

Facultad de Matemática, Astronomía y Física  
Universidad Nacional de Córdoba  
Argentina

**Una aplicación basada en imágenes SAR para el  
monitoreo y prevención de inundaciones en  
Argentina**

**Autores:**

Ileana Belmonte  
Soledad Caamaño

Directora: Silvia Ojeda  
Colaborador de Dirección: Daniel Fridlender

Córdoba, Septiembre 2009



*A Mirta, Kete y Mati. Siempre a mi lado, con todo mi amor...*

*Ile*

*A mi familia y amigos...*

*Soledad*



---

# Índice general

---

<b>Índice general</b>	<b>I</b>
<b>1 Introducción</b>	<b>7</b>
1.1. La problemática de las inundaciones . . . . .	7
1.2. Alerta Temprana . . . . .	8
1.3. CONAE. Objetivos Relacionados . . . . .	8
1.3.1. Descripción del Manejo de Emergencias . . . . .	9
1.3.2. Carta Internacional: El Espacio y Grandes Catástrofes . . .	10
1.3.3. Inundaciones . . . . .	10
Fases de la Inundación . . . . .	11
1.4. Propuesta del trabajo . . . . .	12
1.5. Organización del trabajo . . . . .	12
<b>2 Introducción a la Teledetección</b>	<b>13</b>
2.1. Teledetección . . . . .	13
2.1.1. El espectro electro-magnético . . . . .	14
2.1.2. La región de las micro-ondas . . . . .	16
Características del suelo y el agua . . . . .	18
2.1.3. Propiedades de las imágenes de radar . . . . .	18
2.1.4. Radar de Apertura Sintética - SAR . . . . .	19
<b>3 Procesamiento de imágenes SAR</b>	<b>23</b>
3.1. Introducción . . . . .	23
3.2. Textura . . . . .	23
3.2.1. Técnicas para medir la estructura espacial de una imagen .	24
Medidas de variación espacial . . . . .	25
3.2.2. Textura en segmentación y clasificación de imágenes . . . .	25
Eliminación de outliers . . . . .	26
3.3. Segmentación . . . . .	26

3.3.1.	Métodos de Segmentación . . . . .	27
	Segmentación basada en el uso de un umbral . . . . .	27
	Segmentación por crecimiento de regiones . . . . .	28
	Detección de bordes . . . . .	28
3.4.	Clasificación . . . . .	29
3.4.1.	Fase de Entrenamiento . . . . .	29
	Clasificación Supervisada . . . . .	30
	Clasificación No Supervisada . . . . .	30
3.4.2.	Fase de Asignación . . . . .	31
	Clasificador por Mínima Distancia . . . . .	31
	Clasificador por Paralelepípedos . . . . .	32
	Clasificador por Máxima Verosimilitud . . . . .	32
	Clasificador por Mahalanobis . . . . .	34
3.4.3.	Fase de Verificación . . . . .	34
<b>4</b>	<b>Algoritmos basados en datos SAR</b>	<b>37</b>
4.1.	Introducción . . . . .	37
4.2.	Algoritmos para la detección de bordes . . . . .	38
4.2.1.	Algoritmos de Contorno Activo . . . . .	39
4.3.	Algoritmo automático para la detección de cuerpos de agua . . . . .	39
4.3.1.	Descripción del método . . . . .	39
4.3.2.	Resumen del algoritmo automático . . . . .	41
<b>5</b>	<b>El Detector Automático de Agua (Automatic Water Detector)</b>	<b>43</b>
5.1.	Descripción de las Fases del Detector Automático de Agua . . . . .	43
5.1.1.	Subfase <i>Estadísticas de Región</i> . . . . .	45
5.1.2.	Subfase <i>Clasificador por Umbral</i> . . . . .	45
5.1.3.	Subfase <i>ML-Estimador</i> . . . . .	46
5.1.4.	Subfases <i>Mahalanobis Clasificador y ML-ReEstimador</i> . . . . .	46
5.1.5.	Subfase <i>Clasificador</i> . . . . .	47
5.2.	Implementación . . . . .	47
5.2.1.	ImageJ . . . . .	47
5.2.2.	Descripción de la implementación . . . . .	48
5.2.3.	Módulo Regions . . . . .	48
5.2.4.	Módulo FloodStatistic . . . . .	50
5.2.5.	Módulo VectorMatrix . . . . .	50
5.2.6.	Módulo AutomaticWaterClassifier . . . . .	50
	InterfaceAlgorithm . . . . .	51
	Submódulo FeatureStatisticRegion . . . . .	51
	Submódulo ThresholdClassifier . . . . .	52
	Submódulo ML-Estimator . . . . .	54
	Submódulo MahalanobisClassifier . . . . .	54

Submódulo Classifier . . . . .	55
5.2.7. Diagramas de Clases . . . . .	55
<b>6 Análisis del Detector</b>	<b>59</b>
6.1. Introducción . . . . .	59
6.2. Sensibilidad a la elección del umbral . . . . .	62
6.2.1. El método MIMO . . . . .	71
6.3. Sensibilidad al tamaño de la ventana de textura . . . . .	77
<b>7 Resultados</b>	<b>87</b>
7.1. Introducción . . . . .	87
7.2. Caracterización y simulación de imágenes SAR de tierra y agua . .	87
7.3. Resultados e ImageJ . . . . .	92
7.4. Conclusiones y Trabajos Futuros . . . . .	94
<b>Bibliografía</b>	<b>97</b>
<b>Índice de figuras</b>	<b>101</b>
<b>Índice de cuadros</b>	<b>103</b>





---

# Agradecimientos

---

Queremos expresar nuestro agradecimiento a:

- Silvia Ojeda, nuestra directora, por toda la paciencia y el apoyo brindado para la realización de este trabajo.
- Frito, por siempre hacerse algún lugarcito, para darnos sus correcciones y sugerencias para mejorar este trabajo.
- Oscar Bustos, “El Profe”, por su interés demostrado, su incondicionalidad, apoyo y ayuda, SIEMPRE.
- Marcelo Scavuzzo por presentarnos la propuesta de este trabajo y ser el nexo entre CONAE y nosotras.
- CONAE y todos aquellos que pertenecen a esta institución, y molestamos para conseguir las imágenes, aporte indispensable para este trabajo.
- Despacho de Alumnos, por atender nuestras “infinitas” consultas, y siempre responder con una sonrisa, en especial María José.

*Ileana y Soledad*

Además de nuestras “gracias” comunes, quiero expresar mi mayor agradecimiento por el apoyo brindado para la realización de este trabajo:

- En primerísimo lugar, a mi madre, por siempre estar, escuchar, ayudar y por supuesto aguantarme...
- A mis hermanos, Mati y Kete, que son parte fundamental en mi vida y por siempre estar en mis mejores y peores momentos.
- A mis abuelas, que soportan mis ausencias...
- A mi “Chu”, porque simplemente es mi “hija” y siempre me regala una sonrisa, y a Vivi por permitirme siempre estar al lado de ella.
- A Paula, por siempre preguntarme y empujarme a terminar este trabajo, y por su disposición “infinita” para ayudarme y escucharme...
- A Sil y Andy, mis grandes amigas y compañeras de aventuras, simplemente por ser y estar.
- A Laurita, porque siempre me ofreció su ayuda, a pesar de sus tiempos breves, pero dedicados a escucharme.
- A Naty, porque siempre me asombra su corazón enorme y lleno de bondad, y por de vez en cuando, océano de por medio, preguntarme sobre el estado de la tesis.
- A Martín, mi gran amigo, por estar siempre presente, personal o virtualmente.
- A Edu, “anche” por ser mi compañía y ayuda on-line, siempre escucharme (leerme) y responder a todas las dudas y problemas que surgían...
- A María José, Glo y Patry, porque nunca faltaron sus frases de apoyo y aliento...
- A todos mis compañeros de trabajo, por soportarme en este proceso de tesis y permitirme las ausencias para este trabajo.
- A todos aquellos, que seguramente en este momento me olvido... Pero siempre estuvieron interesados y preguntando: *cómo va la tesis???*

A todos ellos, de corazón... MUCHÍSIMAS GRACIAS!!!!!!!!!!!!!!!

*Ile.-*

- A mi familia, por la educación que me han dado, sin la cual, no habría sido posible seguir el camino que me ha llevado hasta la culminación de esta tesis.
- A mis amigos que siempre me brindan su apoyo incondicional.

Finalmente, en el entorno de trabajo y en el marco de lo social quiero agradecer a todos/as aquellos/as que han colaborado tanto activa como pasivamente en la conquista de este logro.

*Soledad.-*



---

# Resumen

---

La teledetección, a través de sensores remotos activos y pasivos, constituye una herramienta de gran utilidad para el desarrollo de sistemas de prevención, seguimiento y evaluación de inundaciones. Entre los estudios, que facilitan el uso de información satelital proveniente de imágenes SAR, para detección automatizada de superficies de agua, mediante técnicas de clasificación no supervisada, podemos señalar un algoritmo desarrollado recientemente (2004), por P. Ahtonen, M. Euro, M. Hallikainen, S. Solbø, B. Johansen y I. Solheim [26]. En este trabajo realizamos la implementación computacional y un estudio detallado de este algoritmo. La implementación se realizó en JAVA, y constituirá una nueva funcionalidad para el software ImageJ, programa de procesamiento de imágenes de dominio público [1].

**Palabras claves:** teledetección, sensores remotos activos y pasivos, imágenes SAR, clasificación no supervisada, textura.



# Capítulo 1

---

## Introducción

---

### 1.1. La problemática de las inundaciones

La repetición de anomalías extremas de las precipitaciones que se traducen en abundancia excesiva o escasez de agua, es decir en inundaciones o sequías, respectivamente, es un componente normal de la variabilidad natural del clima. Estas anomalías tienen en muchos casos implicaciones socioeconómicas y ambientales de gran envergadura. Entre los efectos negativos de las inundaciones y las sequías se destacan las pérdidas de vidas y daños materiales; las migraciones en masa de personas y animales; la degradación del medio ambiente y la escasez de alimentos, energía, agua y otras necesidades básicas [18].

En el plan de ejecución de la Cumbre Mundial sobre Desarrollo Sostenible (CMDS), que tuvo lugar en Johannesburgo en agosto y septiembre de 2002, se subraya la necesidad de “... *mitigar los efectos de sequías e inundaciones mediante la adopción de medidas como el uso más eficiente de la información y la predicción climática y meteorológica, los sistemas de alerta temprana, la gestión de los suelos y los recursos naturales, las prácticas agrícolas y la conservación de los ecosistemas con el fin de poner freno a las tendencias actuales y reducir al mínimo la degradación de los suelos y los recursos hídricos...*” [18]

Las comunidades están expuestas a diversos peligros y riesgos, tanto naturales como antropógenos. El éxito de la puesta en práctica de estrategias de gestión de desastres requiere gran número de actividades y supone la intervención de diversos organismos. Es necesaria la participación de personas, familias y comunidades así como una amplia representación de la sociedad civil, centros de investigación, gobiernos y organizaciones voluntarias. Todas estas instituciones cumplen una función vital para lograr que las alertas conduzcan a la adopción de medidas preventivas. El proceso debe contar con la presencia de todos los sectores y de las más diversas disciplinas, debiéndose llevar a cabo actividades que contribuyan a

garantizar la ejecución de los planes de emergencias en casos de desastres.

Este enfoque contribuye al intercambio estructurado de información y al establecimiento de relaciones de organización eficaces y tiene la ventaja que permite hacer frente de manera más eficaz a los riesgos comunes para la población, facilita el uso eficiente de los recursos y del personal y combina las preocupaciones en materia de desarrollo con los planes para casos de emergencias y las actividades de prevención, recuperación y mitigación [18].

## 1.2. Alerta Temprana

La alerta temprana y la predicción son elementos esenciales de la serie de pasos necesarios para reducir los efectos sociales y económicos de todos los peligros naturales, incluidas las inundaciones [18].

Visto el enorme impacto en términos de vidas humanas, pérdidas materiales, perturbación social, reducción de la productividad social, interrupción de servicios o destrucción de infraestructura, el Programa Espacial Nacional (PEN) confiere una alta prioridad a la asistencia de instituciones con responsabilidad directa en la Gestión de los Desastres. En este sentido, el PEN tiene por objetivo la producción y provisión de información espacial relevante y oportuna en la prevención, preparación, asistencia, evaluación y recuperación de desastres de origen natural o antropogénico.

La información espacial resulta clave en la prevención, supervisión, y alerta de emergencias tales como: inundaciones, terremotos, erupciones volcánicas, avalanchas, incendios, sequías, tornados, plagas, derrames químicos y contaminación del agua, suelo y atmósfera. En particular, la construcción de mapas de riesgo y peligrosidad requieren de abundantes volúmenes de información georreferenciada que en algunos casos cambia rápidamente (ejemplo: la humedad del suelo y de la vegetación para la evaluación de índices de riesgo de incendio o inundaciones). La rápida evolución de los parámetros ambientales que determinan el riesgo, requieren de una continua actualización, lo que es solamente posible gracias a la observación permanente desde el espacio. Esto es particularmente destacable en países con la extensión territorial y distribución poblacional de Argentina [35].

## 1.3. CONAE. Objetivos Relacionados

La Comisión Nacional de Actividades Espaciales (CONAE) tiene como mandato la formulación e implementación del Plan Espacial Nacional (PEN) centrado en el uso pacífico de las tecnologías de observación de la Tierra desde el Espacio.

El Plan Espacial Nacional se centra en la generación de Ciclos de Información Espacial Completos que dan coherencia y vinculan entre sí todas las actividades de CONAE, clarificando los objetivos parciales que deben alcanzarse en cada uno de



los Cursos de Acción en los que se ha ordenado la actividad espacial y definiendo el destino social y las áreas de aplicación de los desarrollos en tecnología espacial.

Dentro de estos ciclos se encuentra el Ciclo de Información Espacial para el Manejo de Emergencias, señalado por el Plan Espacial Nacional como una de las áreas prioritarias de aplicación de la información espacial, abarcando la vigilancia y el seguimiento de emergencias y catástrofes naturales o antropogénicas tales como incendios, inundaciones, sequías, erupciones volcánicas, terremotos, deslizamientos de tierra y avalanchas, derrames de hidrocarburos y contaminación marina, eclosión de algas, plagas en cultivos, contaminación industrial y otros, quizá de menor importancia para nuestro país, como huracanes, tornados, etc [13].

Es evidente que, dado los importantes costos económicos y sociales, es fundamental reducir el impacto de los desastres naturales o antropogénicos. Por lo tanto, la reducción de la vulnerabilidad debería ser un objetivo central dentro de una estrategia integrada de manejo de emergencias. Entendemos como Gestión de Emergencias, al conjunto de acciones y procesos diseñados para amortiguar o mitigar los efectos de una emergencia o un desastre antes, durante o después del mismo.

### 1.3.1. Descripción del Manejo de Emergencias

El manejo de emergencias comprende una serie de etapas o fases, que incluyen la planificación previa al desastre, la preparación y pronóstico, la respuesta y asistencia, la recuperación y la reconstrucción. Todas y cada una de estas etapas requieren de un aporte intensivo de información y la tecnología espacial juega un importante rol en el suministro de ésta [13].

En el desarrollo de una emergencia se pueden definir tres etapas:

- **Fase de Prevención**

Conjunto de acciones tendientes a reducir el impacto negativo de un desastre antes que éste ocurra. Incluye actividades orientadas a evitar o reducir los riesgos, como evaluación del riesgo, probabilidad de ocurrencia y vulnerabilidad de la región; también comprende pronóstico, predicción y diseño de medidas estructurales y no-estructurales.

- **Fase de Asistencia**

Comprende las acciones requeridas inmediatamente antes, durante o inmediatamente después de ocurrido el desastre. Incluye la alerta temprana cuando es posible, la respuesta y la primera evaluación de daños.

- **Fase de Recuperación**

Conjunto de medidas tendientes a restablecer el funcionamiento normal de la infraestructura dañada y de los vínculos y actividades sociales, económi-

cas y personales que hubieren sido afectados. Incluye evaluación de costos y el seguimiento de los daños causados, continuando la acción comenzada en la etapa anterior. El factor "tiempo" no es tan crítico como durante la fase anterior de la emergencia.

### 1.3.2. Carta Internacional: El Espacio y Grandes Catástrofes

La CONAE participa desde el año 2003 en la Carta Internacional "El Espacio y las Grandes Catástrofes", creada entre las agencias espaciales de numerosas naciones. **La Carta** tiene el fin de facilitar gratuitamente el acceso a información de origen espacial a los países que lo soliciten para actuar ante una catástrofe en su territorio, y opera de manera que obtengan rápidamente imágenes satelitales de las zonas afectadas por la situación de emergencia, provocada por desastres [12, 2].

La intervención de la Carta permite al país que sufre una emergencia, contar con imágenes satelitales procesadas, de modo que ofrezcan mayor información para este tipo de eventos. Esto permite una rápida interpretación de la situación en la que se encuentra el lugar afectado, como así también la identificación de los pasos necesarios para la estimación de daños y su rápida mitigación.

### 1.3.3. Inundaciones

Las inundaciones constituyen el desastre más devastador en el mundo, con mayor pérdida de vidas y de daños a la propiedad que cualquier otro desastre.

Los satélites de observación terrestre han demostrado ser una excelente herramienta para proveer información hidrológica y del uso operacional de un monitoreo detallado de inundaciones y evaluación de daños.

En el contexto de un análisis general de este fenómeno, es necesario identificar diferentes "zonas morfológicas", en las cuales diferentes tipos de eventos producen clases específicas de riesgos y desastres. Se identifican dos zonas morfológicas:

- Áreas planas

Los daños son causados por la inundación producida por fuertes precipitaciones (tanto locales como en las zonas río arriba que provoca el desborde de los ríos de llanura). La duración de las lluvias efectivas necesarias para producir inundaciones es usualmente de horas a días, es decir, que su evolución es relativamente lenta, y sus efectos duran largo tiempo.

- Áreas montañosas

Los daños son causados prácticamente en forma simultánea con el evento meteorológico por deslizamientos, arrastre de material e inundaciones. Las inundaciones son generalmente del tipo repentinas (flash flood) ya que son

extremadamente rápidas y agravadas por los deslizamientos, transporte de sedimentos, etc.

### Fases de la Inundación

#### ■ PREVENCIÓN

En esta fase de la emergencia, las acciones para prevenir y reducir el impacto de la inundación, pueden ser descriptas en dos sub-fases:

##### ● Preparación

Incluye historia, memoria corporativa y climatología. Para las metodologías regionales es esencial la geomorfología, análisis hidrológico y climatológico e investigación de eventos pasados. La percepción remota contribuye con datos meteorológicos para el modelado hidrológico y el mapeo de eventos históricos. Las investigaciones a nivel local incluyen topografía, datos hidráulicos, rugosidad de los cauces de ríos, uso de la tierra, etc. La percepción remota contribuye para el mapeo topográfico (generación de modelos digitales de elevación - DEMs), uso y rugosidad de la tierra.

##### ● Predicción

Esta sub-fase incluye pronóstico y mapas de riesgo hídrico, en los cuales los modelos hidrológicos juegan un papel fundamental. Estos modelos requieren varios tipos de datos, como uso y cobertura de la tierra, tipo y humedad del suelo, intensidad y cantidad de precipitaciones, DEMs y drenajes. La compleja información del uso de la tierra puede requerir datos de alta resolución espacial de grandes áreas, lo que sólo puede ser obtenido por sistemas de percepción remota.

#### ■ ASISTENCIA

Esta fase puede dividirse en dos sub-fases: alerta, referida a las acciones requeridas inmediatamente antes del evento, incluyendo alarma cuando sea posible; y de respuesta, que se refiere a las acciones a tomar durante e inmediatamente después de la emergencia.

##### ● Alerta

Para establecer los mecanismos de alerta deben estudiarse los factores ambientales para monitorear y estudiar las condiciones que llevan a la emergencia. Los satélites meteorológicos proveen información de precipitaciones, temperatura, vientos y humedad del suelo.

##### ● Respuesta

Durante la inundación, es fundamental la localización e identificación de la áreas afectadas con precisión espacial, y en el momento preciso, para poder actuar y mitigar el daño.

Desde la percepción remota, las acciones en esta etapa son importantes para el apoyo logístico en la asistencia y en la primera evaluación de daños.

- **RECUPERACIÓN**

En esta fase se requiere información y evaluación de daños, haciendo un seguimiento de la acción comenzada en la etapa anterior. El factor “tiempo” no es tan crítico como durante el desarrollo de la emergencia.

## 1.4. Propuesta del trabajo

Este trabajo propone la implementación del algoritmo propuesto en *SAR and optical algorithms for discrimination of water bodies* [26], el cual analiza imágenes SAR, pudiendo diferenciar agua de tierra. Esta implementación será un aporte para la vigilancia y seguimiento de emergencias y catástrofes, mas precisamente inundaciones.

La implementación de este algoritmo será una herramienta más para el software ImageJ [1]. ImageJ es un programa de dominio público de procesamiento de imágenes, desarrollado en una arquitectura abierta que proporciona extensibilidad a través de plugins de JAVA.

## 1.5. Organización del trabajo

En el **Capítulo 2** realizamos una breve introducción a la Teledetección y sistemas de radares SAR.

En el **Capítulo 3** se describen algunos modelos matemáticos que son utilizados para el estudio de texturas en imágenes satelitales. Definiendo además, conceptos pertinentes como reconocimiento de patrones, características, vectores característicos, etc. Por otro lado, detalla además algunos de los métodos de clasificación y segmentación de imágenes satelitales.

El **Capítulo 4** habla sobre algoritmos de “contorno activo” que son usados para delinear zonas inundadas en imágenes satelitales, presentando además una propuesta de clasificación no supervisada, el cuál será el eje del desarrollo del **Capítulo 5**, que describe la especificación del Detector Automático de Agua.

En el **Capítulo 6** se realiza un estudio minucioso de las debilidades del método, mostrando algunas soluciones. El **Capítulo 7**, tratará sobre los resultados, conclusiones y posibles trabajos futuros.

## Capítulo 2

---

# Introducción a la Teledetección

---

### 2.1. Teledetección

La Teledetección se define como la técnica de adquisición y posterior tratamiento de datos de la superficie terrestre desde sensores instalados en plataformas espaciales, en virtud de la interacción electromagnética existente entre la tierra y el sensor, siendo la fuente de radiación proveniente del sol o del propio sensor [24, 23].

Un sistema de percepción remota o teledetección, requiere al menos, tres componentes: un foco energético, la superficie terrestre y un sensor. Una de las formas más habituales para clasificar a los sensores remotos es mediante la energía procedente de las distintas cubiertas [24].

Existen tres formas de adquirir información a partir de un sensor: por *reflexión*, por *emisión* y por *emisión-reflexión*. La primera es la forma más importante de la teledetección pues se deriva directamente de la luz solar, principal fuente de energía de nuestro planeta.

El sol ilumina la superficie terrestre, que refleja esa energía en función del tipo de cubierta presente sobre ella. Ese flujo reflejado se recoge por el sensor, que lo transmite posteriormente a las estaciones receptoras. Entre superficie y sensor se interpone la atmósfera, que dispersa y absorbe parte de la señal original.

Existen variadas formas de clasificar los sensores remotos, una de las más habituales considera el procedimiento para recibir la energía procedente de las distintas cubiertas. En este sentido, se habla de dos tipos de sensores [24, 23]:

- *Pasivos*

Son los sensores que se limitan a recibir la energía proveniente de un foco exterior a ellos (por ejemplo: sol).

- *Activos*

Son los sensores que son capaces de emitir su propio haz de energía. Estos últimos son, lógicamente, más flexibles puesto que no dependen tanto como los primeros de las condiciones exteriores al sistema Sensor - Tierra.

### 2.1.1. El espectro electro-magnético

Según la teoría ondulatoria, la energía electro-magnética se transmite de un lugar a otro siguiendo un modelo armónico y continuo, a la velocidad de la luz y conteniendo dos campos de fuerzas ortogonales entre sí: eléctrico y magnético [23].

Las características de este flujo energético pueden describirse por dos elementos: longitud de onda  $\lambda$  y frecuencia  $F$ , como se muestra en la ecuación (2.1). La primera hace referencia a la distancia entre dos picos sucesivos de una onda, mientras que la frecuencia designa el número de ciclos pasando por un punto fijo en una unidad de tiempo.

$$c = \lambda F \quad (2.1)$$

donde  $c$  indica la velocidad de la luz,  $\lambda$  expresa la longitud de onda y  $F$  la frecuencia [23].

Podemos definir cualquier tipo de energía radiante en función de su longitud de onda. El espectro electromagnético es la sucesión continua de esos valores de frecuencia, aunque conceptualmente se divide en bandas, en las que la radiación electromagnética manifiesta un comportamiento similar. La organización de estas bandas de longitudes de onda o frecuencia se denomina espectro electro-magnético. Comprende desde longitudes de onda más cortas (rayos gamma, rayos X), hasta las kilométricas (telecomunicaciones).

Desde el punto de vista de la teledetección, conviene destacar una serie de bandas espectrales [23]:

- *Espectro visible* (0,4 a 0,7  $\mu\text{m}$ )

Es la única radiación electro-magnética que pueden percibir nuestros ojos, coincidiendo con las longitudes de onda en donde es la máxima radiación solar. Suelen distinguirse tres bandas elementales: azul (0,4 a 0,5  $\mu\text{m}$ ); verde (0,5 a 0,6  $\mu\text{m}$ ) y rojo (0,6 a 0,7  $\mu\text{m}$ ), en razón de los colores primarios que nuestros ojos perciben a esas longitudes de onda.

- *Infrarrojo próximo* (0,7 a 1,3  $\mu\text{m}$ )

Es importante por su capacidad para discriminar masas vegetales y concentraciones de humedad.

- *Infrarrojo medio* (1,3 a 8  $\mu\text{m}$ )

Es la banda donde se entremezclan los procesos de reflexión de la luz solar y de emisión de la superficie terrestre. Resulta idóneo para estimar contenido de humedad en la vegetación y detección de focos de alta temperatura.


- *Infrarrojo lejano o térmico* (8 a 14  $\mu\text{m}$ )

Incluye la porción emisiva del espectro terrestre, en donde se detecta el calor proveniente de la mayor parte de las cubiertas terrestres.

- *Micro-ondas* (a partir de 1  $\mu\text{m}$ )

Es de gran interés por ser un tipo de energía bastante transparente a la cubierta nubosa. La frecuencia de las microondas se clasifica de manera arbitraria en bandas identificadas por letras. Las que se emplean más comúnmente en los radares son:

- Banda-X: de 2.4 a 3.75 cm (12.5 a 8 GHz).
- Banda-C: de 3.75 a 7.5 cm (14 a 8 GHz).
- Banda-S: de 7.5 a 15 cm (4 a 2 GHz).
- Banda-L: de 15 a 30 cm (2 a 1 GHz).
- Banda-P: de 30 a 100 cm (1 a 0.3 GHz).



**Figura 2.1:** Espectro electro-magnético. Fuente: *The Canada Centre for Remote Sensing* [24]

### 2.1.2. La región de las micro-ondas

La banda del espectro que se inicia en las longitudes de onda milimétricas se denomina región de las micro-ondas. Se trata de las longitudes mayores utilizadas en teledetección.

La observación en esta banda es complementaria y más compleja que la realizada en bandas ópticas, y está aumentando notablemente gracias a la creciente disponibilidad de satélites equipados con equipos de micro-ondas (ERS, Radarsat, etc). La virtud fundamental de esta región del espectro es ser prácticamente transparente a la influencia atmosférica. Esta propiedad hace idóneo el trabajo en esta región del espectro, especialmente para recoger información de aquellas zonas del planeta donde la cobertura de nubes es muy frecuente [23].

La observación en esta banda puede dividirse en pasiva y activa, en la teledetección pasiva el sensor se limita a recoger la energía que procede de las cubiertas terrestres. Por el contrario, los sensores activos no sólo recogen sino que también emiten su propio flujo de energía. Los sensores más importante en este campo son los activos, que emiten su propio haz de micro-ondas para recoger posteriormente su reflexión sobre la superficie terrestre. Normalmente se conocen como RADAR (**R**adio **D**etection and **R**anging). Por tratarse de un haz emitido artificialmente, pueden controlarse las condiciones de adquisición de imágenes: ángulo, distancia, orientación, polarización, etc.

Cuando se emite un haz de micro-ondas desde un radar a la superficie terrestre, la mayor parte de ese haz es dispersado al contacto con ella. El haz principalmente se dispersa hacia la atmósfera (en el caso del suelo), dentro del mismo objeto (en el caso de la vegetación), o se refleja especularmente (en el caso del agua). En función de estos tres comportamientos el radar registrará una señal de retorno muy diferente [23].

Como ocurre en otras bandas del espectro, cada cubierta ofrece distintos comportamientos. Otros factores que podríamos denominar medio ambientales, influyen en la señal finalmente detectada por el sensor. Los más importantes son: la rugosidad y geometría del terreno, el ángulo de incidencia del flujo y su polarización.

En cuanto a la rugosidad, incide directamente en la intensidad de la señal del retorno, siendo ésta mayor cuando más elevada es la rugosidad. La rugosidad no sólo depende de la estructura de la superficie, sino también de la longitud de onda de la observación. En longitudes de ondas cortas, una superficie relativamente llana puede aparecer como rugosa, mientras se comporta como lisa en longitudes mayores. Esta relación se concreta gracias al criterio de Rayleigh, que considera una cubierta como rugosa si:

$$s_h \geq \frac{\lambda}{8} \cos \theta \quad (2.2)$$

donde  $s_h$  es la desviación típica de la altura de la superficie;  $\lambda$  la longitud de onda



de observación, y  $\theta$  el ángulo de incidencia. Esto indica que a igual rugosidad del terreno, éste aparecerá tanto más liso cuanto se trabaje a longitudes de onda mayores, y/o con ángulos de incidencia mayores (esto es, en una observación más oblicua). Esta relación es muy importante, ya que en una superficie que aparece como rugosa, la dispersión de retorno se dirige en todas las direcciones y el sensor capta una fuerte señal. En cambio, si la cubierta aparece lisa la reflexión tiende a ser especular y la señal de retorno puede llegar a ser prácticamente nula. Este es el caso de las masas de agua en calma, que aparecen con tonos oscuros en una imagen de radar [23].

Junto a la rugosidad, es conveniente considerar la geometría del terreno: pendientes y orientaciones del ángulo de incidencia del radar. En el caso de zonas urbanas, resulta muy frecuente obtener señales de retorno particularmente intensas, debido a la presencia de los denominados reflectores de esquina, que cambian la trayectoria de la señal incidente retornándola en la misma dirección de origen.

Cuando si se combina un ángulo de incidencia bajo con una longitud de onda larga, el pulso del radar puede penetrar a una cierta profundidad. Es importante tener en cuenta que el ángulo de incidencia cambia en la dirección perpendicular a la trayectoria del satélite; es decir, no es constante para cada punto de la imagen, ya que la observación que realizan los equipos de radar es lateral. También del ángulo de incidencia depende la información morfológica que proporciona el radar. Con ángulos altos el efecto de sombra se realiza notablemente, aunque también lo hacen las deformaciones geométricas [23].

Otro de los factores mencionados anteriormente es la polarización, que se refiere a la orientación del campo eléctrico. La mayor parte de los radares son diseñados para transmitir la radiación de microondas horizontalmente polarizado (H) o verticalmente polarizado (V). Asimismo la antena recibe la energía ya sea horizontalmente o verticalmente polarizada, y algunos radares pueden recibir ambas. De este modo, puede haber cuatro combinaciones de transmitir y recibir polarizaciones [23, 24]:

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

Las dos primeras combinaciones de polarización se mencionan como *polarizadas* porque transmiten y reciben lo mismo. Las otras dos combinaciones se mencionan como polarización cruzada porque transmiten y reciben polarizaciones cruzadas una de la otra. La longitud de onda y la polarización afectan a un radar en como “ve” la superficie terrestre. Por lo tanto, imágenes de radar de diferente

polarización y longitud de onda pueden proveer información complementaria de la región a ser estudiada [24].

### Características del suelo y el agua

Los suelos rugosos y secos tendrán un mayor coeficiente de retro-dispersión y, por lo tanto aparecerán con tonos claros en una imagen de radar. Si la señal se reduce, manteniendo constante otras condiciones se tratará entonces de suelos más húmedos. Los núcleos de población, altamente rugosos a longitudes largas, también aparecen con tonos claros, lo que permite discriminarlos frente a los espacios cultivados limítrofes [23].

En cuanto al agua, la región de las microondas proporciona una cierta capacidad de penetración, siempre que el ángulo de incidencia sea bajo y se trabaje con longitudes de onda largas. El agua, casi siempre refleja especularmente el pulso recibido, con lo que el retorno es bastante bajo. En el caso de existir una cierta rugosidad superficial, por ejemplo oleaje, puede manifestarse en la imagen de radar, siempre que el ángulo de incidencia sea bajo. Esta explicación resulta muy útil para detectar anomalías en la superficie, por ejemplo manchas de petróleo [23].

### 2.1.3. Propiedades de las imágenes de radar

Las imágenes de radar tienen un cierto grado de lo que se denomina *speckle*. El speckle se ve en la textura de la imagen como un granulado “sal y pimienta”.

El speckle es esencialmente una forma de ruido, el cual degrada la calidad de la imagen y hace que la interpretación (visual o digital) sea más difícil. Por lo que es necesario reducir el ruido antes de la interpretación y análisis. La reducción se logra por dos métodos [24]:


- Proceso “multi-look”

Consiste en la división del haz del radar en sub-rayos más estrechos. Cada sub-haz provee una “vista” (look) independiente en la escena iluminada. Cada una de estas “vistas” está además sujeta al ruido speckle, pero sumando y promediando todas las vistas se obtiene la imagen final con el ruido speckle reducido. Este proceso se realiza usualmente durante la adquisición de los datos [24].

- Filtro espacial

Este proceso se realiza durante el análisis de una imagen. La reducción del ruido speckle consiste en mover una ventana de dimensiones pequeñas (p. ej. 3x3 píxeles o 5x5 píxeles) sobre cada píxel de la imagen, aplicando un cálculo matemático (p. ej. la media); usando para este los valores de los píxeles que están bajo la ventana, y reemplazando el píxel central con el

nuevo valor. La ventana se desliza por las filas y columnas de la imagen, un pixel a la vez, hasta que la imagen entera es cubierta. Calculando el promedio de una pequeña ventana alrededor de cada pixel, se logra un suavizado y una reducción visual del ruido speckle [24, 23].



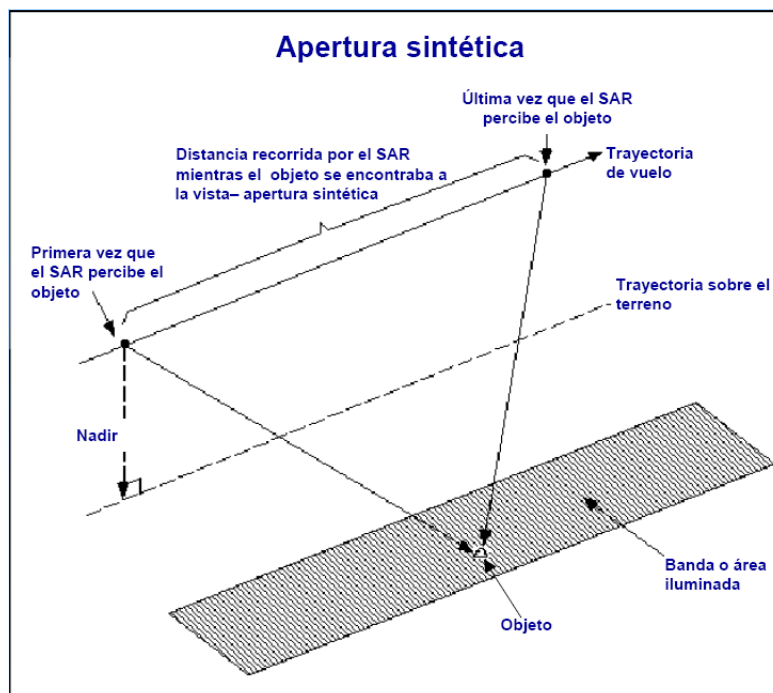
**Figura 2.2:** (a) Corte de imagen SAR (Gentileza CONAE) con ruido speckle. (b) Imagen a la que se le aplicó un filtro de mediana para reducir el ruido.

Uno de los mayores problemas del suavizado es que difumina los bordes y otros detalles de realce de la imagen. Cuando el objetivo es la reducción del ruido más que el difuminado, el empleo de los **filtros de mediana** representa una posibilidad alternativa. En este caso el nivel de gris de cada pixel se reemplaza por la mediana de los niveles de gris del entorno de ese pixel. Este método es particularmente efectivo cuando el patrón de ruido consiste en componentes fuertes y de forma “picuda”, y la característica que se desea preservar es la agudeza de los bordes [22].


Su interés se corresponde con el propio de las mediana como medida de centralidad, ya que es menos sensible a los valores extremos y por lo tanto significa una menor modificación de los datos [23].

#### 2.1.4. Radar de Apertura Sintética - SAR

El radar de apertura sintética (SAR - **S**ynthetic **A**perture **R**adar) es un sistema de radar de iluminación lateral que produce una imagen de resolución fina de la superficie bajo observación. Al moverse a lo largo de su trayectoria, el radar ilumina hacia un lado de la dirección de vuelo franjas continuas y paralelas entre sí, de la superficie en estudio y acumula la información de las microondas que se reflejan. La señal que se graba a bordo, se procesa apropiadamente para formar una imagen digital [24].



**Figura 2.3:** Concepto de apertura sintética. Fuente: *The Canada Centre for Remote Sensing* [24]




**Figura 2.4:** Geometría del vuelo SAR. Fuente: *The Canada Centre for Remote Sensing* [24]

La Figura 2.4 ilustra la geometría del vuelo de un radar SAR, donde la plataforma viaja en la dirección de vuelo (A) con el nadir (B) directamente bajo

la plataforma. El rayo microondas es transmitido oblicuamente perpendicular a la dirección de vuelo que ilumina un área(C) que es compensado desde el nadir. La distancia entre el radar y el objetivo en la superficie en la dirección perpendicular al vuelo, se le llama **alcance** (D). Se le conoce como **azimut**(E) a la distancia a lo largo de la trayectoria [24].


En un sistema de radar, la resolución tiene dos dimensiones, una en la dirección del alcance y otra en la del azimut.

La resolución en la dirección del alcance se determina por las características del radar y las del procesador, esencialmente esas características de la señal a lo largo de la trayectoria entre el sensor y la superficie iluminada. La resolución en la dirección del alcance depende de la longitud del pulso transmitido; un pulso corto proporciona mejor resolución. La señal del radar se graba en el dominio del alcance. Esta señal, ya en forma digital, se proyecta al plano del terreno al procesar la imagen [24].



**Figura 2.5:** Geometría SAR. Fuente: *The Canada Centre for Remote Sensing* [24]


La Figura 2.5a muestra el rango o alcance cercano (A), que es la parte del área iluminada más cercana al nadir de la plataforma de radar, mientras la parte del área iluminada más lejana del nadir es llamado rango o alcance lejano (B). El ángulo de incidencia (Figura 2.5b) es el ángulo entre el rayo de radar y el superficie de tierra (A) que aumenta, moviéndose a través del área iluminada desde el rango cercano al lejano. El ángulo de mirada (B) es el ángulo en el que el radar mira a la superficie [24].



**Figura 2.6:** Resolución en dirección del alcance

A diferencia de sistemas ópticos, la resolución espacial de un radar es una función de las propiedades específicas de la radiación microondas y efectos geométricos. Si un Radar de Apertura Real (RAR) es usado para la formación de imagen, un solo pulso se transmite y la señal de la energía reflejada es usada para formar la imagen. En este caso, la resolución es dependiente de la longitud efectiva del pulso en la dirección de inclinación y del ancho de la iluminación en la dirección de azimuth. La resolución del rango es dependiente de la longitud del pulso ( $P$ ). Dos objetivos distintos sobre la superficie serán resueltos en la dimensión del rango si su separación es mayor que la mitad de la longitud de pulso. Por ejemplo, los objetivos 1 y 2 no serán separables mientras los objetivos 3 y 4 si (Figura 2.6) [24].

En un radar convencional, la resolución en la dirección del azimuth se determina por el ancho angular del haz. Para que dos objetos puedan ser identificados independientemente, deben estar separados en la dirección del azimuth por una distancia mayor al ancho del haz en el terreno. El SAR sintetiza una antena (virtual) muy grande al grabar la fase de la señal de las microondas que recibe, y mediante un procesamiento adecuado, se adquiere una resolución en la dirección del azimuth que depende del largo de esa antena sintética y es inversamente proporcional al tamaño de la antena real [24].



**Figura 2.7:** Resolución en dirección del azimuth

## Capítulo 3

---

# Procesamiento de imágenes SAR

---

### 3.1. Introducción

Una de las tareas más importantes en el procesamiento y análisis de imágenes es la producción de cartografía temática. Una de las formas más comunes de realizar esta tarea es mediante la segmentación y clasificación digital de imágenes para discriminar cubiertas en una serie de categorías homogéneas [11].

Muchas veces se utiliza el término *segmentación* para hacer referencia al problema de, dada una imagen, asignar cada píxel a una de las posibles clases en las que fue particionada dicha imagen, sin que estas clases hagan referencia a una cubierta particular del terreno.

El término *clasificación* será utilizado para designar el problema de, dada una imagen segmentada, atribuir a cada clase el rótulo correspondiente al tipo de cubierta del terreno, por ejemplo agua, zonas urbanas, etc. (Frery, 1993)

La extracción de información sobre la textura de una imagen, esto es, sobre la distribución espacial de los niveles de intensidad de gris en áreas o vecindarios, se utiliza tanto para la segmentación de imágenes como para la identificación, caracterización y clasificación de aquellos elementos zonales del paisaje heterogéneos [19].

En este capítulo se estudia en primer término el significado de textura y su importancia para el procesamiento de imágenes y luego se analizan los métodos de segmentación más conocidos y se presenta una descripción de la clasificación digital de imágenes con énfasis en aplicaciones de teledetección.

### 3.2. Textura

En términos generales podríamos decir que textura refiere a la aparente rugosidad o suavidad de una región de la imagen; en definitiva al contraste espacial

entre los elementos que la componen.

La textura de la imagen procede de la relación entre el tamaño de los objetos y la resolución del sensor. Cuando un objeto ocupa una superficie inferior a  $1 \text{ mm}^2$  en la imagen no puede identificarse individualmente, sino sólo a través de la variabilidad espacial que provoca. De esta forma, en función del tamaño de los objetos se distingue [23]:

1. **Textura grosera**, cuando los objetos están comprendidos entre  $0,25$  y  $1 \text{ mm}^2$  a la escala de la imagen,
2. **Textura media**, objetos comprendidos entre  $0,04$  y  $0,25 \text{ mm}^2$ , y
3. **Textura fina**, objetos inferiores a  $0,04 \text{ mm}^2$ .

En sentido estricto, además del tamaño de los objetos que forman una cubierta determinada, la textura con la que aparecen en la imagen puede variar en función de diversos factores. Los más importantes son el ángulo de observación del sensor, las condiciones de iluminación, y la longitud de onda.

En cualquier caso, el criterio de textura es muy importante para discriminar determinadas cubiertas que pueden ofrecer un comportamiento espectral uniforme.

### 3.2.1. Técnicas para medir la estructura espacial de una imagen

El objetivo de las técnicas que presentamos en esta sección es medir la textura o contraste espacial entre los píxeles que componen la imagen [23].

Una definición más pertinente para nuestros propósitos de textura, es la de presentarla como un atributo que representa la disposición espacial de los niveles de gris de los píxeles en una región [38]. Si el nivel de gris es constante en toda la región de un objeto, se dice que el objeto no tiene textura. Si el nivel de gris varía significativamente dentro del objeto, entonces el objeto tiene textura. Cuando tratamos de medir la textura, se trata de cuantificar la naturaleza de la variación del nivel de gris dentro de un objeto.

Una característica de textura es un valor, calculado a partir de la imagen de un objeto, que cuantifica en algún sentido la variación de nivel de gris en el objeto. Por esta razón cobran especial interés las técnicas de análisis de textura, mediante las cuales se describe la distribución de niveles de gris relativa al vecindario de cada píxel calculando variables estadísticas que describan propiedades como la variabilidad, el contraste, valor medio, etc. y que permitan obtener nuevas imágenes o bandas de textura que puedan utilizarse de forma aislada o combinadas con bandas espectrales para clasificar las imágenes originales [32].



### Medidas de variación espacial

Como dijimos antes la textura hace referencia a la heterogeneidad con la que aparecen los tonos de gris en una imagen; los índices numéricos de textura se dirigen a medir la variedad espacial entre los  $ND$  (niveles de gris) de los píxeles que forman la imagen. Podemos dividir estos índices entre aquellos que operan sobre toda la imagen, por ejemplo: *Desviación estándar*, *Dimensión fractal*, *Autocorrelación espacial* y *Semi-variograma*, y los que se apoyan en ventanas móviles, que se desplazan consecutivamente afectando al píxel central en cada paso, por ejemplo: *Desviación estándar local*, *Diferencias absolutas*, *Entropía*, *Medidas sobre la matriz de coincidencias* y *Dimensión textual* [23].

- *Desviación estándar local*: se calcula como la dispersión de los  $ND$  de una ventana de píxeles en relación con su promedio. Esta medida resulta muy sencilla y se ha mostrado un comportamiento eficaz en el inventario forestal, como indicador de la densidad y homogeneidad de especies.
- *Diferencias absolutas* entre los  $ND$  máximos y mínimos de la ventana considerada:

$$T = |ND_{max,i} - ND_{min,i}| \quad (3.1)$$

siendo  $i$  cualquiera de los píxeles adyacentes al central de la ventana. Esta medida se ha empleado para estimar la textura en zonas afectadas por diversos procesos ambientales.

#### 3.2.2. Textura en segmentación y clasificación de imágenes

La información sobre la textura de una imagen se utiliza tanto para la segmentación como para la clasificación de imágenes. En teledetección, en la práctica, el análisis de textura se basa en la extracción de características estadísticas [19].

Si deseamos un sistema para distinguir entre objetos de diferente tipo, primero debemos decidir qué características de los objetos deben ser medidas para producir parámetros descriptivos. Los atributos particulares que se miden se llaman características (*feature*) del objeto, y los valores resultantes de los parámetros conforman el “vector característico” de cada objeto. La selección adecuada de los parámetros es importante, ya que serán utilizados para identificar los objetos. El valor medio y la desviación estándar son dos características muy utilizadas para la “clasificación” [31].

En el caso general, si se tienen  $l$  características  $x_i$ ,  $i = 1, 2, \dots, l$  se usa como vector característico

$$x = [x_1, x_2, \dots, x_l]^T \quad (3.2)$$

donde  $T$  denota transposición. Cada uno de los vectores característicos identifica de manera única al objeto [31].

Los vectores característicos cuya verdadera clase se conoce y son usados para el diseño de un clasificador, son denominados “vectores de entrenamiento” (trainig feature vectors).

La selección de características, puede ser vista como el proceso de eliminación de algunas características (comenzando con la más pobre) y combinando otras que están relacionadas, hasta que el conjunto de características se hace manejable y el rendimiento es adecuado. Si el conjunto de características se reduce de  $M$  características a un número más pequeño  $N$ , buscamos el conjunto de  $N$  características que maximiza el rendimiento global del futuro clasificador [38].

Algunos autores, denominan a esta etapa como *preprocesamiento* [31]; etapa que describe el tratamiento realizado en las características antes de su utilización. Este procesamiento implica la eliminación de *outliers* (valores atípicos), el ajuste de las características para proteger el rango dinámico de sus respectivos valores, el tratamiento de datos faltantes, etc.

### Eliminación de outliers

Un *outlier* es un punto que se encuentra muy lejos de la media de la correspondiente variable aleatoria. Esta distancia se mide con respecto a un umbral dado, generalmente una cierta cantidad de veces la desviación estándar. Para una variable aleatoria distribuida normalmente, la distancia de dos veces la desviación estándar cubre aproximadamente el 95 % de las mediciones, y una distancia de tres veces la desviación estándar cubre aproximadamente un 99 %.

Puntos con valores muy diferentes al valor medio, producen grandes errores durante la fase de entrenamiento de la clasificación y pueden tener efectos desastrosos. Estos efectos son aún peores cuando los outliers son el resultado de mediciones ruidosas. Si el número de outliers es muy pequeño, éstos generalmente son descartados. Sin embargo, si éste no es el caso y son el resultado de una distribución con colas muy largas, entonces el diseñador debe adoptar funciones de costo que no sean muy sensible a la presencia de estos valores atípicos [31].

## 3.3. Segmentación

El primer paso en cualquier proceso de análisis de imágenes es la segmentación. Mediante la segmentación vamos a dividir la imagen en las partes y objetos que la forman. El nivel al que se realiza esta subdivisión depende de la aplicación en particular, es decir, la segmentación terminará cuando se hayan detectado todos los objetos de interés para la aplicación. En general, la segmentación automática es una de las tareas más complicadas dentro del procesamiento de imágenes.

Los algoritmos de segmentación se basan prácticamente en dos propiedades de los niveles de gris de la imagen: discontinuidad y similitud. Dentro de la primera

categoría se intenta dividir la imagen basándonos en los cambios bruscos en el nivel de gris. Las áreas de interés en esta categoría son la detección de puntos, de líneas y de bordes en la imagen. Dentro de la segunda categoría, el interés se centra en el estudio de técnicas de umbrales, crecimiento de regiones, y técnicas de división y fusión [34].

### 3.3.1. Métodos de Segmentación

En esta sección se describen resumidamente algunos métodos de segmentación que han aparecido en la literatura reciente sobre este tema.

#### Segmentación basada en el uso de un umbral

La umbralización es una técnica de segmentación ampliamente utilizada. Se dice que es un método de producción de regiones de uniformidad dentro de una imagen basada en algún criterio de umbral. La operación de umbralización puede ser vista como una operación que implica realizar comprobaciones frente a una función  $T$  de la forma:

$$T = T\{x, y, A(x, y), f(x, y)\}$$

donde  $f(x, y)$  es el nivel de gris del punto  $(x, y)$ , y  $A(x, y)$  representa alguna propiedad local en el vecindario de este punto, por ejemplo, la media del nivel de gris de una vecindad centrada en  $(x, y)$  [33]. Una imagen umbralizada se define como:

$$g(x, y) = \begin{cases} 1 & f(x, y) \geq T \\ 0 & f(x, y) < T \end{cases}$$

Esta técnica se emplea cuando hay una clara diferencia entre los objetos a extraer respecto del fondo de la escena. Los principios que rigen son la similitud entre los píxeles pertenecientes a un objeto y sus diferencias respecto al resto. Por tanto, la escena debe caracterizarse por un fondo uniforme y por objetos parecidos. Al aplicar un umbral, la imagen de niveles de gris quedará binarizada; etiquetando con “1”, los píxeles correspondientes al objeto y con “0”, aquellos que son del fondo [20].

La selección del valor del umbral, se realiza generalmente a partir del histograma de la imagen. Así si una imagen está compuesta de un objeto que aparece en la escena sobre un fondo, entonces es de esperar que el histograma sea bimodal. Por ejemplo, si el objeto es más claro que el fondo, en el histograma aparecerán dos picos, el ubicado en los valores de gris más elevados correspondientes al objeto y otro pico para niveles de gris más bajos, correspondientes al fondo. En la Figura 3.1 se muestra un histograma bimodal, en el cual el umbral se ubica entre los dos picos del histograma [33].

La selección automática del umbral, es un problema difícil. Por otro lado el histograma no siempre es bimodal; además en el caso de imágenes SAR, éstas están contaminadas con ruido speckle.

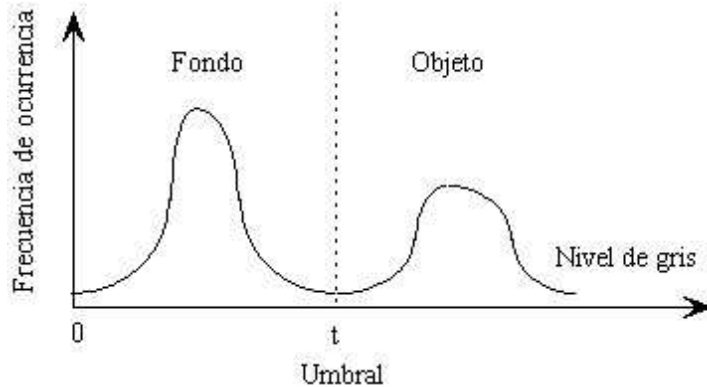


Figura 3.1: Ejemplo de un histograma bimodal [33].

### Segmentación por crecimiento de regiones

Los métodos de segmentación basados en regiones asignan un vector de características a cada región, y segmentan la imagen de acuerdo con los valores de funciones discriminantes adecuadas definidas sobre el espacio de esas características [28]. Los procedimientos más usuales, dentro de este esquema, son el *crecimiento de regiones* (*region growing*) y el *separa y une* (*split and merge*), los cuales suelen ser inicializados con semillas. Estos métodos comienzan por un píxel, el cual es seleccionado automáticamente o proporcionado por el usuario y a continuación examinan los píxeles vecinos para decidir si tienen características similares al inicial. De ser así, el píxel vecino que cumpla con tal condición de similitud, es agrupado junto con los anteriores para conformar así una región. Una crítica a estos procedimientos es que el resultado obtenido es demasiado dependiente de las condiciones iniciales.

### Detección de bordes

En los métodos de detección de bordes la técnica que se emplea consiste en localizar los bordes que existen entre las distintas regiones que participan en las imágenes [28]. La idea de cómo localizar un borde en la imagen es considerar que un borde es un límite o contorno en el cual ocurren cambios significativos en algún parámetro físico de la imagen, tal como la reflectancia superficial, la iluminación, o la distancia de la superficie visible al observador. Los cambios en los parámetros físicos de la imagen se manifiestan de diversas formas, incluyendo

cambios en intensidad, color y textura. Estos cambios en la imagen son usados para localizar los bordes o contornos.

### 3.4. Clasificación

Se puede decir que la clasificación es una de las fases más importante del tratamiento digital de imágenes. Su objetivo es convertir la imagen original en otra imagen, del mismo tamaño y características de la original, pero con la diferencia de que los  $ND$  de los píxeles no tienen relación con la radiancia del sensor, sino que es una etiqueta que identifica la categoría o clase asignada a ese píxel. Es importante considerar que no se puede aplicar ciertas operaciones estadísticas a una imagen clasificada, debido a que, pese a ser digital, no es una variable cuantitativa, sino cualitativa.

La clasificación digital comienza definiendo cada una de las categorías que se pretenden distinguir (fase de entrenamiento), luego continua con la agrupación de los píxeles de la imagen en una de esas categorías (fase de asignación), y culmina con la comprobación y la verificación de resultados (fase de verificación) [23]. Resumiendo en este esquema de clasificación pueden distinguirse las siguientes fases:

1. Fase de Entrenamiento
2. Fase de Asignación
3. Fase de Verificación

#### 3.4.1. Fase de Entrenamiento

Esta fase resulta ciertamente compleja ya que se trata de definir con rigor cada una de las categorías que se pretenden discriminar, teniendo en cuenta su propia variabilidad en la zona de estudio. Este objetivo se alcanza seleccionando una muestra de píxeles de la imagen que representen, adecuadamente, a las categorías de interés. Usando estos píxeles se pueden calcular los  $ND$  medios y la variabilidad numérica de cada categoría.

Varios autores han comprobado que los resultados de la clasificación, están mucho más influidos por la definición previa de las categorías, que por el criterio con el que éstas son posteriormente discriminadas (Hixson et al., 1980; Story y Campbell, 1986; Gong y Howarth, 1990b). Por lo tanto esta fase es considerada la columna vertebral de la clasificación numérica.

Tradicionalmente se han dividido los métodos de clasificación en dos grupos: supervisado y no supervisado, de acuerdo con la forma en que son obtenidas las estadísticas de entrenamiento.

El método supervisado parte de un conocimiento previo del terreno, a partir del cual se seleccionan las muestras para cada una de las categorías. Por su parte, el método no supervisado realiza una búsqueda automática de grupos de valores homogéneos dentro de la imagen. Queda al analista la labor de encontrar correspondencias entre esos grupos y sus categorías de interés.

En resumen, la elección entre uno y otro método dependerá de los datos y medios disponibles y de las propias preferencias personales (Marx y Hildebrandt, 1978; Townshend y Justice, 1981).

### **Clasificación Supervisada**

Podemos definir esta clasificación como un proceso en que píxeles de identidad conocida, ubicados dentro de áreas de entrenamiento, se utilizan para clasificar píxeles de identidad desconocida; para realizar esto, el analista selecciona áreas de identidad conocida de la cubierta terrestre de interés (cultivos, forestaciones, suelos, etc.) delineándolas sobre la imagen digital, bajo formas de polígonos, como regiones de interés constituyendo los “datos de entrenamiento”. Para realizar la selección el analista debe tener un conocimiento previo del área de estudio, ya sea por reconocimiento de campo, por consulta de mapas, fotografías aéreas, etc. En definitiva se asume que las áreas de entrenamiento son fieles representantes de las distintas categorías, y por lo tanto las medidas extraídas a partir de sus  $ND$  definen convenientemente a esas clases [23].

### **Clasificación No Supervisada**

Este método tiene como objetivo determinar, con la mínima intervención posible del usuario, las clases presentes en la imagen. No es necesario conocer detalles del área de estudio, por lo que la intervención humana se centra más en la interpretación posterior a la clasificación.

Esta familia de estrategias involucra algoritmos que permiten encontrar los grupos de píxeles con  $ND$  u otras características similares; la idea es que los valores de  $ND$  dentro de un cierto tipo de cubierta de terreno estén próximos en el espacio de mediciones, mientras que los datos provenientes de categorías diferentes deberían estar comparativamente más separados. Para realizar los agrupamientos se pueden utilizar diversas técnicas como, por ejemplo, *Agrupamiento o Clusters* del Análisis Estadístico Multivariado, que se basa en lo siguiente:

- Determinar las variables que intervienen,
- Establecer el criterio para medir la similitud o distancia entre objetos,
- Aplicar algún criterio para agrupar los objetos similares.

Decimos que las variables son las bandas espectrales seleccionadas para la clasificación y los objetos son los píxeles que componen la imagen.

Para delimitar las clases se debe calcular la similitud entre píxeles o matriz de distancia. Se han propuesto varios criterios para medir esta distancia, siendo el más usual el que se basa en la distancia euclidiana, pero también se puede utilizar la de Mahalanobis. Por otra parte, se deben definir las condiciones de agrupamiento. Los algoritmos de agrupamiento son numerosos siendo los más utilizados en clasificación no supervisada el de *k-means* (Johnson y Wichern, 1998) e *IsoData* (Duday Hart, 1973).

En resumen el método no supervisado puede considerarse como exploratorio, dirigido a deducir las clases presentes en la imagen, ya que se orienta a definir precisamente los grupos o categorías que intervendrán en la clasificación propiamente dicha [11].

### 3.4.2. Fase de Asignación

Una vez que se dispone del conjunto de datos de entrenamiento se debe tratar de adjudicar cada uno de los píxeles de la escena a alguna clase. Entre los algoritmos clásicos para estos fines citaremos los siguientes:

- Clasificador por Mínima Distancia
- Clasificador por Paralelepípedos
- Clasificador por Máxima Verosimilitud
- Clasificador por Mahalanobis

#### Clasificador por Mínima Distancia

El criterio más sencillo para signar un píxel a una de las categorías consiste en incluirlo en la más cercana es decir, en aquella que minimice la distancia entre ese píxel y el centroide de la clase.

Pueden considerarse varias formas de medir esa distancia espectral entre píxeles y clases. La más empleada, es la distancia euclidiana:

$$d_{x,A} = \sqrt{\sum_{i=1..m} (ND_{x,i} - \overline{ND}_{A,i})^2} \quad (3.3)$$

donde  $d_{x,A}$  es la distancia entre el píxel  $x$  y la categoría A;  $ND_{x,i}$  el valor correspondiente al píxel a clasificar en la banda  $i$ , y  $\overline{ND}_{A,i}$  el valor medio de esa categoría en la misma banda, dicho valor se calcula utilizando los datos de entrenamiento. Tras calcular esta distancia para todas las categorías se obtiene el  $d_{x,A}$  más pequeño, asignando el píxel  $x$  a esa categoría [23].

Desde el punto de vista computacional este algoritmo es bastante sencillo y rápido de ejecutar, y puede ofrecer buenos resultados cuando no se observe un gran solape entre categorías.

### Clasificador por Paralelepípedos

En este método, el usuario fija un área de dominio para cada categoría, teniendo en cuenta sus valores de centralidad y dispersión. Posteriormente, un píxel es asignado a dicha clase si sus  $ND$  están dentro de ese área de dominio, en todas las bandas consideradas. Esquemáticamente, el píxel  $x$  será asignado a la clase  $A$  si sus  $ND$  en las distintas bandas ( $ND_{x,k}$ ) están incluidos en el área de dominio de esa clase:

$$\overline{ND}_{A,i} - R_{A,i} \leq ND_{x,i} \leq \overline{ND}_{A,i} + R_{A,i} \quad (3.4)$$

para todo  $i$ , variando de 1 hasta el número de bandas.  $R_{A,i}$  indica el rango de dispersión señalado para la categoría  $A$  en cada banda  $i$ .

En este caso la regla de decisión es que el píxel  $x$  es asignado a la clase  $A$  si sus  $ND$  se encuentran a menos de una determinada distancia del centro de esa clase. Esa distancia se fija por el intérprete, aunque suele identificarse con la desviación estándar o también puede emplearse el rango de categoría entre otros. En cualquier caso, conviene considerar que cuanto mayor sea ese umbral, mayor también el número de píxeles incluidos es esa clase, pero también más grande el riesgo de confusiones con categorías vecinas. Este criterio de asignación tiende a delinear unos polígonos multidimensionales de lados paralelos, de ahí su nombre, en torno al centro de cada categoría. Este clasificador es rápido y fácil de implementar. Tiene sin embargo fuentes de error asociadas al frecuente solapamiento de los paralelepípedos: un píxel puede caer dentro de más de un paralelepípedo si éstos se solapan. Puede darse también el caso de que no caiga en ninguno. Estos factores quitan robustez al clasificador [23].

### Clasificador por Máxima Verosimilitud

Este es un algoritmo paramétrico que, a diferencia de los anteriormente considerados (no paramétricos) asume alguna distribución estadística particular para las clases consideradas. Este clasificador es uno de los más empleados en la clasificación supervisada y utiliza un modelo probabilístico, comúnmente la distribución gaussiana para formular sus reglas de decisión en la categorización de los píxeles.

Los parámetros necesarios para este modelo, como la media y la matriz de covariancia se obtienen de los datos de las áreas de entrenamiento. Veamos los fundamentos de este clasificador.

Supongamos que una imagen posee un total de  $M$  clases que representaremos como  $C_i$ ,  $i = 1 \dots M$ , para determinar la clase a la que pertenece un píxel en la posi-



ción  $x$ , nos interesa fundamentalmente conocer las probabilidades condicionales  $P(C_i|x)$ ,  $i = 1...M$ .

El término  $P(C_i|x)$  da la probabilidad de que la clase correcta para un píxel en la posición  $x$  sea  $C_i$ . La clasificación se llevará a cabo según la regla:

$$x \in C_i \text{ si } P(C_i|x) > P(C_j|x) \forall j \neq i \quad (3.5)$$

El problema es que los  $P(C_i|x)$  en (3.5) son desconocidos. Ahora bien, si tenemos suficientes datos de entrenamiento podremos estimar una distribución de probabilidad  $P(x|C_i)$  que describe la posibilidad de encontrar un píxel de una clase  $C_i$  en la posición  $x$ .

Para un píxel en una posición  $x$  existirá un conjunto de probabilidades relativas de que el píxel pertenezca a cada una de dichas clases. A esta probabilidad podremos estimarla a partir de los datos de entrenamiento. Tenemos ahora una probabilidad desconocida,  $P(C_i|x)$ , que es la que nos interesa, y una conocida  $P(x|C_i)$  obtenida a partir de los datos de entrenamiento. Ambas están relacionadas por el teorema de Bayes:

$$P(C_i|x) = P(x|C_i)P(C_i)/P(x) \quad (3.6)$$

donde  $P(C_i)$  es la probabilidad de que la clase  $C_i$  esté presente en la imagen. En cuanto a  $P(x)$  es la probabilidad de encontrar un píxel de cualesquiera de las clases en la posición  $x$ . Aunque para lo que sigue  $P(x)$  no va a ser importante podemos notar que por el teorema de la probabilidad total:

$$P(x) = \sum_{i=1}^M P(x|C_i)P(C_i) \quad (3.7)$$

Basándonos en (3.6) podemos escribir la regla (3.5) como

$$x \in C_i \text{ si } P(x|C_i)P(C_i) > P(x|C_j)P(C_j) \forall j \neq i \quad (3.8)$$

En (3.8) se eliminó  $P(x)$  al ser factor común. Por conveniencia matemática definiremos funciones discriminantes  $g_i(x)$  como:

$$g_i(x) = \ln P(x|C_i)P(C_i) = \ln P(x|C_i) + \ln P(C_i) \quad (3.9)$$

con lo cual podremos escribir (3.8) como

$$x \in C_i \text{ si } g_i(x) > g_j(x) \forall j \neq i \quad (3.10)$$

Pasemos ahora a considerar la forma de la función de distribución de probabilidad  $P(x|C_i)$ . Asumiremos para dicha función el modelo normal multivariado. En consecuencia, para un caso de  $N$  bandas espectrales puede demostrarse que:

$$P(x|C_i) = (2\pi)^{-N/2} |\Sigma_i|^{-1/2} \exp\{-1/2(x - m_i)^t \Sigma_i^{-1} (x - m_i)\} \quad (3.11)$$

donde  $m_i$  y  $\Sigma_i$  son respectivamente la media y la matriz de covarianza de los datos de la clase  $C_i$ , reescribiendo (3.9) y teniendo en cuenta (3.11) resulta

$$g_i(x) = \ln P(C_i) - 1/2 \ln |\Sigma_i| - 1/2(x - m_i)^t \Sigma_i^{-1} (x - m_i) \quad (3.12)$$

donde suprimimos el término  $(-N/2) \ln(2\pi)$  común a todos los  $g_i(x)$ , el que no contribuye a la discriminación. Puesto que la dificultad de estimar  $P(C_i)$  hace que usualmente esta probabilidad se considere la misma para todas las clases podemos simplificar (3.12) eliminando dicho término así como el factor común  $1/2$ . Finalmente queda:

$$g_i(x) = -\ln |\Sigma_i| - (x - m_i)^t \Sigma_i^{-1} (x - m_i) \quad (3.13)$$

Este clasificador asigna cada píxel no clasificado a una clase, de acuerdo a un criterio Gaussiano de probabilidad [42].

### Clasificador por Mahalanobis

La distancia de Mahalanobis es definida como [42]:

$$d(x, m_i) = \sqrt{(x - m_i)^t \Sigma^{-1} (x - m_i)} \quad (3.14)$$

donde  $m_i$  es el vector promedio y  $\Sigma$  la matriz de covarianza de las muestra.

Actualmente dicha distancia es usada para diferentes propósitos estadísticos, por ejemplo para la detección de datos fuera de rango (outliers).

El procedimiento es el siguiente: un vector  $x$  pertenece a la  $i$ -ésima clase si la distancia entre él y el centroide de la  $i$ -ésima clase es mínimo.

### 3.4.3. Fase de Verificación

En sentido estricto ninguna clasificación puede considerarse completa hasta que su grado de exactitud sea evaluado. Este puede definirse como el grado de concordancia entre las clases asignadas por el clasificador y sus ubicaciones correctas según datos recolectados por el analista y considerados como datos de referencia.

El instrumento más usual para evaluar la exactitud de una clasificación es la matriz de confusión, también llamada matriz de error o de contingencia. Esta es una matriz cuadrada de  $n \times n$ , donde  $n$  es el número de clases. Dicha matriz muestra la relación entre dos series de medidas correspondientes al área en estudio. La primera serie corresponde a datos de referencia adquiridos de observaciones de campo, inspección de estadísticas agrícolas, interpretación de fotos aéreas y otras fuentes similares. La segunda corresponde a la categorización de los píxeles realizada por el clasificador para las clases de interés. En una matriz de confusión las columnas corresponden a los datos de referencia, mientras que las filas corresponden a las asignaciones del clasificador.

A partir de una matriz de confusión pueden deducirse varios índices relativos a la exactitud de la clasificación. Para definir y comentar dichos índices observemos la tabla de valores de una matriz de confusión [42], visualizada en el Cuadro 3.1.

		Clases de referencia			Total
		A	B	C	
Categorías deducidas	A	35	2	2	39
	B	10	37	3	50
	C	5	1	41	47
Total		50	40	46	136

**Cuadro 3.1:** Ejemplo de Matriz de Confusión

Los elementos de la diagonal indican los píxeles que fueron correctamente clasificados. Todos los elementos fuera de la diagonal indican errores de omisión o de comisión. Los errores de omisión corresponden a los elementos no diagonales de las columnas (ej.: un total de 15 píxeles que debieran haber sido clasificados como “clase A”, se asignaron a otras clases). Los errores de comisión corresponden a los elementos no diagonales de las filas (ej.: 5 píxeles Clase A y 1 de Clase B se incluyeron erróneamente en la “Clase C”).

A partir de la matriz de confusión podemos calcular varias medidas de interés desde el punto de vista de la exactitud:

- **Exactitud Global:** Se calcula dividiendo el número total de píxeles correctamente clasificados por el número total de píxeles de referencia y expresándolo como porcentaje. En nuestro caso, sería:

$$(113/136) * 100 = 83,088 \%$$

Este índice es global y no nos indica cómo la exactitud se reparte entre las diversas categorías individuales. Muchas veces las categorías individuales presentan exactitudes drásticamente diferentes pero se combinan de modo que esto no se refleja en la exactitud global. Examinando la matriz de confusión vemos que podemos utilizar dos métodos para evaluar la exactitud de las categorías individuales:

- **Exactitud del Usuario:** Se calcula dividiendo el número de píxeles correctamente clasificados en cada categoría por el número total de píxeles que fueron clasificados en dicha categoría (total de la fila). Como ejemplo en nuestro caso tenemos para la Clase A

$$(35/39) * 100 = 89,74 \%$$

Este índice se justifica en el caso de que el usuario está especialmente interesado en el porcentaje de cada clase que ha sido correctamente clasificado.

- **Exactitud de Productor:** Resulta de dividir el número de píxeles correctamente clasificados en cada categoría por el número de píxeles de referencia utilizados para dicha categoría (total de la columna). En nuestro caso tendremos para la clase A:

$$(35/50) * 100 = 70 \%$$

El productor está más interesado en este índice pues le dice cuan bien los píxeles de referencia han sido clasificados.

Las medidas de exactitud que acabamos de considerar, aunque simples de usar están basadas sea en la diagonal principal, sea en las filas y columnas de la matriz de confusión solamente. Estas medidas no aprovechan la información contenida en dicha matriz considerada en conjunto. Más aún, puede ocurrir que una distribución totalmente aleatoria de los píxeles en las clases pueda conducir a resultados aparentemente correctos en la matriz de confusión [42].

Buscando superar estos inconvenientes se ha propuesto un índice denominado coeficiente kappa. Este estadístico es una medida de la diferencia entre la exactitud lograda en la clasificación con un clasificador automático y la chance de lograr una clasificación correcta con un clasificador aleatorio.

La siguiente es la expresión de  $\kappa$  más adecuada para fines computacionales:

$$\kappa = \frac{N \sum_{i=1}^r x_{(i,i)} - \sum_{i=1}^r (x_{(i,+)}x_{(+,i)})}{N^2 - \sum_{i=1}^r (x_{(i,+)}x_{(+,i)})} \quad (3.15)$$

donde  $r$  es el número de filas de la matriz,  $x_{(i,i)}$  indica el acuerdo observado,  $x_{(i,+)}$  es el total de observaciones en la fila  $i$ ,  $x_{(+,i)}$  es el total de observaciones en la columna  $i$  y  $N$  el total de observaciones incluidas en la matriz.

Un valor de  $\kappa$  igual a 1 indica un acuerdo pleno entre la realidad y lo clasificado, mientras un valor cercano a 0 sugiere que el acuerdo observado es puramente debido al azar. Por su parte un valor negativo, supone también una clasificación pobre, si bien su sentido depende de otros factores externos, como el propio tamaño de la muestra [23].

## Capítulo 4

---

# Algoritmos basados en datos SAR

---

### 4.1. Introducción

La tarea de encontrar contornos y superficies de regiones es de suma importancia en el análisis de imágenes SAR porque permite interpretar automáticamente las mismas y solucionar problemas fundamentales en el área de procesamiento de imágenes.

Las imágenes de Radar de Apertura Sintética (SAR, Synthetic Aperture Radar) son utilizadas en monitoreo ambiental, conocimiento del ecosistema, detección de manchas de petróleo en el mar, detección de claros en bosques, inundaciones, agricultura y planeamiento urbano entre otras aplicaciones. Como se señaló en el capítulo 2 este tipo de imágenes posee un ruido inherente a su proceso de captura y formación, llamado ruido speckle. Este ruido es lo que hace que en estas imágenes se vea un granulado, y es la razón por la cual las mismas resultan muy difíciles de analizar e interpretar [30].

Cuando nos referimos a encontrar contornos de regiones podemos decir que existen algoritmos de detección de bordes que llevan a cabo dicha tarea. El ruido speckle es la principal dificultad a la que se deben enfrentar dichos algoritmos ya que muchos de ellos encuentran regiones utilizando extracción local de características, es decir utilizando la información presente en un pixel. En el caso de detección de bordes de objetos en imágenes con ruido speckle, no es posible utilizar la información puntual, sino que hay que analizar la imagen a partir de conjuntos de píxeles.

En lo que respecta a la detección de superficies de regiones este trabajo está enfocado particularmente a la detección de superficies de agua. Tradicionalmente, esta tarea se ha desarrollado a partir de técnicas de clasificación sustentadas en la determinación de umbrales sobre la intensidad de la imagen. Estas técnicas requieren datos muy precisos del ángulo de incidencia el cual ayuda a determinar

el aspecto de un objeto en la imagen. La utilidad de estas metodologías es de eficacia limitada dado que el contraste entre la tierra y el agua disminuye con el ángulo de incidencia. Por lo tanto resulta de gran interés el desarrollo de métodos de clasificación de imágenes SAR, que actúen con cierta independencia del ángulo de incidencia, preferentemente no supervisados y que permitan la detección automática de superficies de agua. Además un algoritmo debería ser lo bastante robusto para hacer frente al ruido multiplicativo (speckle); es decir, el proceso de segmentación debe considerar no sólo los valores de cada píxel sino también las propiedades de la textura de la imagen que será procesada. Tales métodos de segmentación ya han sido desarrollados tanto en el contexto del procesamiento de imágenes como en el computacional [26].

En la siguiente sección hablaremos sobre algoritmos para la detección de bordes y se estudiarán, en particular, los algoritmos de contorno activo cuyas principales ventajas son:

1. dan una estimación de los contornos de cuerpos de agua en imágenes SAR
2. son resistentes al ruido speckle propio de dichas imágenes.

En la última sección desarrollaremos el algoritmo automático para la detección de cuerpos de agua, basado en el método de máxima verosimilitud, el cual es el tema de estudio de este trabajo.

## 4.2. Algoritmos para la detección de bordes

La detección de bordes es un método del proceso de segmentación y además es uno de los más usados comúnmente en el análisis de imágenes. Esto es debido a que ellos detectan el contorno de un objeto.

Un borde es el límite entre un objeto y el fondo. Esto quiere decir que si los bordes en una imagen pueden ser identificados con exactitud, todos los objetos de la imagen pueden ser localizados y propiedades básicas como áreas, perímetros y formas pueden ser determinadas.

Técnicamente, la detección de bordes es el proceso de localización de los píxeles de borde y el realce de los mismos lo cual aumentará el contraste entre los bordes y el fondo de modo que estos se hagan más visibles [40].

Diversos autores han estudiado el problema de adaptar los métodos clásicos de procesamiento de imágenes para que puedan ser aplicados a imágenes SAR, utilizando técnicas basadas en detección de bordes ([9], [37], [39]) o filtrado ([17], [21], [25]), con relativo éxito. Estas técnicas tienen en común el análisis de la imagen completa pixel por pixel, lo que implica un alto costo computacional, teniendo en cuenta las grandes dimensiones que pueden poseer las imágenes SAR.

### 4.2.1. Algoritmos de Contorno Activo

Los algoritmos de contornos activos (*Snakes*) están siendo muy utilizados en los últimos años, por su robustez y tratabilidad; ellos usan estadísticas de la imagen para alcanzar su objetivo, que es básicamente delinear objetos en una imagen.

Dichos algoritmos (snakes o serpenteantes) son modelos estadísticos que encuentran fronteras en imágenes incompletas o ruidosas. La idea es que la serpiente (representado por un contorno cerrado discreto de nodos unidos) es puesta sobre un área aproximadamente homogénea la que luego será delineada. Por ejemplo: si queremos delinear un círculo ruidoso, blanco sobre un fondo negro, debemos inicializar la serpiente de modo que cada nodo este, al principio, dentro del círculo. Luego un algoritmo iterativo es el encargado de conducir la serpiente para encontrar fronteras en la imagen. Este método ha sido satisfactoriamente usado para la delimitación de áreas inundadas [26].

El primer algoritmo de detección de bordes para imágenes ópticas, basado en evolución de curvas por medio de la minimización de la energía y cálculo variacional, fue desarrollado por Kass *et al* [15]. Consiste en la evolución de una curva dentro de la imagen, hasta ajustar el borde de un objeto. Este método presenta serias limitaciones porque tiene dificultades en la convergencia si el objeto no es convexo, es muy sensible a la ubicación del contorno inicial y no permite cambios en la topología. Se han desarrollado diversas mejoras a este procedimiento que solucionan los problemas planteados, como los métodos de *distance snakes* [27], *balloon snakes* [14], *contornos deformables* [16] y *gradient vector flow snakes* [29], que resultan muy poco robustos en imágenes con ruido y son muy sensibles a modificaciones en los parámetros, como se muestra en el artículo [10], donde se comparan todos ellos.

Otra clase de algoritmos de contornos activos son aquellos basados en regiones. Germain *et al.* presentaron en [36] un algoritmo de este tipo para datos que siguen la ley de probabilidad  $\Gamma$ . En este esquema un contorno es deformado iterativamente para localizar el borde de un objeto, guiado por un criterio estadístico, utilizando la distribución  $\Gamma$  para caracterizar los datos. El problema del método es que la distribución  $\Gamma$  no modela apropiadamente los datos SAR provenientes de regiones muy heterogéneas.

## 4.3. Algoritmo automático para la detección de cuerpos de agua

### 4.3.1. Descripción del método

El método propuesto por Ahtonen, Euro, Hallikainen, Solbø, Johansen y Solheim [26], para la detección de cuerpos de agua, está basado en la información

proporcionada por la textura de la imagen, y utiliza como características de textura, medidas estadísticas locales: rango de la intensidad, media y varianza.

Es importante elegir características de textura que produzcan buena separación entre las diferentes clases de textura que se desea distinguir. La media y la varianza locales han mostrado ser capaces de distinguir correctamente entre texturas de agua y tierra como ya hemos explicado en el capítulo 3.

En este trabajo, se obtienen características de textura a partir de imágenes de intensidad; para cada posición  $(i, j)$  se define el vector  $n(i, j)$  que contiene los valores de intensidad de la imagen en una ventana de  $N \times N$  píxeles, con  $N$  impar, centrada en la posición  $(i, j)$ . El vector  $y(i, j)$  dado por:

$$y(i, j) = [DR(\{n_{i,j}\}), E(\{n_{i,j}\}), Var(\{n_{i,j}\})]^T \quad (4.1)$$

proporciona información local sobre la textura de la imagen; donde  $DR(\{n_{i,j}\}) = \max(\{n_{i,j}\}) - \min(\{n_{i,j}\})$ ,  $E(\{n_{i,j}\})$  es la media y  $Var(\{n_{i,j}\})$  es la varianza, calculadas sobre los valores de intensidad del vector  $n(i, j)$ . Al conjunto de valores  $\{E(\{n(i, j)\})\}_{(i,j)}$  se lo conoce con el nombre de “media de la imagen”. En adelante, cuando sea necesario simplificar la notación y siempre que no cause confusión, se indicará  $y$  en lugar de  $y(i, j)$ .

Las clases a discriminar son dos: tierra y agua. El clasificador constituye un método de clasificación no supervisado pues sólo impone una pre-clasificación basada en la determinación de umbrales que se calculan automáticamente a partir de los datos; no requiere de datos de entrenamiento para las clases, cuya exactitud es crucial para el buen funcionamiento de la mayoría de los clasificadores supervisados (ver Capítulo 3). Además en la clasificación supervisada se requiere conocer con bastante exactitud el ángulo de incidencia para cada clase de entrenamiento y para cada escena, lo cual evidentemente no es necesario en el método que se implementa en este proyecto.

Denotaremos  $\omega_l$  a la clase “tierra”, y con  $\omega_w$  a la clase “agua”. Ambas clases pueden ser modeladas con una función de distribución Gaussiana tridimensional. Esto es, para  $c \in \{w, l\}$  y para cada  $y$ :

$$p(y, \omega_c) = \frac{\exp\{(-1/2)(y - \mu_c)^T \Sigma_c^{-1} (y - \mu_c)\}}{(2\pi)^{3/2} |\Sigma_c|^{1/2}} \quad (4.2)$$

donde  $\mu_c$  denota al vector promedio de la clase  $c$  y  $\Sigma_c$  es la matriz de covarianza de la clase  $c$ .  $\mu_c$  y  $\Sigma_c$  son parámetros desconocidos. Para estimarlos, se establece un umbral sobre el histograma del conjunto  $\{E(\{n(i, j)\})\}_{(i,j)}$  (umbral sobre la media de la imagen). A partir de este umbral se preclasifican los píxeles en una



u otra clase y se estiman preliminarmente  $\mu_c$  y  $\Sigma_c$ , como:

$$\hat{\mu}_c = \frac{1}{N_c} \sum_{n=1}^{N_c} y_n \quad (4.3)$$

$$\hat{\Sigma}_c = \frac{1}{N_c} \sum_{n=1}^{N_c} (y_n - \hat{\mu}_c)(y_n - \hat{\mu}_c)^T \quad (4.4)$$

con  $c \in \{w, l\}$ , siendo  $\{y_1, y_2, y_3, \dots, y_{N_c}\}$  el conjunto de vectores correspondientes a píxeles preclasificados en la clase  $c$ . A estos vectores se los llama “vectores de auto-entrenamiento de la clase  $c$ ”.

Para imágenes que contienen superficies de agua y superficies de tierra, el histograma de la media de las intensidades, tendrá generalmente una moda correspondiente a los píxeles de agua y una moda correspondiente a los píxeles de tierra. La propuesta de los autores del detector automático de agua, es usar como umbral la intensidad mínima entre las modas [26], aunque no se detalla cómo calcularlo.

Para mejorar la exactitud de la clasificación, se eliminan los outliers de ambas clases, y se re estiman  $\hat{\mu}_c$  y  $\hat{\Sigma}_c$ . Se definen como outliers de la clase  $c$  a los píxeles cuyos vectores de autoentrenamiento satisfacen la condición:

$$(y - \hat{\mu}_c)^T \hat{\Sigma}_c^{-1} (y - \hat{\mu}_c) > \chi_{n,\alpha}^2 \quad (4.5)$$

donde  $\chi_{n,\alpha}^2$  es el valor de la distribución Chi-Cuadrado que deja a su derecha el  $\alpha\%$  de los datos,  $n$  es el número de componentes del vector característico, en este caso 3. Este algoritmo está basado en un clasificador de máxima verosimilitud (desarrollado en el capítulo 3) que simplemente clasifica al píxel  $(i, j)$  dentro de la clase con más alta probabilidad de incluir a  $y(i, j)$ . Es decir:

$$y(i, j) \in \begin{cases} \omega_l & \text{si } p(y(i, j)|\omega_l) > p(y(i, j)|\omega_w) \\ \omega_w & \text{si } p(y(i, j)|\omega_w) > p(y(i, j)|\omega_l) \end{cases}$$

### 4.3.2. Resumen del algoritmo automático

A continuación presentamos el algoritmo del proceso previamente descrito:

- Reducción del ruido speckle de la imagen SAR
- Para cada posición  $(i, j)$  usar la información de los píxeles contenidos en una ventana  $N \times N$ , con  $N$  impar para definir el vector  $n_{i,j}$ , y calcular el vector dado por:

$$y(i, j) = [\text{máx}\{n_{i,j}\} - \text{mín}\{n_{i,j}\}, E(\{n_{i,j}\}), \text{Var}(\{n_{i,j}\})]^T$$

- Determinar el umbral  $t$  (mínimo local entre modas) en el histograma de la media de la imagen.

- Usar el umbral  $t$  para obtener dos conjuntos de índices; uno correspondiente a los píxeles pre-clasificados como agua y otro correspondiente a los píxeles pre-clasificados como tierra,

$$Y_l = \{(i, j) | \bar{y}(i, j) > t\}$$

$$Y_w = \{(i, j) | \bar{y}(i, j) \leq t\}$$

- Estimar la media y la varianza en cada clase como  $\hat{\mu}_c$  y  $\hat{\Sigma}_c$  dados por (4.3) y (4.4).
- Para cada  $c \in \{w, l\}$ , remover los outliers, sustituyendo  $Y_c$  por  $\tilde{Y}_c$ :

$$\tilde{Y}_c = \{(i, j) | (y(i, j) - \hat{\mu}_c)^T \hat{\Sigma}_c^{-1} (y(i, j) - \hat{\mu}_c) \leq \chi_{n, \alpha}^2\}$$

- Re-estimar  $\hat{\mu}_c$  y  $\hat{\Sigma}_c$  de  $\tilde{Y}_c$ ,  $c \in \{w, l\}$ .
- Clasificar al píxel  $(i, j)$  como agua si:

$$p(y(i, j); \hat{\mu}_w; \hat{\Sigma}_w) > p(y(i, j); \hat{\mu}_l; \hat{\Sigma}_l)$$

## Capítulo 5

# El Detector Automático de Agua (Automatic Water Detector)

### 5.1. Descripción de las Fases del Detector Automático de Agua

El Detector Automático de Agua consta de tres fases principales, ellas son: *Regionalizar*, *Clasificador Automático de Agua* y *Colorear Región*, como se pueden observar en la Figura 5.1.

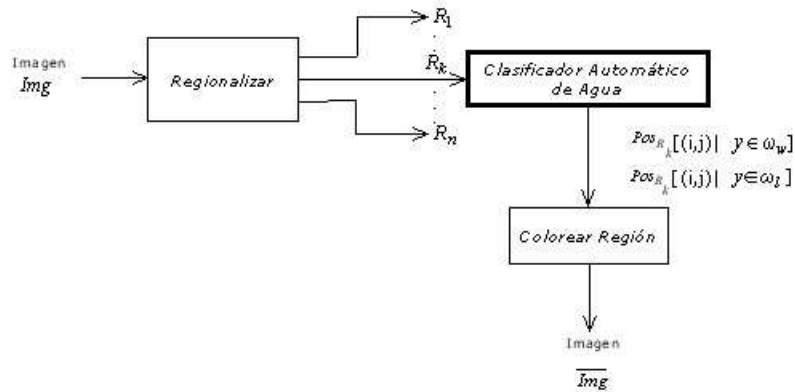


Figura 5.1: Fases del Detector Automático de Agua

La fase *Regionalizar* recibe una imagen de radar previamente procesada *Img* a través de un filtro de mediana, procedimiento que como se describe en la sección 2.1.3 en la página 18, se utiliza para reducir el ruido speckle inherente a este tipo

de imágenes.

*Regionalizar* se encarga de particionar  $Img$  en regiones más pequeñas,  $R_1 \dots R_n$ , las cuales serán clasificadas secuencialmente por la fase *Clasificador Automático de Agua*. Esta división se debe al gran tamaño de las imágenes de radar; esto es debido a que las imágenes de radar son en general de gran tamaño. En el caso de las imágenes RADARSAT 1 que se utilizaron para este trabajo, tienen un área nominal sobre el terreno de  $8m$ , un área aproximada (en  $Km$ ) de  $50 \times 50$  y un tamaño de la imagen digital aproximado a  $8000 \times 8000$  píxeles [24].

Dada una región  $R_k$ , la fase *Colorear Región* es la encargada de pintar en la imagen  $Img$ , las posiciones de la región ya clasificadas como agua y como tierra. Luego de realizar este proceso para cada región se obtendrá la imagen completa pintada  $\overline{Img}$ .

El algoritmo presentado en la sección 4.3.2, página 41 es desarrollado por la fase principal, *Clasificador Automático de Agua*. Ésta recibe una región  $R_k$ , la cual será procesada por el algoritmo; obteniendo como resultado las posiciones de  $R_k$  clasificadas en cada categoría, tierra o agua. Dicha fase se compone de seis subfases: ***Estadísticas de Región***, ***Clasificador por Umbral***, ***ML-Estimador***, ***Mahalanobis Clasificador***, ***ML-ReEstimador*** y ***Clasificador***, como se puede apreciar en la Figura 5.2.

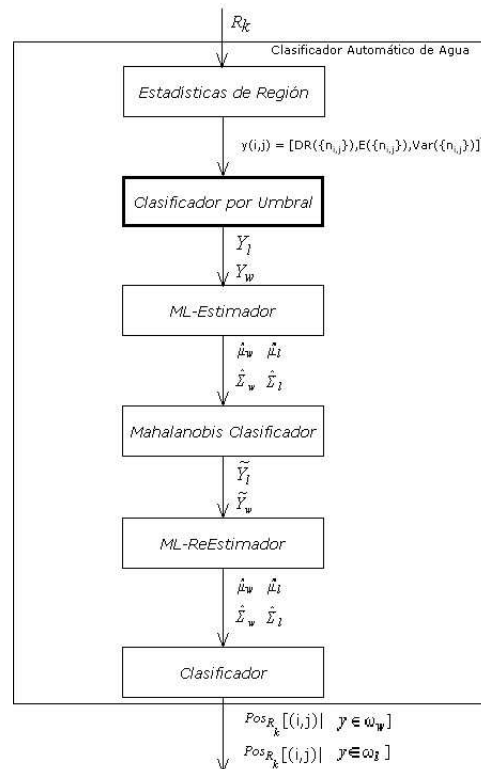


Figura 5.2: Subfases de *Clasificador Automático de Agua*

A continuación se describen cada una de estas subfases. Es fácil comprobar que las mismas implementan el algoritmo desarrollado en [26] que describimos en la sección 4.3.2 en página 41.

### 5.1.1. Subfase Estadísticas de Región

Es la encargada de recibir la región  $R_k$  y analizar las características estadísticas de ésta, obteniendo el vector característico para cada posición  $(i, j)$  de  $R_k$ . Puntualmente, para cada píxel con posición  $(i, j)$  en la región, definimos  $y(i, j)$ , cuya función es proporcionar información local de la textura; usando para este fin una ventana móvil de  $N \times N$ , con  $N$  impar, la cual se centra en  $(i, j)$ .

El vector característico  $y(i, j)$  está dado por:

$$y(i, j) = [DR(\{n_{i,j}\}), E(\{n_{i,j}\}), Var(\{n_{i,j}\})]^T \quad (5.1)$$

donde  $n_{i,j}$  es un vector que contiene los valores de intensidad de los píxeles vecinos a  $(i, j)$ ,  $DR(\{n_{i,j}\}) = \max(\{n_{i,j}\}) - \min(\{n_{i,j}\})$ ,  $E(\{n_{i,j}\})$  es el promedio y  $Var(\{n_{i,j}\})$  es la varianza, calculadas sobre los elementos del vector  $n_{i,j}$ .

### 5.1.2. Subfase Clasificador por Umbral

Realiza una primera clasificación en base a un umbral, el cual es calculado automáticamente a partir del histograma de la región  $R_k$ . Comprende cuatro subfases, como se puede ver en la Figura 5.3

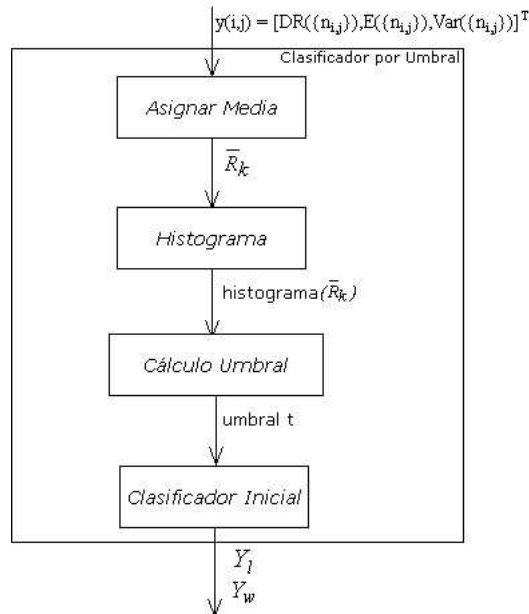


Figura 5.3: Subfases de *Clasificador por Umbral*

- **Asignar Media:** Esta subfase recibe el vector característico  $y(i, j)$  dado por la ecuación 5.1 y asigna a cada píxel de posición  $(i, j)$  en  $R_k$  la esperanza de calculada en base a sus píxeles vecinos, es decir,  $E(\{n_{i,j}\})$ . De esta forma se obtiene una región suavizada a la que llamamos  $\bar{R}_k$ .
- **Histograma:** Recibe la región suavizada  $\bar{R}_k$  y calcula el histograma de la región; para imágenes que contienen tierra y agua, en general el histograma tendrá una moda correspondiente a los píxeles de agua y una correspondiente a los de tierra.
- **Cálculo Umbral:** Como su nombre lo indica, su objetivo es; a partir del histograma de  $\bar{R}_k$  (histograma del conjunto  $\{E(\{n_{i,j}\})\}_{(i,j)}$ ), calcular automáticamente el umbral  $t$  que será el mínimo local entre modas.
- **Clasificador Inicial:** Recibe el umbral  $t$  y realiza la primera clasificación en base a éste, obteniendo dos conjuntos de índices  $Y_w$  e  $Y_l$ , correspondientes a los píxeles preclasificados como agua y a los píxeles preclasificados como tierra, respectivamente.  $Y_w$  e  $Y_l$  están dados por:

$$\begin{aligned} Y_w &= \{(i, j) | E(\{n_{i,j}\}) \leq t\} \\ Y_l &= \{(i, j) | E(\{n_{i,j}\}) > t\} \end{aligned} \quad (5.2)$$

### 5.1.3. Subfase ML-Estimador

Recibe las clases  $Y_w$  (agua) e  $Y_l$  (tierra) dados por (5.2), a partir de éstas, estima la media  $\hat{\mu}_c$  y la matriz de covarianza  $\hat{\Sigma}_c$ , con  $c \in \{w, l\}$  dados por:

$$\hat{\mu}_c = \frac{1}{|Y_c|} \sum_{q \in Y_c} y_q \quad (5.3)$$

$$\hat{\Sigma}_c = \frac{1}{|Y_c|} \sum_{q \in Y_c} (y_q - \hat{\mu}_c)(y_q - \hat{\mu}_c)^T \quad (5.4)$$

### 5.1.4. Subfases Mahalanobis Clasificador y ML-ReEstimador

*Mahalanobis Clasificador* realiza una segunda clasificación en base a la distancia de Mahalanobis, para cada  $c \in \{w, l\}$  remueve los outliers sustituyendo  $Y_c$  por  $\tilde{Y}_c$ ; donde  $\tilde{Y}_c$  esta dado por:

$$\tilde{Y}_c = \{(i, j) | (y(i, j) - \hat{\mu}_c)^T \hat{\Sigma}_c^{-1} (y(i, j) - \hat{\mu}_c) \leq \chi_{n,\alpha}^2\} \quad (5.5)$$

Definimos como outliers de la clase  $c$ , a los píxeles cuyos vectores ya clasificados en la etapa previa, satisfacen la condición:

$$(y(i, j) - \hat{\mu}_c)^T \hat{\Sigma}_c^{-1} (y(i, j) - \hat{\mu}_c) > \chi_{n,\alpha}^2 \quad (5.6)$$

donde  $n$  es el número de componentes, en este caso 3 y  $\alpha$  el nivel de significación.

*ML-ReEstimador*, efectúa un nuevo cálculo de  $\hat{\mu}_c$  dada en (5.3) y  $\hat{\Sigma}_c$  de la ecuación (5.4); basándose en las clases  $\tilde{Y}_c$  de la ecuación (5.5).

### 5.1.5. Subfase Clasificador

Esta subfase realiza la clasificación final, asignando el vector característico  $y(i, j)$  a la clase con mayor probabilidad,

$$y(i, j) \in \begin{cases} \omega_l & \text{si } p(y(i, j)|\omega_l) > p(y(i, j)|\omega_w) \\ \omega_w & \text{si } p(y(i, j)|\omega_w) > p(y(i, j)|\omega_l) \end{cases}$$

donde  $\omega_w$  y  $\omega_l$  representan las clases de píxeles que son clasificados como agua y los que son clasificados como tierra, respectivamente. Ambas clases pueden ser modeladas con una función de distribución Gaussiana tridimensional.

$$p(x|\omega_c) = \frac{\exp\{(-1/2)(x - \mu_c)^T \Sigma_c^{-1} (x - \mu_c)\}}{(2\pi)^{3/2} |\Sigma_c|^{1/2}} \quad (5.7)$$

donde  $\mu_c$  y  $\Sigma_c$ , son el vector de la media y la matriz de covarianza, respectivamente, de la clase  $c \in \{w, l\}$ . Como se describió en la sección 3.4.2,  $p(x|\omega_c)$  es la probabilidad que  $x$  pertenezca a la clase  $\omega_c$ .

Los parámetros en  $p(x|\omega_c)$  son estimados a partir de los datos de entrenamiento;  $\hat{\mu}_c$  y  $\hat{\Sigma}_c$ .

La clasificación final será, entonces, decidir si el píxel  $(i, j)$  pertenece a la clase “agua” si cumple:

$$p(y(i, j)|\omega_w) > p(y(i, j)|\omega_l) \quad (5.8)$$

## 5.2. Implementación

### 5.2.1. ImageJ

Es un programa de dominio público de procesamiento de imágenes en JAVA, se puede ejecutar ya sea como un applet online o con las distribuciones descargables, hay distribuciones disponibles para Windows, Mac OS, Mac OS X y Linux.

Puede mostrar, editar, analizar, procesar, guardar e imprimir imágenes de 8, 16 y 32 bits. Lee la mayoría de los formatos de imágenes, incluyendo TIFF, GIF, JPEG, BMP, DICOM, FITS y “raw”. Además soporta “stacks”, que son conjuntos de imágenes que comparten una misma ventana.

Calcula valores estadísticos de áreas y píxeles seleccionados por el usuario. Mide distancias y ángulos. Además puede crear y dibujar histogramas de densidades. Soporta funciones de procesamiento de imágenes tales como manipulación del contraste, nitidez, detección de bordes y filtro de mediana.

Realiza transformaciones geométricas como escala, rotación y giros, se puede realizar zoom hasta 32:1 y 1:32. Todas las funciones de análisis y procesamiento están disponibles para cualquier factor de magnificación. El programa soporta cualquier número de ventanas (imágenes) simultáneas, limitadas solo por la memoria disponibles.

ImageJ fue diseñado con una arquitectura abierta que proporciona extensibilidad a través de plugins de JAVA. Los plugins escritos por el usuario permiten resolver cualquier análisis o procesamiento de imágenes.

Las funcionalidades de ImageJ pueden ser extendidas por el usuario en forma de macros o plugins. Los macros son una manera fácil de ejecutar una serie de comandos de ImageJ, éstos se pueden escribir en el editor que provee ImageJ.

Los plugins son más poderoso que los macros y la mayoría de los comandos de los menús son implementados mediante plugins. Los plugins son implementados como clases de Java, lo que significa que se pueden utilizar todas las características del lenguaje. El uso más común de los plugins son filtros que realizan algún análisis o procesamiento de alguna imagen o stack, entre otras utilidades [41].

### 5.2.2. Descripción de la implementación

La implementación del *Detector Automático de Agua* (AutomaticWaterDetector) se realizó en el lenguaje de programación Java y está pensado como una nueva funcionalidad para el software antes descrito. Esta idea fue motivada a partir de la propuesta del trabajo, en la que se pedía que la herramienta fuera de público dominio y pudiese ser utilizada en cualquier sistema operativo. Mediante la investigación y búsqueda bibliográfica, descubrimos ImageJ y con él la posibilidad de crear nuevas funcionalidades, extendiendo las capacidades del software; utilizando el manejo y procesamiento de imágenes que ImageJ provee.

En las siguientes secciones se describen los módulos, con sus respectivas clases y métodos, que forman parte de la implementación del *AutomaticWaterDetector* (Figura 5.4).

### 5.2.3. Módulo Regions

Implementa las fases *Regionalizar* y *Colorear Región*, descritas en la sección 5.1 en las páginas 43 y 44, respectivamente. Este módulo (Figura 5.5) recibe una imagen de radar *Img* previamente filtrada, dividiéndola en regiones  $R_1, \dots, R_n$ ; este procedimiento se realiza cuando *Img* tiene grandes dimensiones, ya que los cálculos involucrados para la clasificación se ven limitados por la memoria disponible.

Constituyen este módulo, **CRegions** cuyo método es *createRegion*. **ProcessRegion**, con el método *processRegion*, que se encargará de crear la región  $R_k$ , utilizando el método de **CRegions**, ejecutar el algoritmo que realiza la clasifi-



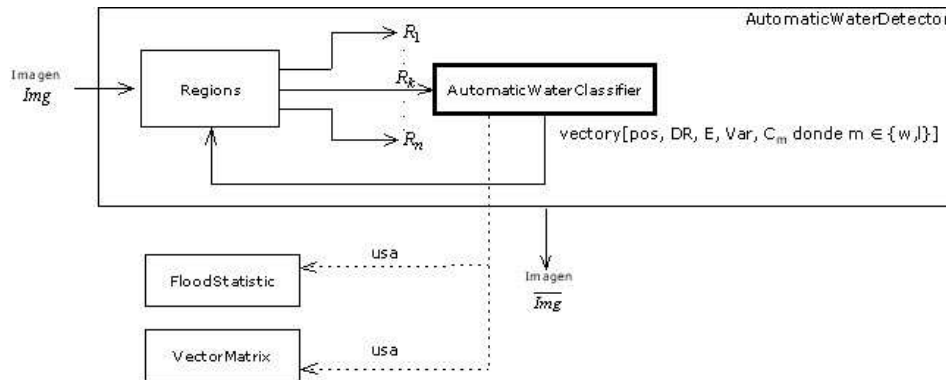


Figura 5.4: Módulos del AutomaticWaterDetector

cación para esa región; luego de la clasificación llamará a *paintImage*, método de la clase **ManageImage**, responsable de pintar los píxeles de la región que pertenecen a cada una de las categorías resultantes de la clasificación. La acción de colorear los píxeles se realiza sobre *Img*, previo mapeo de las posiciones de  $R_k$  en las posiciones que les corresponde en la imagen original.

**ProcessImage** implementa la interfaz del módulo *InterfaceProcessImage*; en esta clase definimos el tamaño que tendrán las regiones. Lleva a cabo el manejo de los bordes de las regiones, tarea que resulta necesaria; ya que, al utilizar una ventana móvil  $N \times N$  (con  $N$  impar), se pierden  $(N - (\lfloor N/2 \rfloor + 1))$  filas o columnas de cada uno de los bordes de la región. Por lo tanto, al procesar la siguiente región, deberíamos sumar los bordes que no se procesaron de la anterior. Si no tuviéramos en cuenta estos detalles, nos quedarían pequeñas porciones en la imagen sin analizar, y al pintar se verían líneas verticales y horizontales sin el coloreado producto de la clasificación. Por todo esto, es necesario manejar el solapamiento de bordes entre regiones, para que no haya partes de *Img* sin procesamiento, excepto, claro está, los bordes de la imagen grande.

Otra tarea que esta clase lleva a cabo, es el manejo y captura de la excepción que es lanzada en la clase **VectorMatrix** por el método *minversa*, cuando éste no puede realizar la inversa de una matriz de covarianza, necesaria para calcular  $p(x|\omega_c)$  (ecuación 5.6, página 46) porque su determinante es 0. El significado de que el determinante de la matriz de covarianza es 0, es que ésta contiene valores que son homogéneos, que en términos de la textura analizada por la ventana  $5 \times 5$ , podemos decir que la zona en estudio es de una textura bastante uniforme. Lo que nos lleva a querer ampliar la zona de estudio (ventana móvil), para analizar un sector mas grande que nos provea información con mayor heterogeneidad en términos de textura.

Retomando, el método *processImage*, al capturar la excepción, procesará la región  $R_k$  con una ventana móvil de tamaño  $7 \times 7$  para estudiar la textura; y hará los cálculos pertinentes para solapar los bordes, teniendo en cuenta el tamaño

de la ventana móvil, y con esto la cantidad de filas y columnas que no se procesan.

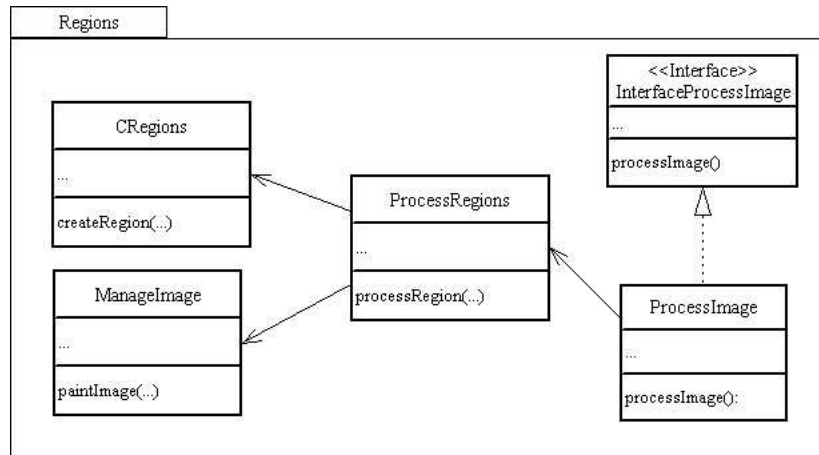


Figura 5.5: Clases del Módulo Regions

#### 5.2.4. Módulo FloodStatistic

Tiene como tarea calcular  $DR$ ,  $E$ ,  $Var$  del vector  $n_{i,j}$  (sección 5.1.1, página 45), las características estadísticas necesarias para luego formar el vector característico del píxel con posición  $(i, j)$  (ecuación 5.1).

Está formado por la clase **FloodStatistic** que implementa los métodos: *mean*, *variance*, *min* y *max*.

#### 5.2.5. Módulo VectorMatrix

Está formado por la clase **VectorMatrix** que implementa los métodos relacionados con el Álgebra lineal, éstos son *det*, *minversa*, *prodMatriz*, *restaVect*, *transpuesta*, *transpVector*, *adj2x2* y *adjunta*. Como mencionamos en la sección 5.2.3, el método *minversa* es el encargado de lanzar una excepción (que maneja y captura la clase **ProcessImage**) cuando el determinante de la matriz que se quiere invertir es 0.

#### 5.2.6. Módulo AutomaticWaterClassifier

Este módulo implementa la fase *Clasificador Automático de Agua* es decir, el algoritmo descrito en 4.3.2. Esta compuesto por una interfaz **InterfaceAlgorithm** y cinco submódulos: **FeatureStatisticRegion**, **ThresholdClassifier**, **ML\_Estimators**, **MahalanobisClassifier** y **Classifier**, como se muestra en la Figura 5.6.

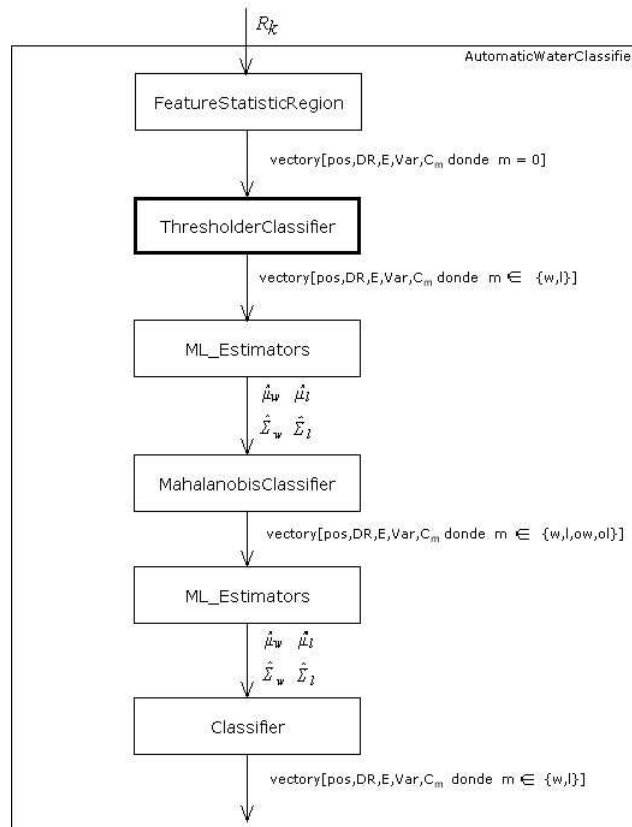


Figura 5.6: Submódulos del Módulo AutomaticWaterClassifier

### InterfaceAlgorithm

Esta interfaz cuyo método es *runAlgorithm* define el servicio que es prestado por el módulo AutomaticWaterClassifier, sin embargo no lo implementa. La clase **AWDetector** es la clase encargada de implementar el método de dicha interfaz.

### Submódulo FeatureStatisticRegion

Implementa la subfase *Estadísticas de Región* (5.1.1). Esta formado por la clase: **FeatureStatisticRegion**, la cual implementa los métodos *window*, método abstracto, y *VFeatureT* (Figura 5.7).

Recibe como input una región  $R_k$ , a la cual se le aplica la ventana móvil para extraer la información de textura y formar el vector característico  $y(i, j)$  dado por:

$$vector[ pos, DR, E, Var, C_m \text{ con } m = 0 ] \quad (5.9)$$

El vector es implementado como una matriz de tamaño  $5 \times T_R$ , donde  $T_R$  es el número total de píxeles de la región  $R_k$ . Como se observa en la ecuación (5.9), las cinco componentes del vector son:

- $pos$ , número de tipo Int, que contiene la posición  $(i, j)$  del píxel.
- $DR$ , descripto en la sección 4.3.1 (pág. 39).
- $E$ , descripto en la sección 4.3.1 (pág. 39).
- $E$ , descripto en la sección 4.3.1 (pág. 39).
- $C_m$ , label que indica a que clase pertenece el píxel de la posición  $pos$ . Inicialmente este label es 0; lo que representa que el píxel no pertenece a ninguna clase.

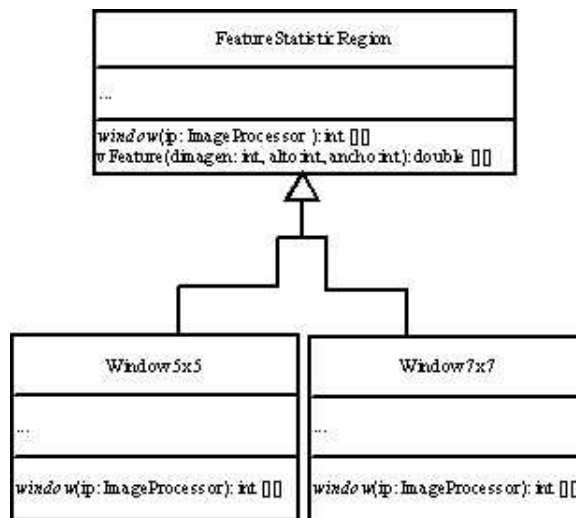
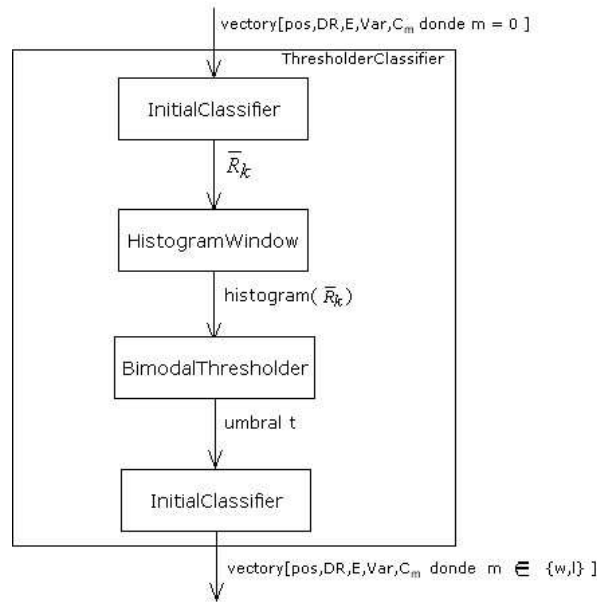


Figura 5.7: Clase FeatureStatisticRegion

### Submódulo ThresholdClassifier

Implementa la subfase *Clasificador por Umbral* (sección 5.1.2, página 45). Está compuesto por tres submódulos: **InitialClassifier**, **HistogramWindow** y **BimodalThreshold** como se observa en la Figura 5.8.



**Figura 5.8:** Submódulos del ThresholdClassifier

- **Submódulo InitialClassifier:** Implementa las subfases *Asignar Media* y *Clasificador Inicial*. Recibe el vector característico *vectory* dado por (5.9) y asigna la esperanza ( $E$ ) a la región  $R_k$  en la posición indicada por  $pos$ . De esta forma se obtiene una región suavizada,  $\bar{R}_k$ .

Además, lleva a cabo la primera clasificación en base a un umbral  $t$ , calculado automáticamente por **BimodalThresholder**. Como resultado de esta clasificación modifica el label  $C_m$ , asignándole una nueva etiqueta,  $C_w$  o  $C_l$ , dependiendo de la categoría ( $Y_w$  o  $Y_l$ , ecuación (5.2), respectivamente) fue asignado el píxel de posición  $pos$ .

$$vectory[pos, DR, E, Var, C_m \text{ donde } m \in \{w, l\}] \quad (5.10)$$

Las dos funciones de este submódulo son llevadas a cabo por la clase *InitialClassifier* cuyos métodos son *assignMean* y *separateClasses*.

- **Submódulo HistogramWindow:** Es el encargado de implementar la subfase *Histograma* (sección 5.1.2), a través de la clase *HistogramWindow*, provista por ImageJ.

Recibe la región suavizada  $\bar{R}_k$  y calcula el histograma de ésta.

- **Submódulo BimodalThresholder:** Implementa *MIMO* (sección 5.1.2). Recibe el histograma de  $\bar{R}_k$  y calcula el umbral  $t$  que es el mínimo local entre modas.

Lo recientemente descrito, se implementa en la clase **BimodalThresholder** cuyos métodos son: *calculateThresholder*, *max*, *min*. Las clases del submódulo ThresholdClassifier se pueden ver en la Figura 5.9.

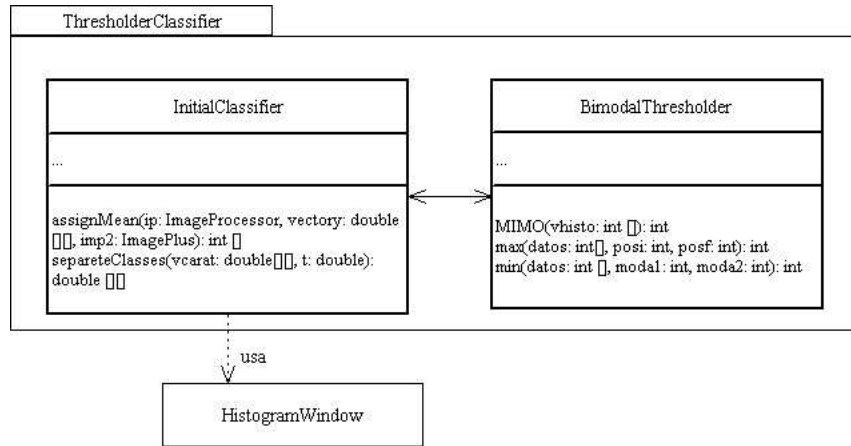


Figura 5.9: Clases del submódulo ThresholdClassifier

### Submódulo ML-Estimator

Implementa las subfases *ML-Estimador* y *ML-ReEstimador* (5.1.3 y 5.1.4, respectivamente). El input es el vector característico *vectory* dado por (5.10) y realiza el cálculo de  $\hat{\mu}_c$  y  $\hat{\Sigma}_c$ , con  $c \in \{w, l\}$ , de cada clase, ecuaciones (5.3) y (5.4). La clase encargada de esta función es la *MLEstimator*, con los métodos *mu* y *sigma*.

### Submódulo MahalanobisClassifier

Implementa la subfase *Mahalanobis Clasificador* 5.1.4. Recibe como input  $\hat{\mu}_c$  y  $\hat{\Sigma}_c$   $c \in \{w, l\}$  y es el encargado de hacer la segunda clasificación en base a la distancia de Mahalanobis, modificando el label del *vectory*.

La etiqueta  $C_m$ , será  $C_w$  o  $C_l$  si los píxeles de posición *pos* pertenecen a las categorías agua o tierra, dadas por la ecuación (5.2). Además  $C_m$ , puede ser  $C_{o_w}$  o  $C_{o_l}$ , si el píxel en *pos*, luego de realizar la segunda clasificación en base a la distancia de Mahalanobis, resultó ser outlier de agua o de tierra, respectivamente.

$$vectory[pos, DR, E, Var, C_m \text{ donde } m \in \{w, l, o_w, o_l\}] \quad (5.11)$$

donde  $o_w$ ,  $o_l$  son outliers de agua y tierra respectivamente.

Esta función es llevada a cabo por la clase *MahalanobisClassifier* cuyo método es *mahalanobis*.

### Submódulo Classifier

Implementa la subfase *Clasificador* (sección 5.1.5). Recibe como input el vector característico (ecuación 5.11),  $\hat{\mu}_c$  (ecuación 5.3) y  $\hat{\Sigma}_c$  (ecuación 5.4), las dos últimas obtenidas por **ML-Estimator**, en base a las categorías resultantes de la clasificación en base a la distancia de Mahalanobis (ecuación 5.5).

La función principal de este submódulo es realizar la clasificación final de los píxeles. Clasificación que se hará en base a la probabilidad de que el píxel de posición  $pos$ , pertenezca a la categoría “agua” o “tierra” (ecuaciones 5.7 y 5.8, de la sección 5.1.5, página 47).

$$vectors[pos, DR, E, Var, C_m \text{ donde } m \in \{w, l\}] \quad (5.12)$$

La clase encargada de realizar esto es Classifier cuyo método es *gaussianProb*.

#### 5.2.7. Diagramas de Clases

La interacción entre las clases del módulo **AutomaticWaterClassifier** se muestra la Figura 5.10.

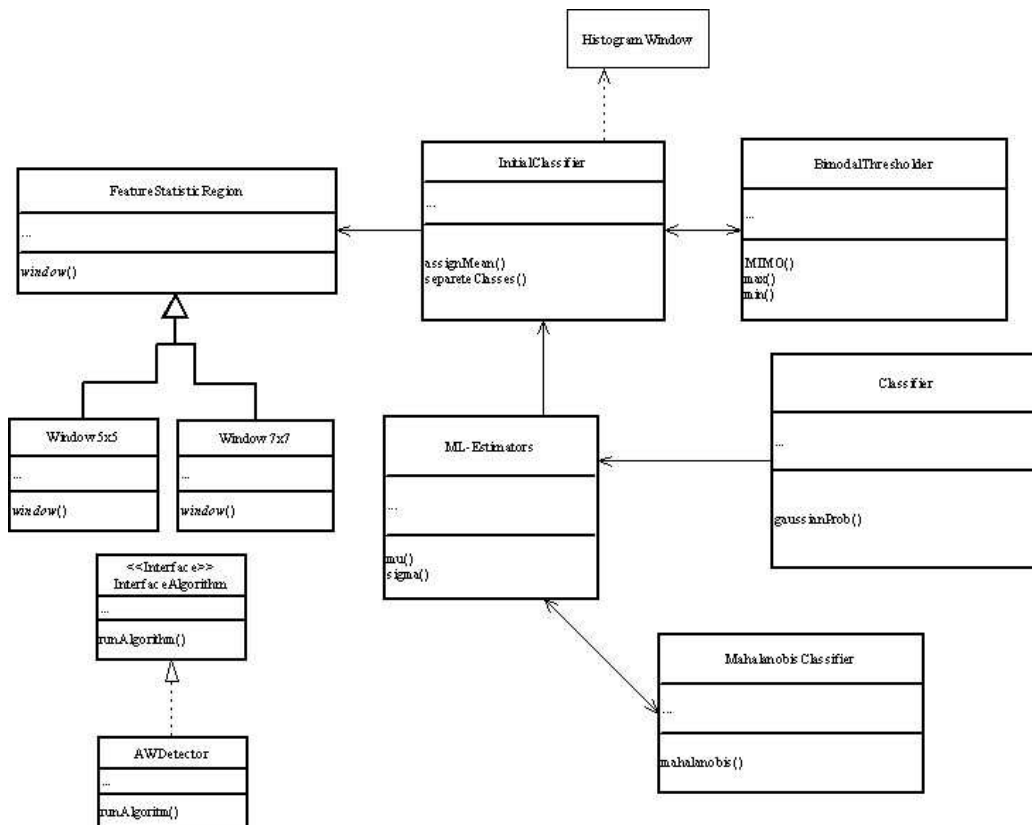


Figura 5.10: Clases del AutomaticWaterClassifier

El diagrama con la interacción entre todas las clases e interfaces que componen al Detector Automático de Agua (AutomaticWaterDetector) se pueden observar en las Figuras 5.11 y 5.12 respectivamente. En la Figura 5.11 podemos observar en color rojo las clases pertenecientes a ImageJ, en color azul la interfaz y clases pertenecientes al módulo AutomaticWaterClassifier, en color verde las pertenecientes al módulo Regions, en color marrón las pertenecientes al módulo FloodStatistic y en naranja al módulo VectorMatrix.

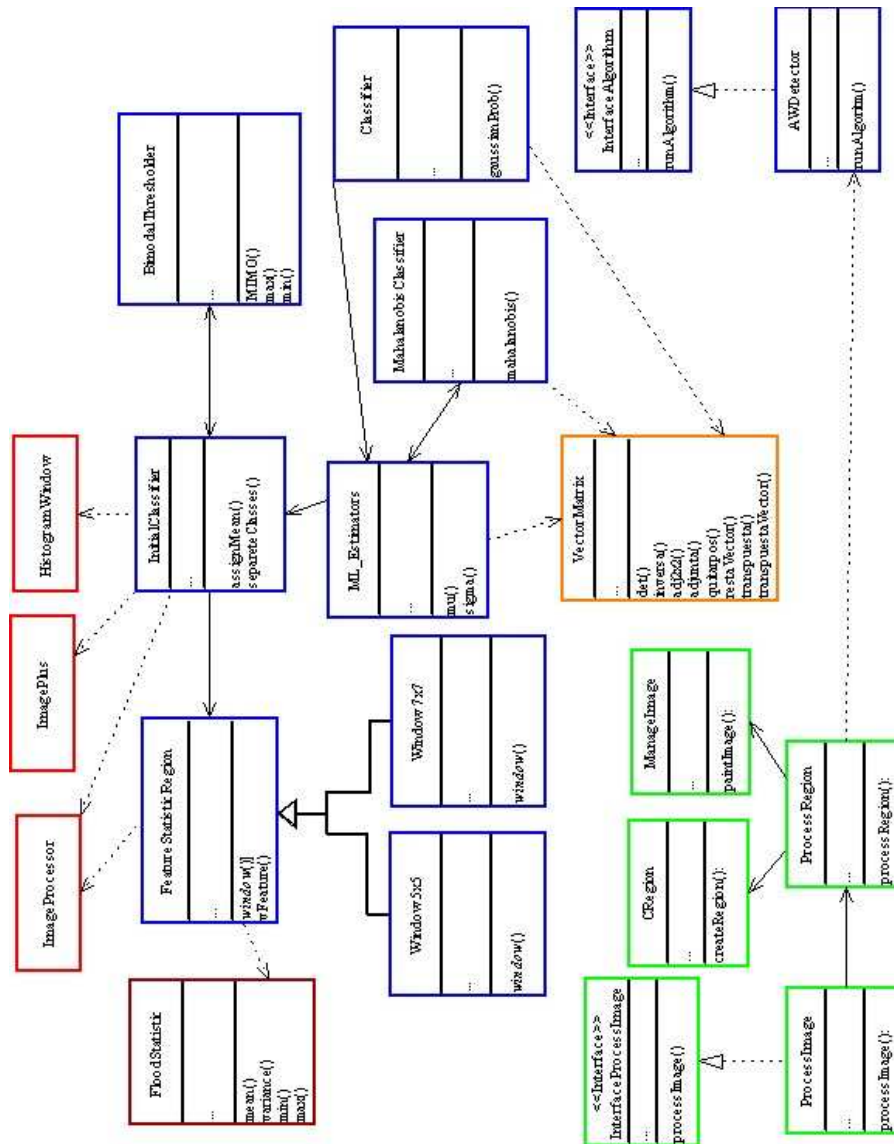


Figura 5.11: Diagrama de Clases del Automatic Water Detector.

El diagrama con la interacción entre los módulos del AutomáticoWaterDetector se pueden ver en la Figura 5.13.



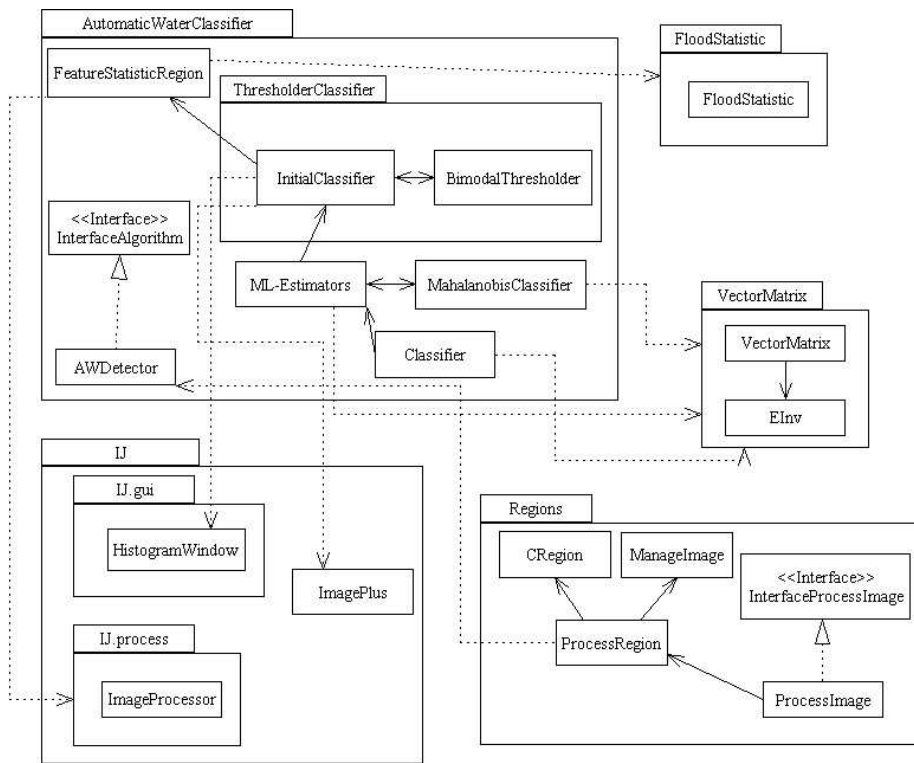


Figura 5.12: Diagrama de Clases

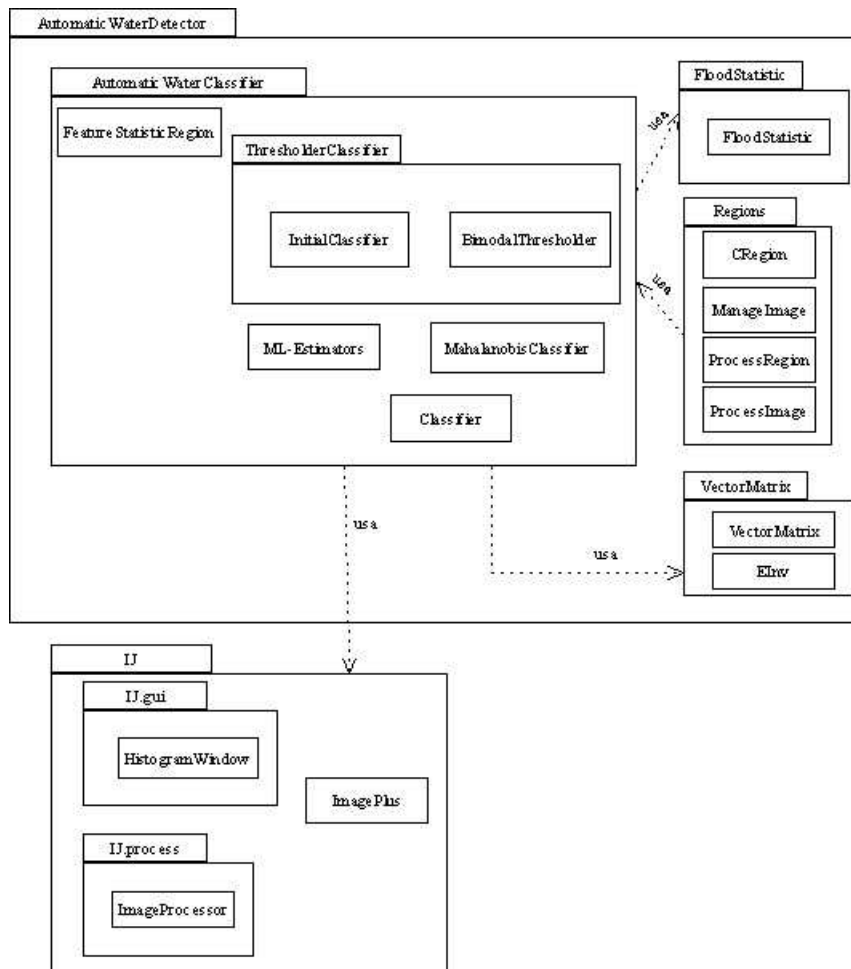


Figura 5.13: Diagrama de Módulos



## Capítulo 6

---

# Análisis del Detector

---

### 6.1. Introducción

Las inundaciones constituyen uno de los desastres más devastadores en el mundo, con mayor pérdida de vidas y de daños a la propiedad que cualquier otro tipo de desastres. Pueden afectar extensas áreas y evolucionar rápidamente.

Las imágenes SAR son especialmente adecuadas a este tipo de emergencias, cuando las inundaciones se deben a lluvias intensas y persistentes, el seguimiento de estos eventos se ve limitado por el hecho de que las zonas afectadas se encuentran cubiertas de nubes. Dichas imágenes son una herramienta insustituible dado que se pueden obtener bajo cualquier condición meteorológica.

Tradicionalmente, la detección de superficies de agua basada en imágenes SAR se ha desarrollado a partir de la determinación de umbrales sobre la intensidad de la imagen. Sin embargo, este método necesita datos muy precisos del ángulo de incidencia; ya que el contraste entre la tierra y el agua, disminuye con el ángulo de incidencia, la utilidad de esta metodología es limitada [26].


Es por ello, que resulta de gran interés el desarrollo de métodos que posibiliten la detección de superficies de agua a partir de imágenes de radar, con cierta independencia del ángulo de incidencia. Además, es importante que tales métodos sean suficientemente robustos como para hacer frente al ruido multiplicativo que es inherente a las imágenes SAR. Es decir, el proceso de segmentación debe considerar además de los valores de los píxeles, las características de la textura en la imagen a ser procesada [26].

En este contexto, el algoritmo presentado en el Capítulo 5, tiene como objetivo contribuir al uso de información satelital proveniente de imágenes SAR, para la detección automática de agua. Por ello, oportunamente se solicitó a la Comisión Nacional de Actividades Espaciales (CONAE), imágenes SAR de zonas inundadas de la República Argentina, para poder evaluar el funcionamiento del *Detector*

*Automático de Agua*. CONAE gentilmente cedió diversos cortes de imágenes SAR.

La figura 6.1 muestra la zona a la que pertenecen los primeros cortes de imagen SAR otorgadas por CONAE, estos cortes forman parte de una imagen con centro de escena en  $-22^{\circ}48'$  y  $-63^{\circ}59'$  del sensor SAR, satélite RADARSAT 1, radar que opera en la banda-C ( $5.3\text{ GHz}$ , longitud de onda de  $5.66\text{ cm}$ ) con polarización HH [24], en modo “fino”, haz y posición F2, lo que nos indica que tiene un ángulo de incidencia en el rango de los  $38.8^{\circ}$  y los  $42.5^{\circ}$ .

Se observa en la figura 6.1 que la imagen pertenece a la zona de Tartagal, provincia de Salta. La imagen SAR es del día 18 de Abril del 2006, época en la que se registraron graves inundaciones en la ciudad.



**Figura 6.1:** Imagen con centro de escena:  $-22^{\circ}48'$  y  $-63^{\circ}59'$ .

La imagen SAR original perteneciente a la zona que se observa en la figura, Salta - República Argentina.


Fuente: Google Earth [3, 4]



**Figura 6.2:** Imagen con centro de escena:  $-32^{\circ}91'$  y  $-60^{\circ}53'$ .

La imagen SAR original pertenece a la zona que se muestra en esta figura, Santa Fé - República Argentina.

Fuente: Google Earth [3, 4]



**Figura 6.3:** Imagen con centro de escena:  $-33^{\circ}34'$  y  $-60^{\circ}37'$ .

La imagen SAR original pertenece a la zona que se muestra en esta figura, Santa Fé - República Argentina.

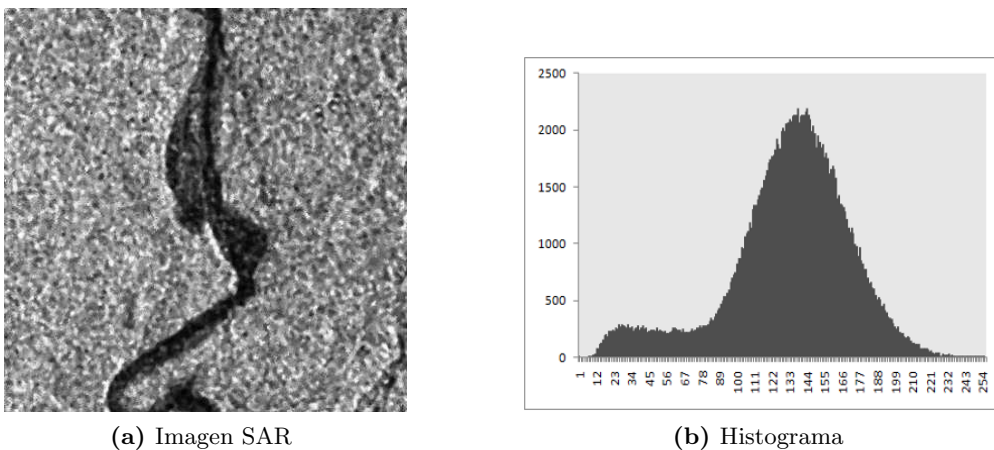
Fuente: Google Earth [3, 4]

Otros cortes fueron provistos por CONAE, ya que un punto de importancia a evaluar es la independencia del método, respecto del ángulo de incidencia. Las figuras 6.2 y 6.3, muestran la región de otros cortes cedidos por CONAE de la provincia de Santa Fé, imágenes que fueron tomadas en el año 2007, más precisamente en Abril, época en Santa Fé atravesaba lluvias muy intensas, con un saldo de personas muertas y decenas de miles evacuadas, 3.5 millones de hectáreas anegadas, rutas intransitables y puentes destruidos.

Las imágenes que en una segunda oportunidad nos proveyera CONAE, pertenecen a un sensor SAR, satélite RADARSAT 1, una de éstas con centro de escena en  $-32.91^\circ$  y  $-60.53^\circ$  (Figura 6.2), y la segunda tiene centro de escena a  $-33.34^\circ$  y  $-60.37^\circ$  (Figura 6.3). Ambas son de modo “fino”, con haz y posición F1, es decir, que el ángulo de incidencia varía entre  $36.4^\circ$  y  $40.3^\circ$  [24].


## 6.2. Sensibilidad a la elección del umbral

El método implementado, constituye un método de clasificación no-supervisado, tal como se señaló en el Capítulo 3, solo impone una pre-clasificación basada en la determinación de un umbral a partir del histograma de la media de la imagen SAR. Los autores [26], sugieren definir a este umbral como la intensidad mínima entre modas, pero no se detalla cómo calcularlo. Una manera de proceder, consiste recurrir a métodos provistos por ImageJ [5, 6, 7, 8].




**Figura 6.4:** Corte de imagen SAR de 400x400 píxeles, perteneciente a la zona que muestra la figura 6.1; con su respectivo histograma de la media.






**Figura 6.5:** Corte de imagen SAR (6.4a), clasificada en base al umbral calculado por el método ISODATA.



**Figura 6.6:** Corte de imagen SAR (6.4a), clasificada en base al umbral calculado por el método Mixture.




**Figura 6.7:** Corte de imagen SAR (6.4a), clasificada en base al umbral calculado por el método Otsu.

Los resultados para un corte, de 400x400 píxeles, de una imagen perteneciente a la zona de Salta (Figura 6.1), se muestran en las figuras 6.5, 6.6, 6.7. En la figura 6.5, se puede observar la clasificación que realiza el método en base al cálculo del umbral, por el método ISODATA, provisto en ImageJ [1, 8], cuyo valor es  $t = 112$ . En 6.5a se puede ver la imagen donde solo se marcan los píxeles que son clasificados como agua, mientras que en la imagen 6.5b se pueden diferenciar los píxeles clasificados como “agua” y aquellos que son clasificados como “tierra”.

De manera análoga se puede observar la figura 6.6, clasificada en base al umbral calculado por el método Mixture,  $t = 39$ , y la figura 6.7; clasificada en base al umbral calculado por Otsu,  $t = 130$ .

Como podemos ver, el algoritmo es muy sensible al proceso de determinación del umbral. Consecuentemente nos planteamos el desarrollo de un algoritmo que estime tan precisamente como sea posible el mínimo entre dos modas en el histograma de este tipo de imágenes.




**Figura 6.8:** Corte de imagen SAR (6.4a), clasificada en base al umbral calculado por nuestro método.


La Figura 6.8 muestra el resultado de clasificar con el método que proponemos en este trabajo, para calcular el mínimo entre modas; en este caso el umbral dado por nuestro método es:  $t = 55$ .

Las siguientes figuras muestran cortes de imágenes SAR, con sus respectivos histogramas de media. Se puede observar, además, los distintos resultados de clasificación obtenidos con los métodos propios de ImageJ y el resultado de clasificar en base al umbral calculado con nuestro método.






(a) Imagen SAR




(b) Histograma

**Figura 6.9:** Corte de imagen SAR de 400x400 píxeles, perteneciente a la zona que muestra la figura 6.2; con su respectivo histograma de la media.




(a)




(b)


**Figura 6.10:** Corte de imagen SAR (6.9a), clasificada en base al umbral calculado por el método ISODATA  $t = 87$ .




**Figura 6.11:** Corte de imagen SAR (6.9a), clasificada en base al umbral calculado por el método Mixture  $t = 73$ .




**Figura 6.12:** Corte de imagen SAR (6.9a), clasificada en base al umbral calculado por el método Otsu  $t = 93$ .



**Figura 6.13:** Corte de imagen SAR (6.9a), clasificada en base al umbral calculado por nuestro método  $t = 97$ .




(a) Imagen SAR




(b) Histograma

**Figura 6.14:** Corte de imagen SAR de 400x400 píxeles, perteneciente a la zona que muestra la figura 6.1; con su respectivo histograma de la media.




(a)




(b)

**Figura 6.15:** Corte de imagen SAR (6.14a), clasificada en base al umbral calculado por el método ISODATA  $t = 96$ .







**Figura 6.16:** Corte de imagen SAR (6.14a), clasificada en base al umbral calculado por el método Mixture  $t = 23$ .



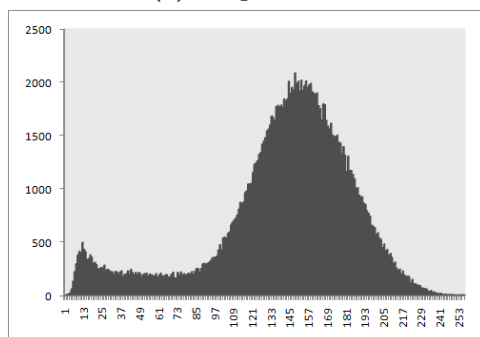
**Figura 6.17:** Corte de imagen SAR (6.14a), clasificada en base al umbral calculado por el método Otsu  $t = 102$ .



**Figura 6.18:** Corte de imagen SAR (6.14a), clasificada en base al umbral calculado por nuestro método  $t = 89$ .




(a) Imagen SAR



(b) Histograma

**Figura 6.19:** Corte de imagen SAR de 400x400 píxeles, perteneciente a la zona que muestra la figura 6.1; con su respectivo histograma de la media.




(a)

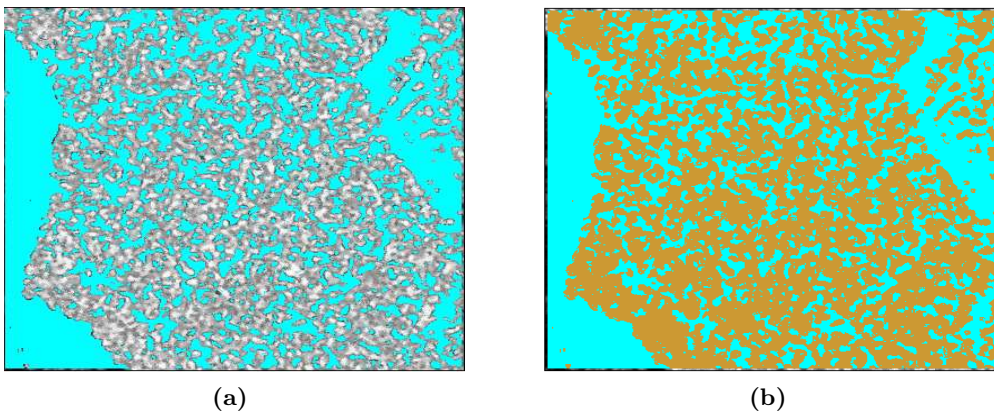


(b)


**Figura 6.20:** Corte de imagen SAR (6.19a), clasificada en base al umbral calculado por el método ISODATA  $t = 105$ .



**Figura 6.21:** Corte de imagen SAR (6.19a), clasificada en base al umbral calculado por el método Mixture  $t = 30$ .




**Figura 6.22:** Corte de imagen SAR (6.19a), clasificada en base al umbral calculado por el método Otsu  $t = 133$ .



**Figura 6.23:** Corte de imagen SAR (6.19a), clasificada en base al umbral calculado por nuestro método  $t = 71$ .

### 6.2.1. El método MIMO

Como mencionamos anteriormente, la elección del umbral en este clasificador, es un punto crítico del algoritmo. Como pudimos observar en el análisis anterior, el resultado de la clasificación final es sumamente dependiente del valor del umbral. Deseamos que éste sea el mínimo entre modas calculado a partir del histograma, motivación que nos llevo a pensar en un método que este basado en la forma del histograma, idealmente queremos uno bimodal, situación que no siempre se da. Mostramos algunas tipologías de histogramas resultantes a partir de los diversos cortes de imágenes SAR con los que trabajamos en este proyecto.



**Figura 6.24:** Tipologías de Histogramas

MIMO es el método resultante que surgió del proceso de estudio de las diversas tipologías de histogramas (Figuras 6.24 y 6.25). La propuesta original fue evolucionando, originalmente se comenzó trabajando con un histograma del tipo



(Figura 6.24a), el cual pertenece a una imagen que contiene tierra y agua. Al ampliar nuestro grupo de imágenes, fueron manifestándose nuevas tipologías de histogramas que debíamos contemplar.




Figura 6.25: Tipologías de Histogramas

MIMO (array:histo)

- Calcular el máximo del histograma (histo) M y su posición P
- Calcular  $dif\_d = 255 - P$  y  $dif\_i = P$
- Si  $P \geq 85$ 
  - $NP = P/2$
  - $M1 = \max(\text{histo}, 5, NP)$
  - $m1 = \min(\text{histo}, 5, NP)$
  - $M2 = \max(\text{histo}, NP + 1, P)$



```

- m2 = min(histo, NP + 1, P)
- Si 0 <= pos_m1 <pos_M1

    umbral = min(histo, pos_M1, P)

- Si no

    - Si pos_M1 <= pos_m1 <pos_M2
        - Si m1 <= m2
            - umbral = m1
        - Si no
            - umbral = m2

- Si dif_d >dif_i and P <85

    - interv = |255 - P|/4
    - m1 = min(histo, P, P+interv)
    - M1 = max(histo, P+interv, P+2interv)
    - m2 = min(histo, P+2interv, P+3interv)
    - M2 = max(histo, P+3interv, 255)
    - dif1 = M1 - m1
    - dif2 = M2 - m2
    - Si M2 >M1

        - Si dif1 <dif2

            umbral = min(histo, P, pos_M2)

        - Si no

            umbral = min(histo, P, pos_M1)

- Si no

    umbral = min(histo, P, pos_M1)


- return pos_umbral

```


Este método, MIMO, es el producto de nuestro estudio y experiencia con los diversos tipos de histogramas. Las figuras 6.26, 6.27 y 6.28 muestran algunos resultados producto de la clasificación realizada en base a nuestro método MIMO.



(a) Imagen SAR a la cual se le aplico filtro de mediana, para reducir el ruido speckle



(b) Imagen SAR, donde se observan los píxeles clasificados como agua




(c) Imagen SAR, donde los píxeles están clasificados como agua y como tierra

**Figura 6.26:** Corte de imagen SAR de 948x2388 píxeles, perteneciente a la zona de la figura 6.2 clasificada en base al umbral calculado por MIMO




**Figura 6.27:** Imagen SAR a la cual se le aplico filtro de mediana, para reducir el ruido speckle





(a) Imagen SAR, donde se observan los píxeles clasificados como agua




(b) Imagen SAR, donde los píxeles están clasificados como agua y como tierra

**Figura 6.28:** Corte de imagen SAR de 1500x1500 píxeles, perteneciente a la zona de la figura 6.2 clasificada en base al umbral calculado por MIMO


### 6.3. Sensibilidad al tamaño de la ventana de textura

En [26] los autores consideran una ventana deslizante de tamaño  $5 \times 5$ , para captar localmente la información de textura de la imagen. Sugieren que ventanas de mayor tamaño no son adecuadas para aplicar el detector, ya que ellas tienden a desdibujar los bordes de las diferentes clases.


En este trabajo, se implementó el detector, con diferentes tamaños de ventanas deslizantes para captar la textura local de la imagen SAR. Una consideración a tener en cuenta es que la ventana se limita a los píxeles centrales, por lo que los bordes de la imagen no se afectan con este proceso, si usamos una ventana de tamaño  $3 \times 3$ , por ejemplo, perderíamos la primera línea y última de la imagen. En general, usando una ventana de tamaño  $N \times N$  ( $N$  impar), el total de líneas que perdemos de analizar por cada borde de la imagen es,  $N - (\lfloor N/2 \rfloor) + 1$ , donde  $\lfloor n \rfloor$ , denota la parte entera de  $n$ .



**Figura 6.29:** Corte de imagen SAR, a la cual se le aplicó una ventana para analizar la textura de tamaño  $3 \times 3$




**Figura 6.30:** Corte de imagen SAR, a la cual se le aplicó una ventana para analizar la textura de tamaño  $5 \times 5$




**Figura 6.31:** Corte de imagen SAR, a la cual se le aplicó una ventana para analizar la textura de tamaño  $7 \times 7$






**Figura 6.32:** Corte de imagen SAR, a la cual se le aplicó una ventana para analizar la textura de tamaño  $9 \times 9$



**Figura 6.33:** Corte de imagen SAR, a la cual se le aplicó una ventana para analizar la textura de tamaño  $11 \times 11$



**Figura 6.34:** Corte de imagen SAR, a la cual se le aplicó una ventana para analizar la textura de tamaño  $13 \times 13$

Las figuras 6.29 a la 6.34 muestran el resultado de aplicar diferentes tamaños de ventanas móviles desde  $3 \times 3$  a un tamaño  $13 \times 13$ . En el ítem (a) de las figuras se puede observar, los puntos que el clasificador marca como outliers de agua (color rojo) y los outliers de tierra (color verde). El ítem (b) muestra las imágenes clasificadas con los píxeles que son agua (color celeste), tierra (color marrón), outliers de agua (color rojo) y outliers de tierra (color verde).

En los puntos (c) y (d) las figuras corresponden a la clasificación de los píxeles que solo son agua, y a la imagen clasificada en tierra y agua, respectivamente; en ambos casos sin outliers.

Al realizar la comparación entre los diferentes tamaños de ventana móvil para captar localmente la textura de la imagen; se observó que la clasificación pierde calidad al aumentar el tamaño de la ventana. En efecto, cuando el tamaño de la ventana aumenta, se pierden detalles presentes en la imagen original, como por ejemplo pequeñas porciones de tierra en medio del agua o pequeñas porciones de agua en medio de la tierra, que son clasificados dentro de la clase de predominio del entorno. Este hecho se cuantifica al observar la disminución de los píxeles marcados como outliers en ambas categorías (Cuadro 6.1). Al usar ventanas pequeñas el algoritmo, marca como “dudosos” un mayor número de píxeles que con ventanas de mayor tamaño. Sin embargo al usar ventanas grandes, se




obtiene una clasificación de menor calidad que con ventanas mas pequeñas.


Tamaño de la Ventana	# Outlier (Agua)	# Outlier (Tierra)
3x3	47	29
5x5	35	29
7x7	32	17
9x9	28	6
11x11	25	6
13x13	12	0

**Cuadro 6.1:** Número de outliers para las dos categorías, variando el tamaño de la ventana. Figuras 6.29 a la 6.34.


Las imágenes y tabla que se muestran a continuación analizan la variación del tamaño de la ventana de textura, para otro corte de imagen SAR.




**Figura 6.35:** Corte de imagen SAR, a la cual se le aplicó una ventana para analizar la textura de tamaño 3x3




**Figura 6.36:** Corte de imagen SAR, a la cual se le aplicó una ventana para analizar la textura de tamaño  $5 \times 5$




**Figura 6.37:** Corte de imagen SAR, a la cual se le aplicó una ventana para analizar la textura de tamaño  $7 \times 7$



**Figura 6.38:** Corte de imagen SAR, a la cual se le aplicó una ventana para analizar la textura de tamaño  $9 \times 9$



**Figura 6.39:** Corte de imagen SAR, a la cual se le aplicó una ventana para analizar la textura de tamaño  $11 \times 11$



**Figura 6.40:** Corte de imagen SAR, a la cual se le aplicó una ventana para analizar la textura de tamaño  $13 \times 13$

Tamaño de la Ventana	# Outlier (Agua)	# Outlier (Tierra)
3x3	12	74
5x5	8	76
7x7	2	80
9x9	0	34
11x11	0	41
13x13	0	19

**Cuadro 6.2:** Número de outliers para las dos categorías, variando el tamaño de la ventana. Figuras 6.35 a la 6.40.

Luego de las observaciones que se pueden hacer en las figuras anteriores, podemos obtener algunas conclusiones. Cuando queremos captar localmente la textura en una imagen, un criterio conveniente, será considerar una ventana que no se concentre excesivamente alrededor del punto central, al extremo de no captar diversidad en la textura. Por otra parte, una ventana de mayor tamaño conduce a un deterioro en la calidad de la clasificación, especialmente en los bordes entre clases.

Una regla que podemos considerar, es que existe una relación inversa entre el tamaño de la ventana y la calidad de la clasificación. Ventanas muy chicas dan lugar solo a regiones sin textura con la consiguiente complicación en el método que invierte la matriz de covarianza, mientras que ventanas excesivamente grandes producen una clasificación deficiente.

En definitiva, no hay un criterio que especifique concretamente cuál debe ser el tamaño de la ventana. Como hemos mencionado anteriormente en la sección 5.2.3 (página 48), en este trabajo realizamos el estudio de la textura local, con una ventana de tamaño  $5 \times 5$ , y cuando resulta necesario, ampliamos la zona de estudio con una ventana  $7 \times 7$ .



## Capítulo 7

---

# Resultados

---

### 7.1. Introducción

En este capítulo nos proponemos cuantificar la efectividad del clasificador, habiendo implementado el método MIMO. Muestreamos imágenes de la zona de Tartagal (de cortes de la zona perteneciente a la Figura 6.1, del 18 de Abril de 2006) proporcionadas por CONAE, considerando 100 cortes elegidos al azar de 400x400 píxeles. A partir de estas imágenes estimamos el nivel de gris promedio del agua y el nivel de gris promedio de tierra seca. Con dichas estimaciones, generamos por simulación imágenes, donde determinadas áreas representan agua y otras tierra firme. Estas áreas presentan una geometría simple (rectángulos, cuadrados o combinaciones de estas figuras), por ejemplo, simulando un río que atraviesa un campo y lo interesante es que a priori, conocemos para cada píxel, si éste es un píxel de agua o de tierra.

Posteriormente, le pedimos al clasificador que clasificara las imágenes simuladas y verificamos sobre cada píxel, si éste fue correctamente clasificado. Finalmente calculamos indicadores e índices presentados en el Capítulo 3, los que dieron cuenta de la exactitud en la clasificación

### 7.2. Caracterización y simulación de imágenes SAR de tierra y agua


Partimos de cien cortes seleccionados al azar de 400x400 píxeles de estas imágenes SAR de Tartagal, proporcionadas por CONAE, del año 2006 correspondientes a la inundación del Abril del 2006. A cada uno de los cortes, se le aplicó el clasificador, el cual umbraló los correspondientes histogramas con el método MIMO y clasificó a cada píxel como "tierra." "agua." En cada clase se determinó la media ( $\bar{x}$ ) y el desvío estándar ( $\bar{s}$ ). Así obtuvimos cien valores de  $\bar{x}_{A_i}$

y  $\bar{s}_{Ai}$  de la clase agua, y cien valores de  $\bar{x}_{Ti}$  y  $\bar{s}_{Ti}$  para la clase tierra, donde  $i = 1 \dots 100$ . Luego construimos intervalos de confianza del 95% para la media del nivel de gris del agua ( $\bar{x}_A$ ) y para la media del nivel de gris de la tierra ( $\bar{x}_T$ ) en estas imágenes:  $\bar{x} \pm 1,96 \frac{\bar{s}}{\sqrt{100}}$  para cada clase. La siguiente tabla muestra los resultados de este estudio:

	<b>Agua</b>	<b>Tierra</b>
<b>Media</b>	$\bar{x}_A = 25.97655$	$\bar{x}_T = 130.55338$
<b>Desvío estándar</b>	$\bar{s}_A = 15.39097$	$\bar{s}_T = 38.28346$
<b>Intervalo de Confianza</b>	(22,959 - 28,993)	(123,049 - 138,056)

**Cuadro 7.1:** Estimaciones obtenidas para tierra y agua


Los resultados del experimento anterior se utilizaron para simular imágenes de tierra y agua con una geometría sencilla (Figura 7.1). Si bien estas imágenes sólo son modelos que intentan representar la realidad, presentan la ventaja de que conocemos cuál es la clase a la que pertenece cada píxel; es decir, dado cualquier píxel de la imagen, sabemos a priori si se trata de un píxel de agua o de tierra.




**Figura 7.1:** Imágenes simuladas a partir de las estimaciones del Cuadro 7.1



Las siguientes imágenes muestran los resultados de la clasificación, para las imágenes presentadas en la Figura 7.1.



**Figura 7.2:** Imágenes de la figura 7.1 clasificadas



**Figura 7.3:** Imágenes de la figura 7.1 clasificadas

A continuación presentamos las matrices de confusión, resultantes del proceso de clasificación, y los índices mencionados en el Capítulo 3.

		Clases de referencia		Total
		Agua	Tierra	
Categorías deducidas	Agua	61821	0	61821
	Tierra	1539	93456	94995
Total		63360	93456	156816

**Cuadro 7.2:** Matriz de Confusión correspondiente a la imagen de la figura 7.1a

### Índices calculados en base a la Tabla 7.2

- *Exactitud Global* = 99.01 %
- *Exactitud del usuario (Agua)* = 100 %
- *Exactitud del usuario (Tierra)* = 98.38 %
- *Exactitud del productor (Agua)* = 97.57 %
- *Exactitud del productor (Tierra)* = 100 %
- *Índice  $\kappa$*  = 0.98

		Clases de referencia		Total
		Agua	Tierra	
Categorías deducidas	Agua	78408	1495	79903
	Tierra	0	76913	76913
Total		78408	78408	156816

**Cuadro 7.3:** Matriz de Confusión correspondiente a la imagen de la figura 7.1b

### Índices calculados en base a la Tabla 7.3

- *Exactitud Global* = 99.04 %
- *Exactitud del usuario (Agua)* = 98.12 %

- *Exactitud del usuario (Tierra) = 100 %*
- *Exactitud del productor (Agua) = 100 %*
- *Exactitud del productor (Tierra) = 98.09 %*
- *Índice  $\kappa = 0.98$*

		Clases de referencia		Total
		Agua	Tierra	
Categorías deducidas	Agua	38167	0	38167
	Tierra	1251	117398	118649
Total		39418	117398	156816

**Cuadro 7.4:** Matriz de Confusión correspondiente a la imagen de la figura 7.1c

#### Índices calculados en base a la Tabla 7.4

- *Exactitud Global = 99.20 %*
- *Exactitud del usuario (Agua) = 100 %*
- *Exactitud del usuario (Tierra) = 98.94 %*
- *Exactitud del productor (Agua) = 96.82 %*
- *Exactitud del productor (Tierra) = 100 %*
- *Índice  $\kappa = 0.97$*

		Clases de referencia		Total
		Agua	Tierra	
Categorías deducidas	Agua	77082	0	77082
	Tierra	1726	78008	79734
Total		78808	78008	156816

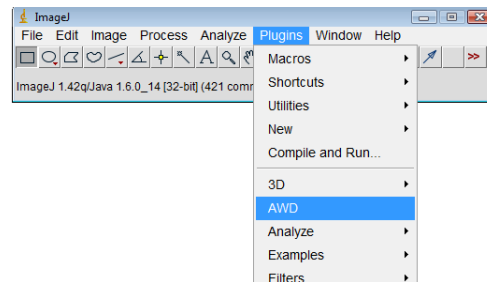
**Cuadro 7.5:** Matriz de Confusión correspondiente a la imagen de la figura 7.1d

#### Índices calculados en base a la Tabla 7.5

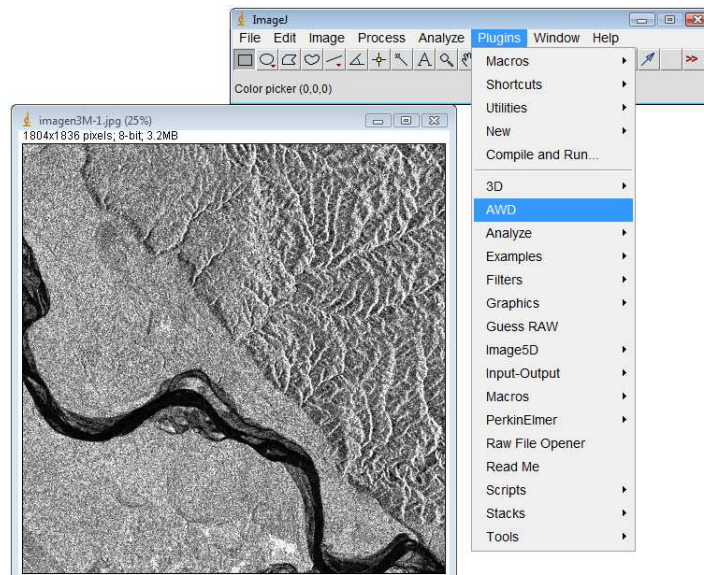
- *Exactitud Global = 98.89 %*
- *Exactitud del usuario (Agua) = 100 %*
- *Exactitud del usuario (Tierra) = 97.83 %*
- *Exactitud del productor (Agua) = 97.80 %*
- *Exactitud del productor (Tierra) = 100 %*
- *Índice  $\kappa = 0.97$*

### 7.3. Resultados e ImageJ

En esta sección mostramos algunas imágenes que resumen el trabajo presentado, y su vinculación con ImageJ.



**Figura 7.4:** El programa ImageJ. AWD es el botón para ejecutar nuestro clasificador



**Figura 7.5:** ImageJ

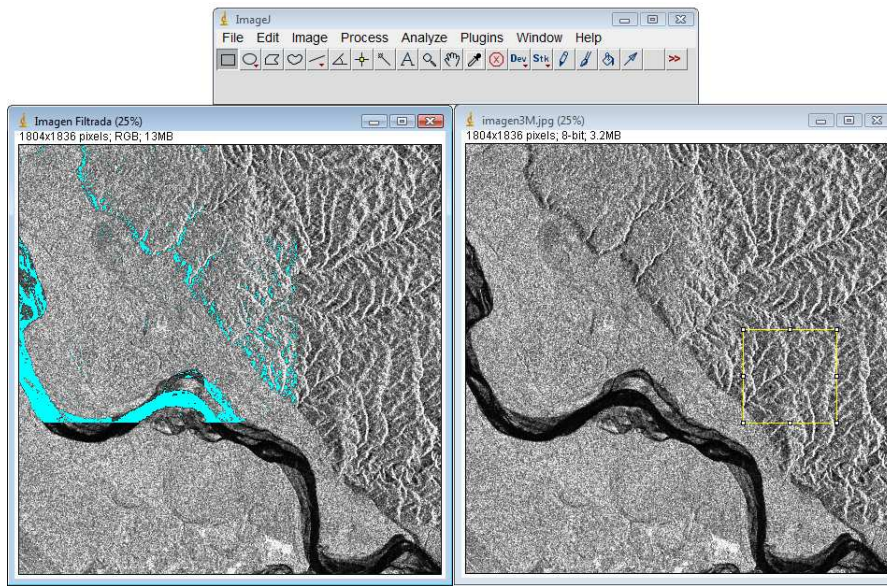


Figura 7.6: El proceso de clasificación

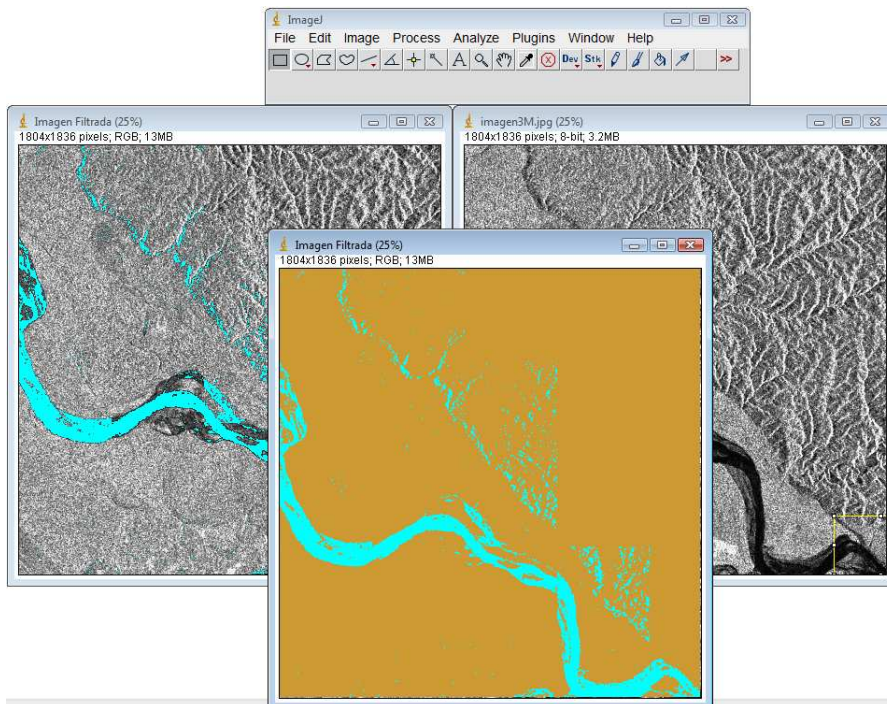


Figura 7.7: Imágenes resultantes de la clasificación

## 7.4. Conclusiones y Trabajos Futuros

En este trabajo se analizó e implementó en JAVA el algoritmo propuesto por [26] para detectar agua a partir de imágenes SAR. Se trata de un método de clasificación no supervisado, que permite distinguir entre agua y tierra, a partir de imágenes SAR, con cierta independencia del ángulo de incidencia. El método requiere establecer un umbral en el histograma de la intensidad de la imagen; tal umbral se define como la intensidad mínima entre dos modas, sin embargo los autores de la propuesta, no establecen cómo calcularlo. Consecuentemente, desarrollamos un algoritmo que a partir de un histograma bimodal, establece la posición del mínimo entre las dos modas. Se observó que, a los fines de la clasificación de este tipo de imágenes, este método de umbralización funciona mejor que otras metodologías propuestas en ImageJ, como ISODATA, MIXTURE y OTSU.

Con respecto al tamaño de la ventana deslizante que capta localmente la textura de la imagen, se observó que la clasificación pierde calidad al aumentar el tamaño de la ventana. En efecto, cuando el tamaño de la ventana aumenta, se pierden detalles presentes en la imagen original, como por ejemplo pequeñas porciones de tierra en medio del agua o pequeñas porciones de agua en medio de la tierra, que son clasificados dentro de la clase de predominio. Este hecho se cuantifica al observar la disminución de los píxeles marcados como outliers en ambas categorías (Tablas 6.1 y 6.2). Al usar ventanas pequeñas el algoritmo marca como "dudosos" un mayor número de píxeles que con ventanas de mayor tamaño. Sin embargo al usar ventanas grandes, se obtiene una clasificación de menor calidad que con ventanas pequeñas.

Se realizó también un estudio empírico, cuantificando la exactitud del método de clasificación en imágenes simuladas de tierra y agua. Los resultados obtenidos fueron altamente satisfactorios.

La implementación de este algoritmo y el método de umbralamiento propuesto constituirán una nueva herramienta para el software ImageJ.

Como posible continuación de este trabajo, se espera probar el funcionamiento de este clasificador en imágenes SAR de otras zona que hubieran sido afectadas por inundaciones, donde se evidencien otras características de suelo y topografía. Dada la dependencia observada con respecto al tamaño de la ventana deslizante que capta la textura de la imagen a nivel local, sería de interés establecer un criterio objetivo que indique en cada caso cuál es el tamaño de ventana óptimo que se debe adoptar, en términos de lograr una correcta clasificación.

---

# Bibliografía

---

- [1] <http://rsbweb.nih.gov/ij/>. [citado en p. 5, 12, 64]
- [2] <http://www.disasterscharter.org/>. [citado en p. 10]
- [3] <http://www.digitalglobe.com/index.php/85/QuickBird>. [citado en p. 60, 61]
- [4] <http://en.wikipedia.org/wiki/Quickbird>. [citado en p. 60, 61]
- [5] <http://rsbweb.nih.gov/ij/plugins/mixture-modeling.html>. [citado en p. 62]
- [6] <http://rsbweb.nih.gov/ij/plugins/entropy.html>. [citado en p. 62]
- [7] <http://rsbweb.nih.gov/ij/plugins/otsu-thresholding.html>. [citado en p. 62]
- [8] <http://rsbweb.nih.gov/ij/plugins/multi-thresholder.html>. [citado en p. 62, 64]
- [9] Bovik, A. On detecting edge in speckle imagery. *Acoustics, Speech and Signal Processing - IEEE Transactions on* Volume 36, Issue 10, Page(s):1618 - 1627, 1988. [citado en p. 38]
- [10] Dumitras, A. and Venetsanopoulos, A.N. A comparative study of snake models with application to object shape description in bi-level and gray-level. *Proceedings of IEEE-EURASIP Workshop on Nonlinear Signal and Image Processing*, Baltimore, USA, June 3-6, 2001 (copyright (c) by IEEE), 2001. [citado en p. 39]
- [11] Ferrero, Susana Beatriz. *Evaluación de clasificaciones Máxima Verosimilitud Gaussiana y de Modas Condicionales Iteradas para imágenes ópticas multiespectrales*. PhD thesis, Facultad de Ciencia., .Químicas y Naturales - Universidad Nacional de Río Cuarto, 2004. [citado en p. 23, 31]
- [12] CONAE. Carta internacional: El espacio y las grandes catástrofes. [http://www.conae.gov.ar/emergencias/WEB\\_Carta\\_espanol.htm](http://www.conae.gov.ar/emergencias/WEB_Carta_espanol.htm), 2007. [citado en p. 10]
- [13] Dra. Hernandez, A. M., Dr. Moragues, J. y CONAE. Uso de la información espacial para la gestión de emergencias. <http://www.conae.gov.ar/emergencias/emergencias.html>, Diciembre 2002. [citado en p. 9]



- [14] Cohen, L. D. On active contour models and balloons. CVGIP: Image Understanding archive Volume 53, Issue 2, Pages 211-218, 1991. [citado en p. 39]
- [15] Kass, M., Withkin, A. and Terzopoulos, D. Snakes: Active contour model. International Journal of Computer Vision, VOL 1, No.1. [citado en p. 39]
- [16] McInerney, T. and Terzopoulos, D. *Medical image segmentation using topologically adaptable surfaces*. Springer Berlin / Heidelberg, 1997. [citado en p. 39]
- [17] Smith, D. Speckle reduction and segmentation of SAR images. International Journal of Remote Sensing, 17(11). [citado en p. 38]
- [18] Programa Asociado de gestión de crecientes (APFM). Documento conceptual: Gestión integrada de crecientes. [citado en p. 7, 8]
- [19] Ruiz Fernández, L., Acosta, P., Fernández Sarría, A., Pardo Pascual, J. and Porres de la Haza, M. Mejora de la eficiencia en la segmentación de imágenes por texturas mediante filtros de energía, 2001. [citado en p. 23, 25]
- [20] Automática e Informática Industrial Departamento Electrónica. Apuntes de visión artificial. <http://www.gnu.org/copyleft/fdl.html>. [citado en p. 27]
- [21] Fjortoft, R., Lopes, A., Marthon, P. and Cubero-Castan, E. An optimal multi-edge detector for SAR image segmentation. Geoscience and Remote Sensing, IEEE Transactions on Volume 36, Issue 3, Page(s):793 - 802, 1998. [citado en p. 38]
- [22] Gonzalez, R. C. and Woods, R. E. *Digital image processing*. Prentice Hall, New Jersey, 2002. [citado en p. 19]
- [23] Chuvieco, Emilio. *Fundamentos de Teledetección Espacial*. Ediciones Rialp S.A, Madrid. España, 2000. [citado en p. 13, 14, 16, 17, 18, 19, 24, 25, 29, 30, 31, 32, 36]
- [24] Canada Centre for Remote Sensing. Fundamentals of remote sensing. [http://www.ccrs.nrcan.gc.ca/resource/tutor/fundam/index\\_e.php](http://www.ccrs.nrcan.gc.ca/resource/tutor/fundam/index_e.php). [citado en p. 13, 15, 17, 18, 19, 20, 21, 22, 44, 60, 62]
- [25] Lopes, A., Nezry, E., Touzi, R. and Laur, H. Structure detection and statistical adaptive speckle filtering in SAR images. International Journal of Remote Sensing, VOL 14, No.9. [citado en p. 38]
- [26] Anthonen, P., Euro, M., Hallikainen, M., Solbø, S., Johansen, B. and Solheim, I. Sar and optical algorithms for discrimination of water bodies. [http://projects.itek.norut.no/floodman/Deliverables/D1\\_2\\_Report.doc](http://projects.itek.norut.no/floodman/Deliverables/D1_2_Report.doc), January 2004. [citado en p. 5, 12, 38, 39, 41, 45, 59, 62, 77, 94]
- [27] Cohen, L.D. and Cohen, I. Finite-element methods for active contour models and balloons for 2-d and 3-d images. Pattern Analysis and Machine Intelligence, IEEE Transactions on Volume 15, Issue 11, Page(s):1131 - 1147, 1993. [citado en p. 39]
- [28] Medina, R. and Bellera, J. Bases del procesamiento de imágenes médicas. [citado en p. 28]
- [29] Chenyang, Xu and Prince, J.L. Gradient vector flow: a new external force for snakes. Computer Vision and Pattern Recognition, 1997. Proceedings., 1997 IEEE Computer Society Conference on 17-19 June 1997 Page(s):66 - 71, 1997. [citado en p. 39]



- [30] Gambini, María Julia. *Modelos de Segmentación basados en Regiones y Contornos Activos aplicados a Imágenes de Radar de Apertura Sintética*. PhD thesis, Universidad de Buenos Aires - Facultad de Ciencias Exactas y Naturales - Departamento de Computación, 2006. [citado en p. 37]
- [31] Theodoridis, S. and Koutroumbas, K. *Pattern Recognition*. Academic Press, 2002. [citado en p. 25, 26]
- [32] Fernández Sarría, A. and Recio, J. and Ruiz Fernández, L. Análisis de imágenes mediante texturas: aplicación a la clasificación de unidades de vegetación. [citado en p. 24]
- [33] Meléndez Islas, A. R. y Altamirano Robles, L. *Estimación de fondo y primer plano en secuencias de imágenes para la detección de objetos en movimiento*. PhD thesis, XVI Congreso Nacional y II Congreso Internacional de Información y Computación de la ANIEI, Octubre 2003. [citado en p. 27, 28, 101]
- [34] Martín, Marcos. Técnicas clásicas de segmentación de imagen. <http://poseidon.tel.uva.es/~carlos/ltif10001/segmenclasica.pdf>, 2002. [citado en p. 27]
- [35] España, Martín. Información espacial para la gestión de desastres: La experiencia de la conae. <http://www.conae.gov.ar/emergencias/emergencias.html>, Julio 2002. [citado en p. 8]
- [36] Germain, Oliver. *Edge detection and localization in SAR images: a comparative study of global filtering and active contour approaches*. PhD thesis, Université de Droit, d'Économie et des Science d'Aix-Marseille, 2001. [citado en p. 39]
- [37] Touzi, R., Lopes, A. and Bousquet, P. A statistical and geometrical edge detector for SAR images. <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=7708&isnumber=404>, 1988. [citado en p. 38]
- [38] Castleman, Kenneth R. *Digital image processing*. Prentice-Hall, New Jersey, 1996. [citado en p. 24, 26]
- [39] Oliver, C., Connell, I.M. and White, R. Optimum edge detection in SAR. SPIE on Satellite Remote Sensing, 2584. [citado en p. 38]
- [40] Parker, J. R. *Algorithms for Image Processing and Computer Vision*. Wiley Computer Publishing John Wiley and Sons, Inc., 1997. [citado en p. 38]
- [41] Bailer, Werner. Writing imagej plugin - a tutorial. <http://www.imagingbook.com/fileadmin/goodies/ijtutorial/tutorial171.pdf>. [citado en p. 48]
- [42] Richards, J.A. and Jia, Xiuping. *Remote Sensing and Digital Image Analysis: An Introduction*. Springer - Verlag, Berlin, 1999. [citado en p. 34, 35, 36]



---

# Índice de figuras

---

2.1. Espectro electro-magnético . . . . .	15
2.2. Ruido Speckle . . . . .	19
2.3. Concepto de apertura sintética . . . . .	20
2.4. Geometría del vuelo SAR . . . . .	20
2.5. Geometría SAR . . . . .	21
2.6. Resolución en dirección del alcance . . . . .	22
2.7. Resolución en dirección del azimut . . . . .	22
3.1. Ejemplo de un histograma bimodal [33]. . . . .	28
5.1. Fases del Detector Automático de Agua . . . . .	43
5.2. Subfases de <i>Clasificador Automático de Agua</i> . . . . .	44
5.3. Subfases de <i>Clasificador por Umbral</i> . . . . .	45
5.4. Módulos del AutomaticWaterDetector . . . . .	49
5.5. Clases del Módulo Regions . . . . .	50
5.6. Submódulos del Módulo AutomaticWaterClassifier . . . . .	51
5.7. Clase FeatureStatisticRegion . . . . .	52
5.8. Submódulos del ThresholdClassifier . . . . .	53
5.9. Clases del submódulo ThresholdClassifier . . . . .	54
5.10. Clases del AutomaticWaterClassifier . . . . .	55
5.11. Diagrama de Clases del Automatic Water Detector. . . . .	56
5.12. Diagrama de Clases . . . . .	57
5.13. Diagrama de Módulos . . . . .	57
6.1. Imagen con centro de escena: $-22^{\circ}48'$ y $-63^{\circ}59'$ . . . . .	60
6.2. Imagen con centro de escena: $-32^{\circ}91'$ y $-60^{\circ}53'$ . . . . .	61
6.3. Imagen con centro de escena: $-33^{\circ}34'$ y $-60^{\circ}37'$ . . . . .	61
6.4. Corte de imagen SAR y su histograma . . . . .	62
6.5. Corte de imagen SAR clasificada . . . . .	63
6.6. Corte de imagen SAR clasificada . . . . .	63

6.7. Corte de imagen SAR clasificada . . . . .	63
6.8. Corte de imagen SAR clasificada . . . . .	64
6.9. Corte de imagen SAR y su histograma . . . . .	65
6.10. Corte de imagen SAR clasificada . . . . .	65
6.11. Corte de imagen SAR clasificada . . . . .	66
6.12. Corte de imagen SAR clasificada . . . . .	66
6.13. Corte de imagen SAR clasificada . . . . .	66
6.14. Corte de imagen SAR y su histograma . . . . .	67
6.15. Corte de imagen SAR clasificada . . . . .	67
6.16. Corte de imagen SAR clasificada . . . . .	68
6.17. Corte de imagen SAR clasificada . . . . .	68
6.18. Corte de imagen SAR clasificada . . . . .	68
6.19. Corte de imagen SAR y su histograma . . . . .	69
6.20. Corte de imagen SAR clasificada . . . . .	69
6.21. Corte de imagen SAR clasificada . . . . .	70
6.22. Corte de imagen SAR clasificada . . . . .	70
6.23. Corte de imagen SAR clasificada . . . . .	70
6.24. Histogramas de imágenes SAR . . . . .	71
6.25. Histogramas de imágenes SAR . . . . .	72
6.26. Corte de imagen SAR . . . . .	74
6.27. Imagen SAR 1500x1500 píxeles . . . . .	75
6.28. Corte de imagen SAR . . . . .	76
6.29. Ventana móvil $3 \times 3$ . . . . .	77
6.30. Ventana móvil $5 \times 5$ . . . . .	78
6.31. Ventana móvil $7 \times 7$ . . . . .	78
6.32. Ventana móvil $9 \times 9$ . . . . .	79
6.33. Ventana móvil $11 \times 11$ . . . . .	79
6.34. Ventana móvil $13 \times 13$ . . . . .	80
6.35. Ventana móvil $3 \times 3$ . . . . .	81
6.36. Ventana móvil $5 \times 5$ . . . . .	82
6.37. Ventana móvil $7 \times 7$ . . . . .	82
6.38. Ventana móvil $9 \times 9$ . . . . .	83
6.39. Ventana móvil $11 \times 11$ . . . . .	83
6.40. Ventana móvil $13 \times 13$ . . . . .	84
7.1. Imágenes simuladas . . . . .	88
7.2. Imágenes simuladas clasificadas . . . . .	89
7.3. Imágenes simuladas clasificadas . . . . .	89
7.4. El programa ImageJ . . . . .	92
7.5. ImageJ . . . . .	93
7.6. El proceso de clasificación . . . . .	93
7.7. Imágenes resultantes de la clasificación . . . . .	94

---

# Índice de cuadros

---

3.1. Ejemplo de Matriz de Confusión . . . . .	35
6.1. Tabla de outliers . . . . .	81
6.2. Tabla de outliers . . . . .	84
7.1. Estimaciones obtenidas para tierra y agua . . . . .	88
7.2. Matriz de Confusión correspondiente a la imagen de la figura 7.1a . .	90
7.3. Matriz de Confusión correspondiente a la imagen de la figura 7.1b . .	90
7.4. Matriz de Confusión correspondiente a la imagen de la figura 7.1c . .	91
7.5. Matriz de Confusión correspondiente a la imagen de la figura 7.1d . .	91