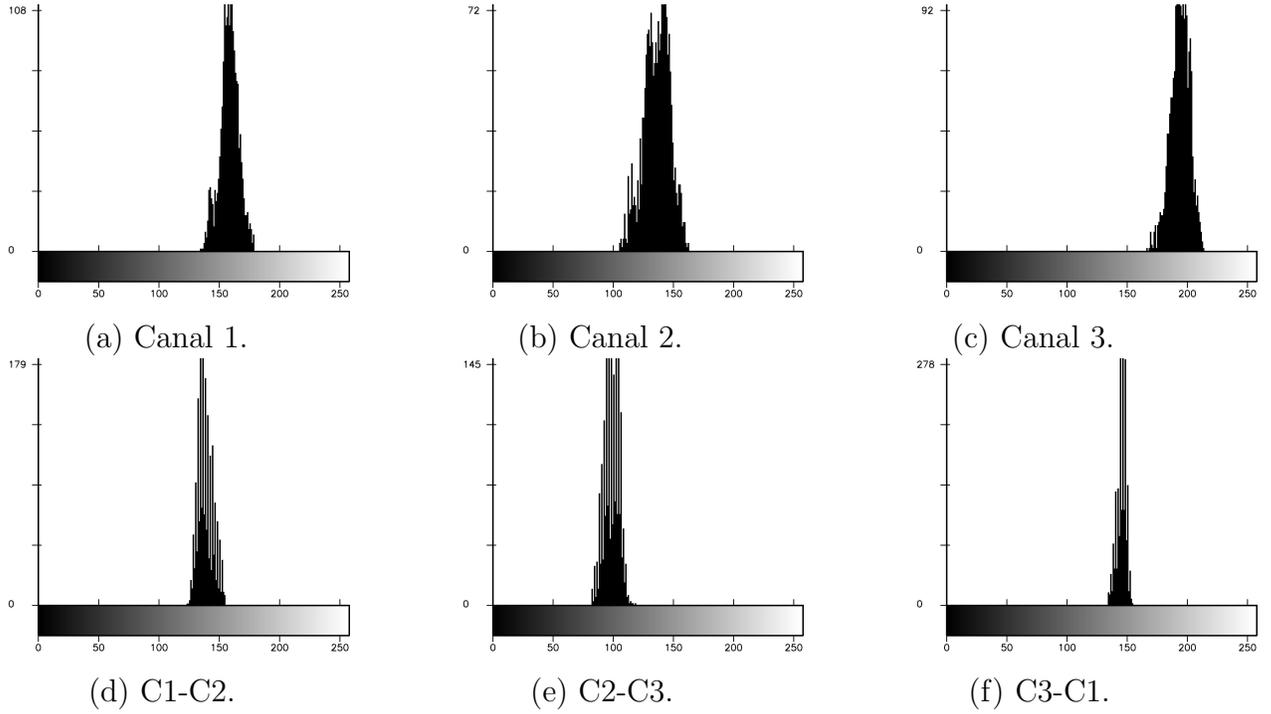


Figura 4-2: Histogramas. Diferencia de canales.

con un color verde claro.

Para la segmentación en color se han utilizado varias transformaciones que buscan separar las zonas homogéneas en las imágenes [76]. En nuestra investigación utilizamos las transformaciones propuestas por Ohta et al. [77] y Báez et al. [78]. Ohta propone los siguientes atributos $I_1 = \frac{(R+G+B)}{3}$, $I_2 = \frac{(R-B)}{2}$ y $I_3 = \frac{(2G-R-B)}{2}$, los cuales son componentes importantes (según el autor) para representar la información de color. A su vez, Báez utiliza las transformaciones $C_1 = \frac{(R-G)}{2}$, $C_2 = \frac{(G-B)}{2}$ y $C_3 = \frac{(B-R)}{2}$, y manifiesta que al hacer las diferencias por pares de canales $R - G$, $G - B$ y $B - R$, en los histogramas resultantes se hace una distinción clara entre las diferentes zonas homogéneas de color. En nuestro análisis encontramos que al hacer las diferencias por pares de canales los histogramas se estrechan haciendo más selectivas las características. En las Figuras 4-2 (a), (b) y (c) se aprecia el histograma para el canal 1, canal 2 y el canal 3 respectivamente de una región perteneciente a la clase 4, y en las Figuras 4-2 (d), (e) y (f) se encuentra el histograma para las diferencias de canales, los cuales se destacan por ser más angostos, siendo a su vez más selectivo.

Las características empleadas para la segmentación buscan captar los atributos de color de las imágenes, por esta razón la característica uno (x_1), corresponde al valor de intensidad del canal uno; la característica dos (x_2) es la intensidad del canal dos; la característica tres (x_3) es la intensidad del canal tres; la característica cuatro (x_4) es la diferencia de la intensidad del canal uno y dos; la característica cinco (x_5) es la diferencia de la intensidad del canal

Tabla 4-2: Características. Vector de entrada.

Nombre	Característica
x_1	Valor del píxel del canal 1 (c_1)
x_2	Valor del píxel del canal 2 (c_2)
x_3	Valor del píxel del canal 3 (c_3)
x_4	$\left\lceil \frac{(c_1 - c_2)}{2} + 127 \right\rceil$
x_5	$\left\lceil \frac{(c_2 - c_3)}{2} + 127 \right\rceil$
x_6	$\left\lceil \frac{(c_3 - c_1)}{2} + 127 \right\rceil$
x_7	$\left\lceil \frac{(c_1 + c_2 + c_3)}{3} \right\rceil$

dos y tres; la característica seis (x_6) es la diferencia de la intensidad del canal tres y uno; y la característica siete (x_7) es la intensidad promedio (ver Tabla 4-2). A la diferencia de los canales en las características (x_4 , x_5 y x_6), se les agrega 127 para tener siempre datos positivos. El rango de valores para todas las siete características empleadas oscila desde 0 y 255, es decir $0 \leq x_i \leq 255$.

Adicionalmente se hizo un estudio de la capacidad discriminante, es decir de la capacidad de separar lo más nitidamente posible las clases existentes. Para ello se utilizó la relación de Fisher [79, 80] definida como muestra la Ecuación 4-1.

$$R_F = \frac{(\bar{x}_1 - \bar{x}_2)^2}{\sigma_1^2 + \sigma_2^2} \quad (4-1)$$

La relación de Fisher cuantifica simultáneamente la separación interclases y la fiabilidad interna de las clases. Entendiendo la fiabilidad como el hecho de que los objetos de una misma clase deberán presentar la menor dispersión posible, menor varianza. Una característica será tanto más discriminante cuanto mayor sea su relación de Fisher. Es decir, interesa que la distancia de las medias de dos clases sea elevada y, al mismo tiempo, que la varianza de ambas clases sea lo menor posible.

En las Tablas 12-8, 12-9, 12-10, 12-11 y 12-12, se presenta la relación de Fisher de cada una de las clases medida para cada característica. En la Tabla 12-8 se aprecia que la característica que mejor diferencia a la clase 1 de la clase 2, es x_2 , teniendo también buen desempeño x_7 , x_3 y x_1 . Entre la clase 1 y la clase 3 la característica que tiene mejor desempeño es x_3 , seguida de x_7 y x_2 . Entre la clase 1 y la clase 4 la característica que posee la mayor discriminabilidad es x_5 , teniendo también buen desempeño x_6 y x_2 . De igual manera, la característica que mejor se comporta para diferenciar la clase 1 y la clase 5 es x_7 , seguida de x_3 y x_1 . Y finalmente, para diferenciar la clase 1 de la clase 6, la característica que tiene mejor desempeño es x_3 , también teniendo buen comportamiento x_7 y x_1 .

En la Tabla **12-13** se presenta la relación de Fisher entre clases. En dicha tabla se observa que la distancia entre las clases es significativa siendo las características utilizadas discriminantes. Sólo existe una distancia pequeña entre la clase 3 y la 6.

La segmentación y clasificación se realizaron simultáneamente píxel a píxel en la imagen aplicando tres clasificadores los cuales se describen en la siguiente sección.

4.3. Clasificador Bayesiano

El clasificador Bayesiano es un clasificador probabilístico basado en el teorema de Bayes que asume independencia entre las variables predictoras. El clasificador Bayes normal es un clasificador simple que asume que el vector características tiene una distribución normal, es decir asume que la función de distribución es Gaussiana. Utilizando los datos del entrenamiento el algoritmo estima las medias y la matriz de covarianza por clase, y utiliza éstos valores para las predicciones.

4.3.1. Teorema de Bayes

El teorema de Bayes expresa la probabilidad condicional de un evento aleatorio A dado B en términos de la distribución de probabilidad condicional del evento B dado A y la distribución de probabilidad condicional marginal de sólo A. Formalmente podemos expresar el teorema diciendo que $\{A_1, A_2, \dots, A_i, \dots, A_n\}$ son un conjunto de sucesos excluyentes y exhaustivos y tales que la probabilidad de cada uno de ellos es distinta de cero. Sea B un suceso cualquiera del que se conocen las probabilidades condicionales $P(B | A_i)$. Entonces la probabilidad $P(A_i | B)$ viene dada por la Ecuación 4-2.

$$P(A_i | B) = \frac{P(B | A_i)P(A_i)}{P(B)} \quad (4-2)$$

Donde:

- $P(A_i)$ son las probabilidades a priori.
- $P(B | A_i)$ es la probabilidad de B en el caso que se de A_i .
- $P(A_i | B)$ son las probabilidades a posteriori.

4.4. Clasificador Fuzzy c-means.

El algoritmo de agrupamiento borroso Fuzzy c-means es frecuentemente utilizado en el reconocimiento de patrones [73, 74]. Éste método permite que un mismo conjunto de datos pertenezca a más de una clase y esta basado en la minimización de una función de costo (ver

Ecuación 4-4). A continuación presentamos el modelo básico del algoritmo.

Sea $\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)$ un conjunto de n vectores de características en el espacio R^p . Donde p representa el número de características de cada vector. Dado \mathbf{X} , decimos que existe c subconjuntos borrosos o grupos (clusters) donde $\{\mu_{ik} = \mu_i(\mathbf{x}_k), 1 \leq k \leq n, 1 \leq i \leq c\}$ satisfacen las tres condiciones siguientes:

$$0 \leq \mu_{ik} \leq 1, \quad 1 \leq i \leq c, \quad 1 \leq k \leq n. \quad (4-3a)$$

$$\sum_{i=1}^c \mu_{ik} = 1, \quad 1 \leq k \leq n. \quad (4-3b)$$

$$0 < \sum_{k=1}^n \mu_{ik} < n \quad 1 \leq i \leq c. \quad (4-3c)$$

Donde μ_{ik} es la función de pertenencia del vector \mathbf{x}_k al grupo i . El algoritmo Fuzzy c -means (FCM) es un algoritmo de optimización iterativo que minimiza la siguiente función costo:

$$J = \sum_{k=1}^n \sum_{i=1}^c \mu_{ik}^m \|\mathbf{x}_k - \mathbf{v}_i\|^2 \quad (4-4)$$

Donde n es el número de datos, c es número de grupos o clases, donde \mathbf{x}_k es el k -ésimo vector de la muestra, \mathbf{v}_i es el vector que ubica el centro del i -ésimo grupo y m es una constante mayor que uno. Las funciones de pertenencia a un determinado grupo se hallan con la Ecuación 4-5.

$$\mu_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{\|\mathbf{x}_k - \mathbf{v}_i\|}{\|\mathbf{x}_k - \mathbf{v}_j\|} \right)^{\frac{2}{m-1}}} \quad (4-5)$$

La minimización de la función costo (Ecuación 4-4) es un problema de optimización no lineal que se puede solucionar utilizando varios métodos entre los que podemos mencionar: minimización iterativa, “recocido simulado” y algoritmos genéticos. Pero el método más habitual es el algoritmo FCM. La suficiencia de las Ecuaciones 4-5 y 4-8 para minimizar la función costo y la convergencia del algoritmo FCM fue demostrado por Bezdek [75]. El proceso de resolución de la función costo es iterativo y puede caer en mínimos locales, dado que dicha función mide distancias y valores de pertenencia.

El algoritmo se inicia considerando un número de grupos c y escogiendo aleatoriamente los centros \mathbf{v}_i con $i = 1, 2, \dots, c$. El método converge a una solución para los vectores \mathbf{v}_i que representan un mínimo local o un punto de silla de la función costo. Los siguientes pasos implementan el algoritmo:

Paso 1 Se inicializan las constantes c , m y ϵ tales que cumplen las condiciones:

$$1 \leq c \leq n. \quad (4-6a)$$

$$0 \leq m \leq \infty. \quad (4-6b)$$

$$0 < \epsilon < 1. \quad (4-6c)$$

Paso 2 Se calculan o proponen aleatoriamente los centroides iniciales.

$$\mathbf{V}_0 = (\mathbf{v}_{1,0}, \mathbf{v}_{2,0}, \dots, \mathbf{v}_{c,0}) \in R^p \quad (4-7)$$

Paso 3 Se actualizan los valores de las funciones de pertenencia μ_{ik} utilizando la ecuación 4-5.

Paso 4 Se actualizan los centros de los grupos utilizando la siguiente ecuación:

$$\mathbf{v}_i = \frac{\sum_{k=1}^n (\mu_{ik})^m \mathbf{x}_k}{\sum_{k=1}^n (\mu_{ik})^m} \quad (4-8)$$

La ecuación 4-8 da los centroides como la media ponderada del conjunto de datos que pertenecen a un grupo, donde los pesos son el grado de pertenencia. Debido a esto el algoritmo se llama c-means.

Paso 5 Se chequean las condiciones de terminación del algoritmo. Se determina E_t tal que

$$E_t = \sum_{i=1}^c \|\mathbf{v}_{i,t} - \mathbf{v}_{i,t-1}\|^2 \quad (4-9)$$

Si $E_t \leq \epsilon$ se detiene la rutina, de lo contrario se repite los pasos del 3 al 5. De igual manera se puede detener el algoritmo si t alcanza el número máximo de iteraciones.

Para nuestro caso, el vector características esta en el espacio R^7 . De igual manera utilizamos el clasificador Fuzzy c-means como un clasificador supervisado, es decir partimos de conocer el número de clases. En nuestro algoritmo el valor de c es de cinco ($c = 5$). Se tomó también $m = 2$, $\epsilon = 0,0001$ y el número máximo de iteraciones de 2000. El algoritmo FCM se lanzo cincuenta (50) veces con un número de iteraciones promedio de 85 para la convergencia. Los centroides iniciales los obtenemos de hallar la media de cada característica en cada clase, es decir que para los centros iniciales de cada clase tomamos la media de los valores de entrenamiento.

4.5. Redes Neuronales Artificiales. El Perceptrón Multicapa.

En el proceso de segmentación y clasificación de las imágenes SAR filtradas, se implemento una red neuronal artificial (RNA) con la siguiente arquitectura: siete (7) nodos en la capa de entrada (L_1), ocho (8) neuronas en la capa oculta (L_2) y cinco (5) neuronas en la capa de salida, L_3 (ver Figura 4-4). Todas las neuronas tienen como función de transferencia la función sigmoidea simétrica (ver Ecuación 4-10).

$$f(x) = \frac{\beta(1 - e^{-\alpha x})}{(1 + e^{-\alpha x})} \quad (4-10)$$

Sea x_i la variable de entrada, donde $1 \leq i \leq 7$, es decir el vector de entrada es de dimensión siete (7). Entonces tenemos para la capa 2: $v_j = \sum_{i=1}^7 (w_{ji}x_i + b_j)$ con la función de activación $\varphi_j = \frac{\beta(1 - e^{-\alpha v_j})}{(1 + e^{-\alpha v_j})}$, donde $1 \leq j \leq 8$. Para la capa 3, es decir la la capa de salida: $u_k = \sum_{j=1}^8 (W_{kj}\varphi_j + B_k)$ con la función de activación $y_k = \frac{\beta(1 - e^{-\alpha u_k})}{(1 + e^{-\alpha u_k})}$, donde $1 \leq k \leq 5$. El error de cada salida es $e_k = d_k - y_k$, donde d_k es la respuesta deseada de la neurona k , y el error cuadrático medio es $\varepsilon = \frac{1}{2} \sum_{k=1}^5 e_k^2$. En nuestro caso tomamos $\alpha = 1$, y $\beta = 1$ en todas las capas y se tomó como criterios de parada del algoritmo cien iteraciones (100) o un error de $\epsilon = 0,0001$. La red se entrenó utilizando el algoritmo de propagación hacia atrás (backpropagation). En éste se compara la la salida real con la salida deseada. La diferencia entre ambas constituye un error que se propaga hacia atrás desde la capa de salida hasta la entrada permitiendo la adaptación de los pesos de las neuronas intermedias mediante el método del gradiente descendiente.

Los incrementos en los pesos para la capa tres son: $\Delta W_{kj} = -\eta_1 \frac{\partial \varepsilon}{\partial W_{kj}}$

Tenemos entonces para la capa de salida:

$$\frac{\partial \varepsilon}{\partial W_{kj}} = \frac{\partial \varepsilon}{\partial e_k} \frac{\partial e_k}{\partial y_k} \frac{\partial y_k}{\partial u_k} \frac{\partial u_k}{\partial W_{kj}}, \quad 1 \leq k \leq 5 \text{ y } 1 \leq j \leq 8 \quad (4-11)$$

Además conociendo que:

$$\frac{\partial \varepsilon}{\partial e_k} = e_k = d_k - y_k \quad (4-12)$$

$$\frac{\partial e_k}{\partial y_k} = -1 \quad (4-13)$$

$$\frac{\partial y_k}{\partial u_k} = \frac{[1 - y_k^2]}{2} \quad (4-14)$$

$$\frac{\partial u_k}{\partial W_{kj}} = \varphi_j \quad (4-15)$$

Obtenemos para ΔW_{kj}

$$\Delta W_{kj} = \eta_1 [d_k - y_k] \frac{[1 - y_k^2]}{2} \varphi_j \quad (4-16)$$

Para la capa dos obtenemos:

$$\frac{\partial \varepsilon}{\partial w_{ji}} = \sum_{k=1}^5 \frac{\partial \varepsilon}{\partial e_k} \frac{\partial e_k}{\partial y_k} \frac{\partial y_k}{\partial u_k} \frac{\partial u_k}{\partial w_{ji}}, \quad 1 \leq j \leq 8 \text{ y } 1 \leq i \leq 7. \quad (4-17)$$

además sabemos que:

$$\frac{\partial u_k}{\partial w_{ji}} = \sum_{l=1}^8 \frac{\partial u_k}{\partial \varphi_l} \frac{\partial \varphi_l}{\partial w_{ij}} \quad (4-18)$$

y conociendo que:

$$\frac{\partial \varphi_l}{\partial w_{ji}} = \frac{\partial \varphi_l}{\partial v_l} \frac{\partial v_l}{\partial w_{ji}} \quad (4-19)$$

Combinando la ecuación 4-18 y 4-19 obtenemos:

$$\frac{\partial u_k}{\partial w_{ji}} = \sum_{l=1}^8 \frac{\partial u_k}{\partial \varphi_l} \frac{\partial \varphi_l}{\partial v_l} \frac{\partial v_l}{\partial w_{ji}} \quad (4-20)$$

Ahora, con la ecuación 4-17 y 4-20 obtenemos finalmente:

$$\frac{\partial \varepsilon}{\partial w_{ji}} = \sum_{k=1}^5 \frac{\partial \varepsilon}{\partial e_k} \frac{\partial e_k}{\partial y_k} \frac{\partial y_k}{\partial u_k} \sum_{l=1}^8 \frac{\partial u_k}{\partial \varphi_l} \frac{\partial \varphi_l}{\partial v_l} \frac{\partial v_l}{\partial w_{ji}} \quad (4-21)$$

que es lo mismo que escribir:

$$\frac{\partial \varepsilon}{\partial w_{ji}} = \sum_{k=1}^5 \sum_{l=1}^8 \frac{\partial \varepsilon}{\partial e_k} \frac{\partial e_k}{\partial y_k} \frac{\partial y_k}{\partial u_k} \frac{\partial u_k}{\partial \varphi_l} \frac{\partial \varphi_l}{\partial v_l} \frac{\partial v_l}{\partial w_{ji}} \quad (4-22)$$

Utilizando las identidades conocidas en los pasos anteriores podemos escribir la ecuación 4-22 de la siguiente manera:

$$\frac{\partial \varepsilon}{\partial w_{ji}} = \sum_{k=1}^5 \sum_{l=1}^8 [d_k - y_k] [-1] \frac{[1 - y_i^2]}{2} W_{li} \frac{[1 - \varphi_i^2]}{2} x_j \quad (4-23)$$

y finalmente obtenemos para los incrementos en la capa dos:

$$\Delta w_{ji} = \eta_2 \sum_{k=1}^5 \sum_{l=1}^8 [d_k - y_k] \frac{[1 - y_i^2]}{2} W_{li} \frac{[1 - \varphi_i^2]}{2} x_j \quad (4-24)$$

Para nuestro caso tomamos el valor de $\eta_1 = \eta_2 = 0,1$. Adicionalmente realizamos un estudio del rendimiento de la red neuronal. Se investigó el efecto que tenía el número de neuronas de la capa oculta sobre la razón de verdaderos positivos (RVP). Encontramos que la variación del rendimiento de la red es pequeño al aumentar el número de neuronas en la capa oculta (ver Figura 4-3). Por lo tanto se optó trabajar con ocho (8) neuronas en la capa oculta.

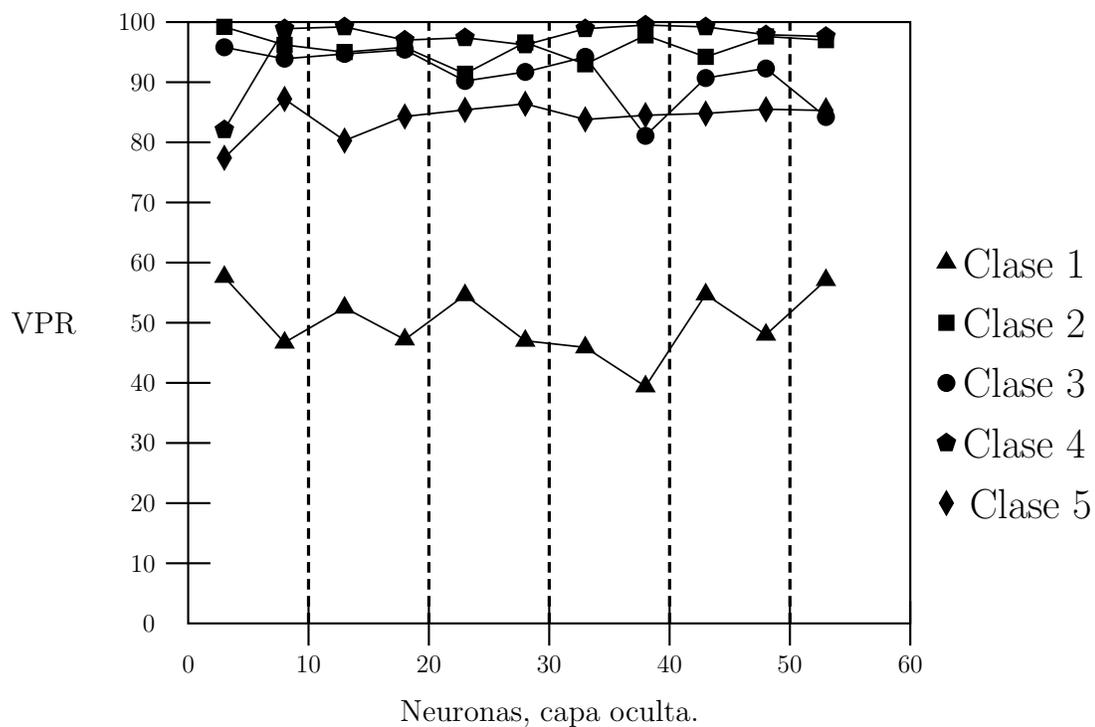


Figura 4-3: Neuronas vs VPR. Perceptrón.

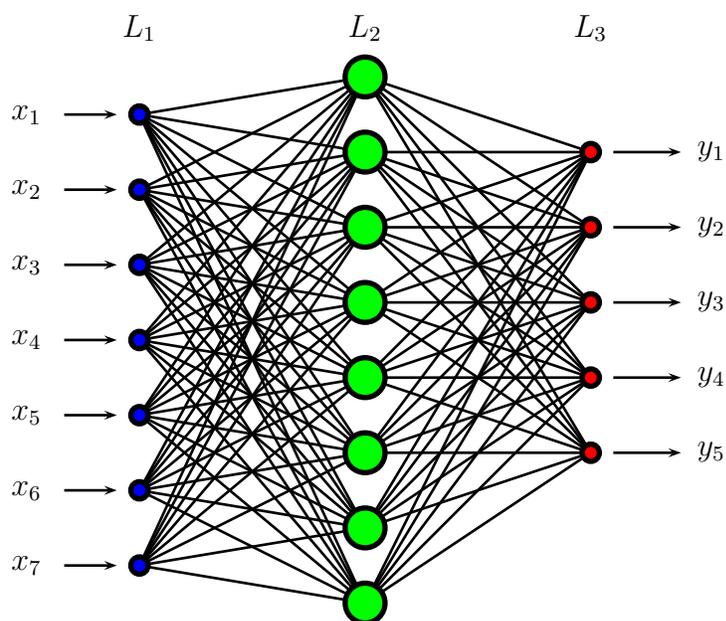


Figura 4-4: Perceptron multicapa.

4.6. Evaluación de resultados.

En un primer paso en la evaluación de los clasificadores, construimos 8 imágenes sintéticas con píxeles tomados de la imagen real. Se seleccionaron regiones homogéneas de la imagen SAR y se construyó con éstas, las imágenes artificiales utilizando cinco mil píxeles de cada una de las cinco clases (en un primer momento no incluimos la clase 6 de pastizales). Cada clase en las imágenes se representó con una región de 25×25 píxeles (ver Figura 4-5 (a)). Para evaluar el desempeño de los clasificadores utilizamos la matriz de confusión, la cual nos permite observar si el sistema se está equivocando. Utilizando la imagen de plantilla (imagen de referencia, valores reales, Figura 4-5 (b)), se compara píxel a píxel con la imagen clasificada, y en la matriz de confusión se registra a que clase corresponde cada píxel según el clasificador y según la plantilla. Las imágenes se filtraron con el filtro de Lee utilizando nuestra propuesta de ventana adaptativa. En el Anexo 2 se presentan las matrices de confusión de las imágenes. Con los datos de la matriz de confusión se calculan los valores con los que se caracteriza el clasificador, es decir: la Sensibilidad, la Especificidad y la Exactitud (ver anexo 5). En las Tablas 4-3, 4-4 y 4-5 se presentan los valores promedios de los índices por clase y la desviación estándar de los mismos.

Como se observa en las Tablas 4-3, 4-4 y 4-5 el rendimiento de cada clasificador varía de una clase a otra. Para la clase 1, el mayor valor de la sensibilidad lo tiene la red neuronal, con una desviación estándar de 18,7. De igual manera el clasificador Perceptrón Multicapa presenta mejor desempeño, en su relación de verdaderos positivos, en las clases 2, 3 y 4. Para la clase 5 el mejor desempeño lo tuvo el clasificador Fuzzy c-means, llegando a tener un valor de $\sigma_{VPR} = 1,2$, el más bajo de todos los clasificadores. Podemos observar que en promedio el mejor desempeño lo tiene el clasificador Perceptrón Multicapa con un valor para el índice VPR de 86,3%.

En las mismas tablas mencionadas anteriormente, se aprecia que la razón de verdaderos negativos de cada clase para el clasificador Perceptrón Multicapa y el clasificador Fuzzy c-means son bastantes p

$$\sigma_n = \frac{\sigma_g}{\bar{g}} \quad (4-25)$$

En las Figuras 4-7 y 4-8 se presentan imágenes clasificadas sin previo filtrado. Las Figuras 4-7 (a) y 4-8 (a) son las imágenes ruidosas a clasificar. Los resultados de la clasificación utilizando los tres clasificadores se observan en las Figuras 4-7 (b), (c) y (d) y en las Figuras 4-8 (b), (c) y (d). Estos resultados muestran que clasificar las imágenes sin filtrar produce un rendimiento inaceptable.

Evaluación de resultados, imagen sintética, incluyendo la clase 6.

Evaluamos nuevamente el desempeño de los clasificadores incluyendo, en una imagen sintética una sexta clase relacionada con pastizales. Esta nueva imagen se construyó con un total de



(a) Imagen sintética 1.



(b) Plantilla.



(c) Clasificada. Bayes.



(d) Clasificada. Fuzzy c-means.



(e) Clasificada. Perceptrón multicapa.

Figura 4-5: Imagen sintética 1 clasificada.**Tabla 4-3:** Características. Clasificador Perceptrón Multicapa. Cinco clases. Promedios.

	VPR	σ_{VPR}	VNR	σ_{VNR}	ACC	σ_{ACC}
<i>Clase 1</i>	67,8 %	18,7	99,7 %	0,4	93,3 %	3,8
<i>Clase 2</i>	94,7 %	1,9	98,1 %	0,7	97,4 %	0,9
<i>Clase 3</i>	95,8 %	3,9	90,4 %	4,1	91,5 %	3,7
<i>Clase 4</i>	95,2 %	3,7	96,0 %	3,1	95,8 %	2,5
<i>Clase 5</i>	78,2 %	11,6	98,5 %	1,5	94,4 %	2,2
<i>Promedio</i>	86,3 %	8,0	96,5 %	2,0	94,5 %	2,6

VPR \Rightarrow Sensibilidad; VNR \Rightarrow Especificidad; ACC \Rightarrow Exactitud.

Tabla 4-4: Características. Clasificador Bayesiano. Cinco clases. Promedios.

	VPR	σ_{VPR}	VNR	σ_{VNR}	ACC	σ_{ACC}
<i>Clase 1</i>	65,1 %	17,6	96,6 %	3,2	90,4 %	4,5
<i>Clase 2</i>	93,7 %	2,3	88,4 %	4,4	89,5 %	3,3
<i>Clase 3</i>	91,4 %	8,2	87,7 %	7,3	88,4 %	6,9
<i>Clase 4</i>	55,5 %	24,2	97,7 %	1,8	89,2 %	5,2
<i>Clase 5</i>	69,9 %	12,7	98,2 %	1,9	92,6 %	3,7
<i>Promedio</i>	75,1 %	13,0	93,7 %	3,7	90,0 %	4,7

VPR \Rightarrow Sensibilidad; VNR \Rightarrow Especificidad; ACC \Rightarrow Exactitud.

Tabla 4-5: Características. Clasificador Fuzzy c-mean. Cinco clases. Promedios.

	VPR	σ_{VPR}	VNR	σ_{VNR}	ACC	σ_{ACC}
<i>Clase 1</i>	65,7 %	18,3	99,7 %	0,4	92,9 %	3,7
<i>Clase 2</i>	83,4 %	5,8	98,9 %	0,04	95,8 %	1,1
<i>Clase 3</i>	80,0 %	15,3	90,5 %	4,1	88,4 %	6,0
<i>Clase 4</i>	73,5 %	17,5	99,2 %	0,9	94,0 %	3,5
<i>Clase 5</i>	94,9 %	1,2	85,9 %	8,4	87,7 %	6,5
<i>Promedio</i>	79,5 %	11,6	94,8 %	2,7	91,8 %	4,2

VPR \Rightarrow Sensibilidad; VNR \Rightarrow Especificidad; ACC \Rightarrow Exactitud.

30,000 píxeles reales distribuidos en doce regiones de 50×50 píxeles. De cada clase se tomaron 5000 píxeles (ver Figura 4-9 (a)).

En la Figura 4-9 se presentan las imágenes clasificadas utilizando: el clasificador Bayesiano, Figura 4-9 (b); el clasificador Fuzzy c-means, Figura 4-9 (c); y el clasificador Perceptrón Multicapa, Figura 4-9 (d). Las matrices de confusión para el clasificador Fuzzy c-means y para el Perceptrón Multicapa se pueden observar en el anexo 2, ver tablas 8-29 y 8-30, respectivamente. Las características medidas para estos dos clasificadores se encuentran en las Tablas 12-3 y 12-4, para imágenes filtradas con el filtro de Lee.

El clasificador Bayesiano presenta confusión principalmente entre: la clase 1 y la 6; entre la 2 y la 6; entre la clase 3 y la clase 6; entre la clase 4 y la 2; entre la clase 5 y la clase 6; y entre la clase 6 y la 1. El mejor desempeño del clasificador Bayesiano para reconocer los píxeles de una región se encuentran para la clase 2, y el desempeño más bajo se tiene con la clase 4. El mejor desempeño del clasificador Bayesiano para excluir píxeles que no son de una clase, se presenta para la clase 5 (ver Tabla 12-1).

Por otra parte, el clasificador Fuzzy c-mean presenta confusión principalmente entre: la clase 1 y la 3; entre la clase 2 y la clase 5; entre la clase 3 y la 5; entre la clase 4 y la 5; entre la clase 5 y la 6; y entre la clase 6 y la 1. El mejor desempeño del clasificador Fuzzy c-means para reconocer píxeles de una región se encuentran para la clase 5 y el desempeño más bajo, para la clase 1. El mejor desempeño del clasificador para excluir píxeles que no son de una clase se presenta para la clase 2 (ver Tabla 8-29).

De igual manera, el clasificador Perceptrón Multicapa presenta confusión principalmente entre: la clase 1 y la 6; entre la clase 2 y la clase 6; entre la clase 3 y la 2; entre la clase 4 y la 3; entre la clase 5 y la 6; y entre la clase 6 y la 1. El mejor desempeño del clasificador Perceptrón Multicapa para reconocer píxeles de una región se encuentran para la clase 2 y el desempeño más bajo, para la clase 6. El mejor desempeño del clasificador para excluir píxeles que no son de una clase se presenta con la clase 4 (ver Tabla 8-30).

El desempeño de los clasificadores varía dependiendo de la clase examinada. De éste estudio podemos concluir que el algoritmo Fuzzy c-means tiene mejor desempeño en promedio, esto utilizando como criterio el valor de la Sensibilidad (o Relación de Verdaderos Positivos VPR), la Especificidad (o Relación de Verdaderos Negativos VNR) y la Exactitud (ver Tablas 12-2, 12-3 y 12-4). Esta última, para el clasificador Fuzzy c-mean presenta en promedio (con todas las clases), valores mayores al 94 %.

Clasificador mixto

Buscando mejorar los resultados realizamos una nueva clasificación por votación utilizando los resultados de los tres clasificadores. La clasificación definitiva de pertenencia de cada píxel se hizo considerando el voto de los tres clasificadores, es decir si dos de ellos coincidían se tomaba esa decisión como cierta. Si la clasificación de los tres algoritmos es diferente se

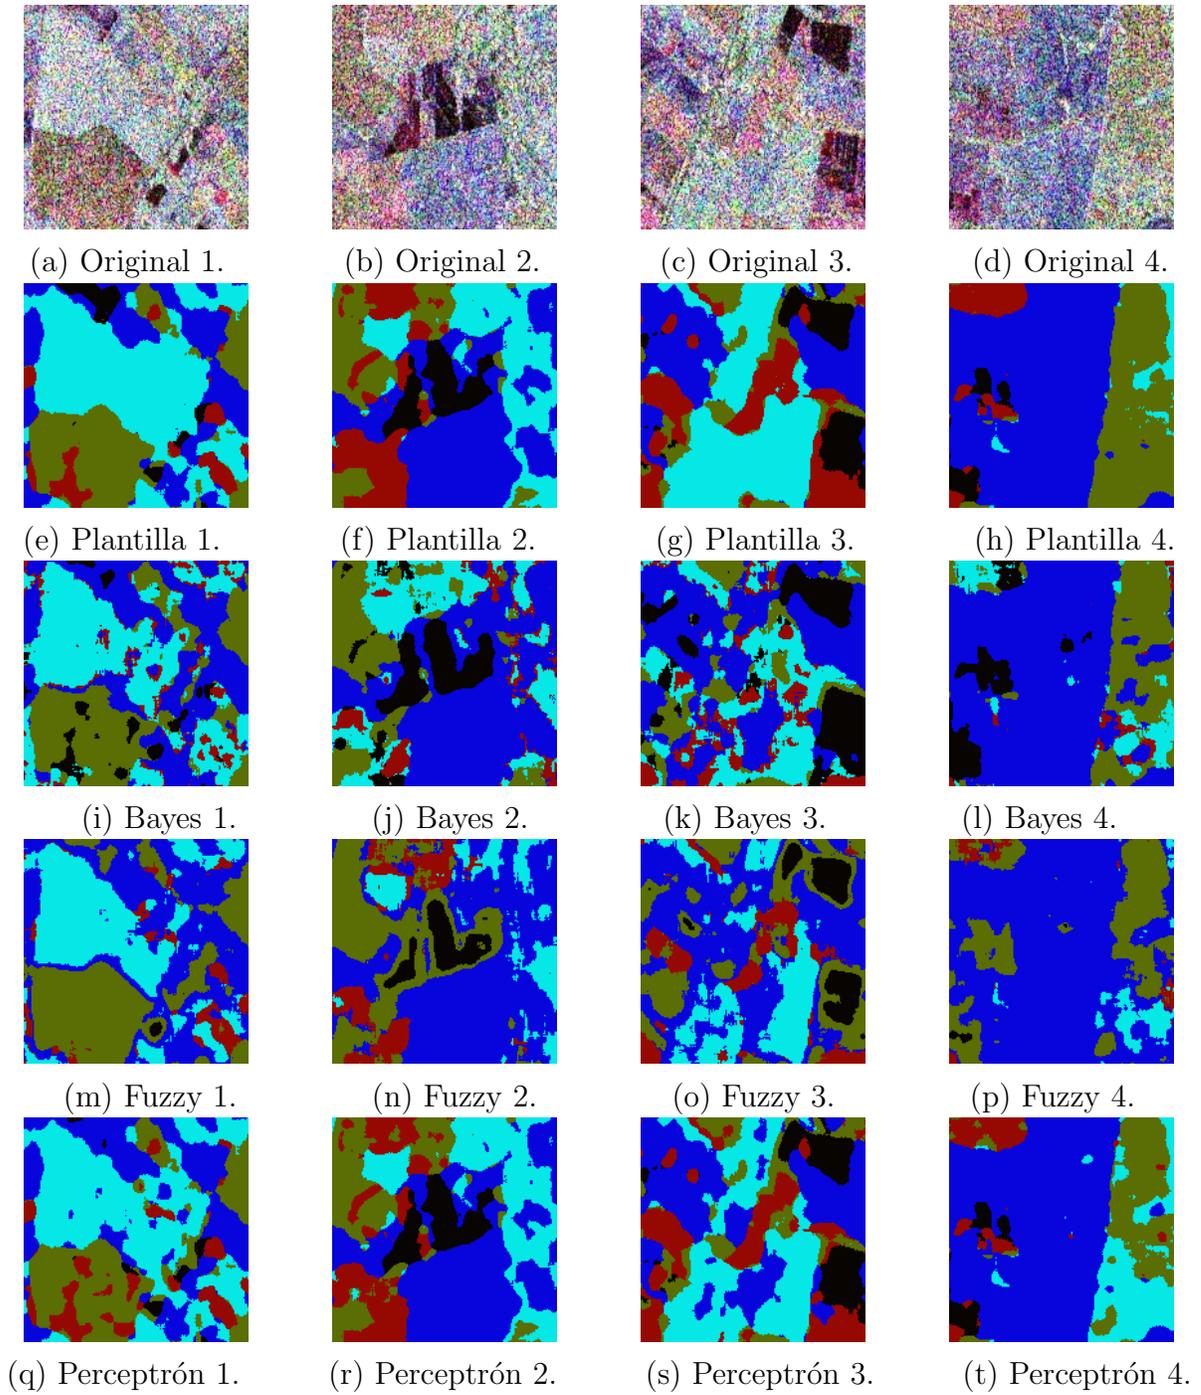


Figura 4-6: Imágenes reales clasificadas. Cinco clases.

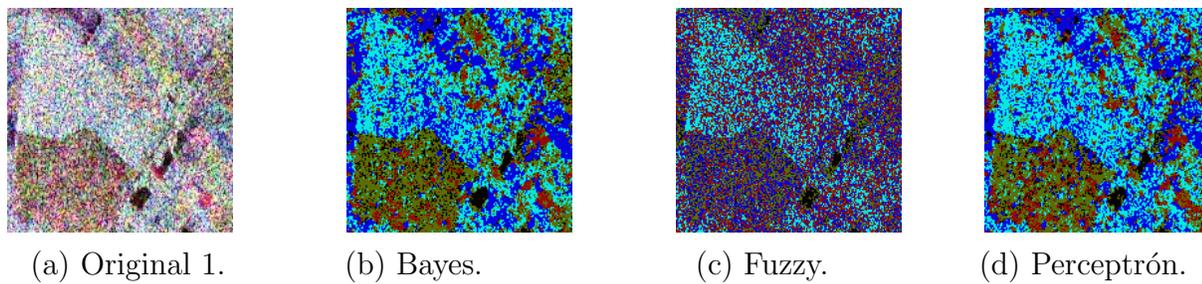


Figura 4-7: Imagen real clasificada sin filtrado. Cinco clases.

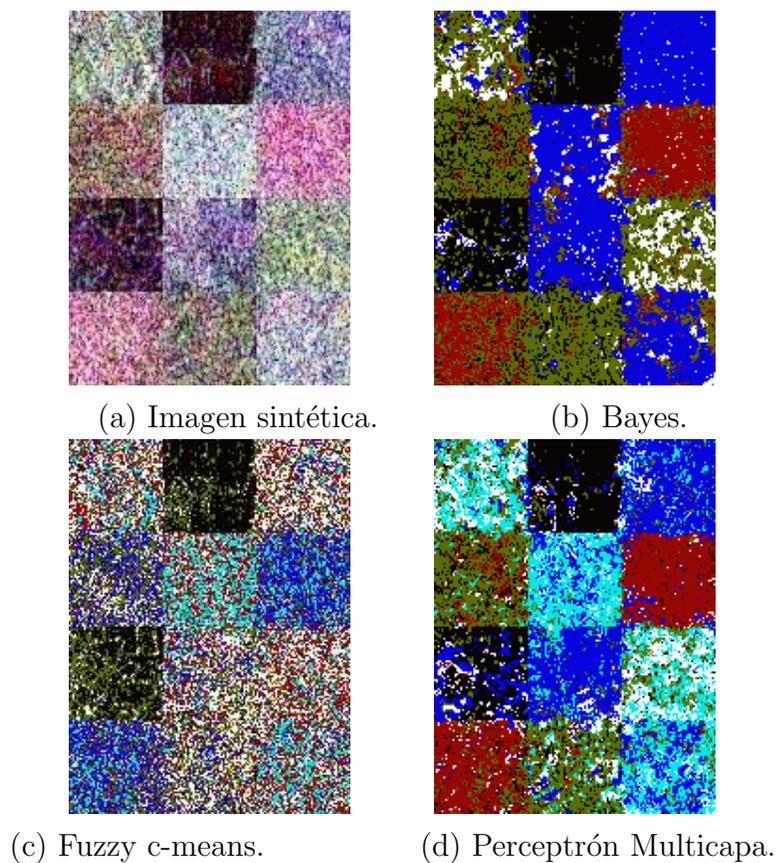


Figura 4-8: Imagen sintética clasificada sin filtrado. Seis clases.

utilizo un criterio de probabilidades con la información de las Tablas **12-2**, **12-3** y **12-4**. En la Tabla **12-5** se consignan los valores de los coeficientes resultantes de la clasificación por Votación, y en la Figura **4-10** (b) se presenta la imagen clasificada por Votación. En la Tabla **8-31** se presenta la matriz de confusión para la clasificación por votación. Se encuentra una mejora de la clasificación con el algoritmo de Votación, en especial para la clase 1 y 6. En promedio la clasificación por Votación tiene mejores resultados.

4.7. Segmentación de imágenes reales de RADARSAT-2.

En una etapa final, después de entrenar y evaluar los clasificadores con imágenes sintéticas, medimos su desempeño con cuatro imágenes reales. En las Figuras **4-6** (a), (b), (c) y (d) se presentan las cuatro imágenes originales a filtrar y clasificar. En éste punto utilizamos los clasificadores entrenados para discernir sobre cinco clases. En las Figuras **4-6** (e), (f), (g) y (h) se presentan las imágenes clasificadas por el experto, las que se utilizan como plantilla en el proceso de evaluación de los clasificadores. Todas las imágenes son filtradas utilizando el filtro de Lee y la propuesta presentada en ésta investigación de ventana adaptativa. En las Figuras **4-6** (i), (j), (k) y (l) se presenta la clasificación realizada por el clasificador Bayesiano. En las Figuras **4-6** (m), (n), (o) y (p) se presenta el resultado del clasificador Fuzzy c-means y en las Figuras **4-6** (q), (r), (s) y (t) encontramos la clasificación con la red neuronal. Las Tablas **4-6**, **4-7** y **4-8** se encuentran los resultados de las medidas de la sensibilidad, especificidad y la exactitud para el clasificador Bayesiano, el Fuzzy c-means y el Perceptrón Multicapa, respectivamente. Como se mencionó anteriormente, se observa que el rendimiento de los clasificadores varía de una clase a otra, al igual que la desviación estándar. El clasificador que tuvo el mejor desempeño con la imagen real fue la red neuronal. Al comparar las imágenes clasificadas con los tres clasificadores, pero teniendo en cuenta la sexta clase relacionada con pastizales (Figura **7-11**), encontramos que los clasificadores presentan mayor confusión. La Figura **7-11** (a) se presenta la zona seleccionada de la imagen real; la Figura **7-11** (b) muestra la imagen filtrada; la Figura **7-11** (c) presenta la imagen clasificada utilizando el clasificador Bayesiano; la Figura **7-11** (d) la imagen clasificada con la red neuronal; la Figura **7-11** (e) la imagen clasificada con el algoritmo Fuzzy c-means y la Figura **7-11** (f) la imagen clasificada con el algoritmo mixto, por Votación.

Tabla 4-6: Imagen real. Clasificador Bayesiano. Cinco clases.

	VPR	σ_{VPR}	VNR	σ_{VNR}	ACC	σ_{ACC}
<i>Clase 1</i>	37,3 %	20,1	89,1 %	2,8	78,6 %	8,0
<i>Clase 2</i>	79,3 %	23,4	94,9 %	1,5	94,3 %	0,9
<i>Clase 3</i>	91,3 %	3,9	82,9 %	3,6	85,5 %	5,6
<i>Clase 4</i>	11,4 %	5,9	94,6 %	2,6	88,7 %	3,2
<i>Clase 5</i>	75,5 %	7,8	94,9 %	1,2	91,5 %	2,6
<i>Promedio</i>	59,0 %	12,2	91,3 %	2,3	87,7 %	4,1

VPR⇒ Sensibilidad; VNR⇒ Especificidad; ACC⇒ Exactitud.

Tabla 4-7: Imagen real. Clasificador Fuzzy c-means. Cinco clases.

	VPR	σ_{VPR}	VNR	σ_{VNR}	ACC	σ_{ACC}
<i>Clase 1</i>	44,1 %	16,5	97,8 %	1,2	86,1 %	4,5
<i>Clase 2</i>	36,3 %	27,3	99,9 %	0,1	96,6 %	0,3
<i>Clase 3</i>	87,4 %	5,0	71,4 %	4,8	78,4 %	4,0
<i>Clase 4</i>	39,9 %	9,6	97,6 %	1,0	91,1 %	3,0
<i>Clase 5</i>	68,2 %	15,1	86,8 %	2,1	82,9 %	4,8
<i>Promedio</i>	55,2 %	14,7	90,7 %	1,8	87,0 %	3,3

VPR⇒ Sensibilidad; VNR⇒ Especificidad; ACC⇒ Exactitud.

Tabla 4-8: Imagen real. Clasificador Perceptrón. Cinco clases.

	VPR	σ_{VPR}	VNR	σ_{VNR}	ACC	σ_{ACC}
<i>Clase 1</i>	91,4 %	9,3	97,0 %	4,9	93,8 %	4,0
<i>Clase 2</i>	84,6 %	26,5	99,9 %	0,1	99,4 %	1,0
<i>Clase 3</i>	99,9 %	0,1	95,3 %	4,7	96,4 %	3,6
<i>Clase 4</i>	92,5 %	4,4	99,1 %	1,1	98,1 %	0,7
<i>Clase 5</i>	86,5 %	17,0	98,5 %	0,6	95,2 %	4,4
<i>Promedio</i>	91,0 %	11,5	97,9 %	2,3	96,6 %	2,7

VPR⇒ Sensibilidad; VNR⇒ Especificidad; ACC⇒ Exactitud.

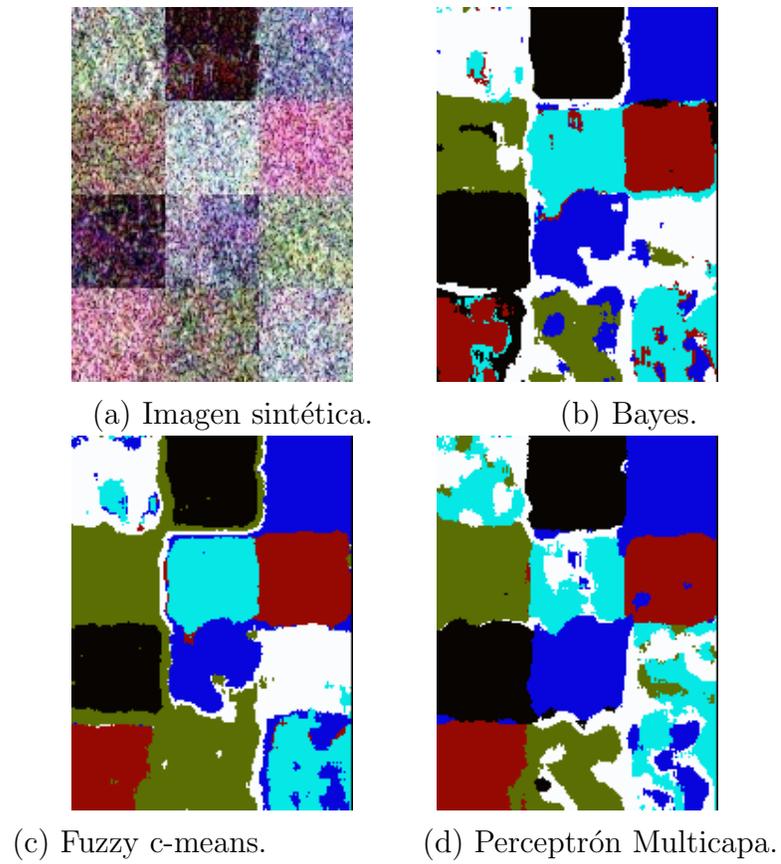


Figura 4-9: Plantilla e Imágenes clasificadas. Filtro Lee.

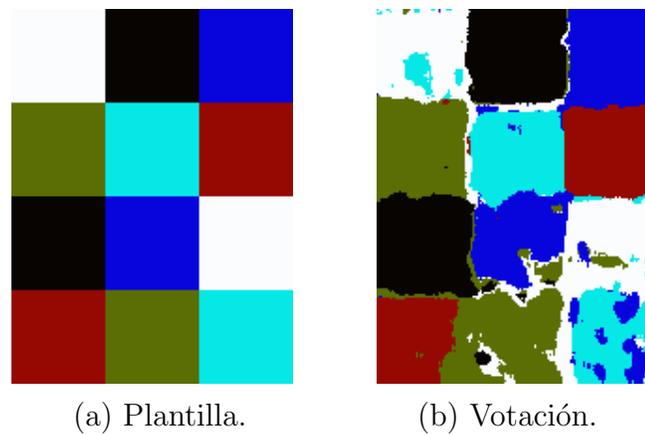


Figura 4-10: Imagen clasificada por Votación. Filtro Lee.

5 Conclusiones

5.1. Introducción

En el presente capítulo presentamos los resultados finales y las conclusiones de nuestra investigación. Primero presentamos las conclusiones generales y luego analizamos los resultados del proceso de filtrado de las imágenes con ruido *speckle* y finalmente presentamos las conclusiones de la segmentación y la clasificación de las imágenes de RADARSAT-2.

5.2. Conclusiones generales

Dentro de las conclusiones generales podemos citar:

- Si es posible realizar una clasificación automática de los estados de desarrollo del arroz a partir de imágenes generadas con el Radar de Apertura Sintética.
- Utilizando las imágenes de RADARSAT-2 es viable identificar los diferentes estados de desarrollo del cultivo de arroz.
- Se requiere, necesariamente antes de cualquier proceso de segmentación o clasificación de las imágenes SAR, realizar una etapa de filtrado para eliminar el ruido *speckle*.
- El rendimiento en la etapa de filtrado mejora considerablemente al utilizar el algoritmo de ventana adaptativa propuesto en ésta investigación.
- Los filtros que tienen mejor desempeño, en el filtrado de las imágenes SAR son: el filtro Lee, el de Frost, el Mediana y el MediaModaNá.
- El desempeño de los clasificadores varía de acuerdo a la clase examinada, teniendo en ciertas clases mejor desempeño unos clasificadores que otros.
- El mejor desempeño (en promedio), de los clasificadores utilizados se obtuvo para la red neuronal artificial, esto en el caso que se seleccionaron cinco clases.
- En la imagen real SAR, en las regiones que hay presencia de cultivos de arroz, la sexta clase hace que los clasificadores presenten mayor confusión.

- Cuando tenemos en cuenta la sexta clase, el algoritmo de clasificación mixto propuesto, que considera los resultados de los tres clasificadores empleados, (Fuzzy c-means, Bayesiano y el Perceptrón Multicapa), en promedio da mejores resultados.
- Es posible realizar un clasificador automático de los estados de desarrollo del cultivo de arroz a partir de imágenes de RADARSAT-2, utilizando en todas sus etapas software libre.

5.3. Resultados del filtrado de las imágenes con ruido *speckle*.

En el presente estudio proponemos un método novedoso para calcular el tamaño de la ventana de proceso en el filtrado de imágenes con ruido *speckle*. Nuestra propuesta de ventana adaptativa se basa en la comparación de las regiones de estudio, la ventana y su perímetro utilizando los momentos invariantes de Hu. Evaluamos el rendimiento de varios filtros de uso corriente utilizando cuatro criterios. El desempeño de los filtros se mide hallando la relación señal a ruido, el índice de mejora de contornos, el error cuadrático medio y el tiempo de proceso. Adicionalmente, proponemos un nuevo algoritmo de filtrado, el Filtro MediaModaNa (MMN) para procesar las imágenes con ruido *speckle*. Ponderamos los resultados definiendo una función de compromiso para cada imagen y para cada porcentaje de ruido de las imágenes sintéticas. Acorde con la evaluación que hicimos los filtros de Lee, Mediana, Moda, Frost y MediaModaNa presentan los mejores resultados. Utilizando el criterio de la Función de Compromiso, observamos que el desempeño de todos filtros se ve incrementado al utilizar el método propuesto por nosotros de ventana adaptativa.

La relación señal a ruido en una determinada imagen disminuye al aumentar el porcentaje de ruido en ésta, pero a su vez, los valores de SNR se ven incrementados al aumentar el tamaño de la ventana de proceso. El índice de mejora de contornos decae al aumentar el tamaño de la ventana.

Un aumento del tamaño de la ventana de proceso ocasiona el incremento del error cuadrático medio. Para todos los porcentajes de ruido en las imágenes los mejores resultados se obtienen para ventanas pequeñas. Observamos que al aumentar el porcentaje de ruido en las imágenes el valor de RMSE también aumenta. Para todos los filtros el tiempo de proceso se ve incrementado al utilizar nuestra propuesta de ventana adaptativa, pero el desempeño medido con la Función de Compromiso se ve incrementado.

Las imágenes de radar no presentan fronteras claramente definidas, éste hecho dificulta identificar fielmente los contornos; además las regiones que se pueden llamar homogéneas tiene gran variabilidad de color. Los filtros de Lee, Frost y Mediana dieron buenos resultados y nuestra propuesta, el Filtro MediaModaNa presentó un buen desempeño con las imágenes reales.

El filtro de Lee requiere información de la desviación estándar del ruido, éste hecho se convierte en una desventaja del algoritmo. En la imágenes reales se vuelve difícil determinar regiones homogéneas y hacer estimativos de la varianza del ruido. También suponer distribuciones normales en las áreas homogéneas no es una aproximación confiable.

5.4. Resultados de la segmentación y la clasificación.

Luego de la segmentación y clasificación de las imágenes con los tres clasificadores utilizados en nuestro trabajo (el algoritmo Fuzzy *c*-means, el clasificador Bayesiano y la red neuronal), encontramos que el rendimiento de los mismos varía de una clase a otra. Para el caso que se entrenaron los clasificadores para discernir sobre cinco clases, el mejor desempeño para seleccionar los píxeles de una determinado estado de desarrollo del cultivo de arroz lo tuvo el clasificador Perceptron Multicapa con un 95,5 % en la clase 3. El mejor desempeño del clasificador Bayesiano lo tuvo en la clase 2, con un rendimiento del 93,7 %, y para el clasificador Fuzzy *c*-means el mejor desempeño lo alcanzó en la clase 5 con un rendimiento del 94,9 % (ver Tablas 4-3, 4-4 y 4-5). En promedio el mejor desempeño lo tuvo el clasificador Perceptron Multicapa con un rendimiento de: $VPR = 86,3 \%$, $VNR = 96,5 \%$ y $ACC = 94,5 \%$.

Cuando procesamos las imágenes reales encontramos que el rendimiento del clasificador Perceptrón Multicapa es mejor que el clasificador Bayesiano y el Fuzzy *c*-means, logrando valores de sensibilidad del orden del 91,0 %; especificidad de 97,9 % y exactitud de 96,6 %. Adicionalmente realizamos un estudio de la red neuronal mirando la influencia del numero de neuronas en la capa oculta en el rendimiento del clasificador. En la Tabla 12-6 se encuentra los valores de la sensibilidad (VPR) para diferentes valores de neuronas en la capa oculta. En la Figura 4-3 se aprecia el comportamiento de la sensibilidad al variar el número de neuronas de la capa oculta para cada clase. Como se aprecia en la Figura 4-3 la razon de verdaderos positivos no se ve afectada significativamente al variar el número de neuronas en la capa oculta.

Cuando consideramos la sexta clase, relacionada con pastizales, se observa que el valor de la sensibilidad es mayor para el clasificador Fuzzy *c*-mean con un porcentaje del 82,5. Para los tres clasificadores hallamos que la razón de verdaderos negativos (especificidad), presentan valores en promedio mayores al 94 % y además, se observa que los tres clasificadores poseen una exactitud mayor al 91 %. De éste estudio podemos concluir que el algoritmo Fuzzy *c*-means tiene mejor desempeño en promedio (ver Tablas 12-2, 12-3 y 12-4). Con el clasificador mixto se logra una pequeña mejoría del desempeño.

La introducción de la sexta clase, relacionada con pastizales ocasiona que los clasificadores se confundan en las zonas donde hay solamente cultivos de arroz, es decir, el desempeño de los clasificadores decae cuanto tenemos en cuenta ésta clase.

6 Futuros trabajos.

El estudio de las imágenes del radar de apertura sintética es un campo relativamente nuevo de investigación a nivel mundial, y un área novedosa de investigación para nuestro país. Debido a las ventajas que posee las imágenes de radar, como poder capturar información de la superficie de la Tierra a cualquier hora del día y prácticamente con cualquier condición atmosférica, son un importante material de estudio para nuestra nación debido precisamente a las condiciones especiales de nuestra geografía. Las imágenes SAR aportan datos que no pueden ser capturados por sensores ópticos y pueden ser utilizadas para la investigación en diferentes áreas. Aunando esfuerzos entre la Universidad Nacional de Colombia y el Instituto Geográfico Agustín Codazzi (IGAC) se pueden adelantar importantes proyectos de investigación utilizando las imágenes de radar.

7 Anexo 1. Gráficas

7.1. Introducción

En éste anexo presentamos algunas de las gráficas elaboradas que se han utilizado para el análisis de los resultados, tanto del filtrado de las imágenes como del proceso de clasificación.

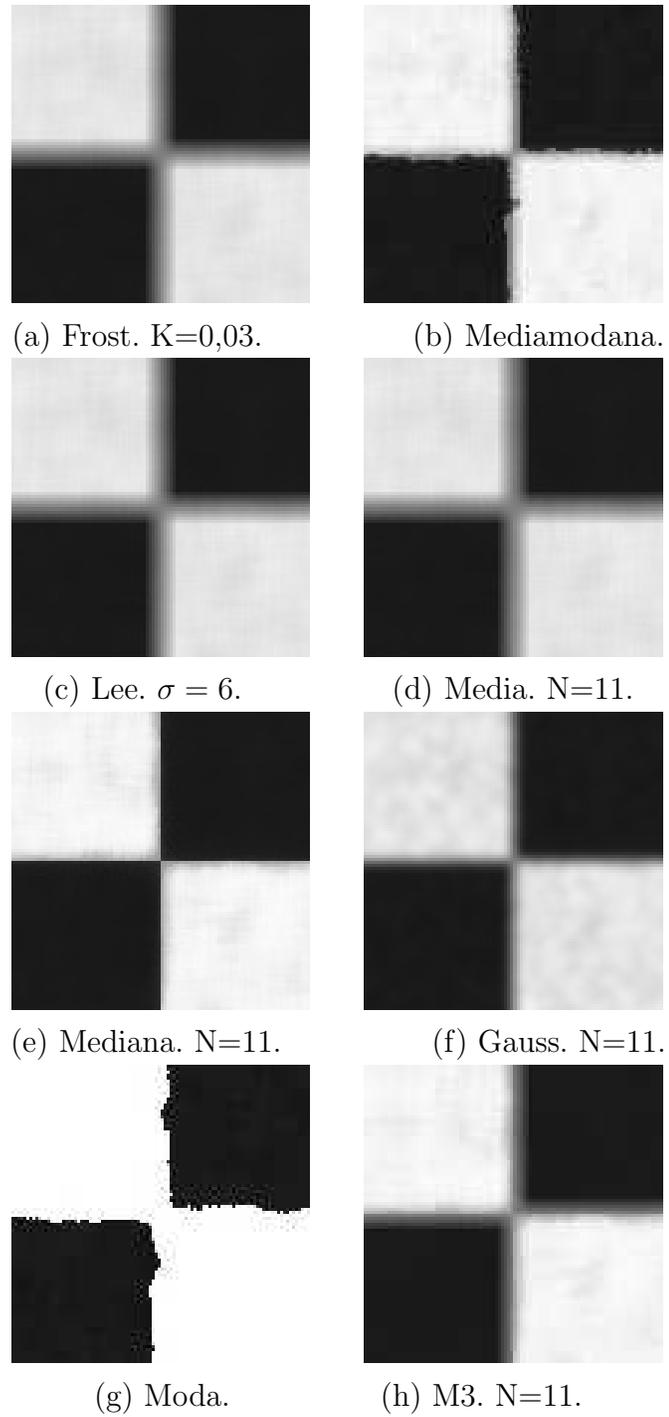


Figura 7-1: Imágenes filtradas ventana fija $N = 11$, ruido de 5 %.

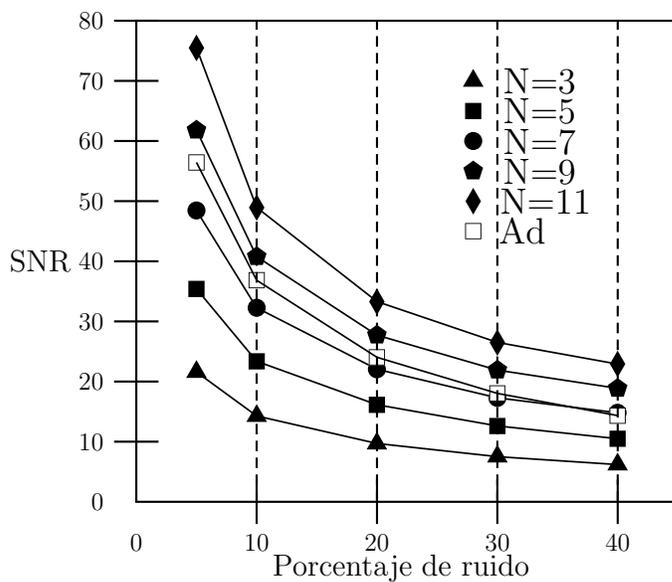


Figura 7-2: SNR vs Ruido. Filtro de Frost $K = 0,03$.

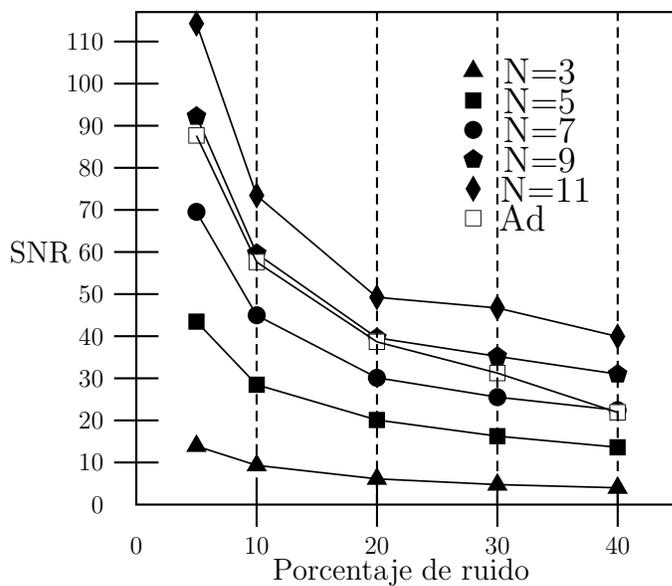


Figura 7-3: SNR vs Ruido. Filtro MediaModaNa.

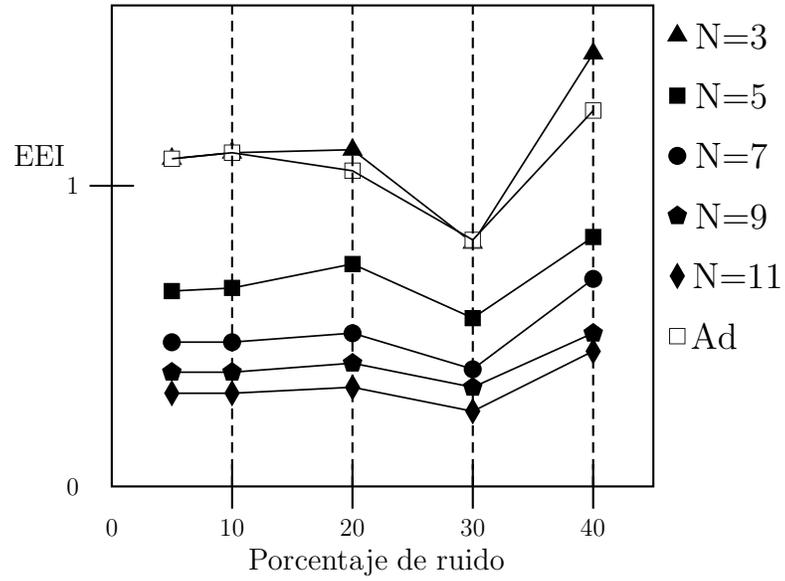


Figura 7-4: EEI vs Ruido. Filtro de Frost $K = 0,03$.

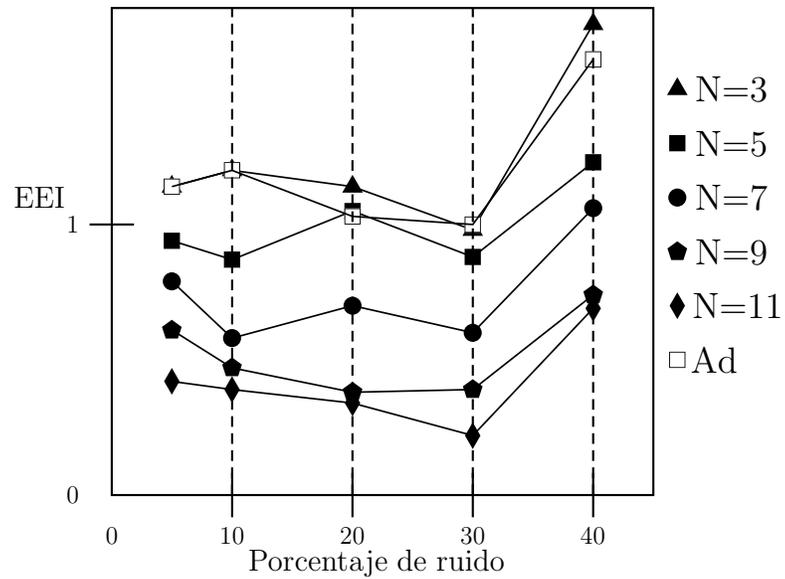


Figura 7-5: EEI vs Ruido. Filtro MediaModaNu.

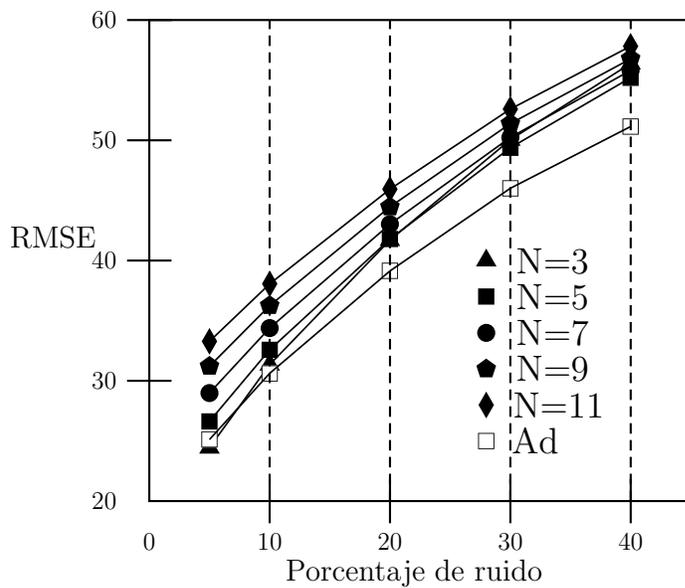


Figura 7-6: RMSE vs Ruido. Filtro de Frost $K = 0,03$.

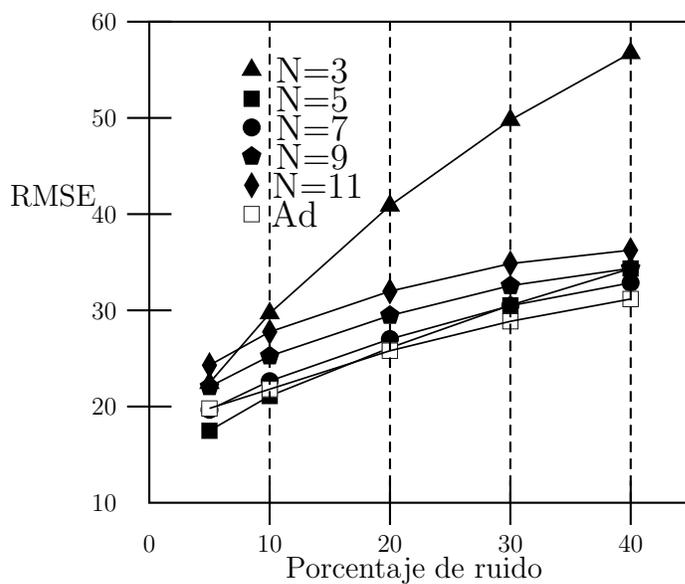


Figura 7-7: RMSE vs Ruido. Filtro MediaModaNa.

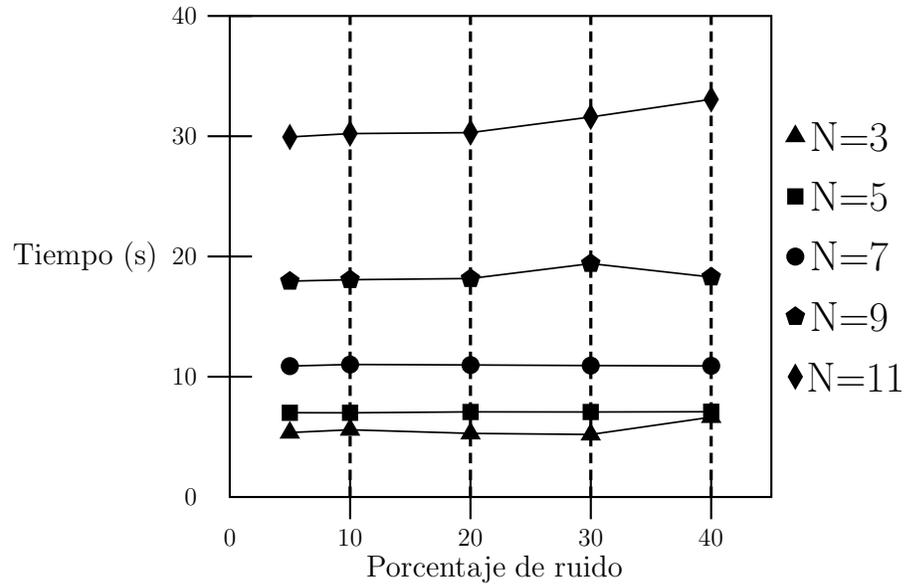


Figura 7-8: Tiempo vs Ruido. Filtro MediaModaN.

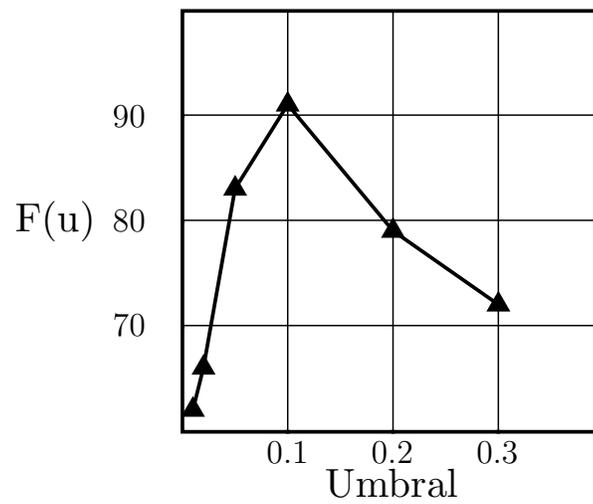


Figura 7-9: Función de Compromiso vs Umbral. Filtro MediaModaN.

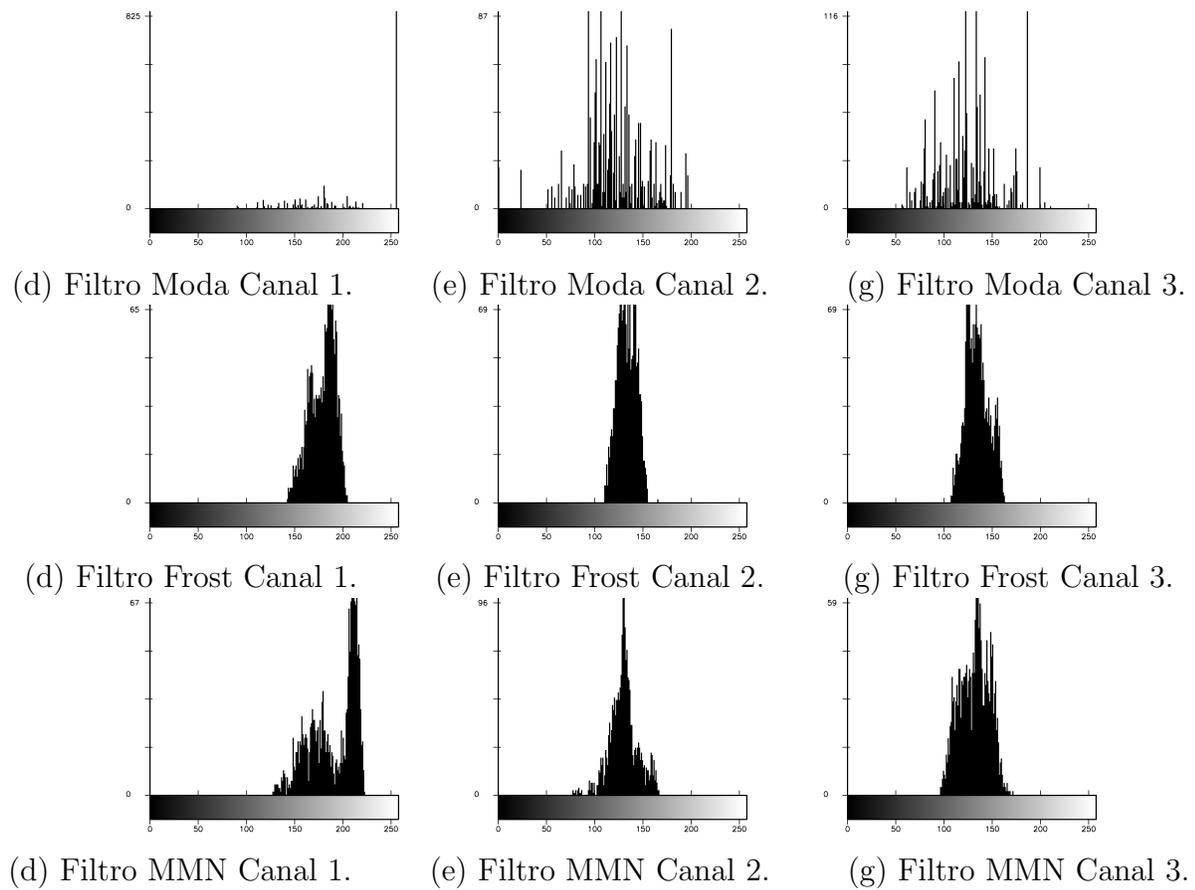


Figura 7-10: Histogramas. Clase 3. Parte II.

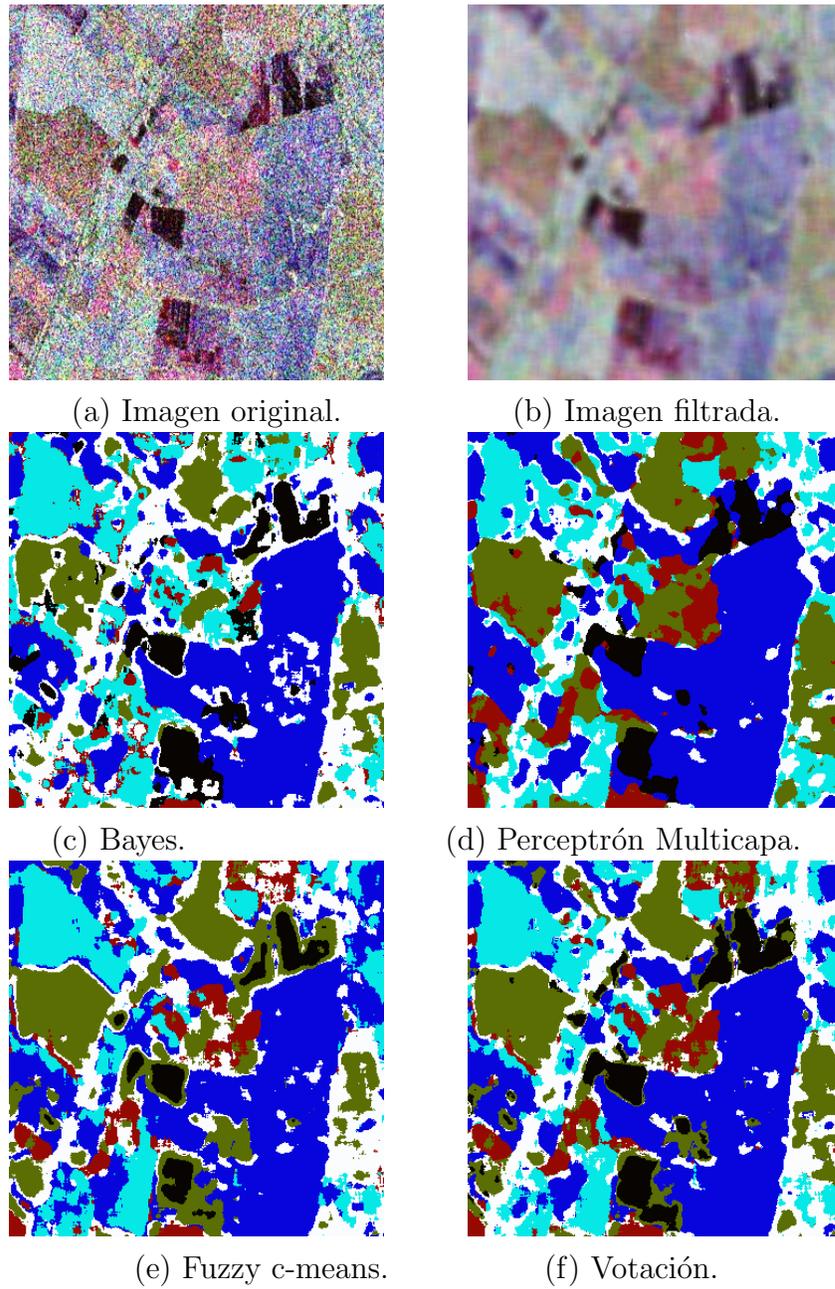


Figura 7-11: Imagen Real clasificada. Seis clases.

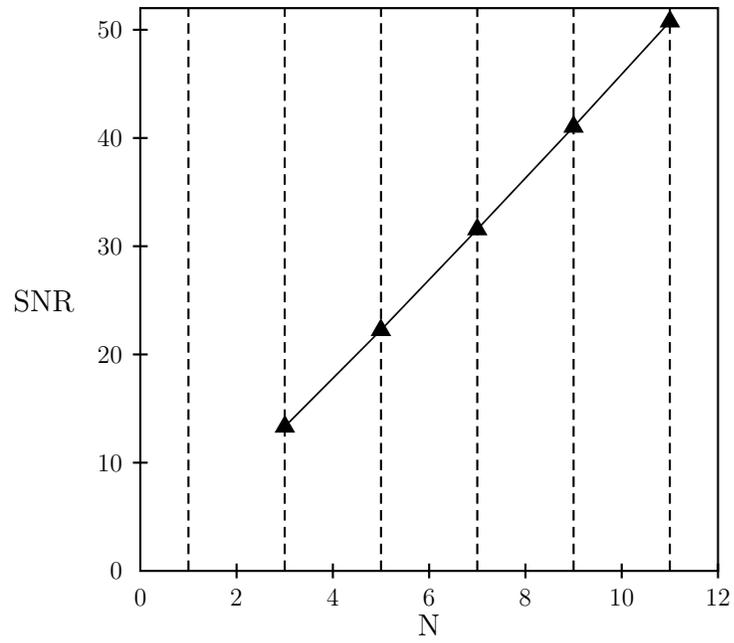


Figura 7-12: SNR vs Ventana. Filtro Lee $\sigma_n = 6$. Ruido 30 %.

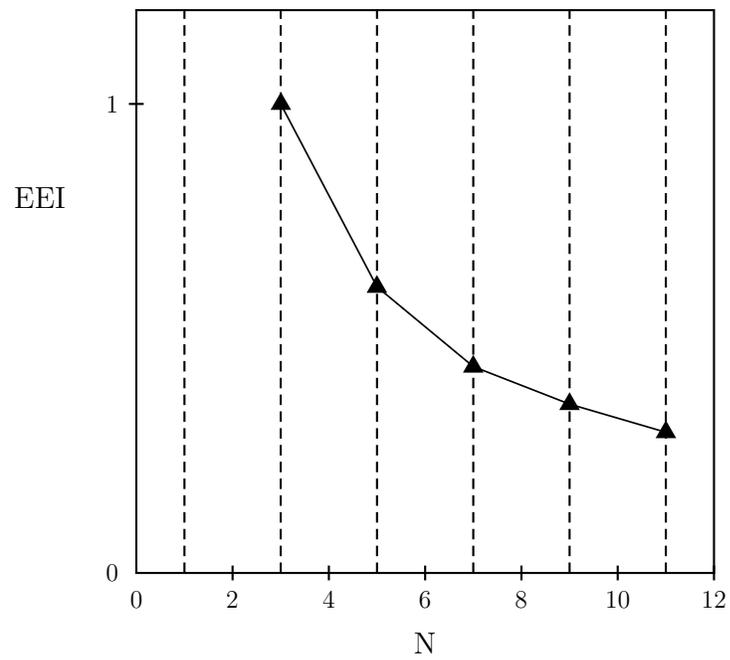


Figura 7-13: EEI vs Ventana. Filtro de Lee $\sigma_n = 6$. Ruido 30 %.

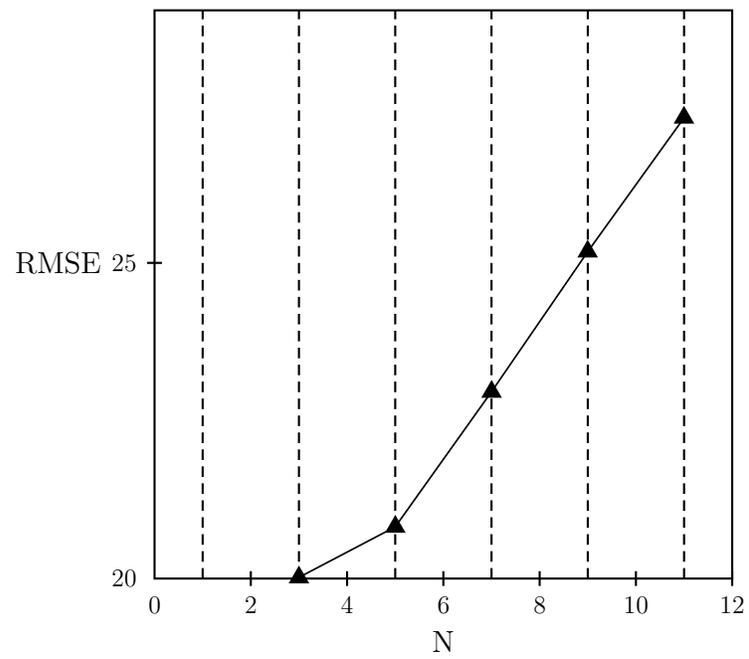


Figura 7-14: RMSE vs Ventana. Filtro de Lee $\sigma_n = 6$. Ruido 30 %.

8 Anexo 2. Tablas I.

8.1. Introducción

En esta sección y en el Anexo 6, se presentan las tablas de resultados. Se elaboran tablas de resultados de los cuatro indicadores escogidos para evaluar el desempeño de los filtros. Se reportan mediciones para filtrado con ventana fijas de tamaños $N=3$ hasta $N=11$, y para ventanas de tamaño adaptativo. Se presentan también las matrices de confusión que se hallaron para evaluar el desempeño de los clasificadores y tablas con los parámetros estadísticos de medición del desempeño de los clasificadores.

Tabla 8-1: $\bar{I}_0 = 255$. Ventana adaptativa. Ruido 5%. $Umbral = 0,10$.

Filtro	SNR	EEI	RMSE	Tiempo (s)
Lee ($\sigma_n = 0,3$)	33,76	1,07	22,05	5,71
Lee ($\sigma_n = 0,5$)	49,47	1,08	22,29	5,68
Lee ($\sigma_n = 1,5$)	56,27	1,09	24,52	5,67
Lee ($\sigma_n = 3,5$)	56,46	1,09	26,28	5,66
Lee ($\sigma_n = 6,0$)	56,47	1,09	26,56	5,66
Media	56,48	1,09	26,71	5,61
Mediana	51,56	1,12	12,75	14,69
Moda	∞	1,22	28,73	10,29
Kuan1($\sigma_n = 0,3$)	34,12	1,07	20,28	5,65
Kuan1($\sigma_n = 0,5$)	49,67	1,08	20,84	5,64
Kuan1($\sigma_n = 1,5$)	56,29	1,09	23,89	5,62
Kuan1($\sigma_n = 3,5$)	56,47	1,09	24,89	5,62
Kuan1($\sigma_n = 6,0$)	56,48	1,09	25,06	5,62
Kuan2	0,85	0,81	139,12	5,67
Gamma	5,91	0,36	123,49	5,83
Frost($K = 0,03$)	56,44	1,09	25,12	13,08
Frost($K = 0,30$)	56,28	1,09	24,63	13,07
Frost($K = 0,50$)	56,08	1,09	24,24	13,15
Frost($K = 1,50$)	54,24	1,09	22,22	13,06
Frost($K = 6,00$)	36,21	1,07	19,94	13,66
Oddy($\alpha = 0,5$)	56,48	1,09	20,34	9,90
Oddy($\alpha = 0,9$)	56,48	1,09	23,51	10,55
Oddy($\alpha = 1,2$)	56,48	1,09	25,17	10,82
Geométrico	51,71	1,10	31,69	10,83
MediaModaNá (MMN)	87,65	1,14	19,81	48,41

Tabla 8-2: $\bar{I}_0 = 255$. Ventana adaptativa. Ruido 10%. $Umbral = 0,10$.

Filtro	SNR	EEI	RMSE	Tiempo (s)
Lee ($\sigma_n = 0,3$)	14,36	1,09	30,13	5,48
Lee ($\sigma_n = 0,5$)	24,98	1,11	29,06	5,47
Lee ($\sigma_n = 1,5$)	36,45	1,11	30,21	5,46
Lee ($\sigma_n = 3,5$)	36,88	1,11	31,59	5,48
Lee ($\sigma_n = 6,0$)	36,88	1,11	31,80	5,47
Media	36,87	1,11	31,92	5,50
Mediana	33,20	1,16	18,87	14,34
Moda	∞	1,31	28,52	10,10
Kuan1($\sigma_n = 0,3$)	14,72	1,09	28,77	5,48
Kuan1($\sigma_n = 0,5$)	25,46	1,11	27,92	5,49
Kuan1($\sigma_n = 1,5$)	36,46	1,11	29,72	5,49
Kuan1($\sigma_n = 3,5$)	36,88	1,11	30,45	5,47
Kuan1($\sigma_n = 6,0$)	36,88	1,11	30,59	5,49
Kuan2	0,88	0,88	137,07	5,49
Gamma	4,07	0,36	127,75	5,50
Frost($K = 0,03$)	36,85	1,11	30,62	12,54
Frost($K = 0,30$)	36,53	1,11	30,28	12,54
Frost($K = 0,50$)	36,22	1,11	30,01	12,48
Frost($K = 1,50$)	33,68	1,11	28,63	12,39
Frost($K = 6,00$)	16,54	1,09	28,46	12,41
Oddy($\alpha = 0,5$)	36,87	1,11	27,46	8,48
Oddy($\alpha = 0,9$)	36,87	1,11	29,65	8,55
Oddy($\alpha = 1,2$)	36,87	1,11	30,66	9,42
Geométrico	32,07	1,11	38,68	10,01
MediaModaNa (MMN)	57,62	1,20	21,80	47,05

Tabla 8-3: $\bar{I}_0 = 255$. Ventana adaptativa. Ruido 20 %. *Umbral* = 0,10.

Filtro	SNR	EI	RMSE	Tiempo (s)
Lee ($\sigma_n = 0,3$)	6,22	1,05	44,57	5,37
Lee ($\sigma_n = 0,5$)	10,67	1,07	40,25	5,38
Lee ($\sigma_n = 1,5$)	22,96	1,06	38,97	5,35
Lee ($\sigma_n = 3,5$)	24,01	1,05	39,91	5,36
Lee ($\sigma_n = 6,0$)	24,04	1,05	40,08	5,35
Media	24,06	1,05	40,17	5,29
Mediana	21,74	1,14	24,02	14,40
Moda	1579,04	1,04	30,85	9,91
Kuan1($\sigma_n = 0,3$)	6,49	1,05	43,14	5,35
Kuan1($\sigma_n = 0,5$)	11,27	1,06	39,09	5,36
Kuan1($\sigma_n = 1,5$)	23,15	1,06	38,53	5,33
Kuan1($\sigma_n = 3,5$)	24,01	1,05	39,01	5,35
Kuan1($\sigma_n = 6,0$)	24,03	1,05	39,11	5,36
Kuan2	1,04	0,89	125,22	5,50
Gamma	2,81	0,30	135,06	5,49
Frost($K = 0,03$)	24,03	1,05	39,14	13,69
Frost($K = 0,30$)	23,74	1,06	38,93	13,61
Frost($K = 0,50$)	23,42	1,07	38,79	13,55
Frost($K = 1,50$)	20,61	1,10	38,20	13,48
Frost($K = 6,00$)	6,81	1,05	43,24	13,49
Oddy($\alpha = 0,5$)	24,06	1,09	37,87	8,27
Oddy($\alpha = 0,9$)	24,06	1,05	38,49	8,22
Oddy($\alpha = 1,2$)	24,06	1,05	39,15	9,18
Geométrico	18,20	1,07	54,03	10,60
MediaModaNa (MMN)	38,65	1,03	25,80	39,83

Tabla 8-4: $\bar{I}_0 = 255$. Ventana adaptativa. Ruido 30%. $Umbral = 0,10$.

Filtro	SNR	EEI	RMSE	Tiempo (s)
Lee ($\sigma_n = 0,3$)	4,00	0,94	57,79	5,38
Lee ($\sigma_n = 0,5$)	6,34	0,90	50,76	5,36
Lee ($\sigma_n = 1,5$)	16,32	0,84	46,10	5,42
Lee ($\sigma_n = 3,5$)	17,96	0,82	46,67	5,38
Lee ($\sigma_n = 6,0$)	18,05	0,82	46,79	5,40
Media	18,07	0,82	46,46	5,23
Mediana	19,58	1,01	28,23	14,50
Moda	57,87	1,18	32,18	9,97
Kuan1($\sigma_n = 0,3$)	4,22	0,94	55,92	5,29
Kuan1($\sigma_n = 0,5$)	6,87	0,89	49,16	5,27
Kuan1($\sigma_n = 1,5$)	16,69	0,83	45,69	5,28
Kuan1($\sigma_n = 3,5$)	17,98	0,82	45,91	5,27
Kuan1($\sigma_n = 6,0$)	18,05	0,82	45,98	5,28
Kuan2	1,40	0,46	108,88	5,41
Gamma	2,28	0,30	141,32	5,44
Frost($K = 0,03$)	18,03	0,82	46,01	12,49
Frost($K = 0,30$)	17,66	0,82	45,97	12,38
Frost($K = 0,50$)	17,26	0,83	45,95	12,34
Frost($K = 1,50$)	14,28	0,85	46,11	12,34
Frost($K = 6,00$)	4,03	0,95	57,62	12,42
Oddy($\alpha = 0,5$)	17,80	0,98	45,66	8,78
Oddy($\alpha = 0,9$)	18,07	0,82	45,58	8,26
Oddy($\alpha = 1,2$)	18,07	0,82	46,00	8,32
Geométrico	3,92	0,68	78,76	8,71
MediaModaNa (MMN)	31,24	1,00	28,86	29,88

Tabla 8-5: $\bar{I}_0 = 255$. Ventana adaptativa. Ruido 40 %. $Umbral = 0,10$.

Filtro	SNR	EEI	RMSE	Tiempo (s)
Lee ($\sigma_n = 0,3$)	3,00	1,03	68,33	5,35
Lee ($\sigma_n = 0,5$)	4,42	1,12	59,72	5,34
Lee ($\sigma_n = 1,5$)	12,10	1,25	51,66	5,35
Lee ($\sigma_n = 3,5$)	14,18	1,25	51,78	5,34
Lee ($\sigma_n = 6,0$)	14,32	1,25	51,86	5,35
Media	14,37	1,25	51,91	5,16
Mediana	16,51	1,70	30,77	14,40
Moda	19,41	1,89	33,57	9,80
Kuan1($\sigma_n = 0,3$)	3,18	1,04	65,96	5,35
Kuan1($\sigma_n = 0,5$)	4,89	1,13	57,41	5,34
Kuan1($\sigma_n = 1,5$)	12,69	1,24	51,12	5,34
Kuan1($\sigma_n = 3,5$)	14,24	1,25	51,08	5,34
Kuan1($\sigma_n = 6,0$)	14,34	1,25	51,12	5,33
Kuan2	1,66	1,32	99,77	5,29
Gamma	1,97	0,36	146,05	5,30
Frost($K = 0,03$)	14,34	1,25	51,15	12,32
Frost($K = 0,30$)	13,93	1,28	51,26	12,22
Frost($K = 0,50$)	13,51	1,30	51,37	12,20
Frost($K = 1,50$)	10,48	1,31	52,27	12,20
Frost($K = 6,00$)	2,86	1,03	69,64	12,21
Oddy($\alpha = 0,5$)	13,39	1,59	49,94	9,06
Oddy($\alpha = 0,9$)	14,15	1,37	51,14	8,00
Oddy($\alpha = 1,2$)	14,37	1,25	51,14	8,21
Geométrico	0,56	0,85	162,08	7,34
MediaModaN (MMN)	21,86	1,61	31,18	24,14

Tabla 8-6: $\bar{I}_0 = 255$. N=3. Ruido 5 %.

Filtro	SNR	EEI	RMSE	Tiempo (s)
Lee ($\sigma_n = 0,3$)	18,84	1,07	21,25	0,32
Lee ($\sigma_n = 0,5$)	21,00	1,08	21,31	0,33
Lee ($\sigma_n = 1,5$)	21,56	1,09	23,17	0,31
Lee ($\sigma_n = 3,5$)	21,58	1,09	24,15	0,32
Lee ($\sigma_n = 6,0$)	21,58	1,09	24,37	0,31
Media	21,58	1,09	24,49	0,25
Mediana	14,00	1,12	20,79	0,71
Gauss	19,20	1,07	23,26	0,02
Moda	7,38	1,22	31,93	4,21
M3	17,87	1,14	17,61	1,38
Kuan1($\sigma_n = 0,3$)	18,93	1,07	23,33	0,31
Kuan1($\sigma_n = 0,5$)	21,02	1,08	21,59	0,34
Kuan1($\sigma_n = 1,5$)	21,56	1,09	23,60	0,34
Kuan1($\sigma_n = 3,5$)	21,58	1,09	24,29	0,33
Kuan1($\sigma_n = 6,0$)	21,58	1,09	24,42	0,32
Kuan2	0,87	0,81	140,24	0,34
Gamma	5,94	0,36	123,08	0,36
Frost($K = 0,03$)	21,58	1,09	24,45	1,26
Frost($K = 0,30$)	21,56	1,09	24,15	1,26
Frost($K = 0,50$)	21,56	1,09	23,91	1,26
Frost($K = 1,50$)	21,45	1,09	22,68	1,26
Frost($K = 6,00$)	19,23	1,07	21,05	1,23
Oddy($\alpha = 0,5$)	21,58	1,09	20,58	0,69
Oddy($\alpha = 0,9$)	21,58	1,09	23,12	0,70
Oddy($\alpha = 1,2$)	21,58	1,09	24,48	0,68
Geométrico	19,99	1,10	28,72	0,54
MediaModaNa (MMN)	13,89	1,14	22,45	5,36

Tabla 8-7: $\bar{I}_0 = 255$. $N=5$. Ruido 5 %.

Filtro	SNR	EEI	RMSE	Tiempo (s)
Lee ($\sigma_n = 0,3$)	26,58	0,95	20,86	0,36
Lee ($\sigma_n = 0,5$)	33,28	0,89	21,23	0,34
Lee ($\sigma_n = 1,5$)	35,37	0,74	24,50	0,37
Lee ($\sigma_n = 3,5$)	35,39	0,67	26,14	0,35
Lee ($\sigma_n = 6,0$)	35,41	0,65	26,50	0,34
Media	35,41	0,64	26,69	0,28
Mediana	25,52	1,08	15,65	2,42
Gauss	26,14	0,94	24,00	0,02
Filtro Moda	51,07	1,09	23,49	4,18
Filtro M3	28,48	0,89	17,61	2,98
Kuan1($\sigma_n = 0,3$)	26,77	0,92	21,02	0,35
Kuan1($\sigma_n = 0,5$)	33,36	0,86	21,72	0,35
Kuan1($\sigma_n = 1,5$)	35,37	0,70	25,22	0,34
Kuan1($\sigma_n = 3,5$)	35,39	0,65	26,37	0,35
Kuan1($\sigma_n = 6,0$)	35,41	0,64	26,58	0,35
Kuan2	0,85	0,53	139,97	0,37
Gamma	5,91	0,21	123,85	0,39
Frost($K = 0,03$)	35,41	0,65	26,63	3,09
Frost($K = 0,30$)	35,37	0,70	26,04	3,09
Frost($K = 0,50$)	35,34	0,75	25,59	3,09
Frost($K = 1,50$)	34,95	0,91	23,31	3,06
Frost($K = 6,00$)	28,26	1,01	20,34	3,03
Oddy($\alpha = 0,5$)	35,41	0,87	21,58	1,51
Oddy($\alpha = 0,9$)	35,41	0,87	24,58	1,49
Oddy($\alpha = 1,2$)	35,41	0,64	26,69	1,48
Geométrico	32,59	0,52	33,26	1,15
MediaModaNa (MMN)	43,47	0,94	17,49	7,01

Tabla 8-8: $\bar{I}_0 = 255$. $N=7$. Ruido 5 %.

Filtro	SNR	EEI	RMSE	Tiempo (s)
Lee ($\sigma_n = 0,3$)	31,25	0,93	21,05	0,40
Lee ($\sigma_n = 0,5$)	43,61	0,85	21,71	0,40
Lee ($\sigma_n = 1,5$)	48,42	0,61	26,20	0,42
Lee ($\sigma_n = 3,5$)	48,46	0,51	28,37	0,39
Lee ($\sigma_n = 6,0$)	48,46	0,48	28,83	0,41
Media	48,45	0,47	29,09	0,32
Mediana	38,58	1,05	14,94	6,07
Gauss	35,15	0,77	25,33	0,01
Moda	∞	0,84	30,58	4,31
M3	40,69	0,77	19,08	5,03
Kuan1($\sigma_n = 0,3$)	31,54	0,90	21,28	0,41
Kuan1($\sigma_n = 0,5$)	43,74	0,79	22,40	0,40
Kuan1($\sigma_n = 1,5$)	48,42	0,55	27,15	0,40
Kuan1($\sigma_n = 3,5$)	48,47	0,49	28,67	0,40
Kuan1($\sigma_n = 6,0$)	48,46	0,48	28,95	0,40
Kuan2	0,84	0,40	138,53	0,44
Gamma	5,90	0,11	124,55	0,45
Frost($K = 0,03$)	48,45	0,48	28,99	5,93
Frost($K = 0,30$)	48,48	0,56	28,00	5,92
Frost($K = 0,50$)	48,47	0,61	27,27	5,91
Frost($K = 1,50$)	47,56	0,86	23,86	5,83
Frost($K = 6,00$)	33,97	1,01	20,28	5,83
Oddy($\alpha = 0,5$)	48,45	1,00	22,96	2,77
Oddy($\alpha = 0,9$)	48,45	0,77	27,31	2,67
Oddy($\alpha = 1,2$)	48,45	0,47	29,09	2,59
Geométrico	44,51	0,38	38,57	2,08
MediaModaNa (MMN)	69,52	0,79	19,67	10,86

Tabla 8-9: $\bar{I}_0 = 255$. N=9. Ruido 5 %.

Filtro	SNR	EEI	RMSE	Tiempo (s)
Lee ($\sigma_n = 0,3$)	34,45	0,92	21,36	0,47
Lee ($\sigma_n = 0,5$)	52,99	0,82	22,29	0,45
Lee ($\sigma_n = 1,5$)	61,69	0,52	27,87	0,46
Lee ($\sigma_n = 3,5$)	61,82	0,41	30,50	0,45
Lee ($\sigma_n = 6,0$)	61,82	0,38	31,06	0,46
Media	61,83	0,37	31,37	0,39
Mediana	52,85	1,00	15,34	12,89
Gauss	41,62	0,69	25,43	0,02
Moda	∞	0,48	36,50	4,25
M3	54,73	0,68	20,87	7,61
Kuan1($\sigma_n = 0,3$)	34,86	0,88	21,66	0,46
Kuan1($\sigma_n = 0,5$)	53,23	0,75	23,15	0,46
Kuan1($\sigma_n = 1,5$)	61,70	0,47	29,02	0,46
Kuan1($\sigma_n = 3,5$)	61,82	0,39	30,86	0,48
Kuan1($\sigma_n = 6,0$)	61,83	0,37	31,19	0,46
Kuan2	0,84	0,32	137,43	0,49
Gamma	5,90	0,05	125,21	0,51
Frost($K = 0,03$)	61,82	0,38	31,21	9,61
Frost($K = 0,30$)	61,78	0,47	29,76	9,61
Frost($K = 0,50$)	61,67	0,54	28,70	9,57
Frost($K = 1,50$)	59,61	0,85	24,15	9,43
Frost($K = 6,00$)	37,23	1,01	20,38	9,48
Oddy($\alpha = 0,5$)	61,83	1,06	23,83	4,45
Oddy($\alpha = 0,9$)	61,83	0,69	29,86	4,21
Oddy($\alpha = 1,2$)	61,83	0,37	31,37	4,09
Geométrico	56,97	0,29	44,04	3,29
MediaModaNa (MMN)	92,24	0,61	22,06	17,95

Tabla 8-10: $\bar{I}_0 = 255$. N=11. Ruido 5 %.

Filtro	SNR	EEI	RMSE	Tiempo (s)
Lee ($\sigma_n = 0,3$)	36,12	0,91	21,73	0,55
Lee ($\sigma_n = 0,5$)	60,26	0,81	22,98	0,52
Lee ($\sigma_n = 1,5$)	75,18	0,47	29,46	0,53
Lee ($\sigma_n = 3,5$)	75,47	0,34	32,50	0,56
Lee ($\sigma_n = 6,0$)	75,47	0,31	33,14	0,52
Media	75,49	0,30	33,50	0,49
Mediana	66,82	0,95	16,09	24,55
Gauss	48,69	0,60	28,41	0,02
Moda	∞	0,00	41,57	4,43
M3	68,94	0,57	22,64	10,92
Kuan1($\sigma_n = 0,3$)	36,55	0,87	22,09	0,53
Kuan1($\sigma_n = 0,5$)	60,64	0,73	23,93	0,56
Kuan1($\sigma_n = 1,5$)	75,21	0,41	30,79	0,54
Kuan1($\sigma_n = 3,5$)	75,47	0,32	32,91	0,56
Kuan1($\sigma_n = 6,0$)	75,47	0,31	33,29	0,54
Kuan2	0,84	0,27	136,55	0,55
Gamma	5,90	0,10	125,85	0,59
Frost($K = 0,03$)	75,48	0,31	33,28	14,34
Frost($K = 0,30$)	75,27	0,41	31,29	14,24
Frost($K = 0,50$)	74,82	0,49	29,88	14,22
Frost($K = 1,50$)	70,99	0,84	24,26	14,06
Frost($K = 6,00$)	38,83	1,00	20,54	14,02
Oddy($\alpha = 0,5$)	75,49	1,02	25,62	6,61
Oddy($\alpha = 0,9$)	75,49	0,64	31,42	6,24
Oddy($\alpha = 1,2$)	75,49	0,30	33,50	5,98
Geométrico	69,78	0,23	49,46	4,80
MediaModaNa (MMN)	114,28	0,42	24,29	29,94

Tabla 8-11: Definición de la Función de compromiso. Filtro MediaModaNá.

% ruido	Función		
5	$F_5 =$	$\frac{100}{3}$	$* \left[\left(\frac{SNR}{114,28} \right) + \left(\frac{EEI}{1,14} \right) + \left(\frac{17,49}{RMSE} \right) \right]$
10	$F_{10} =$	$\frac{100}{3}$	$* \left[\left(\frac{SNR}{73,42} \right) + \left(\frac{EEI}{1,20} \right) + \left(\frac{21,10}{RMSE} \right) \right]$
20	$F_{20} =$	$\frac{100}{3}$	$* \left[\left(\frac{SNR}{49,24} \right) + \left(\frac{EEI}{1,14} \right) + \left(\frac{26,11}{RMSE} \right) \right]$
30	$F_{30} =$	$\frac{100}{3}$	$* \left[\left(\frac{SNR}{46,71} \right) + \left(\frac{EEI}{0,98} \right) + \left(\frac{30,48}{RMSE} \right) \right]$
40	$F_{40} =$	$\frac{100}{3}$	$* \left[\left(\frac{SNR}{39,92} \right) + \left(\frac{EEI}{1,74} \right) + \left(\frac{32,86}{RMSE} \right) \right]$

Tabla 8-12: Función de compromiso. Filtro MediaModaNá.

% ruido	$N = 3$	$N = 5$	$N = 7$	$N = 9$	$N = 11$	Adaptativa
5	$F_5 = 63,35$	$F_5 = 73,49$	$F_5 = 73,01$	$F_5 = 71,16$	$F_5 = 69,61$	$F_5 = 88,32$
10	$F_{10} = 61,26$	$F_{10} = 70,42$	$F_{10} = 67,57$	$F_5 = 67,98$	$F_5 = 69,50$	$F_5 = 91,75$
20	$F_{20} = 58,75$	$F_{20} = 77,63$	$F_{20} = 73,07$	$F_5 = 67,46$	$F_5 = 70,48$	$F_5 = 90,01$
30	$F_{30} = 57,13$	$F_{30} = 74,81$	$F_{30} = 71,96$	$F_5 = 69,58$	$F_5 = 69,96$	$F_5 = 91,51$
40	$F_{40} = 55,96$	$F_{40} = 66,82$	$F_{40} = 72,35$	$F_5 = 71,92$	$F_5 = 76,75$	$F_5 = 84,25$

Tabla 8-13: Código de los filtros.

Filtro	Código
Imagen original	0
Lee	1
Media	2
Mediana	3
Gauss	4
Moda	5
M3	6
Kuan1	7
Kuan2	8
Gamma	9
Frost	10
Oddy	11
Geométrico	12
MediaModaNa	13
Ventana Adaptativa	15

Tabla 8-14: Matriz de confusión. Clasificador Perceptrón. Filtro Lee. Cinco clases. Imagen uno.

		Resultado de la Predicción					<i>Total</i>
		<i>C 1</i>	<i>C 2</i>	<i>C 3</i>	<i>C 4</i>	<i>C 5</i>	
Valor Real	<i>C 1</i>	470	0	155	0	0	625
	<i>C 2</i>	0	602	22	0	1	625
	<i>C 3</i>	0	8	617	0	0	625
	<i>C 4</i>	0	0	44	581	0	625
	<i>C 5</i>	0	26	0	81	518	625
	<i>Total</i>	470	636	838	662	519	3125

Tabla 8-15: Características. Clasificador Perceptrón. Filtro Lee. Cinco Clases. Imagen uno.

	Sensibilidad (VPR)	Especificidad (VNR)	Exactitud (ACC)
<i>Clase 1</i>	75,2 %	100,0 %	95,0 %
<i>Clase 2</i>	96,3 %	98,6 %	98,2 %
<i>Clase 3</i>	98,7 %	91,2 %	92,7 %
<i>Clase 4</i>	93,0 %	96,8 %	96,0 %
<i>Clase 5</i>	82,9 %	100,0 %	96,5 %

Tabla 8-16: Matriz de confusión. Clasificador Perceptrón. Filtro Lee. Cinco clases. Imagen dos.

		Resultado de la Predicción					<i>Total</i>
		<i>C 1</i>	<i>C 2</i>	<i>C 3</i>	<i>C 4</i>	<i>C 5</i>	
Valor Real	<i>C 1</i>	542	0	83	0	0	625
	<i>C 2</i>	0	588	27	0	1	625
	<i>C 3</i>	0	9	616	0	0	625
	<i>C 4</i>	0	0	49	576	0	625
	<i>C 5</i>	0	37	0	72	516	625
	<i>Total</i>	542	634	775	648	526	3125

Tabla 8-17: Características. Clasificador Perceptrón. Filtro Lee. Cinco Clases. Imagen dos.

	Sensibilidad (VPR)	Especificidad (VNR)	Exactitud (ACC)
<i>Clase 1</i>	86,7 %	100,0 %	97,3 %
<i>Clase 2</i>	94,1 %	98,2 %	97,3 %
<i>Clase 3</i>	98,6 %	93,6 %	94,6 %
<i>Clase 4</i>	92,2 %	97,1 %	96,1 %
<i>Clase 5</i>	82,6 %	99,6 %	96,2 %

Tabla 8-18: Matriz de confusión. Clasificador Perceptrón. Filtro Lee. Cinco clases. Imagen tres.

		Resultado de la Predicción					<i>Total</i>
		<i>C 1</i>	<i>C 2</i>	<i>C 3</i>	<i>C 4</i>	<i>C 5</i>	
Valor Real	<i>C 1</i>	504	0	118	0	3	625
	<i>C 2</i>	0	593	31	0	1	625
	<i>C 3</i>	0	0	625	0	0	625
	<i>C 4</i>	0	0	49	576	0	625
	<i>C 5</i>	4	25	0	236	360	625
	<i>Total</i>	508	618	823	812	364	3125

Tabla 8-19: Características. Clasificador Perceptrón. Filtro Lee. Cinco Clases. Imagen tres.

	Sensibilidad (VPR)	Especificidad (VNR)	Exactitud (ACC)
<i>Clase 1</i>	80,6 %	99,8 %	96,0 %
<i>Clase 2</i>	94,9 %	99,0 %	98,2 %
<i>Clase 3</i>	100,0 %	92,1 %	93,7 %
<i>Clase 4</i>	92,2 %	90,6 %	90,9 %
<i>Clase 5</i>	57,6 %	99,8 %	91,4 %

Tabla 8-20: Matriz de confusión. Clasificador Perceptrón. Filtro Lee. Cinco clases. Imagen cuatro.

		Resultado de la Predicción					<i>Total</i>
		<i>C 1</i>	<i>C 2</i>	<i>C 3</i>	<i>C 4</i>	<i>C 5</i>	
Valor Real	<i>C 1</i>	558	0	21	0	46	625
	<i>C 2</i>	0	591	19	0	15	625
	<i>C 3</i>	0	0	620	5	0	625
	<i>C 4</i>	0	0	14	611	0	625
	<i>C 5</i>	0	33	0	209	383	625
	<i>Total</i>	558	624	674	825	444	3125

Tabla 8-21: Características. Clasificador Perceptrón. Filtro Lee. Cinco Clases. Imagen cuatro.

	Sensibilidad (VPR)	Especificidad (VNR)	Exactitud (ACC)
<i>Clase 1</i>	89,3 %	100,0 %	97,9 %
<i>Clase 2</i>	94,6 %	98,7 %	97,9 %
<i>Clase 3</i>	99,2 %	97,8 %	98,1 %
<i>Clase 4</i>	97,8 %	91,4 %	92,7 %
<i>Clase 5</i>	61,3 %	97,6 %	90,3 %

Tabla 8-22: Matriz de confusión. Clasificador Perceptrón. Filtro Lee. Cinco clases. Imagen cinco.

		Resultado de la Predicción					<i>Total</i>
		<i>C 1</i>	<i>C 2</i>	<i>C 3</i>	<i>C 4</i>	<i>C 5</i>	
Valor Real	<i>C 1</i>	325	0	287	0	13	625
	<i>C 2</i>	0	590	29	0	6	625
	<i>C 3</i>	37	21	558	9	0	625
	<i>C 4</i>	0	0	8	617	0	625
	<i>C 5</i>	0	28	13	44	540	625
	<i>Total</i>	362	639	895	670	559	3125

Tabla 8-23: Características. Clasificador Perceptrón. Filtro Lee. Cinco Clases. Imagen cinco.

	Sensibilidad (VPR)	Especificidad (VNR)	Exactitud (ACC)
<i>Clase 1</i>	52,0 %	98,5 %	89,2 %
<i>Clase 2</i>	94,4 %	98,0 %	97,3 %
<i>Clase 3</i>	89,3 %	86,5 %	87,1 %
<i>Clase 4</i>	98,7 %	97,9 %	98,0 %
<i>Clase 5</i>	86,4 %	99,2 %	96,7 %

Tabla 8-24: Matriz de confusión. Clasificador Perceptrón. Filtro Lee. Cinco clases. Imagen seis.

	Resultado de la Predicción					
	<i>C 1</i>	<i>C 2</i>	<i>C 3</i>	<i>C 4</i>	<i>C 5</i>	
Valor Real						
<i>C 1</i>	476	0	149	0	0	625
<i>C 2</i>	0	565	60	0	0	625
<i>C 3</i>	0	19	564	40	2	625
<i>C 4</i>	0	0	0	624	1	625
<i>C 5</i>	0	74	14	59	478	625
<i>Total</i>	476	658	787	723	481	3125

Tabla 8-25: Características. Clasificador Perceptrón. Filtro Lee. Cinco Clases. Imagen seis.

	Sensibilidad (VPR)	Especificidad (VNR)	Exactitud (ACC)
<i>Clase 1</i>	76,2 %	100,0 %	95,2 %
<i>Clase 2</i>	90,4 %	96,3 %	95,1 %
<i>Clase 3</i>	90,2 %	91,1 %	90,9 %
<i>Clase 4</i>	99,8 %	96,0 %	96,8 %
<i>Clase 5</i>	76,5 %	99,9 %	95,2 %

Tabla 8-26: Matriz de confusión. Clasificador Perceptrón. Filtro Lee. Cinco clases. Imagen siete.

		Resultado de la Predicción					<i>Total</i>
		<i>C 1</i>	<i>C 2</i>	<i>C 3</i>	<i>C 4</i>	<i>C 5</i>	
Valor Real	<i>C 1</i>	292	0	252	0	81	625
	<i>C 2</i>	0	601	1	0	23	625
	<i>C 3</i>	0	11	587	27	0	625
	<i>C 4</i>	0	1	3	618	3	625
	<i>C 5</i>	0	27	49	4	545	625
	<i>Total</i>	292	640	892	649	652	3125

Tabla 8-27: Características. Clasificador Perceptrón. Filtro Lee. Cinco Clases. Imagen siete.

	Sensibilidad (VPR)	Especificidad (VNR)	Exactitud (ACC)
<i>Clase 1</i>	46,7 %	100,0 %	89,3 %
<i>Clase 2</i>	96,2 %	98,4 %	98,0 %
<i>Clase 3</i>	93,9 %	87,8 %	89,0 %
<i>Clase 4</i>	98,9 %	98,8 %	98,8 %
<i>Clase 5</i>	87,2 %	95,7 %	94,0 %

Tabla 8-28: Matriz de confusión. Clasificador Perceptrón. Filtro Lee. Cinco clases. Imagen ocho.

		Resultado de la Predicción					<i>Total</i>
		<i>C 1</i>	<i>C 2</i>	<i>C 3</i>	<i>C 4</i>	<i>C 5</i>	
Valor Real	<i>C 1</i>	292	0	252	0	81	625
	<i>C 2</i>	0	601	1	0	23	625
	<i>C 3</i>	0	11	587	27	0	625
	<i>C 4</i>	0	1	3	618	3	625
	<i>C 5</i>	0	27	49	4	545	625
	<i>Total</i>	292	640	892	649	652	3125

Tabla 8-29: Matriz de confusión. Clasificador Fuzzy c-means. Filtro Lee.

	Resultado de la Predicción							<i>Total</i>
	<i>C 1</i>	<i>C 2</i>	<i>C 3</i>	<i>C 4</i>	<i>C 5</i>	<i>C 6</i>	<i>C 7</i>	
<i>C 1</i>	3633	50	920	111	45	241	0	5000
<i>C 2</i>	0	4403	1	0	589	7	0	5000
<i>C 3</i>	51	50	3962	33	512	392	0	5000
<i>C 4</i>	0	50	123	4078	731	18	0	5000
<i>C 5</i>	0	1	1	13	4680	305	0	5000
<i>C 6</i>	364	50	316	57	233	3980	0	5000
<i>C 7</i>	0	0	0	0	0	0	0	0
<i>Total</i>	4448	5910	5088	3827	3590	7137	0	30000

Valor Real

Tabla 8-30: Matriz de confusión. Clasificador Perceptrón Multicapa. Filtro Lee.

	Resultado de la Predicción							<i>Total</i>
	<i>C 1</i>	<i>C 2</i>	<i>C 3</i>	<i>C 4</i>	<i>C 5</i>	<i>C 6</i>	<i>C 7</i>	
<i>C 1</i>	2384	64	994	0	4	1554	0	5000
<i>C 2</i>	0	4914	28	0	23	35	0	5000
<i>C 3</i>	49	163	4671	0	0	118	0	5000
<i>C 4</i>	7	154	344	4246	247	2	0	5000
<i>C 5</i>	10	118	12	22	4004	834	0	5000
<i>C 6</i>	2020	118	56	22	602	2181	1	5000
<i>C 7</i>	0	0	0	0	0	0	0	0
<i>Total</i>	4448	5910	5088	3827	3590	7137	1	30000

Valor Real

Tabla 8-31: Matriz de confusión. Clasificador Votación. Filtro Lee.

		Resultado de la Predicción							<i>Total</i>
		<i>C 1</i>	<i>C 2</i>	<i>C 3</i>	<i>C 4</i>	<i>C 5</i>	<i>C 6</i>	<i>C 7</i>	
Valor Real	<i>C 1</i>	3660	64	694	9	12	561	0	5000
	<i>C 2</i>	0	4923	1	0	47	29	0	5000
	<i>C 3</i>	60	163	4163	1	328	285	0	5000
	<i>C 4</i>	6	154	143	4062	627	8	0	5000
	<i>C 5</i>	5	118	0	18	4351	508	0	5000
	<i>C 6</i>	444	118	102	24	198	4114	0	5000
	<i>C 7</i>	0	0	0	0	0	0	0	0
	<i>Total</i>	4175	5540	5103	4114	5563	5505	0	30000

9 Anexo 3. Pseudocódigos.

9.1. Introducción

En ésta sección se presenta el pseudocódigo de algunas funciones empleadas para el procesamiento de las imágenes satelitales de radar. Se elaboraron ciento treinta programas en C++ utilizando la librería OpenCV, y se implementaron cuarenta función como una librería complementaria. Se implementó todo en un equipo Intel(R) Pentium(R) Dual CPU T2390 @ 1.86GHz, con 2,5 GB de memoria RAM en una plataforma con Ubuntu.

Función Altura_Ventana

Esta función calcula el nuevo tamaño de la ventana para el filtro adaptativo. La función *Altura_Ventana*, recibe cuatro parámetros: la imagen a procesar *ImagenLeida*; el tamaño actual de la ventana N ; la coordenada x y la coordenada y de la región de la imagen a estudiar. La función retorna el nuevo valor del tamaño de la ventana. El pseudocódigo de la función *Altura_Ventana* consta de los siguientes ítem:

1. Se definen las variables de entrada.
2. Se verifican que los valores de x y y no estén por fuera de la imagen.
3. Se verifica que la combinación de x , y y N no estén por fuera de la imagen.
4. Se selecciona de la imagen la zona de estudio.
5. Se hallan los píxeles de la frontera externa para la ventana de tamaño N , con su centro en las coordenadas (x, y) , llamando a la función *Perimetro_Ventana*.
6. Si los píxeles del perímetro son todos uno, se deja el mismo tamaño de ventana y se retorna el valor de N . Esto significa que se esta por fuera de la imagen.
7. Se comparan las dos regiones: los píxeles al interior de la ventana de tamaño N y los del perímetro, utilizando los momentos de H_u empleando una determinada métrica.
8. Se utiliza como umbral el valor de 0.1 para determinar que tan similares son las regiones.
9. Si las regiones son similares, se aumenta el tamaño de la ventana a $N + 2$ y se retorna el nuevo valor de N .

10. Si las regiones no son similares, se compara la región interna de la ventana $N - 2$ (centrada en (x, y)), con los píxeles de la frontera externa utilizando los momento de Hu.
11. Si la región interna de la ventana $N - 2$ no es similar a la región del perímetro, se retorna el nuevo valor de $N - 2$ para el tamaño de la ventana.
12. Si la región interna de la ventana $N - 2$ y su perímetro son similares el tamaño de la ventana se mantiene en N y se retorna éste valor.

Función Perimetro_Ventana

Esta función halla los píxeles de la frontera de la ventana de estudio. Recibe como parámetros: la imagen a procesar, el tamaño de la ventana actual y las coordenadas del píxel central. La función retorna una imagen con los píxeles de la frontera. El pseudocódigo de la función Perimetro_Ventana consta de los siguientes ítem:

1. Se definen las variables de entrada.
2. Se halla coordenada (x, y) de la esquina superior de la ventana de estudio.
3. Se verifica que no se este por fuera de la imagen.
4. Se seleccionan los píxeles del perímetro exterior de la ventana de estudio.
5. Se crea una imagen con los píxeles de la frontera de la imagen.
6. Se retorna la imagen creada con los píxeles de la frontera.

Función Evaluar_Filtro

Esta función evalúa el rendimiento de los filtros. Recibe como parámetros: la imagen con ruido; la imagen filtrada; coordenadas (x, y) del lugar a hacer la evaluación; tamaño de la ventana; matriz donde se guardan los resultados y coordenadas (xc, yc) del contorno. La función retorna la matriz con los 12 parámetros medidos. El pseudocódigo de la función Evaluar_Filtro consta de los siguientes ítem:

1. Se definen las variables de entrada.
2. Se halla media y desviación estándar de la imagen con ruido y la imagen filtrada en las coordenadas (x, y) .
3. Se almacena la media (por canal) de la imagen con ruido en la columna 8 de la matriz *resultados*.

4. Se almacena la desviación estándar (por canal) de la imagen con ruido en la columna 9 de la matriz *resultados*.
5. Se almacena la media (por canal) de la imagen filtrada en la columna 10 de la matriz *resultados*.
6. Se almacena la desviación estándar (por canal) de la imagen filtrada en la columna 11 de la matriz *resultados*.
7. Se halla el valor de *SNR* y se almacena en la columna 0 de la matriz *resultados*.
8. Se halla el valor de *ENL* y se almacena en la columna 1 de la matriz *resultados*.
9. Se halla el valor de *SSI* y se almacena en la columna 2 de la matriz *resultados*.
10. Se halla el valor de *SMPI* y se almacena en la columna 3 de la matriz *resultados*.
11. Se halla el valor de *EEI* y se almacena en la columna 4 de la matriz *resultados*.
12. Se halla el valor de *EPI* y se almacena en la columna 5 de la matriz *resultados*.
13. Se halla el valor de *Q* y se almacena en la columna 6 de la matriz *resultados*.
14. Se halla el valor de *RMSE* y se almacena en la columna 7 de la matriz *resultados*.

Filtro Moda

Esta función realiza el filtrado de la región de interés aplicando el filtro moda. Recibe como parámetros: la imagen a filtrar, el tamaño de la ventana de filtrado y las coordenadas del píxel a procesar. Retorna el nuevo valor del píxel central aplicando el filtro moda. El pseudocódigo de la función consta de los siguientes ítem:

1. Se ubica píxel central (x, y) de la ventana de tamaño $N \times N$.
2. Se halla el histograma, $P(I)$, de la región de interés.
3. Se determina el máximo de la función $P(I)$.
4. Se encuentra el nivel de intensidad I_m asociado al máximo de $P(I)$.
5. Se asigna el valor I_m al píxel (x, y) .
6. Se desliza la ventana.

10 Anexo 4. Momentos.

En ésta sección presentamos un breve resumen de los momentos estadísticos, que son una medida cuantitativa de un conjunto de datos. Un momento estadístico es una función medible, que dada una muestra estadística de valores les asigna un número, que sirve para estimar o inferir características de una población. En nuestro caso los valores que tomamos para calcular los momentos fueron las intensidades de cada píxel en las regiones de estudio.

10.1. Momentos en una dimensión

Sea I_i , donde $i = 0, 1, 2, \dots, L - 1$, represente todos los posibles valores de intensidad en una imagen digital de $M \times N$. La probabilidad, $p(I_i)$ de que el nivel de intensidad I_i aparezca en una image se calcula con la expresión 10-1 .

$$p(I_i) = \frac{n_i}{MN} \quad (10-1)$$

Donde n_i representa el número de veces que el nivel de intensidad I_i aparece en la imagen y NM es el número total de píxeles de la imagen. Evidentemente la suma de las probabilidades es uno como muestra la ecuación 10-2.

$$\sum_{i=0}^{L-1} p(I_i) = 1 \quad (10-2)$$

La media de las intensidades esta dada por la ecuación 10-3.

$$m = \sum_{i=0}^{L-1} I_i p(I_i) \quad (10-3)$$

Similarmente la varianza de las intensidades esta dada por la ecuación 10-4.

$$\sigma^2 = \sum_{i=0}^{L-1} (I_i - m)^2 p(I_i) \quad (10-4)$$

La varianza es una medida de que tanto están separados los valores de I_i al rededor de la media y es una medida útil para el contraste de la imagen. En general el n-simo momento de una variable aleatoria I alrededor de la media esta dado por la ecuación 10-5.

$$\mu_n(I) = \sum_{i=0}^{L-1} (I_i - m)^n p(I_i) \quad (10-5)$$

Podemos apreciar que $\mu_0(I) = 1$, $\mu_1(I) = 0$ y $\mu_2(I) = \sigma^2$. Mientras que la media y la varianza tienen una relación obvia e inmediata con las propiedades visuales de una imagen, los momentos de mayor orden son más sutiles. Por ejemplo, un momento de tercer orden positivo indica que las intensidades están corridas hacia valores mayores que la media, un momento de tercer orden negativo indica la condición contraria, y un momento de tercer orden cero indica que las intensidades están distribuidas igualmente a ambos lados de la media [72].

10.2. Momentos invariantes 2D

Los momentos en dos dimensiones de orden $(p + q)$ de una imagen digital $f(x, y)$ de tamaño $M \times N$ están definidos por la ecuación 10-6.

$$m_{pq} = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} x^p y^q f(x, y) \quad (10-6)$$

donde p y q son enteros tales que $p = 0, 1, 2, \dots$ y $q = 0, 1, 2, \dots$. Los correspondientes momentos centrales de orden $(p + q)$ se definen como la ecuación 10-7.

$$\mu_{pq} = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} (x - \bar{x})^p (y - \bar{y})^q f(x, y) \quad (10-7)$$

para $p = 0, 1, 2, \dots$ y $q = 0, 1, 2, \dots$, donde \bar{x} está descrito por la ecuación 10-8, y \bar{y} por la ecuación 10-9.

$$\bar{x} = \frac{m_{10}}{m_{00}} \quad (10-8)$$

$$\bar{y} = \frac{m_{01}}{m_{00}} \quad (10-9)$$

Los momentos centrales normalizados, denotados por η_{pq} , se definen como indica la ecuación 10-10 .

$$\eta_{pq} = \frac{\mu_{pq}}{\mu_{00}^\gamma} \quad (10-10)$$

donde γ está definido por la ecuación 10-11.

$$\gamma = \frac{p + q}{2} + 1 \quad (10-11)$$

para $p + q = 2, 3, \dots$

Un conjunto de siete momentos invariantes puede ser derivado de los momentos de segundo y tercer orden. Estos momentos son invariantes a traslación, escalado reflexión y rotación [70] [71] y son conocidos como los momentos invariantes de Hu (ver Tabla 10-1).

Tabla 10-1: Momentos invariantes de Hu

$h_1 = \eta_{20} + \eta_{02}$
$h_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2$
$h_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2$
$h_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2$
$h_5 = (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] +$ $(3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]$
$h_6 = (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] +$ $4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03})$
$h_7 = (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] -$ $(\eta_{30} - 3\eta_{12})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]$

11 Anexo 5. Evaluación del Clasificador binario.

11.1. Clasificador binario.

El clasificador binario clasifica los miembros de un conjunto de objetos en dos clases o grupos, de acuerdo al hecho que cumplan un determinado número de propiedades o características.

11.2. Matriz de confusión.

Para evaluar el desempeño de los clasificadores se utiliza la matriz de confusión, la cual nos permite ver si el sistema está confundiendo dos clases. Para construir la matriz de confusión utilizamos una imagen de plantilla (que nos da los valores reales de correspondencia de cada píxel), y se compara con la imagen clasificada. En la matriz se registra a que clase corresponde cada píxel según el clasificador y según la plantilla. Los valores de la filar corresponden a los datos reales y los de las columnas a los resultados de la predicción del clasificador.

Verdadero Positivo

Los Verdaderos Positivos (VP), son los pixeles clasificados correctamente, son los éxitos. En ingles "True Positives", TP.

Verdaderos Negativos

Los Verdaderos Negativos (VN), son lo pixeles que no son de una determinada clase que son rechazados correctamente, es decir los falsos rechazos. En ingles "True Negatives", TN.

Falsos Positivos

Los Falsos Positivos (FP), son las falsas alarmas, son los pixeles clasificados como pertenecientes a una clase cuando no son de esa clase. En ingles "False Positives", FP.

Falsos Negativos

Los Falsos Negativos (FN), son los falsos rechazos. Los falsos negativos son los píxeles que son de la clase pero que se clasifican en otra clase. En inglés "False Negatives", FN.

Sensibilidad

La sensibilidad o Razón de Verdaderos Positivos (VPR) es la habilidad del clasificador para clasificar correctamente a un píxel de una determinada clase. Se define como la ecuación .

$$VPR = \frac{VP}{VP + FN} \quad (11-1)$$

Especificidad

La Especificidad (SPC) o Razón de Verdaderos Negativos (VNR) es la capacidad del clasificador para descartar los píxeles que no pertenecen a la clase en estudio. se define según la ecuación .

$$VNR = \frac{VN}{VN + FP} \quad (11-2)$$

A continuación presentamos como ejemplo, el calculo realizado para hallar los coeficientes estadísticos, utilizando los datos de la Tabla **12-1** que contiene medidas utilizando el clasificador Bayesiano. Para el estudio de la CLASE 1 hallamos los valores:

1. Verdaderos Positivos. $VP = 3570$.
2. Verdaderos Negativos. $VN = 24122$.
3. Falsos Positivos. $FP = 878$.
4. Falsos Negativos. $FN = 1430$.

Con los valores de la lista anterior, se calculan los siguientes coeficientes:

- Sensibilidad (VPR) = $\frac{VP}{VP + FN} = \frac{3570}{3570 + 1430} = \frac{3570}{5000} = 71,4\%$
- Especificidad (VNR) = $\frac{VN}{FP + VN} = \frac{24122}{24122 + 878} = \frac{24122}{25000} = 96,4\%$
- Exactitud (ACC) = $\frac{VP + VN}{VP + FN + FP + VN} = \frac{27692}{30000} = 92,3\%$

12 Anexo 6. Tablas II

Tabla 12-1: Matriz de confusión. Clasificador de Bayes. Filtro Lee.

		Resultado de la Predicción						<i>Total</i>	
		<i>C 1</i>	<i>C 2</i>	<i>C 3</i>	<i>C 4</i>	<i>C 5</i>	<i>C 6</i>		<i>C 7</i>
Valor Real	<i>C 1</i>	3570	50	385	356	0	639	0	5000
	<i>C 2</i>	0	4785	1	0	5	209	0	5000
	<i>C 3</i>	127	60	4040	38	0	735	0	5000
	<i>C 4</i>	396	803	19	3363	3	416	0	5000
	<i>C 5</i>	30	152	501	0	3377	940	0	5000
	<i>C 6</i>	325	60	142	70	205	4198	0	5000
	<i>C 7</i>	0	0	0	0	0	0	0	0
	<i>Total</i>	4448	5910	5088	3827	3590	7137	0	30000

Tabla 12-2: Características. Clasificador Bayesiano.

	Sensibilidad (VPR)	Especificidad (VNR)	Exactitud (ACC)
<i>Clase 1</i>	71,4 %	96,5 %	92,3 %
<i>Clase 2</i>	95,7 %	95,5 %	95,5 %
<i>Clase 3</i>	80,8 %	95,8 %	93,3 %
<i>Clase 4</i>	67,3 %	98,1 %	93,0 %
<i>Clase 5</i>	67,5 %	99,1 %	93,9 %
<i>Clase 6</i>	84,0 %	88,2 %	87,5 %
<i>Promedio</i>	77,8 %	95,5 %	92,5 %

Tabla 12-3: Características. Clasificador Fuzzy c-means.

	Sensibilidad (VPR)	Especificidad (VNR)	Exactitud (ACC)
<i>Clase 1</i>	72,7 %	98,3 %	94,1 %
<i>Clase 2</i>	88,1 %	99,2 %	97,3 %
<i>Clase 3</i>	79,2 %	94,6 %	92,0 %
<i>Clase 4</i>	81,6 %	99,1 %	96,2 %
<i>Clase 5</i>	93,6 %	91,6 %	91,9 %
<i>Clase 6</i>	79,6 %	96,1 %	93,4 %
<i>Promedio</i>	82,5 %	96,5 %	94,2 %

Tabla 12-4: Características. Clasificador Perceptrón Multicapa.

	Sensibilidad (VPR)	Especificidad (VNR)	Exactitud (ACC)
<i>Clase 1</i>	47,7 %	91,7 %	84,3 %
<i>Clase 2</i>	98,3 %	97,5 %	97,7 %
<i>Clase 3</i>	93,4 %	94,3 %	94,1 %
<i>Clase 4</i>	84,9 %	99,8 %	97,3 %
<i>Clase 5</i>	80,1 %	96,5 %	93,8 %
<i>Clase 6</i>	43,6 %	89,8 %	82,1 %
<i>Promedio</i>	74,7 %	94,9 %	91,6 %

Tabla 12-5: Características. Clasificador Votación.

	Sensibilidad (VPR)	Especificidad (VNR)	Exactitud (ACC)
<i>Clase 1</i>	73,2 %	97,9 %	93,8 %
<i>Clase 2</i>	98,5 %	97,5 %	97,7 %
<i>Clase 3</i>	83,3 %	96,2 %	94,1 %
<i>Clase 4</i>	81,2 %	99,8 %	96,7 %
<i>Clase 5</i>	87,0 %	95,2 %	93,8 %
<i>Clase 6</i>	82,3 %	94,4 %	92,4 %
<i>Promedio</i>	84,3 %	96,8 %	94,8 %

Tabla 12-6: Razón de Verdaderos positivos. Evaluación Perceptrón. Capa oculta.

N	3	8	13	18	23	28	33	38	43	48	53
<i>Clase 1</i>	57.6	46.7	52.5	47.2	54.6	47.0	45.9	39.4	54.7	48.0	57.1
<i>Clase 2</i>	99.2	96.2	95.0	95.8	91.4	96.6	93.0	97.8	94.2	97.6	97.0
<i>Clase 3</i>	95.8	93.9	94.7	95.4	90.2	91.7	94.2	81.1	90.7	92.3	84.2
<i>Clase 4</i>	82.1	98.9	99.2	97.0	97.4	96.2	98.9	99.5	99.2	97.9	97.6
<i>Clase 5</i>	77.4	87.2	80.3	84.3	85.4	86.4	83.8	84.5	84.8	85.5	85.3
<i>Promedio</i>	82.4	84.5	84.3	83.9	83.8	83.5	83.1	80.4	84.7	84.2	84.2

VPR \Rightarrow Sensibilidad.**Tabla 12-7:** Filtro de Lee ($\sigma_n = 6,0$). Ruido 30%. Adaptativa $Umbral = 0,10$.

Ventana	SNR	σ_{SNR}	EEI	σ_{EEI}	RMSE	σ_{RMSE}
$N = 3$	13,33	0,47	1,00	0,04	20,02	0,07
$N = 5$	22,26	0,98	0,61	0,02	20,82	0,04
$N = 7$	31,56	1,73	0,44	0,01	22,96	0,04
$N = 9$	41,03	2,57	0,36	0,01	25,18	0,03
$N = 11$	50,76	3,45	0,30	0,01	27,30	0,02
<i>Adaptativa</i>	37,77	2,17	0,99	0,04	20,17	0,08

Tabla 12-8: Relación de Fisher. Entre Clases. Clase 1.

	$C_1 \leftrightarrow C_2$	$C_1 \leftrightarrow C_3$	$C_1 \leftrightarrow C_4$	$C_1 \leftrightarrow C_5$	$C_1 \leftrightarrow C_6$
x_1	103,58	12,86	6,96	164,84	43,32
x_2	210,75	48,63	15,32	88,43	20,47
x_3	111,43	246,32	8,44	187,90	201,13
x_4	1,57	8,35	5,43	1,33	0,09
x_5	14,29	0,09	20,26	6,46	0,73
x_6	5,01	12,59	15,91	16,03	2,21
x_7	150,01	83,34	11,00	201,09	72,97

Tabla 12-9: Relación de Fisher. Entre Clases. Clase 2.

	$C_2 \leftrightarrow C_3$	$C_2 \leftrightarrow C_4$	$C_2 \leftrightarrow C_5$	$C_2 \leftrightarrow C_6$
x_1	56,65	88,02	25,50	46,21
x_2	90,14	76,46	79,71	69,16
x_3	32,89	128,62	39,66	32,43
x_4	2,24	1,77	5,64	1,00
x_5	16,48	6,46	3,88	12,18
x_6	32,82	3,92	2,13	13,19
x_7	63,69	124,72	45,95	56,37

Tabla 12-10: Relación de Fisher. Entre Clases. Clase 3.

	$C_3 \leftrightarrow C_4$	$C_3 \leftrightarrow C_5$	$C_3 \leftrightarrow C_6$
x_1	3,82	32,39	3,41
x_2	1,52	2,92	0,43
x_3	225,76	3,26	0,00
x_4	0,03	17,57	7,04
x_5	21,80	8,21	0,39
x_6	51,31	60,26	3,91
x_7	48,19	10,96	0,23

Tabla 12-11: Relación de Fisher. Entre Clases. Clase 4.

	$C_4 \leftrightarrow C_5$	$C_4 \leftrightarrow C_6$
x_1	165,20	25,89
x_2	6,05	0,23
x_3	182,51	198,72
x_4	9,85	4,62
x_5	12,05	20,35
x_6	1,02	27,10
x_7	154,65	42,48

Tabla 12-12: Relación de Fisher. Entre clases. Clase 5.

	$C_5 \leftrightarrow C_6$
x_1	20,77
x_2	3,47
x_3	2,55
x_4	2,34
x_5	6,74
x_6	29,41
x_7	5,45

Tabla 12-13: Relación de Fisher. Entre clases.

	$C_i \leftrightarrow C_1$	$C_i \leftrightarrow C_2$	$C_i \leftrightarrow C_3$	$C_i \leftrightarrow C_4$	$C_i \leftrightarrow C_5$	$C_i \leftrightarrow C_6$
C_1	0	127,81	44,31	12,98	115,83	38,35
C_2	—	0	55,03	90,68	41,33	47,52
C_3	—	—	0	26,64	18,73	1,71
C_4	—	—	—	0	49,28	25,19
C_5	—	—	—	—	0	7,95
C_6	—	—	—	—	—	0

13 Bibliografia

Bibliografía

- [1] Posada, Elena y Santacruz, Alí. Clasificación de los estados fenomenológicos del cultivo de arroz a partir de imágenes de RADARSAT-2 mediante el programa PolSarpro. Análisis Geográfico. Revista del Instituto Geográfico Agustín Codazzi. No 44. 2010. ISSN 0120-8551. pp. 73-82.
- [2] Liaghat, S. and Balasundram, S. A review: the role of remote sensing in precision agriculture. American Journal of Agricultural and Biological Sciences 5 (1). pp. 50-55. 2010.
- [3] Fundamentals of Remote Sensing. A Canada Centre of Remote Sensing. Remote Sensing Tutorial. Natural Resources Canada.<http://www.nrcan.gc.ca/earth-sciences/geography-boundary/remote-sensing/funda>
- [4] Radar Polarimetry. Advanced Radar Polarimetry Tutorial. Canada Centre for Remote Sensing. http://ccrs.nrcan.gc.ca/resource/index_e.php#tutor.
- [5] Lee, Jong-Sen and Pottier, Eric. Polarimetric Radar Imaging from Basic to Applications. Optical Science and Engineering. University of Rochester. Rochester, New York. Taylor and Francis Grup. 2009.
- [6] Wangsness, Roald K. Campos Electromagnéticos. Editorial Limusa, S.A. de C.V. Grupo Noriega Editores. Balderas 95, México, D.F. 1994. ISBN 968-18-1316-2.
- [7] Hecht, Eugene y Zajac, Alfred. Optica. Addison Wesley Iberoamericana, S.A. Wilmington, Delaware, E.U.A. 1986.
- [8] <http://gs.mdacorporation.com/>
- [9] Lira Chávez, Jorge. Introducción al Tratamiento Digital de Imágenes. Instituto de Geofísica. UNAM. Fondo de Cultura Económica. 2002.
- [10] Anfinson, Stian N., Doulgeris, Anthony and Eltoft, Torbjorn. Estimation of the Equivalent Number of Looks in Polarimetric SAR Imagery. Department of Physics and Technology University of Tromso. Norway. DRAFT. January 14, 2008.
- [11] Serkan, M. Musaoglu, N. Kirkici, H. and Ormeci, C. Edge and Fine Detail Preservation in SAR Images Through Speckle Reduction with an Adaptive Mean Filter. International Journal of Remote Sensing. Vol. 29. N° 23. 10 December 2008. pp. 6727-6738.

-
- [12] Bermúdez G., D.; Jarabo A., P.; Nieto B., J.C.; De la Mata M., D. y Gil P., R. Estudio comparativo de algoritmos para la reducción del *speckle* en imágenes SAR. XXI Simposium Nacional de la Union Científica Internacional de Radio. Libro de Actas- URSI 2006. pp. 618-621.
- [13] Baraldi, A. and Parmiggiani, F. Note. An alternative form of the Lee filter for speckle suppression in SAR images. Graphical Models and Image Processing. Vol. 57. N° 1. January. 1995. pp. 75-78.
- [14] Lee, Jong-Sen; Wen, Jen-Hung; Ainsworth, Thomas L.; Chen, Kun-Shan and Chen, Abel J. Improved sigma filter for speckle filtering of SAR imagery. IEEE Transactions on Geoscience and Remote Sensing. Vol. 47. N° 1. January 2009. pp. 202-213.
- [15] Lee, J.S. Speckle suppression and analysis for synthetic aperture radar images. Optical Engineering (ISSN 0091-3286). Vol. 25. May 1986 pp. 636-643.
- [16] Lee, J.S. A simple speckle smoothing algorithm for synthetic aperture radar images. IEEE Transactions on Systems, Man and Cybernetics. Vol 13. N° 1. 1983. pp. 85-89.
- [17] Gagnon, L. and Jouan, A. Speckle Filtering of SAR images - A Comparative Study Between Complex-Wavelet-Based and Standard Filters. In Proc. SPIE # 3169. San Diego. 1997. pp. 80-91.
- [18] Cóbreces Álvarez, Ana María; Rosa Zurera, Manuel, Vicen Bueno, Raúl y Sáez Landete, Jose B. Reducción de ruido *speckle* sobre imágenes SAR en el dominio wavelet. XXI Simposium Nacional de la Union Científica Internacional de Radio. Libro de Actas- URSI 2006. pp. 612-615.
- [19] Vidal-Pantaleoni, A. and Martí, D. Comparison of different speckle-reduction techniques in SAR images using wavelet transform. International Journal of Remote Sensing. Vol. 25. N° 22. 2004. pp. 4915-4932.
- [20] Buemi, María Elena; Jacobo, Julio and Mejai, Marta. SAR image processing using adaptive stack filter. Pattern Recognition Letters. Vol. 31. 2010. pp. 307-314.
- [21] Huang, Shi-qi; Liu, Dai-zhi; Gao, Gui-qing and Guo, Xi-jian. A novel method for speckle noise reduction and ship target detection in SAR images. Pattern Recognition. Vol 42. 2009. pp. 1533-1542.
- [22] Jie, Chen; Jing, Zhu; Chunsheng, Li; Yinqing. A novel speckle filter for SAR images based on information-theoretic heterogeneity measurements. Chinese Journal of Aeronautics. Vol. 22. 2009. pp. 528-534.

-
- [23] Tetuko, Josaphat; Sumantyo, Sri and Amini, Jalal. A model for removal of speckle noise in SAR images (ALOS PALSAR). *Canadian Journal of Remote Sensing*. Vol 34. N° 6. 2008. pp. 503-515.
- [24] Su, Jingtang and Ma, Hongbing. A new speckle reduction algorithm for SAR images. *Asian and Pacific Conference on Synthetic Aperture Radar Proceedings. APSAR 2007. 1st Asian and Pacific Conference on*. 05/12/2007.
- [25] Nyoungui, A. Ndi; Tonye, E. and Akono, A. Avaluation of speckle filtering and texture analysis methods for land cover classification from SAR images. *International Journal of Remote Sensing*. Vol. 23. N° 9. 2002. pp. 1895-1925.
- [26] Zhang, Y.; Huang, H.; Chen, X.;Wu, J. Mapping Paddy Rice Biomass Using ALOS/PALSAR Imagery. *International Workshop on Education Technology and Training & 2008 International Workshop on Geoscience and Remote Sensing*. pp. 207 - 210.
- [27] García-Pineda, Oscar; Zimmer, Beate; Howard, Matt; Pichel, William; Li, Xiaofeng and MacDonald, Ian R. Using SAR images to delineate ocean oil slicks with a texture-classifying neural network algorithm (TCNNA). *Canada Journal of Remote Sensing*. Vol. 35. N° 5. pp. 411-421. 2009.
- [28] Choudhury, Indrani and Chakraborty, M. SAR signature investigation of rice crop using RADARSAT data. *International Journal of Remote Sensing*. Vol 27. N° 3. February 2006. pp. 519-534.
- [29] Shao, Yun; Fan, Xiangtao; Liu, Hao; Xiao, Jianhua; Ross, S.; Brisco, B.; Brown, R.; Staples, G. Rice monitoring and production estimation using multitemporal RADARSAT. *Remote Sensing of Environment*. Vol. 76. 2001. pp. 310-325.
- [30] Chakraborty, M.; Manjunath, K.R.; Panigrahy, S.; Kundu, N. and Parihar, J.S. Rice croa parameter retrieval using multi-temporal, multi-incidence angle Radarsat SAR date. *ISPRS Journal of Photogrammetry and Remote Sensing*. Vol. 59. 2005. pp. 310-322.
- [31] Chakraborty, M. and Panigrahy, S. A processing and software system for rice crop inventory using multi-date RADARSAT ScanSAR data. *ISPRS Journal of Photogrammetry and Remote Sensing*. Vol. 55. 2000. pp. 119-128.
- [32] Zhang, Yuan.; Wang, Cuizhen.; Wu, Jiaping.; Qi, Jiaguo.; Sala, William. Mapping paddy rice with multitemporal ALOS/PALSAR imagery in southeast China. *International Journal of Remote Sensing*. Vol. 30, No. 23. December 2009. pp. 6301–6315.
- [33] Wang, Cuizhen; Wu, Jiaping; Zhang, Yuan; Pan, Guangdong; Qi, Jiaguo and Salas, Willian. Characterizing L-band scattering of paddy rice in southeast China with radiative transfer model and multitemporal ALOS/PALSAR imagery. *IEEE Transactions on Geoscience and Remote Sensing*. Vol. 47. N° 4. Abril 2009. pp. 988-998.

-
- [34] López, J.M. and Fortuny, J. Estimación de la altura de cosechas mediante interferometría polarimétrica radar: experimentos en laboratorio. *Telecomunicación, Medio Ambiente y Cambio global*. 2001. pp. 70-73.
- [35] Panigrahy, S.; Manjunath, K.R.; Chakraborty, M.; Kundu, N. and Parihar, J.S. Evaluation of RADARSAT standard beam for identification of potato and rice crops in Indian. *ISPRS Journal of Photogrammetry and Remote Sensing*. Vol. 54. 1999. pp. 254-262.
- [36] Oza, S.R.; Panigrahy, S. and Parihar, J.S. Concurrent use of active and passive microwave remote sensing data for monitoring of rice crop. *International Journal of Applied Earth Observation and Geoinformation*. Vol. 10. September 2008. pp. 296-304.
- [37] Dong, Yanfang; Pang, Yong; Sun, Guoqing; Zhang, Zhongjun. Radar Backscatter of Rice Fields From ASAR Data and Modeling. *Geoscience and Remote Sensing Symposium, 2004. IGARSS '04. Proceedings. 2004 IEEE International*. Vol.6. Sept. 2004. pp. 4332 - 4335.
- [38] Beaulieu, Jean-Marie and Touzi, Ridha. Classification of Polarimetric SAR Images Using Radiometric and Texture Information. *Geoscience and Remote Sensing Symposium, 2008. IGARSS 2008. IEEE International*. July 2008. pp. IV - 29 - IV - 32.
- [39] Waske, Bjorn; Braun, Matthias and Menz, Gunter. A segment-based speckle filter using multisensoral remote sensing imagery. *IEEE Geoscience and Remote Sensing Letters*. Vol. 4. N°2. April 2007. pp. 231-235.
- [40] Lee, Jong-Sen; Hoppel, Karl W.; mango, Stephen A. and Miller, Allen R. Intensity and phase statistics of multilook polarimetric and interferometric SAR imagery. *IEEE Transactions on Geoscience and Remote Sensing*. Vol. 32. N° 5. September 1994. pp. 1017-1028.
- [41] Lira, J. and Frulla, L. An Automated region Growing for Segmentation of Texture Regions in SAR images. *International Journal of Remote Sensing*. Vol. 19, N° 18. 1998. pp 3595-3606.
- [42] Li, W.; Béné, G.B. He, D.-C. Wang, S.; Ziou, D and Gwyn, H.J. Classification of SAR images using morphological texture features. *International Journal of Remote Sensing*. Vol. 19. N° 17. 1998. pp. 3399-3410.
- [43] Rajesh, K.; Jawahar, C.V.; Sengupta, S. and Sinha, S. Performance analysis of textural features for characterization and classification of SAR images. *International Journal of Remote Sensing*. Vol. 22. N° 8. 2001. pp. 1555-1569.
- [44] Du, L.; Grunes, M.R. and Lee, J.S. Unsupervised segmentation of dual-polarization SAR images based on amplitude and texture characteristics. *International Journal of Remote Sensing*. Vol. 23. N° 20. 2002. pp. 4383-4402.

-
- [45] Fu, K.S. and Mui, J.K. A Survey on Image Segmentation. *Pattern Recognition*.13:3–16, 1981.
- [46] Sahoo, P.K. Soltani, S. Wong, A.K.C. and Chen, Y.C. A Survey of Thresholding Techniques. *Computer Vision, Graphics and Image Processing*, 41:233–260, 1988.
- [47] Wang, Rong. Gao, Li-Qun. Yang, Shu and Liu and Yan Chun. An Edge Detection Method By combining fuzzy logic and neural network. *Proceedings of the Fourth International Conference on Machine Learning and Cybernetics, Guangzhou, 18-21 August 2005*
- [48] Wong, H.S. and Guan, L. A Neural Learning Approach for Adaptive Image Restoration Using a Fuzzy Model-based Network Architecture. *IEEE Trans,Neural Network* 12 (3) (2001) 516-531.
- [49] Atkinson,P.M. and Tatnall, A.R.L. Introduction Neural networks in remote sensing. *Int. J. Remote Sensing*. 1997.Vol. 18.N 4, 699-709.
- [50] Tamura, Hideyki. Mori, Shunji and Yamawaki, Takashi. Textural Features Corresponding to Visual Perception. *IEEE Transactions on Systems, Man, and Cybernetics*. Vol. SMS-8. N° 6. June 1978. pp. 460-473.
- [51] Haralick, Robert M., Shanmugam K. and Dinstein, Its'hak. Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*. Vol. SMC-3, N°6, November 1973. pp. 610-621.
- [52] Reed, Todd R., and Du Buf, J.M Hans. A Review of Recent Texture Segmentation and Feature Extraction Techniques. *CVGIP. Image Understanding*. Vol. 57. N° 3, May. 1993. pp. 359-372.
- [53] Shi, Zhenghao and Fung, Ko B. A comparison of digital speckle filters. *Proceedings of IGRASS 94.Canada Centre for Remote Sensing*, 1994. pp. 2129 - 2133.
- [54] Lee, J.S. Speckle analysis and smoothing of synthetic aperture radar images.*Computer Graphics and Image Processing*. 1981. N 17. pp. 24-32.
- [55] Lee, Jong-Sen; Wen, Jen-Hung; Ainsworth, Thomas L.; Chen, Kun-Shan and Chen, Abel J. Improved sigma filter for speckle filtering of SAR imagery. *IEEE Transactions on Geoscience and Remote Sensing*. Vol. 47. N° 1. January 2009. pp. 202-213.
- [56] Kuan, Darwin.T.; Sawchuk, Alexander.A.; Strand, Timothy.C. and Chavel, Pierre. Adaptative restoration of images with speckle. *IEEE Transactions on Acoustics Speech and Signal Processing*. Vol. 35. pp. 373-383.

- [57] Kuan, Darwin.T.; Sawchuk, Alexander.A.; Strand, Timothy.C. and Chavel, Pierre. Adaptive noise smoothing filter for images with signal dependent noise. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. Vol. PAMI-7. No. 2. March 1985. pp. 165-177.
- [58] Pajares M., Gonzalo y De la Cruz, Jesús M. *Visión por Computador. Imágenes Digitales y Aplicaciones*. Segunda Edición. Alfaomega Grupo Editorial, S.A. de C.V. Mexico. 2008.
- [59] Shamsoddini, A. and Trinder, J.C. Image texture preservation in speckle noise suppression. *ISPRS Commission VII Symp.*, Vienna, Austria, 5-7 July. www.gmat.unsw.edu.au/snap/publications/shamsoddini&trinder2010a.pdf
- [60] García, R.; González, C.; De la Vega, R.; Valverde, A. y Sebem, E. Análisis del comportamiento de filtros de reducción de speckle en imágenes ER2-SAR. *Teledetección y Desarrollo Regional*. X Congreso de Teledetección. Cáceres, España, 2003. pp. 325-328. www.aet.org.es/congresos/x/cac73.pdf
- [61] Sheng, Yongwei and Xia, Zong-Guo. A comprehensive evaluation of filters for radar speckle suppression. *IGARSS '96; International Geoscience and Remote Sensing Symposium*, Lincoln, NE; UNITED STATES; 27-31 May 1996. pp. 1559-1561. ieeexplore.ieee.org/jiel3/3772/11018/00516730.pdf
- [62] Lopes, Armand; Touzi, Ridha and Nezry, E. Adaptive speckle filters and scene heterogeneity. *IEEE Transactions on Geoscience and Remote Sensing*. Vol 28. N 6. November 1990. pp. 992-1000.
- [63] Lopes, Armand and Sery, Franck. Optimal speckle reduction for the product model in multilook polarimetric SAR imagery and the Wishart distribution. *IEEE Transactions on Geoscience and Remote Sensing*. Vol 35. N 3. May 1997. pp. 632-647.
- [64] Nielsen, Allan A.; Skriver, Henning and Conradsen, Knut. Complex Wishart distribution based analysis of polarimetric synthetic aperture radar data. 2007. IEEE.
- [65] Lira, J. and Frulla, L. An Automated region Growing for Segmentation of Texture Regions in SAR images. *International Journal of Remote Sensing*. Vol. 19, N° 18. 1998. pp 3595-3606.
- [66] Ristau, J.P. and Moon, Wooil M. Adaptive filtering of random noise in 2-D geophysical data. *Geophysics*. Vol. 66. N 1. January - Februar. 2001. pp. 342- 249.
- [67] Park, J.M.; Song, W.J. and Pearlman, W. A. Speckle filtering of SAR images based on adaptive windowing. *IEE. Proc. Vision, Image and Signal Processing*. Vol. 146. N° 4. August 1999. pp. 191-197.

-
- [68] Thangavel, K., Manavalan, R. and Aroquiaraj, Laurence. Removal of speckle noise from ultrasound medical image based on spacial filters: comparative study. ICGST-GVIP Journal, ISSN 1687-398X, Volume (9), Issue (III), June 2009 .
- [69] <http://www.saldana-tolima.gov.co/index.shtml>
- [70] Hu, Ming Kuei. Visual pattern recognition by moment invariants. IRE Transactions on information theory. Vol. IT-8. 1962. pp. 179-187.
- [71] Flusser, Jan and Suk, Tomas. Rotation moment invariants for reconognition of symmetric objects. IEEE Transactions on Image Processing. Vol 15. No.12. December 2006. pp. 3784-3790.
- [72] Gonzalez, Rafael C. and Woods, Richard E. Digital Image Processing. Third Edition. Pearson Education Asia Ltda. 2010.
- [73] Kulkarni, Arun D. Computer Vision and Fuzzy-Neural Systems. Prentice Hall. 2001.
- [74] Babusca, R. Fuzzy and Neural Control Disc Course Lecture notes(september 2004). Delft University of Technology.
- [75] Bezdek, J.C., C. Coray, R. Gunderson and J. Watson (1981). Detection and characterization of cluster substructure, I. Linear structure: Fuzzy c-lines. SIAM J. Appl. Math. 40(2), 339–357
- [76] Cheng, H.D.; Jiang, X.H.; Sun, Y. and Wang, Jingli. Color image segmentation: advances and prospects. Pattern Recognition. Volume 34, Issue 12, December 2001, Pages 2259–2281.
- [77] Ohta, Yu-Ichi; Kanade, Takeo and Sakai, Toshiyuki. Color information for region segmentation. Computer Graphics and Image Processing. Volume 13, Issue 3, July 1980, Pages 222–241.
- [78] Báez Rojas, J.J.; Guerrero, M.L.; Conde Acevedo, J.; Padilla Vivanco, A. y Urcid Serano, G. Segmentación de imágenes de color. Revista Mexicana de Física. Volumen 50. Número regular 6. Diciembre 2004. pp. 579-587.
- [79] Gómez Allende, Darío Maravall. Reconocimiento de Formas y Visión Artificial. Addison Wesley Iberoamericana, S.A. Wilmington, Delaware, E.U.A. 1994.
- [80] Webb, Andrew R. Statistical Pattern Recognition. Second Edition. John Wiley & Sons, Ltda. 2002.

OTRAS REFERENCIAS CONSULTADAS:

- Alley, Michael. The Craft of Scientific Presentation. Critical Steps to Succeed and Critical Errors to Avoid. Springer-Verlag New York, Inc. 2003.
- Bradski, Gary, and Kaeble, Adrian. OpenCV, Computer Vision with the OpenCV Library. Copyright © 2008. Published by O'Reilly Media, Inc., 1005 Gravenstein Highway North, Sebastopol, CA 95472. September 2008: First Edition.
- De Castro Korgi, Rodrigo. El Universo \LaTeX . Universidad Nacional de Colombia. Segunda edición. Segunda reimpresión. 2007. Bogotá.
- Eco, Umberto, Cómo se Hace una Tesis. Técnicas y Procedimientos de Estudio, Investigación y Escritura. Octava reimpresión:junio del 2006, Barcelona. Editorial Gedisa, S.A.
- Freeman, J.A. y Skapura, D.M.. Redes Neuronales, Algoritmos, Aplicaciones y Técnicas de Programación. Addison Wesley.1993.
- Wonnacott, Thomas H. y Wonnacott, Ronald J. Introducción a la Estadística. Segunda edición. Editorial Limusa, S.A. de C.V. Grupo Noriega Editores. Balderas 95. Mexico, D.F. 1997.