

**Desarrollo de una metodología para la detección de cuerpos  
de agua mediante el análisis de imágenes SAR COSMO  
SkyMed y de DEMs**

*Por Sofía Lanfri*

Presentado ante la Facultad de Matemática, Astronomía y Física y el Instituto de Altos Estudios Espaciales Mario Gulich como parte de los requerimientos para la obtención del grado de

*MAGÍSTER EN APLICACIONES ESPACIALES DE ALERTA Y RESPUESTA TEMPRANA A EMERGENCIAS*

UNIVERSIDAD NACIONAL DE CÓRDOBA

Septiembre, 2011

©IG - CONAE/UNC 2011

©FaMAF - UNC 2011

Director: *Dr. Alejandro C. Frery*

**Palabras Claves:** Radar de apertura sintética, COSMO-SkyMed, agua, modelos hidrológicos, emergencias, IDL.

## **Resumen**

En esta tesis se integran índices hidrológicos relativos a la acumulación de agua del terreno con datos radar de la constelación COSMO-SkyMed en una metodología de detección de cuerpos de agua continentales y zonas anegables, apropiada para aplicaciones de tipo operativo de monitoreo; que potencialmente puede ser usada en prevención y respuesta, tanto a inundaciones como a brotes de enfermedades transmitidas por vectores. Se definió un procedimiento de cálculo de índice topográfico de humedad a partir de un modelo de elevación digital y se consideró el efecto de la cobertura de vegetación en este patrón de acumulación de humedad. Se generó un sistema de clasificación de imágenes COSMO-SkyMed, basado en novedosas variables de textura y entrenado automáticamente. Todos los algoritmos desarrollados en esta tesis fueron implementados en el lenguaje de programación IDL.

## **Abstract**

In this thesis, hydrological indexes related to terrain water accumulation were combined with radar data of the COSMO-SkyMed constellation in a methodology for continental water bodies and high flood propensity areas detection, suitable for operative monitoring applications, that could potentially be used in prevention and response, not only of floods but also of vector-borne diseases outbreaks. It was defined a procedure for the calculation of a topographic wetness index from a digital elevation model, and it was considered the effect of vegetation cover on this wetness accumulation pattern. It was developed a classification system for COSMO-SkyMed images based on original texture variables and automatically trained. All the algorithms developed in this thesis were implemented in the programming language IDL.

## Agradecimientos

Esta tesis es una actividad de investigación realizada gracias a los fondos de la beca de la *Maestría en Aplicaciones Espaciales de Alerta y Respuesta Temprana a Emergencias*, otorgada por la Comisión Nacional de Actividades Espaciales (CONAE) y la Agencia Espacial Italiana (ASI). Por lo tanto, agradezco enormemente a estas instituciones por la posibilidad brindada. Mi sincero agradecimiento a mis directores Dr. Alejandro Frery y Dr. Marcelo Scavuzzo, quienes guiaron este trabajo de tesis. Finalmente, quiero dar las gracias al equipo de investigadores del Instituto de Altos Estudios Espaciales Mario Gulich (CONAE), el cual fue de gran soporte en la realización del mismo.

## **Resumen**

En esta tesis se integran índices hidrológicos relativos a la acumulación de agua del terreno con datos radar de la constelación COSMO-SkyMed en una metodología de detección de cuerpos de agua continentales y zonas anegables, apropiada para aplicaciones de tipo operativo de monitoreo; que potencialmente puede ser usada en prevención y respuesta, tanto a inundaciones como a brotes de enfermedades transmitidas por vectores. Se definió un procedimiento de cálculo de índice topográfico de humedad a partir de un modelo de elevación digital y se consideró el efecto de la cobertura de vegetación en este patrón de acumulación de humedad. Se generó un sistema de clasificación de imágenes COSMO-SkyMed, basado en novedosas variables de textura y entrenado automáticamente. Todos los algoritmos desarrollados en esta tesis fueron implementados en el lenguaje de programación IDL.

## **Abstract**

In this thesis, hydrological indexes related to terrain water accumulation were combined with radar data of the COSMO-SkyMed constellation in a methodology for continental water bodies and high flood propensity areas detection, suitable for operative monitoring applications, that could potentially be used in prevention and response, not only of floods but also of vector-borne diseases outbreaks. It was defined a procedure for the calculation of a topographic wetness index from a digital elevation model, and it was considered the effect of vegetation cover on this wetness accumulation pattern. It was developed a classification system for COSMO-SkyMed images based on original texture variables and automatically trained. All the algorithms developed in this thesis were implemented in the programming language IDL.

# Índice

<b>Índice</b>	<b>IV</b>
<b>Índice de figuras</b>	<b>VIII</b>
<b>Índice de tablas</b>	<b>XVII</b>
<b>1. Introducción general</b>	<b>1</b>
1.1. Motivación . . . . .	4
1.2. Objetivo general . . . . .	6
1.3. Objetivos específicos . . . . .	6
1.4. Estructura de la tesis . . . . .	7
<b>2. Índice topográfico de humedad</b>	<b>8</b>
2.1. Marco teórico . . . . .	8
2.1.1. Modelos de elevación digital del terreno . . . . .	8
2.1.1.1. Resolución espacial . . . . .	10
2.1.2. Modelos hidrológicos . . . . .	11
2.1.3. Dirección de flujo . . . . .	12
2.1.3.1. SFD8 . . . . .	13
2.1.3.2. MFD8 . . . . .	14
2.1.3.3. SFD $\infty$ . . . . .	14
2.1.3.4. MFD $\infty$ . . . . .	14
2.1.4. Acumulación de flujo . . . . .	16
2.1.5. Índice topográfico de humedad . . . . .	17
2.2. Objetivos abordados en el capítulo . . . . .	18
2.2.1. Aportes del capítulo . . . . .	19
2.3. Materiales y métodos . . . . .	19
2.3.1. Área de estudio . . . . .	19
2.3.1.1. Topografía y cobertura del suelo . . . . .	21
2.3.1.2. Clima . . . . .	21
2.3.2. Diagrama metodológico . . . . .	22
2.3.3. Recolección y preprocesamiento de datos . . . . .	22

2.3.3.1.	Datos de elevación digital . . . . .	22
2.3.4.	Especificación de la metodología . . . . .	23
2.3.4.1.	Tecnología de desarrollo empleada . . . . .	23
2.3.4.2.	Implementación de algoritmos . . . . .	24
2.3.5.	Evaluación de los algoritmos implementados . . . . .	29
2.4.	Resultados . . . . .	30
2.5.	Discusión y conclusiones . . . . .	38
<b>3.</b>	<b>Índice fito-topográfico de humedad</b>	<b>43</b>
3.1.	Marco teórico . . . . .	43
3.2.	Objetivos abordados en el capítulo . . . . .	48
3.2.1.	Aportes del capítulo . . . . .	49
3.3.	Materiales y métodos . . . . .	49
3.3.1.	Área de estudio . . . . .	49
3.3.2.	Recolección y preprocesamiento de datos . . . . .	49
3.3.2.1.	Datos de elevación digital . . . . .	49
3.3.3.	Especificación de la metodología . . . . .	51
3.3.3.1.	Tecnología de desarrollo empleada . . . . .	51
3.3.3.2.	Implementación de algoritmos . . . . .	51
3.4.	Resultados . . . . .	55
3.5.	Discusión y conclusiones . . . . .	58
<b>4.</b>	<b>Delimitación de cuerpos de agua: Introducción y definiciones</b>	<b>61</b>
4.1.	Marco teórico . . . . .	61
4.1.1.	Sensado remoto de radares de apertura sintética . . . . .	61
4.1.1.1.	Orígenes del sensado remoto y de radares de apertura sintética	64
4.1.1.2.	Proceso de emisión, interacción y recepción con radar . . . . .	67
4.1.1.3.	Radar de Apertura Sintética . . . . .	69
4.1.1.4.	Factores que influyen la característica de la señal . . . . .	71
4.1.1.5.	Interacción con la superficie . . . . .	75
4.1.1.6.	Corrección radiométrica . . . . .	78
4.1.1.7.	Coefficiente de retrodispersión o <i>backscattering</i> . . . . .	78
4.1.1.8.	Modelado estadístico de imágenes SAR . . . . .	79
4.1.2.	COSMO-SkyMed SAR . . . . .	81
4.2.	Metodologías de detección de cuerpos de agua: estado del arte . . . . .	84
4.2.0.1.	Tecnologías existentes para clasificación de imágenes SAR . . . . .	91
4.3.	Conceptos empleados en la metodología . . . . .	92
4.3.1.	Modelo Gaussiano multivariado . . . . .	92
4.3.2.	Clasificación de Máxima verosimilitud . . . . .	92
4.3.3.	Medidas muestrales de textura . . . . .	92

4.3.4. Matriz de correlación . . . . .	95
4.3.5. Análisis de Componentes Principales (ACP) . . . . .	96
4.3.6. Morfología matemática . . . . .	96
4.3.7. Matriz de confusión . . . . .	100
<b>5. Delimitación de cuerpos de agua: Algoritmos</b>	<b>103</b>
5.1. Objetivos abordados en el capítulo . . . . .	103
5.1.1. Aportes del capítulo . . . . .	104
5.2. Materiales y métodos . . . . .	104
5.2.1. Área de estudio . . . . .	104
5.2.2. Diagrama metodológico . . . . .	105
5.2.3. Recolección y preprocesamiento de datos . . . . .	105
5.2.3.1. Datos de radar . . . . .	105
5.2.3.2. Datos ópticos . . . . .	106
5.2.4. Especificación de la metodología . . . . .	106
5.2.4.1. Tecnología de desarrollo utilizada . . . . .	106
5.2.4.2. Módulos desarrollados . . . . .	106
5.2.5. Evaluación de los clasificadores . . . . .	120
5.3. Resultados . . . . .	121
5.4. Discusión y conclusiones . . . . .	131
<b>6. Evaluación e integración de las metodologías</b>	<b>136</b>
6.1. Objetivos abordados en el capítulo . . . . .	136
6.1.1. Aportes del capítulo . . . . .	136
6.2. Materiales y métodos . . . . .	136
6.2.1. Área de estudio . . . . .	136
6.2.1.1. Topografía y cobertura del suelo . . . . .	137
6.2.1.2. Clima . . . . .	137
6.2.2. Recolección y preprocesamiento de datos . . . . .	138
6.2.2.1. Datos de radar . . . . .	138
6.2.2.2. Datos de elevación digital . . . . .	139
6.2.2.3. Datos ópticos . . . . .	139
6.2.3. Especificación de la metodología . . . . .	139
6.3. Resultados . . . . .	141
6.4. Discusión y conclusiones . . . . .	152
<b>7. Conclusiones generales</b>	<b>155</b>
7.1. Aportes a mi formación profesional . . . . .	158
<b>Referencias</b>	<b>162</b>

<b>Apéndices</b>	<b>176</b>
<b>Apéndice A</b>	<b>176</b>
<b>Apéndice B</b>	<b>177</b>
<b>Apéndice C</b>	<b>179</b>
<b>Apéndice D</b>	<b>183</b>
<b>Apéndice E</b>	<b>184</b>



# Índice de figuras

2.1.	Ejemplo de modelos de <b>simple</b> y <b>múltiple</b> dirección de flujo de agua. . . . .	13
2.2.	Ilustración del funcionamiento de los modelos de determinación de dirección de flujo: SFD8, MFD8, SFD $\infty$ y MFD $\infty$ . En las figuras de dirección de flujo posibles para cada modelo (2.2(a),2.2(c), 2.2(e), 2.2(g)) los nodos negros demarcan los centros de los píxeles del DEM y las líneas negras continúan unen estos centros. En las figuras del patrón de flujo determinado por cada modelo (2.2(b),2.2(d), 2.2(f), 2.2(h)) las líneas curvas representan las curvas de nivel de un terreno con disminución de altura hacia abajo y el flujo de agua es representado en estas figuras mediante píxeles en escala de grises (de blanco a negro) de acuerdo a la cantidad de flujo hacia ese píxel determinado. . . . .	15
2.3.	Significado de las variables que definen el área específica de cuenca: área total de cuenca por unidad de contorno. . . . .	16
2.4.	Ejemplo de una grilla de dirección de flujo de agua obtenida a partir de un DEM y su derivada grilla de acumulación de flujo de agua. El área de acumulación de cada píxel es calculada como su propia área más el área de acumulación de los vecinos que drenan hacia el píxel en cuestión. . . . .	17
2.5.	Área de estudio localizada en el departamento Alto Paraná, Paraguay. Ésta mide aproximadamente 32 × 17km. Incluye principalmente cuerpos de agua y superficies vegetadas. Se presentan algunas construcciones de manera aislada. . . . .	20
2.6.	Productos del modelado hidrológico que fueron generados en el presente capítulo a partir de un modelo de elevación digital (DEM): 1) pendiente, 2) dirección y 3) acumulación de flujo, e 4) índice topográfico de humedad (TWI). A partir del DEM se obtienen la matriz de pendiente, de dirección y acumulación de flujo. El TWI combina estos últimos productos. . . . .	22
2.7.	DEM A y su correspondiente matriz de pendiente. El DEM A fue simulado mediante una función proporcional a $-e^{-(x^2+y^2)}$ , que representa la topografía de un área de 512×512 m con una resolución espacial de 1 m. La altura del mismo tiene un rango que va desde 0 a 1 km. La matriz de pendiente se presenta en grados y el rango de la misma va de 0 a 45.2°. . . . .	31

2.8. Resultados de la aplicación de los diferentes algoritmos implementados al simulado DEM A. Se presentan las matrices de direcciones de flujo determinadas de acuerdo a cada aproximación. En el caso de la aproximación 1, cada píxel de la matriz indica la única dirección de flujo que le corresponde, codificada como grados de 0 a 315 crecientes en orientación horaria (ver 2.2). Para la aproximación 2 y 3, cada píxel representa las proporción de drenado hacia una determinada dirección (en este caso, dirección 0). La proporción hacia cada dirección en la aproximación 2 y 3 es almacenada en una de 8 posibles bandas. Se presentan además los índices topográficos derivados de cada aproximación. Se observa en los índices de aproximación 1 y 2 un patrón de líneas rojas de altos valores del índice en las intersecciones de las direcciones de flujo, el cual está ausente en el índice de aproximación 3. . . . . 32

2.9. Vista tridimensional de los índices topográficos generados a partir del DEM A. En estas figuras se puede apreciar, de manera más evidente, la distribución de probabilidad de acumulación de agua en el terreno. . . . . 33

2.10. DEM B, simulado mediante una función proporcional a  $-(x+y) - e^{-(x^2+y^2)}$ , que representa la topografía de un área de 512×512 m con una resolución espacial de 1 m. La altura del mismo tiene un rango que va desde 0 a 1 km. . . . . 33

2.11. Resultados de la aplicación de los diferentes algoritmos implementados al DEM B. Se presentan las matrices de direcciones de flujo determinadas de acuerdo a cada aproximación. En el caso de la aproximación 1, cada píxel de la matriz indica la única dirección de flujo que le corresponde, codificada como grados de 0 a 315 crecientes en orientación horaria (ver 2.2). Para la aproximación 2 y 3, cada píxel representa las proporción de drenado hacia una determinada dirección (en este caso, dirección 0). La proporción hacia cada dirección en la aproximación 2 y 3 es almacenada en una de 8 posibles bandas. Se presentan además los índices topográficos derivados de cada aproximación. Se observa en los índices de aproximación 1 y 2 un patrón de líneas de altos y bajos valores del índice el cual es consecuencia directa de estos modelos de direcciones de flujo. Dicho patrón está ausente en el índice de aproximación 3. . . . . 35

2.12. Vista tridimensional de los índices topográficos generados a partir del DEM B. En estas figuras se puede apreciar, de manera más evidente, la distribución de probabilidad de acumulación de agua en el terreno y el patrón de líneas mencionado anteriormente. . . . . 36

2.13. Perfiles horizontales del ASTER GDEM con distinto tipo de procesamiento, correspondiente al área de estudio. Este DEM es una matriz que posee 379 columnas y el rango de valores de altura va de 170 a 250 m. El perfil del DEM sin filtrar se visualiza en rojo y el perfil del DEM luego de aplicar un filtro de media móvil de tamaño de kernel 39×39 se visualiza en verde. Se aprecia el suavizado del perfil que se logra al aplicar el filtro de media . . . . . 36

2.14.	Resultados de la aplicación de los algoritmos al DEM <i>C</i> sin filtrar, correspondiente al ASTER GDEM del área de trabajo (no simulado). Se muestra la vista tridimensional del DEM, cuyo rango de alturas va de 171 a 277 m. Se exponen las matrices de pendiente en grados con un rango de 0 a 35.2°, de dirección de flujo y de índice topográfico derivadas del ASTER GDEM sin filtrado. En el mapa de índice de humedad se observa gran cantidad de sitios con probabilidad de acumular agua que se encuentran ampliamente dispersos en el terreno. . . . .	37
2.15.	Resultados de la aplicación de los algoritmos al DEM <i>C</i> filtrado, correspondiente al ASTER GDEM del área de trabajo (no simulado). Se muestra la vista tridimensional del DEM, cuyo rango de alturas va de 171 a 277 m. Se exponen las matrices de pendiente en grados con un rango de 0 a 35.2°, de dirección de flujo y de índice topográfico derivadas del ASTER GDEM sin filtrado. En el mapa de índice de humedad se observa menor cantidad de sitios más extensos con probabilidad de acumular agua, respecto al mapa derivado del DEM sin filtrar.	39
2.16.	Índices topográficos de humedad superpuestos a una superficie tridimensional de DEM. En el TWI del DEM sin filtrar se observa que dadas las irregularidades del DEM empleado, el número de sitios con extensión reducida y de alta probabilidad de acumulación de agua es mucho mayor que en el correspondiente al DEM filtrado. Se observa que el TWI del DEM filtrado es coincidente con zonas del DEM que evidentemente acumularían agua, tanto si se analiza respecto al DEM filtrado como sin filtrar. . . . .	40
3.1.	Diagrama de los principales componentes (factores y procesos) del ciclo hidrológico. Adaptado de <b>Oki &amp; Kanae [2006]</b> . Se observa cuales son los procesos que permiten la entrada y salida de agua al sistema. . . . .	44
3.2.	Representación esquemática de los principales procesos del ciclo hidrológico. Este diagrama consiste en una profundización de la figura 3.1. . . . .	44
3.3.	Efectos mecánicos e hidrológicos que ejerce la vegetación en una ladera, condicionando el flujo de agua en la misma. Fuente: <b>González &amp; Jimeno [2007]</b> . . . . .	46
3.4.	Perfil topográfico A, simulado mediante una función proporcional a $-e^{-(x^2)}$ , y los resultados de la aplicación del algoritmo de determinación de índice fito-topográfico de humedad sobre el mismo. A partir del perfil A, el cual representa la elevación de un terreno en una dimensión, se obtiene $C_{twi}$ , el cual es luego aplicado al perfil para obtener $TWI_v$ . Se observa la diferencia entre el índice simple $TWI_n$ y el fito-topográfico $TWI_v$ . El efecto de la vegetación disminuye el índice en zonas del pozo del perfil y aumenta el mismo en zonas de ladera. Valores de los parámetros empleados para el cálculo de $TWI_v$ : $pendiente\_baja = 0,1$ , $fv = 0,6$ (constante), $a = 0,7$ . . . . .	56

3.5.	Perfil topográfico $B$ , simulado mediante una función proporcional a $-e^{-(x^2)}$ a la que se le adicionan dos pozos en zonas de pendiente elevada, y los resultados de la aplicación del algoritmo de determinación de índice fito-topográfico de humedad sobre el mismo. A partir del perfil $B$ , el cual representa la elevación de un terreno en una dimensión, se obtiene $C_{twi}$ , el cual es luego aplicado al perfil para obtener $TWI_v$ . Se observa la diferencia entre el índice simple $TWI_n$ y el fito-topográfico $TWI_v$ . El efecto de la vegetación disminuye el índice en zonas de pozos del perfil y aumenta el mismo en zonas de ladera. Valores de los parámetros empleados para el cálculo de $TWI_v$ : $pendiente\_baja = 0,1$ , $fv = 0,6$ (constante), $a = 0,7$ . . . . .	57
3.6.	Terreno $C$ correspondiente a un recorte del ASTER GDEM del área de estudio. Los valores de elevación van desde 182 a 261.4 m. . . . .	58
3.7.	Fracción de vegetación obtenida a partir de una imagen Landsat 5 TM, correspondiente al Path: 224 y Row: 78 y la fecha 26 – 07 – 2010 del área de estudio. . . . .	58
3.8.	Índices topográficos $TWI_n$ y $TWI_v$ correspondientes al terreno $C$ . Valores de los parámetros empleados para el cálculo de $TWI_v$ : $pendiente\_baja = 0,1$ , $a = 0,7$ . . . . .	59
3.9.	Histograma del índice topográfico de humedad normalizado ( $TWI_n$ ) y del índice fito-topográfico de humedad ( $TWI_v$ ) obtenidos. Se observa que la imagen de $TWI_v$ presenta valores más concentrados. . . . .	59
4.1.	Diagrama del espectro electromagnético. Se muestra el tipo, la longitud de onda, y la frecuencia de cada onda electromagnética. Adaptado de: Louis E. Kleiner, Coastal Carolina University. . . . .	66
4.2.	Geometría de vuelo en <i>Side-Looking Airborne Radar</i> (SLAR). Fuente: <a href="#">Christian Wolff, 2008</a> . En 4.2(a) se ilustran los principales términos relacionados a la geometría SLAR, mientras que en 4.2(b) se muestran las variables que determinan la resolución espacial en SLAR. . . . .	67
4.3.	Configuración del sensado de radares de apertura sintética (SAR). Se ilustran los principales términos relacionados a la geometría SAR. . . . .	70
4.4.	Comparación entre imágenes ópticas Landsat (adquisición del 26 – 07 – 2010) y radar SAR COSMO-SkyMed (adquisición del 04 – 06 – 2010), correspondientes al área de estudio del capítulo 5. . . . .	71
4.5.	Capacidad de penetración aproximada de las ondas de radar en la vegetación y en el suelo de acuerdo a su frecuencia ( $X : 5,21 - 2,75cm$ , $C : 7,69 - 5,21cm$ , $L : 76,9 - 19,4cm$ ). . . . .	72
4.6.	Retrodispersión de la superficie en función de su rugosidad. Adaptado de <a href="#">Farr [1993]</a> ( <a href="http://history.nasa.gov/">history.nasa.gov/</a> ) . . . . .	74
4.7.	Apariencia de diferentes tipos de superficies (bosque, agua, cultivos, ciudad) en una imagen radar TerraSAR de Bonn, Alemania. Fuente de la imagen TerraSAR: <a href="http://rst.gsfc.nasa.gov">rst.gsfc.nasa.gov</a> . . . . .	75

4.8. Esquema de los distintos tipos de retrodispersión o reflexión. Fuente de la imagen: <a href="#">Martinis [2010]</a> . . . . .	77
4.9. Modos de adquisición de los distintos satélites COSMO-SkyMed: <i>Himage, Ping-Pong, WideRegion, HugeRegion, Spotlight</i> . Adaptado de: <a href="#">COSMO-SkyMed SAR Products Handbook</a> . . . . .	83
4.10. Esquema de PSLR (Peak to Side Lobe Ratio): relación entre la señal retornada del lóbulo principal y la de lóbulos laterales. . . . .	83
4.11. Esquema de ISLR (Integrated Side Lobe Ratio): relación entre la energía retornada del lóbulo principal y la integrada a partir de varios lóbulos provenientes de ambos lados del principal. . . . .	83
4.12. Ambigüedades en una imagen <a href="#">ENVISAT</a> , específicamente de un producto IMS (Single Look Complex data). . . . .	84
4.13. Ilustración de una imagen binaria y los resultados correspondientes a la aplicación diferentes operadores morfológicos (dilatación, erosión, cierre, y apertura). . . . .	101
5.1. Esquema de los diferentes módulos y productos que forman parte del sistema de clasificación de COSMO-SkyMed desarrollado. . . . .	105
5.2. Organización jerárquica del <i>Hierarchical Data Format (HDF5)</i> , el cual es el formato de distribución de los datos COSMO-SkyMed. . . . .	107
5.3. Organización jerárquica del formato de los distintos modos de adquisición de COSMO-SkyMed ( <i>Himage, Spotlight, ScanSAR, y PingPong</i> ). . . . .	108
5.4. Esquema del funcionamiento del método de remuestreo por convolución cúbica empleado en el módulo de georeferenciación de las imágenes COSMO-SkyMed. . . . .	108
5.5. Esquema del clasificador 1 (dentro del <i>Módulo de algoritmos de clasificación</i> ), el cual comparte la estructura general con el resto de los clasificadores. . . . .	110
5.6. Esquema de la determinación del umbral para el entrenamiento automático de los clasificadores (dentro del <i>Módulo de algoritmos de clasificación</i> ). . . . .	112
5.7. Histograma de una imagen COSMO-SkyMed en valores de $\sigma^{\circ}$ (en dB) que contiene clases: AGUA y NO-AGUA (abarca el resto de las coberturas que no pertenecen a la clase AGUA). La línea roja vertical muestra el umbral propuesto para la separación entre clases . . . . .	112
5.8. <i>Eigenvalues</i> resultantes del análisis de componentes principales de las 8 variables de textura: <i>varianza, desviación estándar, skewness, rango, mediana, media, desviación media y curtosis</i> . . . . .	119
5.9. Imagen de COSMO-SkyMed-2 radiométricamente calibrada y en valores de decibeles, correspondiente al área de estudio. Modo de adquisición: PingPong. Fecha de adquisición: 04 – 06 – 2010. Resolución espacial: 20 m. El rango de valores va de –72 a 13,2 decibeles en la banda de polarización <i>HH</i> , y de –71,7 a 15,1 decibeles en la banda de polarización <i>VV</i> . . . . .	122

5.10. Histogramas de la imagen COSMO-SkyMed-2 radiométricamente calibrada y en valores de decibeles, correspondiente al área de estudio, de modo de adquisición PingPong y fecha de adquisición: 04-06-2010. Se detalla también el histograma de las clases AGUA y NO-AGUA (abarca el resto de las coberturas que no pertenecen a la clase AGUA) seleccionadas automáticamente. . . . . 123

5.11. Ejemplo de resultados del algoritmo de selección automática de muestras de las clases AGUA y NO-AGUA (dentro del *Módulo de algoritmos de clasificación*). Se muestra el gráfico de la primera y segunda derivada calculadas a partir del histograma de una banda de la imagen COSMO-SkyMed. Estas derivadas son utilizadas para encontrar el valor *umbral* para la determinación de clases de entrenamiento. . . . . 124

5.12. variables de textura *A* (media, varianza y rango) correspondientes a la banda de polarización *HH* de la imagen COSMO-SkyMed en decibeles, obtenidas mediante el clasificador 1 y 2. . . . . 125

5.13. Variable de textura *Curtosis* de la banda de polarización *HH* de la imagen COSMO-SkyMed en decibeles. Esta variable pertenece junto con la *media* y la *varianza* a las variables de textura *B* y es obtenida mediante el clasificador 3 y 4. . . . . 126

5.14. Variables de textura *C* (PCA 1, PCA 2, PCA 3) correspondientes a la banda de polarización *HH* de la imagen COSMO-SkyMed en decibeles, obtenidas mediante el clasificador 5 y 6. . . . . 127

5.15. Muestras de clases AGUA y NO-AGUA utilizadas en todas las clasificaciones realizadas en este capítulo, obtenidas mediante análisis visual de la imagen COSMO-SkyMed. Se llevó a cabo esta determinación para no incluir en las clasificaciones la variabilidad ocasionada por el método de muestreo automático aquí desarrollado. . . . . 128

5.16. Resultados de las clasificaciones *DualPol* que involucran a las dos polarizaciones COSMO-SkyMed PingPong, es decir, *HH* y *VV*. . . . . 128

5.17. Detalle 1 de la clasificación que involucra a las dos polarizaciones COSMO-SkyMed: *DualPol*<sub>2</sub>. . . . . 129

5.18. Detalle 2 de la clasificación que involucra a las dos polarizaciones COSMO-SkyMed: *DualPol*<sub>2</sub>. . . . . 129

5.19. Detalle 3 de la clasificación que involucra a las dos polarizaciones COSMO-SkyMed: *DualPol*<sub>2</sub> . . . . . 129

5.20. Ilustración de los resultados obtenidos mediante la aplicación de morfología matemática a la clasificación <i>DualPol</i> <sub>6</sub> . El mapa de probabilidad de presencia de cuerpos de agua es obtenido mediante el análisis de los resultados de los distintos operadores morfológicos, con distintos tamaños de kernel. Se calcula computando el número de veces que un píxel es clasificado como AGUA en las distintas matrices resultantes de operaciones de morfología. La probabilidad tiene un rango que va de 0 a 1, siendo 1 la máxima probabilidad de presencia. .	130
5.21. Resultado de la clasificación supervisada <i>ML</i> de las 6 bandas de la imagen Landsat 5 TM (fecha: 26 – 07 – 2010) empleada. Se utilizó como regiones de entrenamiento a muestras determinadas de manera visual en la imagen óptica. Esta clasificación de la imagen Landsat fue empleada como verdad de campo a la hora de evaluar los clasificadores de imágenes COSMO-SkyMed desarrollados.	131
6.1. Área de estudio en el norte de la ciudad de Rosario, ubicada en el centro-este de Argentina, en la provincia de Santa Fe. . . . .	137
6.2. Caracterización del área de estudio en Rosario, Santa Fe, Argentina. . . . .	138
6.3. Imagen Landsat 5 TM correspondiente al área de estudio en Rosario, Santa Fe, Argentina. <i>Path</i> : 226, <i>Row</i> : 083. Fecha de adquisición: 04-06-2011 . . . . .	139
6.4. Perfiles horizontales del ASTER GDEM con distintos procesamientos. Este DEM es una matriz que posee 324 columnas y el rango de valores de altura va de 0 a 40 m. El perfil del DEM sin filtrar se muestra en rojo, mientras que el perfil del DEM luego de aplicar el filtro de media móvil con un tamaño de kernel de 39 × 39 se visualiza en verde. . . . .	142
6.5. Variables de entrada para el cálculo de $TWI_n$ y $TWI_v$ : ASTER GDEM y fracción de vegetación. . . . .	142
6.6. Índice topográfico de humedad ( $TWI_n$ ) resultante del DEM filtrado. . . . .	143
6.7. Índices topográficos de humedad (simple $TWI_n$ y fito-topográfico $TWI_v$ ) resultantes del DEM no filtrado. . . . .	143
6.8. Matrices binarias resultantes de la aplicación de un umbral en los índices $NDVI$ , $TWI_n$ y $TWI_v$ para clasificación de cuerpos de agua. La imagen de $NDVI$ clasificada es empleada como verdad de campo para la evaluación de las clasificaciones mediante umbrales de 6.8(b) $TWI_n$ y 6.8(c) $TWI_v$ . . . . .	144
6.9. Fotografías tomadas en el área de estudio. . . . .	145
6.10. Fotografías tomadas en el área de estudio. . . . .	146

6.11. Clasificaciones de la imagen Landsat y COSMO-SkyMed Himage, a partir de datos de entrenamiento obtenidos a campo, utilizadas como *verdad de campo* de la clasificación de la imagen COSMO-SkyMed PingPong y COSMO-SkyMed Himage respectivamente. Para validar la clasificación de PingPong, se generó como *verdad de campo* una clasificación supervisada de la imagen Landsat correspondiente al área de estudio, utilizando las regiones de presencia/ausencia obtenidas el muestreo a campo. Para llevar a cabo la evaluación de las clasificaciones de las imágenes COSMO-SkyMed Himage se utilizó como *verdad de campo* el producto resultante de clasificar a una imagen COSMO-SkyMed Himage con la técnica de crecimiento de regiones a partir de semillas colocadas en las áreas de presencia y ausencia de agua conocidas también mediante datos de campo. . . . . 147

6.12. Imágenes COSMO-SkyMed en valores de decibeles calibradas radiométricamente. . . . . 148

6.13. Matrices binarias resultantes de la selección automática de muestras de AGUA y NO-AGUA (clase que abarca el resto de las coberturas que no pertenecen a la clase AGUA) en las distintas imágenes COSMO-SkyMed: PingPong *HH*, PingPong *VV*, Himage *HV* e Himage *HH*. . . . . 149

6.14. Variables de textura *C* (PCA 1, PCA 2, PCA 3) correspondientes a la imagen COSMO-SkyMed Himage *HH*, obtenidas mediante el clasificador 5. . . . . 150

6.15. Resultados de las clasificaciones correspondientes a las distintas imágenes COSMO-SkyMed analizadas. Las clasificaciones 6.15(a), 6.15(b), 6.15(d) y 6.15(e) emplean clasificadores tridimensionales (utilizan 3 variables de textura), mientras que la clasificación 6.15(c) utiliza clasificadores de 6 dimensiones (6 variables de textura). Se puede observar como la precisión varía de acuerdo al modo y polarización de la imagen de entrada en el clasificador, así como a la muestra de entrenamiento utilizada (diferente entre PingPong e Himage). . . . . 151

6.16. Clasificación basada en la integración de las dos metodologías: clasificación de la imagen SAR COSMO-SkyMed (denominada *COSMO* en la leyenda) y del modelo de elevación digital (denominada *DEM*). *DEM, COSMO* representa los píxeles clasificados según la clasificación de COSMO-SkyMed y la clasificación del DEM como AGUA; *DEM, NOCOSMO* representa los píxeles clasificados según la clasificación del DEM como AGUA pero no por la clasificación de COSMO; *COSMO, NODEM* representa los píxeles clasificados según la clasificación de COSMO como AGUA pero no por la clasificación del DEM; *NODEM, NOCOSMO* representa los píxeles no clasificados por ninguna clasificación como AGUA. . . . . 153



6.17. Superposición de la clasificación *PingpongHHVV* (en puntos de color rojo) sobre el DEM (en escala de grises). Los valores del DEM tienen un rango de 0 a 42 m. Se puede visualizar la coincidencia de los cuerpos de agua detectados con la imagen COSMO-SkyMed respecto a las depresiones del DEM. . . . . 153

D.1. Interfaces gráficas de los diferentes módulos desarrollados. . . . . 183

# Índice de tablas

2.1. Comparación de modelos de elevación digital disponibles a la fecha . . . . .	23
2.2. Codificación de dirección de flujo según aproximación 1 . . . . .	25
2.3. Codificación de dirección de flujo según aproximación 2 . . . . .	27
2.4. Codificación de dirección de flujo según aproximación 3 . . . . .	28
3.1. Características de las diferentes bandas del sensor Landsat 5 TM . . . . .	50
4.1. Bandas en las que se divide a la región de microondas . . . . .	66
4.2. Diferentes modos en que pueden ser expresados los valores de coeficiente de retrodispersión de las imágenes de radar . . . . .	79
4.3. Modos de adquisición de los satélites COSMO-SkyMed. . . . .	82
4.4. Ejemplo de una matriz de confusión para un clasificador de dos clases . . . . .	100
4.5. Matriz de confusión para la determinación del estadístico $Kappa$ . . . . .	102
5.1. Características de los seis clasificadores implementados . . . . .	111
5.2. Evaluación de la exactitud de los diferentes clasificadores . . . . .	131
6.1. Clasificaciones de imágenes COSMO-SkyMed llevadas a cabo en este capítulo . . . . .	141
6.2. Evaluación de la exactitud de las clasificaciones mediante selección de un umbral en los índices topográficos de humedad . . . . .	143
6.3. Evaluación de la exactitud de las diferentes clasificaciones de COSMO-SkyMed. . . . .	152
E.1. Características del producto COSMO-SkyMed de modo Spotlight . . . . .	184
E.2. Características del producto COSMO-SkyMed de modo Stripmap Himage . . . . .	184
E.3. Características del producto COSMO-SkyMed de modo Stripmap PingPong . . . . .	185
E.4. Características del producto COSMO-SkyMed de modo ScanSAR WideRegion . . . . .	185
E.5. Características del producto COSMO-SkyMed de modo ScanSAR HugeRegion . . . . .	185

# Capítulo 1

## Introducción general

La delimitación de la distribución y extensión espacial de cuerpos de agua continentales, tanto permanentes como temporales, y su correspondiente monitoreo, es fundamental en aplicaciones tales como la cuantificación de recursos, el modelado hidrológico y el monitoreo de inundaciones. Particularmente, la detección y el monitoreo de inundaciones representan un problema relevante en el manejo de riesgos, siendo las mismas un importante flagelo tanto en áreas urbanas como en rurales de todo el mundo.

Se postulan hipótesis de que el fenómeno de inundaciones podría aumentar con el calentamiento global, e indicios tales como un aumento mayor que el esperado en la intensidad de tormentas con el aumento de temperaturas [Allan & Soden, 2008] y la amplificación de la frecuencia de inundaciones en muchas regiones del mundo [Drogue et al., 2004] respaldarían estas teorías. Existen evidencias de que los eventos de precipitaciones han sido más intensos durante las recientes calurosas décadas en algunas localizaciones en Estados Unidos, Canadá, Australia, Japón, Sudafrica, y Europa [Goudie, 2006]. En su análisis de registros de inundaciones para 29 grandes ríos desde altas a bajas latitudes, Milly et al. [2002] encontraron que, aunque incrementos en inundaciones han ocurrido solo en ciertas décadas y lugares, la frecuencia de grandes inundaciones en general han aumentado particularmente durante las últimas décadas más calurosas. Otras pruebas del aumento en la incidencia de eventos de fuertes precipitaciones en varios países durante estas décadas pueden ser encontradas en Francis & Hengeveld [1998]; Karl & Knight [1998]; Mason et al. [1999].

En este contexto, se torna necesaria la respuesta apropiada, rápida y efectiva a desastres inducidos por inundaciones; para lo cual la caracterización espacial del área afectada por el agua posee fundamental importancia.

En otra perspectiva, el monitoreo de cuerpos de agua tiene un gran valor no solo para la caracterización de ecosistemas sino también para el control de enfermedades humanas relacionadas al agua, incluyendo enfermedades transmitidas por vectores (*enfermedades vectoriales*). A modo de ejemplo, la malaria es una de las más relevantes enfermedades vectoriales en los trópicos y subtrópicos [Githeko et al., 2000], por la cual muere un millón de individuos por año [Lopez et al., 2006]. La misma puede ser causada por diversas especies del género *Plasmo-*

---

*dium*: *Plasmodium falciparum*, *Plasmodium vivax*, *Plasmodium malariae* o *Plasmodium ovale* y los vectores de malaria son especies de mosquitos del género *Anopheles*. Los hábitats larvales de estas especies son usualmente pequeños cuerpos de agua, sin vegetación emergente [Gillies & Coetzee, 1987]. Se conoce que tanto la oviposición del mosquito como la probabilidad de supervivencia larval son proporcionales a la cantidad de agua que el mismo encuentra [Moshe & Andrew, 2004]. Específicamente, se encontró que *Anopheles gambiae* es más prolífico en cuerpos de agua temporarios y turbidos, tales como los formados por lluvia [le Sueur & Sharp, 1988], mientras que en cuerpos de agua permanentes la predación es importante. Del mismo modo, hábitats despejados exponen cuerpos de agua a la energía solar, lo cual acelera el desarrollo de huevos de *Anopheles gambiae*.

Recientes análisis [Smith et al., 2007] sugieren que el control larval puede jugar un rol muy importante en programas de control de enfermedades transmitidas por vectores. La habilidad de localizar hábitat larvales y entender su distribución en el espacio y en el tiempo es un importante componente en el planeamiento de las estrategias de control de vectores [Gu et al., 2008]. La identificación de estos sitios criaderos de larvas es un desafío, y una aproximación práctica sobre amplias regiones es el análisis de información satelital y de productos derivados de la misma. Por lo tanto, una interesante aplicación del monitoreo de cuerpos de agua, permanentes y temporales, sería la caracterización de los sitios de desarrollo de vectores de malaria y su contribución en la definición de algoritmos predictivos de brotes de enfermedad.

La creciente disponibilidad de datos multitemporales satelitales, la variedad de sensores pasivos y activos funcionando en el rango visible y de microondas que están actualmente operantes (o están planificados) con extensa cobertura espacial, posibilitan la detección y el análisis de cuerpos de agua desde el espacio. De esta manera, el análisis de superficies de agua puede ser realizado mediante monitoreo activo de su extensión a través de información proveniente de datos satelitales. Por lo tanto, los sensores espaciales representan una herramienta de gran utilidad para el análisis de extensas regiones, incluso con compleja variabilidad estacional y de difícil acceso, reduciendo el costo en recursos y en tiempo.

Es ampliamente reconocido que la teledetección provee estimaciones hidrológicas indirectas, a través de la interferometría [Alsdorf et al., 2001] o de imágenes visibles o radar [Smith, 1997]. Durante décadas, satélites que operan en el rango visible e infrarrojo del espectro electromagnético han sido empleados para delimitar áreas de inundación alrededor de los cauces de ríos [Blasco et al., 1992]. En las etapas iniciales de la teledetección, los datos disponibles eran de *Landsat Multi Spectral Scanner* (MSS) (de 80 m de resolución), y la banda 7 de MSS, correspondiente a  $0,8 - 1,1\mu m$ , ha sido particularmente adecuada para distinguir agua o suelo húmedo de una superficie seca, debido a la fuerte absorción del agua en la región del infrarrojo cercano del espectro [Smith, 1997].

Desde aproximadamente 1980, el *Landsat Thematic Mapper* (TM) (de 30 m de resolución) se convirtió en la primera fuente de datos para el monitoreo de inundaciones. Especialmente la banda 4, la cual mide en infrarrojo cercano, proporciona una gran discriminación del agua respecto a la superficie seca porque es equivalente a la banda 7 de MSS. En tiempos posteriores,

---

las imágenes SPOT fueron también utilizadas para delimitación de cuerpos de agua basándose en el mismo concepto.

Tanto los sensores activos como los pasivos en el rango de longitudes de onda de las microondas son sensibles a cuerpos de agua en superficie, siendo generalmente superiores a los sensores en el rango del visible e infrarrojo cercano para estudios multitemporales debido a su capacidad de funcionamiento en todas las condiciones meteorológicas y situaciones diurna/nocturna. Particularmente, el avance tecnológico ha permitido el surgimiento de los radares de apertura sintética (*Synthetic Aperture Radars – SAR*), los cuales han sido reconocidos como importantes instrumentos para el monitoreo de superficies de agua. Según Jensen [2000] existen diversas ventajas del sensado remoto de radar, específicamente de los SAR, respecto al sensado óptico. Entre estas se destacan las siguientes:

- Funcionamiento en todas las condiciones meteorológicas: posibilidad de traspasar áreas cubiertas de nubes.
- Capacidad de penetración en la vegetación, el aire, y las superficies con capas de nieve.
- Funcionamiento tanto diurno como nocturno: capacidad de iluminación propia (son sensores activos) posibilitando que el ángulo de iluminación sea controlado y que la cobertura de sensado se realice también durante la noche.

Además de las ventajas anteriormente mencionadas, la ventaja más importante del uso de imágenes SAR radica en su habilidad para diferenciar superficies con agua, dada por el gran contraste que existe entre el comportamiento de esta clase respecto al resto de las coberturas, frente a la radiación de microondas de SAR. Los cuerpos de agua actúan como una superficie reflectora especular, es decir que su respuesta es baja (bajo coeficiente de retrodispersión o *backscatter* en imágenes SAR) y, entonces, lucen como una área oscura. La tierra, por su parte, devuelve mucha mayor cantidad de energía al radar debido por ejemplo a la rugosidad de superficie y esto genera el alto contraste entre la tierra y el agua. Además, como se menciona anteriormente, los SAR pueden detectar agua a través de plantas acuáticas emergentes o canopia forestal (capa superior de hojas del bosque). Sin embargo, son requeridas múltiples polarizaciones para una óptima discriminación entre varios tipos de cobertura inundados [Laurence, 1997].

Diferentes técnicas de procesamiento de imágenes son empleadas para obtener la extensión de superficies cubiertas de agua a partir de imágenes SAR [Brivio et al., 2002]. Entre los métodos de clasificación supervisada que han sido propuestos para la identificación de cuerpos de agua se pueden mencionar los siguientes: interpretación visual, selección de umbrales, análisis de textura, y contornos activos [Schumann et al., 2009].

Aunque la mayor parte de los cuerpos de agua puede ser fácilmente reconocidos visualmente, la detección automática continúa siendo una tarea incompleta. Los requerimientos que originan las emergencias y, por otro lado, la creciente disponibilidad de datos SAR, obligan al desarrollo de herramientas automáticas o semi-automáticas que permitan una rápida interpretación de los mismos.

Tradicionalmente, la detección de cuerpos de agua basada en SAR ha sido llevada a cabo mediante la selección de umbrales en la imagen de intensidad [Brivio et al., 2002]. Sin embargo, la selección de umbrales tiene problemas en la separación agua y tierra, por ejemplo, a diferentes ángulos de incidencia. Una adecuada metodología de detección de superficies de agua debería ser, en principio, independiente del ángulo de incidencia del sensor.

Como una aproximación paralela a la clasificación espacial de cuerpos de agua, un modelo de elevación digital (DEM) permite obtener, mediante modelado hidrológico, productos derivados tales como la dirección de flujo del agua en el terreno, mapas de pendiente, aspecto de la pendiente y relieve de sombras, delineado de cuencas, redes hidrológicas, área de cuencas, longitud de arroyos [Lopez, 1994]. De esta manera, las características físicas de la superficie determinan las características del flujo del agua a través de la misma.

El índice topográfico de humedad (*Topographic Wetness Index – TWI*) [Beven & Kirkby, 1979] es una estimación de la acumulación de humedad (o agua) en una determinada unidad espacial y relaciona el ‘área de acumulación’ (medida del agua que fluye hacia un cierto punto) con la pendiente local (medida de la transmisividad lateral subsuperficial). Esta función determina que las áreas con valores más altos de TWI se saturarán durante una lluvia o el acontecimiento de deshielo con mayor probabilidad. A modo de ejemplo de aplicación, el TWI podría proveer una descripción simple y biológicamente significativa acerca de cómo la topografía afecta el riesgo de malaria a través de la facilitación de sitios potenciales de desarrollo de los mosquitos. Ha sido demostrado previamente que la incidencia local de malaria en una región de Kenya occidental propensa a esta epidemia, mostró fuerte asociación con índices de humedad topográficamente determinados [Cohen et al., 2008]. A su vez, los índices topográficos de humedad locales han predicho hábitats propicios para la presencia de malaria, en algunos casos mejor que variables como uso y cobertura terrestre [Cohen et al., 2010]. Igualmente, en Clennon et al. [2010] se muestra que datos sensados remotamente, combinados con calibraciones de campo, permiten la predicción de potenciales hábitats de desarrollo de vectores en áreas caracterizadas por transmisión de malaria altamente estacional. El TWI podría también, al menos parcialmente, determinar la aptitud de la tierra para agricultura y pasturas, dos tipos de usos de la tierra que se han encontrado asociados a los hábitats larvales en esa región [Minakawa et al., 2005], y por lo tanto, por extensión, con el riesgo de malaria. De esto se deriva que este índice (TWI), u otros índices derivados del modelado hidrológico, podrían no sólo representar una estimación de áreas de potencial anegamiento o inundación sino también proporcionar una herramienta en la identificación de las áreas con comunidades con alto riesgo de transmisión de enfermedades *vectoriales*.

### 1.1. Motivación

Este trabajo de tesis se lleva a cabo en el marco de la *Maestría en Aplicaciones Espaciales de Alerta y Respuesta Temprana a Emergencias*, dictada en el Instituto de Altos Estudios

Espaciales Mario Gulich (IG: <http://www.conae.gov.ar/instgulich/institutogulich.html>), Centro Espacial Teófilo Tabanera, Córdoba; y cuya constitución es una actividad conjunta entre la Comisión Nacional de Actividades Espaciales (CONAE: <http://www.conae.gov.ar>) y la Universidad Nacional de Córdoba (<http://www.unc.edu.ar>).

El IG, el cual funciona en las instalaciones del Centro Espacial Teófilo Tabanera (CETT) de la CONAE, es un centro de investigación, desarrollo y formación de recursos humanos en el campo de la ciencia y tecnología espacial. Dicho instituto es esencial para el desarrollo del Plan Espacial Nacional de la República Argentina, cuya ejecución es responsabilidad de la CONAE.

Una de las principales herramientas con que cuenta el IG para el logro de sus Objetivos es el SIASGE – [Sistema Ítalo-Argentino de satélites para beneficio de la Sociedad, Gestión de las emergencias y desarrollo Económico](#), el cual estará formado por seis satélites con instrumentos radar, de los cuales ya hay cuatro en órbita. SIASGE será una constelación binacional que incluirá a COSMO-SkyMed de la ASI, Agenzia Spaziale Italiana (<http://www.asi.it/>) y SAOCOM de CONAE. COSMO-SkyMed es un SAR operando en banda X (8 GHz) y SAOCOM es un SAR en banda L (1,3 GHz). Los seis satélites se encontrarán ubicados en órbitas polares a la misma altura, en distintos planos orbitales, de tal manera que el conjunto funcione como un instrumento con un enorme ancho de visión sobre la tierra. Ésto permitirá un monitoreo en tiempo casi real, ya que se obtendrá actualización de la información cada aproximadamente doce horas, lo cual es especialmente necesario para el monitoreo y seguimiento de la evolución de catástrofes. El sistema COSMO-SkyMed (Constellation of Small Satellites for Mediterranean basin Observation) consiste en una constelación de cuatro satélites de tamaño medio, y se caracteriza por: cobertura global y en todas las condiciones climáticas, adquisición diurna y nocturna, alta resolución espacial, exactitud (geolocalización, radiometría, etc) y calidad de imágenes, alta resolución temporal (frecuencia de revisita) y capacidad para interferometría y polarimetría entre otras.

En este escenario, y siendo la alerta temprana y respuesta a emergencias uno de los principales objetivos de la maestría, se promovió la orientación de esta tesis hacia la búsqueda de metodologías que colaboren con el desarrollo de un sistema operativo que aumente la capacidad de hacer frente a emergencias, tanto meteorológicas como epidemiológicas, que amenazan a la sociedad.

Específicamente, considerando la elevada resolución espacial (hasta del orden de 1 m) y temporal (aprox. doce horas) ofrecida por la constelación COSMO-SkyMed SAR en actual funcionamiento, resulta necesario evaluar su utilidad y limitaciones para aplicaciones de tipo operativo de monitoreo de cuerpos de agua. Es decir, la utilización de sus datos en sistemas de detección de cuerpos de agua que sean automáticos, robustos, e independientes de características del sensor tales como la polarización o el ángulo de incidencia.

La integración de parámetros hidrológicos, generados a partir de uno de los DEM de mayor resolución espacial disponible al momento (ASTER Global Digital Elevation Model – GDEM con resolución de 30 m en el plano horizontal), con datos radar de la constelación COSMO-SkyMed en una metodología de detección de superficies de agua, representa una interesante

aproximación de trabajo. De esta manera, se pretendió evaluar el empleo de estos datos para aplicaciones de tipo operativo de monitoreo, tales como la cuantificación de recursos y la identificación de variaciones de regímenes de agua. La posibilidad de generar mapas de cuerpos de agua o mapas de extensión de inundaciones en tiempo casi real es invaluable para agencias nacionales o internacionales para el monitoreo de desastres y distribución de esfuerzos o acciones.

### 1.2. Objetivo general

El principal objetivo planteado fue generar metodologías para la detección automática de (1) cuerpos de agua continentales y de (2) zonas anegables con el fin de su potencial uso en prevención y respuesta, tanto a inundaciones como a brotes de enfermedades transmitidas por vectores. En este sentido, se desarrollarán algoritmos para (i) emplear sensores radares de apertura sintética (SAR) COSMO-SkyMed de alta resolución en la delimitación de cuerpos de agua continentales, y (ii) utilizar modelos de elevación digital (DEM) para la estimación de zonas con condiciones topográficas adecuadas para la acumulación de agua.

### 1.3. Objetivos específicos

Los principales objetivos específicos abordados a lo largo de los diferentes capítulos de la tesis son los siguientes:

1. Implementar y evaluar diferentes algoritmos de cálculo de un índice topográfico de humedad en base a un modelo de elevación digital.
2. Desarrollar un índice fito-topográfico de humedad que considere el efecto de la cobertura de vegetación en el patrón de acumulación de agua.
3. Generar una metodología para la clasificación automática de cuerpos de agua en imágenes SAR COSMO-SkyMed.
4. Evaluar la integración de las metodologías de detección de acumulación de agua desarrolladas, es decir, el índice topográfico y la clasificación de COSMO, en un área con riesgo de inundación elevado.
5. Generar módulos de procedimientos, escritos en el lenguaje IDL, que implementen las funcionalidades desarrolladas a lo largo de la tesis, en relación a los objetivos anteriormente planteados.



## **1.4. Estructura de la tesis**

En el capítulo 2 se abarca el objetivo de implementar diferentes algoritmos de cálculo de un índice topográfico de humedad en base a un modelo de elevación digital. En el capítulo 3 se plantea un índice fito-topográfico de humedad que intenta mejorar el modelado hidrológico respecto al producto obtenido en el capítulo 2. En el capítulo 4 se introducen los conceptos teóricos y definiciones para el desarrollo de la clasificación de imágenes COSMO-SkyMed; mientras que en el capítulo 5 se desarrolla la metodología de clasificación automática de cuerpos de agua de dichas imágenes. Por último, en el capítulo 6 se integran las metodologías generadas y mediante análisis de campo se validan las mismas en un área anegable.

# Capítulo 2

## Índice topográfico de humedad

### 2.1. Marco teórico

#### 2.1.1. Modelos de elevación digital del terreno

Los modelos digitales de terreno (DTM) se definen como representaciones digitales de variables relacionadas con la superficie topográfica. Estos incluyen a los modelos de elevación digital (DEMs) y diversas propiedades topográficas tales como modelos de gradiente, pendiente, aspecto, curvatura horizontal, perfiles de paisaje, índices topoclimáticos o modelos no locales como área de cuenca [Florinsky, 1998]. Es decir, los DEMs son un tipo específico de DTM y la fuente de datos para el cálculo de muchas propiedades topográficas derivadas.

Un DEM puede ser definido como una grilla de puntos que contiene datos acerca de la superficie de la tierra. La tercera dimensión o valor 'z' de un DEM es la elevación, la cual es una representación continua del relieve (o forma) del terreno. De acuerdo a Florinsky [1998], un DEM consiste en:

- Un arreglo bidimensional de números representando la distribución espacial de elevaciones sobre una grilla regular.
- Un juego de coordenadas  $(x,y,z)$  para una red irregular de puntos.
- Cadenas de contornos almacenados en la forma de pares de coordenadas  $(x,y)$  a lo largo de curvas de nivel a específicos intervalos de elevación.

Los modelos de elevación digital pueden ser estructurados según dos tipos de formatos:

#### 1. Estructuras vectoriales.

- Contornos o curvas de nivel: polilíneas de altitud constante. Las curvas de nivel se definen como líneas sobre un mapa que conectan puntos de igual elevación.
- (*Triangular Irregular Network: TIN*): red de triángulos irregulares adosados. El terreno se caracteriza mediante la definición de una serie de puntos de interés representativos del mismo, los cuales se conectan formando una red de triángulos. El

terreno queda así dividido en triángulos los cuales definen planos con unas características de pendiente y orientación espacial que caracterizan el relieve dentro de dicho triángulo. Relacionando cada triángulo con los adyacentes, pueden derivarse diversos parámetros hidrológicos.

2. Estructuras raster: guardan la información de modo regular en unidades predefinidas. En este caso la superficie queda dividida en elementos regulares a cada uno de los cuales se le asocia un valor correspondiente a la variable estudiada en dicho elemento. Generalmente, las celdas son de forma cuadrada.
  - Grilla regular: cotas distribuidas sobre una grilla cuadrada. La matriz regular es la estructura más utilizada para construir los modelos digitales de terreno debido a su cómodo manejo informático y simplicidad estructural.
  - *Quadrees*: matrices jerárquicas imbricadas

La información almacenada en formato vectorial requiere menos costo de almacenamiento, pero presenta desventajas desde el punto de vista de su procesamiento. Contrariamente, la ventaja principal del formato raster se encuentra en el manejo más eficiente y adecuado que presenta la información de tipo continuo, permitiendo operaciones sobre dicha información de una manera más acorde con la propia naturaleza de la misma.

Los primeros DEMs han sido producidos mediante digitalización e interpolación de curvas de nivel. Como estructuras raster, los DEMs de grillas regulares son la forma más común de representar digital y gráficamente la forma de la tierra, debido a que mediante este tipo de estructura de datos puede incrementarse la eficiencia de su análisis y el procesamiento de su información. Son representaciones digitales de la topografía o la superficie de la tierra y usualmente son las entradas necesarias y primarias en modelos de análisis hidrológico y aplicaciones de sistemas de información geográfica (SIG).

Los DEMs consisten en una estructura matricial de datos con la elevación topográfica almacenada en cada nodo de la matriz. Las grillas de DEMs son distintos de otras representaciones de DEMs tales como redes triangulares irregulares, además son ampliamente disponibles y simples de utilizar para el análisis de problemas hidrológicos [Moore et al., 1991]. La elevación o altura, al ser una variable continua, es adecuada para representarse mediante una grilla raster. Sin embargo, estos tienen limitaciones debido a su formato de grilla. El inconveniente principal del modelo raster reside en la discretización del espacio que genera, siendo la desventaja más notable la pérdida de precisión del mismo.

Las características físicas de la superficie determinan las características del flujo del agua a través de la misma; al mismo tiempo que el flujo del agua tiende a cambiar las características del terreno. La dirección del flujo está determinada por el 'aspecto' o dirección de la pendiente; esto es, la dirección donde se produce la mayor velocidad de cambio de elevación en un modelo digital. Dado que el flujo de aguas a través de la superficie se da principalmente en la dirección de máxima pendiente, una vez que la dirección de flujo es conocida es posible determinar las

celdas que fluyen hacia una celda particular. Esta información puede ser utilizada para definir los límites de las cuencas y la red de drenaje de un terreno.

En este sentido, el modelado hidrológico permite, en base a un DEM, delinear sistemas de drenaje, cuencas, redes hidrológicas, calcular el área de cada cuenca y la longitud de los cauces [Lopez, 1994] y cuantificar las características del sistema. Los mapas de pendiente (en grados o en porcentajes), aspecto de la pendiente, relieve de sombras, vistas en perspectiva 3D, direcciones de flujo, acumulación de flujo e índice topográfico de humedad, son algunos de los productos derivados del análisis topográfico a partir de un DEM [Wu et al., 2008].

Un sistema de drenaje está definido como el área en la cual escurre el agua y la red a través de la cual fluye hacia un punto más bajo. El flujo del agua a través del sistema de drenaje es solo una sección del ciclo hidrológico, el cual incluye precipitación, evapotranspiración y agua subterránea.

### 2.1.1.1. Resolución espacial

La resolución espacial se refiere al nivel de detalle o el objeto más pequeño que puede ser representado sobre una imagen o grilla, y en el caso de una grilla DEM, es el tamaño de una celda de la grilla o píxel. Por lo tanto, a menor tamaño de celda o píxel, mayor resolución y detalle representa la grilla. La selección de la resolución apropiada de trabajo dependerá de la densidad de la fuente de datos de campo, la distribución de la fuente de datos, la complejidad del terreno, y el objetivo final del estudio.

La precisión de los DEM está principalmente determinada por la resolución espacial horizontal y vertical del modelo y resulta un parámetro fundamental en la obtención de productos derivados.

Durante la última década, las aplicaciones de técnicas de sensado remoto en hidrología han recibido considerable atención. Especialmente, el delineamiento de planicies de inundación, el mapeo de inundaciones y la evaluación de daño por inundación [Hoffmann & Sander, 2007]. El sensado remoto proporciona un modo alternativo más económico de complementar datos hidrológicos de fuentes tradicionales como interpretación visual de mapas de contorno, o ensayos a campo [Vaze & Teng, 2007].

Seleccionar una resolución espacial óptima es una cuestión central en los análisis que involucran a DEM [Aryal & Bates, 2008]. La resolución apropiada debería ser elegida de acuerdo al objetivo del modelado, pero está frecuentemente limitada por la disponibilidad de datos de campo para el área o el tiempo de estudio y por aspectos económicos. Vázquez et al. [2002] sugieren que la selección de la resolución de trabajo es un compromiso entre la minimización del esfuerzo computacional y la retención de la precisión de la realidad del modelo. Una resolución espacial insuficiente puede no representar importantes características topográficas. Por otro lado, una la resolución espacial excesivamente elevada puede introducir indeseadas perturbaciones en estimaciones hidrológicas a partir del terreno, así como también información no aprovechable ni interpretable de acuerdo al objetivo planteado.

### 2.1.2. Modelos hidrológicos

Un modelo constituye una representación abstracta de un cierto aspecto de la realidad. En su estructura intervienen, por una parte, los elementos que caracterizan la realidad modelizada y, por otra parte, las relaciones existentes entre ellos.

Un modelo hidrológico es la representación simplificada de procesos relacionados a la circulación general del agua en la superficie terrestre.

Los modelos hidrológicos pueden clasificarse de la siguiente manera:

**Modelos físicos:** Representación de un sistema bajo condiciones controladas. El modelo puede ser sometido a pruebas reales que simulen determinados eventos extraordinarios que pueden representarse en la cuenca. Su principal ventaja es que, dependiendo de que tan similar sea el modelo al sistema, el grado de confianza en los resultados obtenidos es muy alto.

**Modelos analógicos:** Es la representación de un sistema físico (prototipo), por un sistema físico equivalente, de modo que su comportamiento simule de forma aproximada al del prototipo. Este modelo se basa en la similitud que existe entre ecuaciones que caracterizan los diferentes fenómenos. Por ejemplo, los modelos analógicos utilizados más frecuentemente en hidrología simulan el flujo de agua en un cauce, mediante el flujo de una corriente eléctrica en un circuito compuesto por resistencias y condensadores.

**Modelos matemáticos:** Difieren de los modelos físicos porque prescinden de los esquemas físicos y se centran a la simulación de relaciones matemáticas funcionales. Estas relaciones funcionales casi siempre son ecuaciones diferenciales o ecuaciones en derivadas parciales que permiten representar los fenómenos que están siendo modelados, dichas ecuaciones serán más confiables mientras mejor se conozcan los mecanismos que intervienen en el comportamiento del sistema.

**Continuos y de eventos:** En un modelo continuo, su diseño está programado para varios años y además se basa en reproducir fenómenos que son continuos en el tiempo. Es de eventos cuando se intenta simular una fase del ciclo hidrológico, y el fenómeno estudiado es de menor duración.

**Concentrados y distribuidos:** Un modelo es concentrado cuando los parámetros que determinan los fenómenos producidos varían solo con el tiempo. En un modelo distribuido los parámetros varían también espacialmente (variaciones zonales de tipo de suelo, vegetación, topografía, etc). Para una cuenca hidrográfica, el modelo es distribuido. Una desventaja de los modelos distribuidos es el incremento en la complejidad, datos requeridos, que influyan directamente en el tiempo de ejecución del modelo.

**Determinísticos y estocásticos:** Es determinístico si el resto de variables consideradas en un modelo no tiene un carácter aleatorio y responden a una ley definida. Se considera como

modelos de Causa y Efecto. Es estocástico cuando una de las variables que intervienen en un modelo matemático tiene un carácter aleatorio, es decir dependen de las probabilidades de que sucedan acontecimientos en una larga serie temporal. Estos están basados en los Conceptos Estadísticos de Análisis, donde el fenómeno puede ser considerado como una variable estadística. Estos modelos son particularmente útiles en los estudios hidrológicos.

**Empíricos y conceptuales:** Es empírico cuando se basa en la observación o experimento, y no deriva de la teoría. Se ajusta a los hechos observados y permite predecir lo que sucederá en ciertas circunstancias, porque ya se sabe lo que ha sucedido antes en esas mismas condiciones. La fiabilidad de esos métodos depende de la base de datos experimentales. Es conceptual cuando se basa en las leyes físicas que rigen los fenómenos que se simulan. Los procesos paramétricos son determinados por una combinación de mediciones directas y evaluaciones indirectas durante la calibración.

### 2.1.3. Dirección de flujo

Una de las claves del análisis hidrológico es la determinación de las direcciones de flujo de agua de una cuenca [Tarboton, 1997]. Un DEM contiene suficiente información como para determinar, a una dada escala, los patrones generales de drenaje y las cuencas, siendo la dirección de flujo de cada celda determinada por las elevaciones de las celdas vecinas.

En los modelos de determinación de dirección de flujo se adopta que el agua fluye, de acuerdo a la fuerza de gravedad, desde cada celda hacia celdas vecinas más bajas. El agua puede fluir a una o más de sus celdas vecinas de acuerdo al modelo (Fig. 2.1). Según la mayoría de los modelos, existen ocho direcciones posibles de flujo de una celda considerando las ocho celdas adyacentes.

El método más antiguo y simple para especificar direcciones de flujo es asignar el flujo de cada píxel a solo uno de sus ocho vecinos, adyacente o diagonalmente, en la dirección de la pendiente mayor (Fig. 2.1(a)). Posteriormente se desarrollaron métodos que adoptan múltiples direcciones de flujo (Fig. 2.1(b)).

Los métodos pueden ser divididos en dos grupos de acuerdo a: 1) los que consideran que el flujo se mueve entre los centros de las celdas, y 2) los que consideran que el flujo se mueve libremente a lo largo del DEM (conocidos como *Flow Tracing algorithms*). Los primeros están relacionados con el método 'D8' que será descrito a continuación, mientras que los segundos son más complejos y su uso es más restringido. Otra división posible sería: 1) los que consideran un flujo unidimensional o en una dirección simple, y 2) los que consideran un flujo bidimensional o múltiples direcciones de flujo (Fig. 2.2, página 15).

A continuación se describen los principales modelos que existen para la determinación de matrices de dirección de flujo a partir de un modelo de elevación digital del terreno. En la figura 2.2 se presenta un esquema que ejemplifica las direcciones que pueden ser determinadas según cada modelo y el patrón de flujo espacial derivado en un terreno con declive. En cada

figura de patrón de flujo, este terreno está representado mediante curvas de nivel, siendo las alturas descendientes hacia la parte inferior de las figuras (es decir, declive hacia la parte inferior de cada figura).

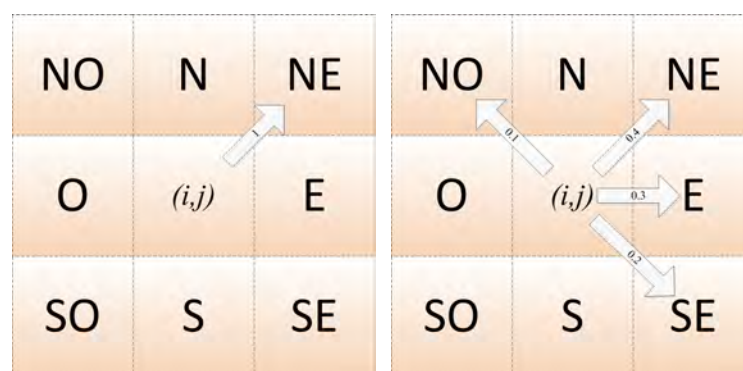
### 2.1.3.1. SFD8

*Single Flow Direction chosen from eight possibilities: Dirección simple a partir de ocho posibilidades*

El primer método, más común y simple utilizado para especificar direcciones de flujo es el *Deterministic 8* (D8), el cual adopta ocho posibles direcciones de flujo. Según este método, los cálculos de direcciones de flujo son realizados para una celda del DEM y se basan en los valores de elevación de las ocho celdas que están espacialmente adyacentes a la misma. Este método fue introducido por O'Callaghan & Mark [1984] y ha sido ampliamente utilizado.

Según este método, el agua drena en la dirección de mayor declive, siendo la misma definida como la disminución en la elevación por unidad de distancia de recorrido. Para calcular la pendiente de una celda respecto a celdas de posición diagonal, la diferencia de elevación es dividida por la raíz cuadrada de dos multiplicada por el tamaño de celda; mientras que para calcular la pendiente hacia celdas de posición rectilínea, la diferencia de elevación es dividida por el tamaño de la celda. La dirección de flujo es codificada de acuerdo a la orientación de una de las ocho celdas que rodea a la celda central.

Por lo tanto, según la aproximación SFD8 las direcciones de flujo están restringidas a múltiplos de  $45^\circ$ , lo cual es la principal desventaja de este método [Costa-Cabral & Burges, 1994]. Los modelos SFD8 han sido criticados por no considerar la dispersión de flujo [Aryal & Bates, 2008]. Además, no son capaces de definir la correcta ruta de flujo si la mayor pendiente se encuentra de manera coincidente en dos direcciones [Wolock & McGabe, 1995].



(a) Simple dirección de flujo. El flujo de agua se dirige hacia una sola dirección, la de mayor pendiente. (b) Múltiples direcciones de flujo. El flujo de agua se dirige hacia más de una dirección posible.

**Figura 2.1:** Ejemplo de modelos de **simple** y **múltiple** dirección de flujo de agua.

### 2.1.3.2. MFD8

*Multiple Flow Direction chosen from 8 possibilities: Dirección múltiple a partir de ocho posibilidades*

Los métodos de múltiples direcciones de flujo han sido sugeridos como una tentativa de superar la limitación en la dispersión real del flujo que generan los modelos SFD8. Mientras el modelo SFD8 es siempre representado como convergente, el modelo MFD8 fue creado como una modificación de este último de modo de representar divergencia de flujo [Bartak, 2009]. En este caso, el agua fluye desde un píxel a cada píxel inferior adyacente de acuerdo a una proporción dada por las pendientes particulares en relación a la suma de pendientes [Kim & Lee, 2004]. Sin embargo, un inconveniente de estos modelos es que pueden generar excesiva dispersión de flujo.

### 2.1.3.3. SFD $\infty$

*Single Flow Direction chosen from infinite possibilities: Dirección simple a partir de infinitas posibilidades*

Esta aproximación fue sugerida por Tarboton [1997], el cual propone utilizar facetas triangulares para superar la limitación del flujo de agua a solo ocho direcciones que suponen los modelos de dirección de flujo SFD8 y MFD8. El modelo SFD $\infty$  selecciona la dirección de mayor pendiente en el rango infinito desde 0° hasta 360°. Construye triángulos con vértices en: 1) el centro de cada celda analizada y 2) los centros de sus dos (mutuamente adyacentes) vecinos; y luego identifica la dirección de mayor declive sobre el plano determinado por los triángulos. Si bien este modelo sigue siendo de dirección de flujo simple, permite que el agua fluya entre dos celdas de altura inferior a la central.

### 2.1.3.4. MFD $\infty$

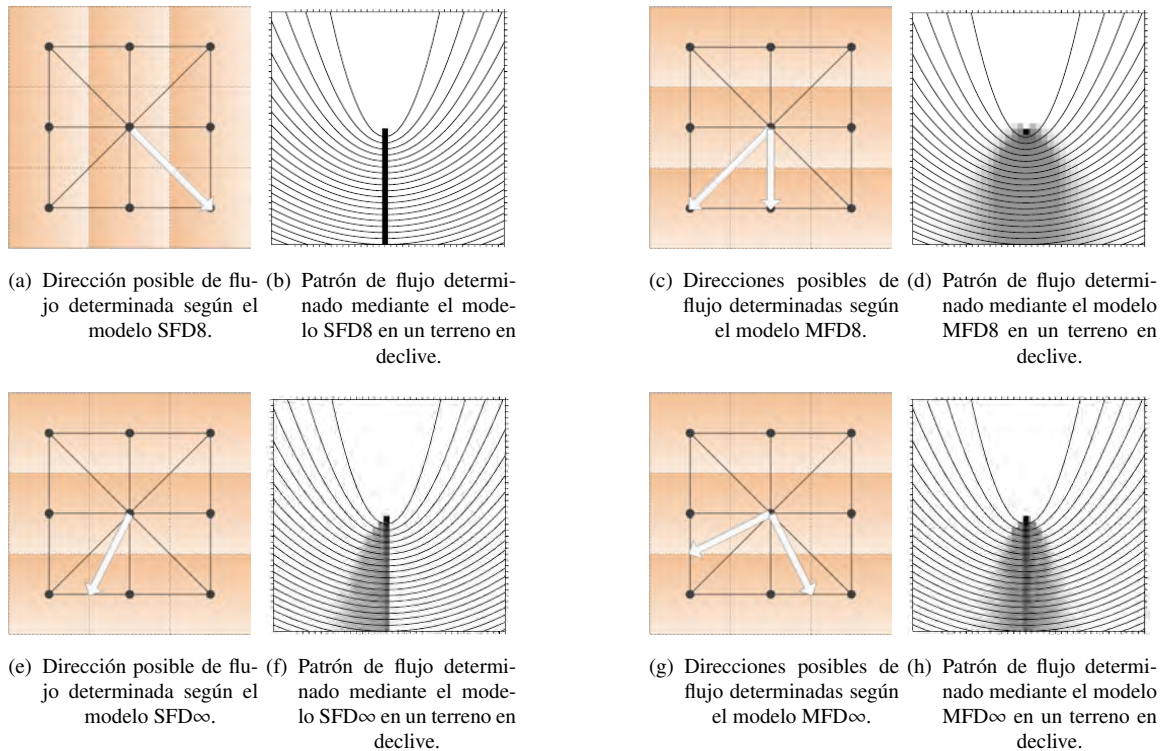
*Multiple Flow Direction from infinite possibilities: Dirección múltiple a partir de infinitas posibilidades*

Seibert & McGlynn [2007] desarrollaron el modelo MFD $\infty$  por combinación de las ventajas de MFD8 y SFD $\infty$ . Son utilizadas facetas triangulares para calcular los gradientes alrededor de la celda en cuestión, y no sólo la dirección de mayor pendiente es considerada sino también todas las posibles direcciones con menor altura. El flujo es dirigido hacia dos vecinos mutuamente adyacentes como en el modelo SFD $\infty$ .

**Para evaluar y diseñar procedimientos de direcciones de flujo a partir de un DEM son importantes las siguientes cuestiones:**

- (1). La necesidad de evitar o minimizar la dispersión del flujo de agua en el terreno analizado,
- (2). la necesidad de evitar el sesgo originado por trabajar con una grilla de datos; es decir, el sesgo originado por la restricción del flujo de agua a sólo ocho direcciones posibles,






**Figura 2.2:** Ilustración del funcionamiento de los modelos de determinación de dirección de flujo: SFD8, MFD8, SFD $\infty$  y MFD $\infty$ . En las figuras de dirección de flujo posibles para cada modelo (2.2(a), 2.2(c), 2.2(e), 2.2(g)) los nodos negros demarcan los centros de los píxeles del DEM y las líneas negras continuas unen estos centros. En las figuras del patrón de flujo determinado por cada modelo (2.2(b), 2.2(d), 2.2(f), 2.2(h)) las líneas curvas representan las curvas de nivel de un terreno con disminución de altura hacia abajo y el flujo de agua es representado en estas figuras mediante píxeles en escala de grises (de blanco a negro) de acuerdo a la cantidad de flujo hacia ese píxel determinado.

- (3). la precisión con la cual las direcciones de flujo son resueltas,
- (4). el uso de una estructura de almacenaje matricial simple y eficiente,
- (5). la robustez, es decir la habilidad de adaptarse a estructuras complejas.

El método SFD8 funciona bien con los puntos (1), (4) y (5), pero no con los (3) y (2). Los métodos de múltiple dirección de flujo evitan error de grillas (2) pero introducen sustancial dispersión y son ineficientes en cuanto al almacenamiento de datos (4). Los métodos de flujo en plano [Costa-Cabral & Burges, 1994] son susceptibles a problemas (5) originados por la aproximación involucrada en el ajuste del plano mediante cuatro puntos.

Dos importantes cantidades que dependen de las direcciones de flujo son: 1) la acumulación de flujo y 2) el área específica de cuenca. La acumulación de flujo,  $A$ , se define como el área total de cuenca encima de un punto dado [Moore et al., 1991]. El área específica de cuenca,  $a$ , está definida como el área total de cuenca (acumulación de flujo) por unidad de contorno,  $L$  [Costa-Cabral & Burges, 1994] (Fig. 2.3):

$$a = \frac{A}{L} \quad (2.1)$$



**Figura 2.3:** Significado de las variables que definen el área específica de cuenca: área total de cuenca por unidad de contorno.

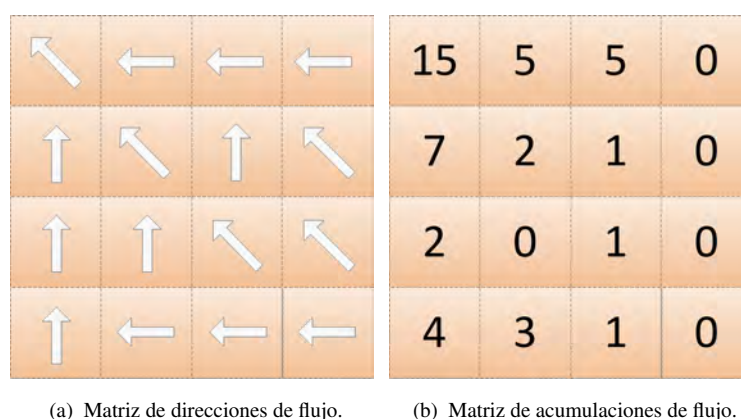
El área específica de cuenca es útil para determinar la saturación relativa, y junto con otros parámetros topográficos, ha sido también usada para analizar procesos tales como erosión, deslizamientos de tierra y cauces [Martz & Garbrecht, 1999].

### 2.1.4. Acumulación de flujo

El cálculo de flujos acumulados brinda la posibilidad de determinar la cantidad de agua de lluvia que puede fluir por una celda dada, asumiendo que llueve en toda la cuenca, que toda la lluvia se convierte en escurrimiento superficial y que no existe infiltración, evapotranspiración u otras pérdidas de agua.

Una vez que la dirección de flujo es determinada, puede ser calculada la matriz de acumulación de flujo. El valor de acumulación de flujo de una celda es el número de celdas corriente arriba que fluyen hacia ésta. En el caso de que cada celda tenga un peso, la acumulación de flujo es igual al peso acumulado de todas las celdas que fluyen hacia ésta. En el contexto de una grilla el área de acumulación (área de cuenca),  $A$ , es el área que contribuye a cada píxel. La acumulación es calculada usando un procedimiento recursivo, en el cual el área de acumulación de cada píxel es tomada como su propia área más el área de acumulación de los vecinos que drenan hacia el píxel en cuestión. Una aproximación de este cálculo iterativo fue iniciada por Marks et al. [1984].

Como resultado del procedimiento, a cada celda se le asigna un valor igual al número de celdas que fluyen a ella. A modo de ilustración, la figura 2.4 muestra una grilla de dirección de flujo de agua obtenida a partir de un DEM y su derivada matriz de acumulación de dicho flujo. Específicamente, la subfigura 2.4(a) muestra las direcciones de flujo, mientras que la subfigura 2.4(b) representa la grilla de acumulación de flujo obtenida de acuerdo a estas direcciones de flujo. Cada valor de acumulación en esta última grilla representa el número de píxeles totales que drenan hacia el píxel determinado.



**Figura 2.4:** Ejemplo de una grilla de dirección de flujo de agua obtenida a partir de un DEM y su derivada grilla de acumulación de flujo de agua. El área de acumulación de cada píxel es calculada como su propia área más el área de acumulación de los vecinos que drenan hacia el píxel en cuestión.

### 2.1.5. Índice topográfico de humedad

#### *Topographic Wetness Index: TWI*

Existen diferentes índices topográficos que son ampliamente utilizados y permiten la cuantificación de las características topográficas. Los índices topográficos son usualmente computados a partir de una grilla de datos de elevación. Por lo tanto, la resolución y el contenido de información de un DEM tiene gran influencia en el calculo de los mismos.

Es una variable que define la tendencia de una celda a acumular agua [Gruber & Peckham,

2009]. Está relacionada con la humedad del suelo y refleja la tendencia de éste a generar escorrentía, ya que áreas con mayor valor del índice, como producto de su configuración topográfica y edáfica, son más proclives a generar escorrentía derivada de la precipitación.

El índice topográfico de humedad (TWI) fue introducido por primera vez por **Beven & Kirkby [1979]** como parte del modelo de escurrimiento TOPMODEL y es uno de los índices más comúnmente aplicado. El TWI [**Beven & Kirkby, 1979**] es una estimación de la acumulación de agua en una determinada unidad espacial y relaciona el ‘área de acumulación’ o acumulación de flujo (medida del agua que fluye hacia un cierto punto) con la pendiente local (medida de la transmisividad superficial).

El TWI se define como:

$$TWI = \ln \frac{a}{\tan\beta} \quad (2.2)$$

donde  $\beta$  es el ángulo de pendiente local y  $a$  es la acumulación de flujo por unidad de superficie.

La acumulación de flujo  $a$ , como se especificó anteriormente, es el área que contribuye a cada píxel y puede ser estimada como el producto del número de píxeles que drenan multiplicado por el área de cada píxel. El índice topográfico de humedad es adimensional.

Esta función implica que las áreas con los valores más altos de TWI se saturan durante una lluvia o el acontecimiento de deshielo con mayor probabilidad y TWI es por lo tanto, una estimación del agua que se acumulará en un sitio.

## 2.2. Objetivos abordados en el capítulo

El propósito del presente capítulo es desarrollar un método para estimar y describir características físicas de la superficie terrestre relacionadas con la posibilidad de acumulación de agua, en base a modelos de elevación digital del terreno. Específicamente, el objetivo es implementar y evaluar diferentes algoritmos para la determinación de índices topográficos de humedad basados en modelos de elevación digital y de esta manera, seleccionar el procedimiento más adecuado para este producto de modelado hidrológico.

### 2.2.1. Aportes del capítulo

En el presente capítulo se lleva a cabo la implementación en el lenguaje *Interactive Data Language* (IDL), de diferentes aproximaciones para el cálculo de un índice topográfico de humedad. En diversos programas de Sistema de Información Geográfica (SIG) se encuentra disponible una aproximación determinada (originada de un único modo de cálculo de direcciones de flujo de agua) para la obtención de este índice, y en la mayoría de los casos, bajo licencia de software de código cerrado (software propietario o privativo). Según este tipo de licencia, los propietarios establecen los derechos de uso, distribución, modificación, y no permiten que el software sea modificado, desensamblado, copiado o distribuido de formas no especificadas en la propia licencia.

El código desarrollado en este capítulo es de dominio público, en el sentido de que es permitido su uso, copia, modificación o redistribución con o sin fines de lucro. Una de las ventajas de la implementación aquí realizada es la posibilidad de incorporar modificaciones en los distintos algoritmos y de esta manera, ampliar la potencialidad del modelado hidrológico de un terreno. En este capítulo, además de implementarse distintas metodologías de obtención de un indicador de probabilidad de acumulación de agua en base a un DEM, se aporta información para la selección de una de estas. Mediante esta selección, se pretende que la metodología, y por lo tanto el índice topográfico de acumulación de agua, capture las características espaciales topográficas relativas a flujo y acumulación de agua de un modo más eficiente que empleando modelos dinámicos de simulación hidrológica.

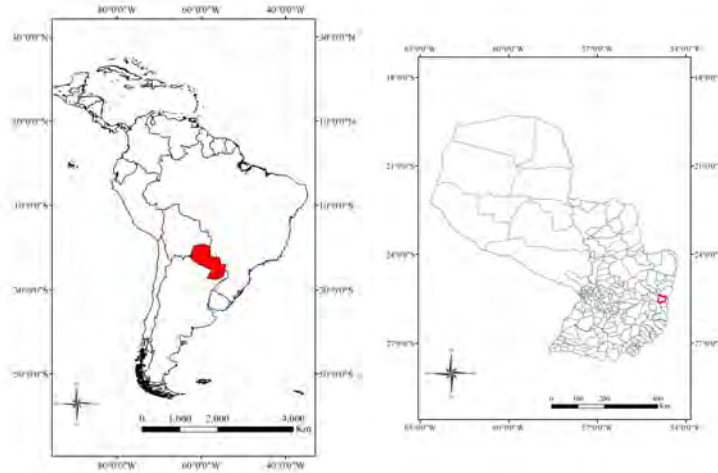
## 2.3. Materiales y métodos

### 2.3.1. Área de estudio

El área de estudio correspondiente al presente capítulo se muestra en la figura 2.5 y está localizada en el departamento Alto Paraná, de Paraguay. Las coordenadas geográficas centrales de la zona en cuestión son 25 °22 '05 S 54 °53 '49 W. El área mide aproximadamente 32 × 17 km. Esta zona abarca localidades como Colonia Acaray, Yguazú y Minga Guazú. Yguazú es una ciudad situada cerca del río Yguazú, en el centro del Departamento de Alto Paraná. En la zona de Minga Guazú se encuentran los ríos Monday, Acaray, el arroyo Acaray-mi y Santa María.


El río Yguazú, que se encuentra al este de Paraguay, discurre por los departamentos de Caaguazú y Alto Paraná, hasta su desembocadura en el río Acaray entre los distritos de Hermandarias y Ciudad del Este. El lugar de su desembocadura ha sido alterado para permitir el aprovechamiento hidroeléctrico de la Represa del Yguazú. Este curso hídrico no posee afluentes, solo se destaca por el lago formado por la hidroeléctrica del mismo nombre. Esta *Central Hidroeléctrica Yguazú* es una de las presas hidroeléctricas más importantes de Paraguay, las otras son Itaipu, Yacyreta y Acaray.

El área de estudio tiene gran importancia epidemiológica, siendo Alto Paraná la localidad




(a) Localización de Paraguay.

(b) Localidad de Minga Guazú, en el departamento Alto Paraná, Paraguay.



(c) Esquema geográfico del área de estudio. En esta se encuentran cuerpos de agua tales como el Lago del río Yguazú, el río Acaray, y el lago Acaray



(d) Imagen [Google Maps](#) del año 2011 correspondiente al área de estudio. Coordenadas centrales: 25°22'05 S 54°53'49 W.

**Figura 2.5:** Área de estudio localizada en el departamento Alto Paraná, Paraguay. Ésta mide aproximadamente  $32 \times 17$  km. Incluye principalmente cuerpos de agua y superficies vegetadas. Se presentan algunas construcciones de manera aislada.

con mayor casos de Dengue por población (casi a 1.000 casos por cada 100 mil habitantes). En el año 2011 se registraron más de 200 casos de Dengue, presentándose tanto el serotipo 1 como el 2 (*Dirección General de Vigilancia de la Salud de Paraguay*: [vigisalud.gov.py](http://vigisalud.gov.py)). En la zona, las enfermedades vectoriales presentes, además del Dengue, son: la fiebre amarilla, malaria, y la leishmaniasis visceral humana.

De acuerdo a [Viveros & Yuruhán \[2010\]](#), la malaria en Paraguay está relacionada con los niveles de pobreza en departamentos como Alto Paraná, Caaguazú, Canindeyú, donde se presentan alteraciones ecológicas debido a la expansión poblacional y construcciones como la de la represa de Itaipú. Ciertas zonas de estos departamentos presentan bajos IDH (Índice de Desarrollo Humano) y elevados IPA (Índice Parasitario de Malaria), un indicador para el control de la malaria [[Viveros & Yuruhán, 2010](#)].

En los años 60, el 90% del territorio paraguayo notificaba casos de malaria, afectados principalmente por la transmisión del *Plasmodium vivax*. En la actualidad, a pesar de las actividades de control que se realizan operativamente desde el año 1959, la enfermedad persiste en 3 de los 17 departamentos del país. Debido al endemismo de la enfermedad en departamentos como Alto Paraná, se ha especulado con la existencia de una relación entre la persistencia de la malaria en el área y factores ambientales producidos por la dinámica del lago Iguazú, vinculado a la represa hidroeléctrica de nombre Acaray [[Muñoz et al., 2010](#)].

### 2.3.1.1. Topografía y cobertura del suelo

El Alto Paraná está constituido por una combinación de valles estrechos por los que recorren los afluentes del río Paraná y por tierras altas y onduladas con elevaciones que llegan a los 300 msnm; prácticamente no existen elevaciones significativas del terreno.

La región del Oriente Paraguayo, específicamente la región de Alto Paraná, experimenta un mayor régimen pluvial (con valores de 1900 a 2200 mm anuales), por lo cual pueden encontrarse importantes formaciones boscosas, que junto con un ecosistema complejo de especies de flora y fauna, determinan una rica y única región ecológica. Particularmente, el departamento del Alto Paraná se caracteriza por contar con los bosques más altos del país con ejemplares de araucaria (pino Paraná). Se presentan comunidades naturales de bosques en suelos saturados, bosques altos (caracterizados por más de 20 m de altura) y medios, bosques de araucarias y cerrados. Es también esta zona la que presenta la mayor diversidad en fauna.

### 2.3.1.2. Clima

La temperatura media anual es de 21 °C; la máxima alcanza los 38 °C y la mínima a 0 °C. En épocas invernales, son constantes las lloviznas y las neblinas.

### 2.3.2. Diagrama metodológico

En la figura 2.6 se muestra un diagrama general de los pasos del modelado hidrológico llevado a cabo, y que serán explicados en la sección 2.3.4.



**Figura 2.6:** Productos del modelado hidrológico que fueron generados en el presente capítulo a partir de un modelo de elevación digital (DEM): 1) pendiente, 2) dirección y 3) acumulación de flujo, e 4) índice topográfico de humedad (TWI). A partir del DEM se obtienen la matriz de pendiente, de dirección y acumulación de flujo. El TWI combina estos últimos productos.

### 2.3.3. Recolección y preprocesamiento de datos

#### 2.3.3.1. Datos de elevación digital

**ASTER *Global Digital Elevation Model* (GDEM):** Existen diversas maneras de obtener un DEM, ya sea aplicando interpolación de datos puntuales, a partir de curvas de nivel digitalizadas, extrayéndolos de pares estereoscópicos de fotografías aéreas o imágenes de satélite mediante procedimientos fotogramétricos, a partir de imágenes de radar aplicando la interferometría o más recientemente, mediante LiDAR.

La utilización de pares estereoscópicos para la generación de un DEM se basa en la disparidad binocular o paralaje, definido como la ‘diferencia’ de la imagen de un objeto proyectado en cada retina [Oñate Valdivieso & Sendra, 2007]. El grado de disparidad entre las imágenes proyectadas de un objeto depende del ángulo de convergencia. La convergencia es la habilidad de enfocar el eje óptico de los dos ojos en un solo objeto. El principio de la disparidad binocular es aplicado en fotogrametría aérea y satelital para calcular la elevación del terreno a partir de la medida del paralaje entre dos imágenes [Toutin, 2002].

Existen dos medios para la obtención de pares estereoscópicos de imágenes satelitales: el primero, capturando imágenes desde órbitas adyacentes entre las que existe traslape (*across-track*) y el segundo, captando las imágenes desde una órbita única (*along-track*).



El *Advanced Spaceborne Thermal Emission And Reflection Radiometer* (ASTER) *Global Digital Elevation Model* (GDEM) fue desarrollado conjuntamente entre *National Aeronautics and Space Administration* (NASA) y *Japan's Ministry of Economy, Trade, and Industry* (METI).

El ASTER es un sensor desarrollado por Japón, a bordo del satélite *Terra*. Este sensor provee datos en 14 bandas: visible-infrarrojo cercano, infrarrojo de onda corta, e infrarrojo térmico. Tiene un campo instantáneo de visión de 15 m. ASTER presenta una órbita heliosincrónica a una distancia de 705 km, con un ciclo de repetición de 16 días, un ancho de barrido de 60 km y una distancia entre órbitas de 172 km. ASTER está compuesto por 3 subsistemas, VNIR, SWIR y TIR; cada uno de los cuales presenta características particulares tales como 3 bandas en la región espectral del visible e infrarrojo cercano (VNIR) con una resolución espacial de 15 m; 6 bandas en la región espectral del infrarrojo de onda corta (SWIR) con una resolución espacial de 30 m y 5 bandas en el infrarrojo térmico con una resolución espacial de 90 m. ASTER también presenta un telescopio con visión hacia atrás que escanea en la región espectral de la banda 3B (VNIR), lo que nos permite realizar modelos digitales de terreno (MDT) por pares estereoscópicos. Por lo tanto, datos de imágenes en estéreo son colectadas usando telescopios mirando con ángulos en *nadir* y *backward* en la banda 3 (VNIR). El ASTER GDEM fue generado a partir de estos pares de imágenes ASTER en estéreo adquiridas sobre la misma zona.

ASTER GDEM abarca la superficie terrestre entre 83 °N y 83 °S y se distribuye en formato GeoTIFF con coordenadas geográficas latitud/longitud, referenciado al geoide WGS84/EGM96. La exactitud estimada para este producto global es 20 m con 95 % de confianza para datos verticales y 30 m con un 95 % de confianza para datos horizontales.

En la tabla 2.1 se detallan las características básicas de distintos DEMs disponibles a la fecha.

**Tabla 2.1:** Comparación de modelos de elevación digital disponibles a la fecha

	ASTER GDEM	SRTM3	GTOPO30
<i>Fuente de datos</i>	ASTER	Space shuttle radar	Organizations with DEM data
<i>Generación y distribución</i>	METI/NASA	NASA/USGS	USGS
<i>Año de liberación</i>	2009	2003	1996
<i>Resolución espacial</i>	30 m	90 m	1000 m

Los datos de ASTER GDEM correspondientes al área de estudio (Fig. 2.1), fueron provistos por CONAE ([conae.gov.ar](http://conae.gov.ar)) en el contexto de la maestría en *Aplicaciones Espaciales de Alerta y Respuesta Temprana a Emergencias*.

### 2.3.4. Especificación de la metodología

#### 2.3.4.1. Tecnología de desarrollo empleada

**Interactive Data Language [IDL, 2009]:** IDL es un lenguaje de programación ampliamente usado para análisis de datos, incluyendo procesamiento de imágenes. Es popular en áreas científicas tales como astronomía y la medicina (análisis de imágenes médicas). Se origina de PV-

Wave (*Precision Visuals - Workstation Analysis and Visualization Environment*) y comparte sintaxis con el mismo.

IDL es dinámicamente tipado y proporciona tipos de datos compuestos tales como caracteres en cadena, arreglos de tipo homogéneo, listas, tablas, y estructuras simples de tipos de datos mixtos; también provee varios tamaños de enteros (tanto flotantes simples como de precisión doble, números reales y complejos). Un lenguaje de programación es dinámicamente tipado si una misma variable puede tomar valores de distinto tipo en distintos momentos.

Este lenguaje permite *multihilo*. En un entorno de multitarea basada en hilos, el hilo es la unidad de código más pequeña que se puede seleccionar para ejecución. La programación basada en multihilos, permite escribir programas más eficientes ya que optimizan los recursos de la Unidad Central de Proceso (CPU), al reducir al mínimo los tiempos de inactividad.

Usa pasaje de argumentos por referencia. Cuando un argumento se pasa por referencia, más que el valor mismo del argumento, lo que se pasa es la dirección de memoria donde ese valor está almacenado. Por lo tanto, la función llamada puede modificar el valor original directamente.

Compila a un código intermedio (como Java). Este tipo de compilación es la encargada de traducir desde el código fuente del programador a un lenguaje intermedio independiente de la plataforma. Existe también una implementación libre del lenguaje denominada GDL (GNU Data Language: [gnudatalanguage.sourceforge.net](http://gnudatalanguage.sourceforge.net)) completamente compatible con IDL 7.1 ([ittvis.com](http://ittvis.com)).

Aunque IDL es una plataforma adecuada para el procesamiento y análisis de señales e imágenes, en [Bustos & Frery \[2005\]](#) se cuestiona su precisión numérica, principalmente en cálculos estadísticos en punto flotante de precisión simple. Debido a esto, en este trabajo se realizaron todos los cálculos con datos en punto flotante de precisión doble.

### 2.3.4.2. Implementación de algoritmos

Se implementaron diferentes algoritmos de determinación de dirección de flujo a fin de evaluar el comportamiento de cada uno en cuanto a la predicción de la acumulación de agua en un terreno. De esta manera, posteriormente se seleccionó el más adecuado de ellos de acuerdo a los objetivos planteados de aplicación de los mismos.

La implementación de los algoritmos que se exponen a continuación y sus respectivas interfaces gráficas de usuario fue llevada a cabo usando el IDE (Integrated Development Environment) IDL Workbench 7.1.1 sobre un sistema operativo GNU/Linux (Ubuntu 10.04, Kernel 2.6.32-31-generic-pae). Las interfaces gráficas de usuario de cada módulo desarrollado son presentadas en el apéndice *D* (ver página 183).

#### **Aproximación 1:** Única principal dirección de flujo

Esta aproximación contiene las siguientes funciones en orden de ejecución:

- *Direcciones de flujo:*

225	270	315
180	(i,j)	0
135	90	45

**Tabla 2.2:** Codificación de dirección de flujo según aproximación 1

A partir de un DEM, esta función genera una matriz en la que cada píxel indica su dirección de flujo. Existen ocho direcciones válidas, definidas por cada uno de los píxeles adyacentes hacia los cuales el píxel analizado  $(i, j)$  puede drenar agua, y las mismas son codificadas de la siguiente manera:

Cada píxel se caracteriza por drenar hacia una única principal dirección de flujo. Esta aproximación se basa en el modelo detallado en la sección 2.1.3.1 y además cumple las siguientes condiciones:

1. Cuando todas las celdas vecinas tienen elevaciones mayores que la celda central su dirección de flujo es nula y por lo tanto, la dirección de flujo es codificada como negativa  $(-1)$  para esta celda.
2. La dirección de flujo es determinada buscando la dirección de mayor pendiente desde cada celda. Esta pendiente se calcula como la diferencia de altura de la celda central  $(DEM_{i,j})$  con las celdas vecinas  $(DEM_{in,jn})$  de menor altura dividido por la distancia medida en unidad de celda. Para celdas orientadas horizontal o verticalmente respecto a la central, la pendiente se define como:

$$Pendiente = \frac{DEM_{i,j} - DEM_{in,jn}}{1} \quad (2.3)$$

Para celdas orientadas diagonalmente respecto a la central, la pendiente se define como:

$$Pendiente = \frac{DEM_{i,j} - DEM_{in,jn}}{\sqrt{2}} \quad (2.4)$$

3. Si existe más de una dirección con la máxima pendiente, la dirección es determinada mediante un mecanismo de selección aleatoria.

■ *Acumulación de flujo:*

El área de acumulación (ver subsección 2.1.4) es calculada mediante un procedimiento recursivo. La acumulación de flujo de cada píxel es obtenida sumando su propia área (considerada de valor 1) con el área de cuenca de los vecinos que tienen alguna proporción de drenado hacia el píxel en cuestión. Es decir, se calcula el flujo acumulado como el peso acumulado de todas las celdas que fluyen pendiente abajo.

A continuación se presenta el pseudocódigo del algoritmo implementado para la

obtención de la matriz de acumulación de flujo:

**Algorithm 2.3.1:** ACUMULFLUJO( $i, j, area, known$ )

**comment:** Calcula la acumulación de flujo del píxel  $i, j$ .

**procedure** DPAREA( $i, j, area, known$ )

**if**  $known[i, j] == 0$

**then** {

**for each**  $(in, jn) \in VECINOS(i, j)$

$p = PROP(in, jn)$

**comment:** PROP: calcula proporción de drenado del vecino  $(in, jn)$  al píxel  $(i, j)$

**if**  $p > 0$

$DPAREA(in, jn)$

**comment:** Llamada recursiva para calcular acumulación del vecino.

$area(i, j) = area(i, j) + p * area(in, jn)$

**comment:** area: acumulará el flujo resultante.

$known[i, j] = 1$

**comment:** known: es una matriz que marca los píxeles que ya fueron analizados.

En esta primera aproximación la proporción hacia la dirección de drenado es  $p = 1$ , debido a que el flujo se orienta totalmente hacia una dirección.

- **Pendiente:**

Se calcula la matriz de pendiente del DEM mediante el uso de la función correspondiente implementada en el software ENVI [ENVI, 2009]. El acceso al menú es el siguiente: *ENVI* → *Topographic* → *Topographic Modeling*.

La pendiente es calculada mediante el ajuste de una superficie cuadrática a los datos de elevación digital y considerando las propiedades derivativas. La unidad resultante de la misma es *grados*, con la convención de  $0^\circ$  para el plano horizontal.

- **Índice topográfico de humedad:**

El índice topográfico de humedad se determina mediante la fórmula 2.2.

A los fines de evitar divisiones por cero, cuando la pendiente en el píxel determinado es cero, el TWI se calcula como:

$$TWI = \ln \frac{a}{\tan(1 \times 10^{-10})} \quad (2.5)$$

**Aproximación 2:** Se define que el flujo se orienta hacia todas las direcciones que poseen un valor de pendiente igual al valor de la máxima pendiente

Esta aproximación contiene las siguientes funciones en orden de ejecución:

5	6	7
4	(i,j)	0
3	2	1

**Tabla 2.3:** Codificación de dirección de flujo según aproximación 2

■ *Direcciones de flujo:*

Cada píxel se caracteriza por drenar hacia todos los píxeles vecinos que poseen un valor de pendiente igual a la máxima pendiente decreciente. El drenado se divide en proporciones equivalentes de acuerdo con el número de píxeles que posee este valor de pendiente máximo. Esta pendiente se calcula como la diferencia de altura de la celda central con las celdas vecinas ( $DEM_{in,jn}$ ) de menor altura dividido por la distancia medida en unidad de celda. Para celdas orientadas horizontal o verticalmente respecto a la central, la pendiente se define como:

$$Pendiente = \frac{DEM_{i,j} - DEM_{in,jn}}{1} \quad (2.6)$$

Para celdas orientadas diagonalmente respecto a la central, la pendiente se define como:

$$Pendiente = \frac{DEM_{i,j} - DEM_{in,jn}}{\sqrt{2}} \quad (2.7)$$

Según esta aproximación, cada píxel está representado por 8 dimensiones (8 direcciones posibles) de las cuales cada una indica la proporción de drenado respecto a esa correspondiente dirección. La siguiente codificación muestra el número de banda que almacena la proporción de drenado correspondiente a cada dirección:

Esta aproximación es una modificación del modelo [2.1.3.1](#).

■ *Acumulación de flujo:*

Se calcula con el mismo procedimiento que en la aproximación 1, con la modificación de  $p$ , el cual es variable dependiendo de cuantas pendientes con valor igual a la máxima pendiente existen. Esto significa que el flujo no se orienta totalmente hacia una dirección, sino a todas las direcciones posibles en las que la diferencia de alturas es igual a la máxima diferencia de alturas entre los vecinos.

■ *Pendiente:*

Se determina la matriz de pendiente del DEM mediante el uso de una función del software ENVI, como se explicó en la aproximación 1.

■ *Índice topográfico de humedad:*

El índice topográfico de humedad se calcula del mismo modo que en la aproximación 1, mediante la fórmula [2.2](#).

**Aproximación 3:** El flujo se orienta hacia todas las direcciones posibles, de ocho permitidas Esta aproximación contiene las siguientes funciones en orden de ejecución:

5	6	7
4	(i,j)	0
3	2	1

**Tabla 2.4:** Codificación de dirección de flujo según aproximación 3

■ *Direcciones de flujo:*

Cada píxel se caracteriza por drenar hacia todos los píxeles vecinos que poseen altura menor que el píxel analizado, en una proporción determinada por la pendiente o diferencia de altura entre este y sus vecinos. Esta pendiente se calcula como la diferencia de altura de la celda central con las celdas vecinas ( $DEM_{in,jn}$ ) de menor altura dividido por la distancia medida en unidad de celda. Para celdas orientadas horizontal o verticalmente respecto a la central, la pendiente se define como:

$$Pendiente = \frac{DEM_{i,j} - DEM_{in,jn}}{1} \quad (2.8)$$

Para celdas orientadas diagonalmente respecto a la central, la pendiente se define como:

$$Pendiente = \frac{DEM_{i,j} - DEM_{in,jn}}{\sqrt{2}} \quad (2.9)$$

Según esta aproximación, cada píxel está representado por 8 dimensiones (8 direcciones) de las cuales cada una almacena la proporción de drenado respecto a esa correspondiente dirección. La siguiente codificación muestra el número de banda que almacena la proporción de drenado correspondiente a cada dirección:

Esta aproximación se basa en el modelo 2.1.3.2 definido anteriormente.

■ *Acumulación de flujo:*

Se calcula con el mismo procedimiento que en la aproximación 1 con diferencia en la determinación de  $p$ , el cual es variable dependiendo del número de vecinos de altura menor que el píxel central y sus correspondientes diferencias de alturas. Por lo tanto, el flujo no se orienta totalmente hacia una dirección, sino hacia todas las direcciones posibles en una proporción que es dependiente de la diferencia de altura entre ambos píxeles.

■ *Pendiente:*

Se determina la matriz de pendiente del DEM mediante el uso de una función del software ENVI, como se explicó en la aproximación 1.

■ *Índice topográfico de humedad:*

El índice topográfico de humedad se calcula del mismo modo que en la aproximación 1.

**Normalización de TWI:** Con el objetivo de generar un índice que pueda ser fácilmente comparable se realiza la normalización del mismo. La normalización del índice calculado

mediante las diferentes aproximaciones es llevada a cabo por la siguiente función:

$$TWIn_{i,j} = \frac{TWI_{i,j}}{\max(TWI)} \quad (2.10)$$

A cada píxel (i,j) de la matriz de índice topográfico obtenida por las anteriormente mencionadas metodologías, se lo divide por el  $\max(TWI)$ . Siendo  $\max(TWI)$  el valor máximo que presenta la matriz de TWI resultante de cada aproximación.

### 2.3.5. Evaluación de los algoritmos implementados

La evaluación se llevó a cabo: 1) en matrices que simulan modelos de elevación digital, y 2) en el ASTER GDEM real del área de estudio. Se generaron DEMs simulados (artificiales) que, al ser de configuración regular simétrica, permiten evaluar de manera más simplificada el comportamiento de los distintos algoritmos implementados. En consecuencia, los DEMs en los que se llevó a cabo la evaluación de los algoritmos implementados son los siguientes:

- DEM A: simulado mediante una función proporcional a  $-e^{-(x^2+y^2)}$ , de tamaño  $512 \times 512$ , que representa la topografía de un área de  $512 \text{ m} \times 512 \text{ m}$  con un tamaño de píxel (resolución espacial) de 1 m.
- DEM B: simulado mediante una función proporcional a  $-(x+y) - e^{-(x^2+y^2)}$ , de tamaño  $512 \times 512$ , que representa la topografía de un área de  $512 \text{ m} \times 512 \text{ m}$  con un tamaño de píxel (resolución espacial) de 1 m.
- DEM C: ASTER GDEM correspondiente al área de estudio, con una resolución espacial de 30 m.

**Preprocesamiento del ASTER GDEM:** Un problema característico en la creación de DEMs es la aparición de concavidades o pozos a lo largo de los fondos de valles. Este tipo de artefactos se genera por el uso de funciones de interpolación de grado superior en zonas conflictivas. La presencia de concavidades tiene importancia en el caso de simulación de procesos hidrológicos ya que interrumpen las líneas de flujo.

En un modelo de elevación digital pueden existir depresiones, es decir sitios donde el agua se estanca. Estas depresiones pueden ser de origen real, pues representan características del terreno, o pueden surgir del procesamiento del DEM. Dichas depresiones detienen artificialmente el flujo y alteran las direcciones de flujo. Un gran número de algoritmos han sido propuestos para llenar depresiones en el DEM y a modo de ejemplo se puede citar a [Planchon & Darboux \[2001\]](#). De estos algoritmos, el de [Jenson & Domingue \[1988\]](#) es bien conocido y ha sido implementado por casi todos los paquetes de software, tales como ArcInfo, TAUDem, y GRASS-GIS. Este método consiste en llenar las depresiones mediante el incremento del valor de las celdas en la depresión adjudicando a las mismas el mínimo de los valores de las celdas que forman el contorno de la depresión. El mismo asume que todas las depresiones son subestimaciones de la elevación originadas en el procesamiento del DEM. La obvia desventaja de este

método es que las depresiones rellenas crean grandes áreas lisas, donde se presenta nuevamente el problema de determinación de las direcciones de flujo.

Desde otro punto de vista, se puede asumir que existe una determinada probabilidad de error en toda la matriz del DEM y por lo tanto, aplicar un filtro de media que reduzca esta incertidumbre con la consecuente pérdida de resolución espacial. Esta aproximación fue empleada en el preprocesamiento del DEM en estudio.

Un filtro de media, o de promedio consiste en un filtro de clase lineal, que suaviza cada elemento de la matriz del DEM, tomando un promedio de sus vecinos. Por lo tanto, este filtro reduce la cantidad de variación entre un píxel y su entorno. La idea de este filtrado es reemplazar cada valor de píxel en una imagen, en este caso en el DEM, con el valor medio de sus vecinos, incluyendo a si mismo. Esto tiene el efecto de eliminar los valores de píxeles que no son representativos de su contexto.

Como parte del preprocesamiento del ASTER GDEM, fue empleado un filtro de media móvil con un tamaño de kernel de  $39 \times 39$ . El resultado de esto fue la reducción de valores inciertos de altura, a costa de la disminución de la resolución espacial (de 30 m a 1 km de resolución).

### 2.4. Resultados

A continuación se presentan los resultados de aplicar los algoritmos topográficos implementados a los diferentes DEMs de evaluación.

**DEM A:** El DEM A, simulado mediante una función Gaussiana inversa bidimensional, se muestra en la subfigura 2.7(a) y representa la topografía de un área de  $512 \text{ m} \times 512 \text{ m}$  con un tamaño de píxel (resolución espacial) de 1 m. La altura del mismo tiene un rango que va desde 0 km a 1 km. La matriz de pendiente (en grados) derivada de este DEM se presenta en la subfigura 2.7(a). Se observa que la pendiente disminuye hacia el centro y hacia las esquinas del mismo.

En la figura 2.8 se presentan los resultados de aplicar cada uno de los diferentes algoritmos al DEM A. Las subfiguras 2.8(a), 2.8(b) y 2.8(c) corresponden a información sobre las direcciones de flujo definidas por los algoritmos de aproximación 1, 2 y 3 respectivamente. La subfigura 2.8(a) muestra la dirección de flujo única de cada píxel según la codificación 2.2. La interpretación del esquema de las direcciones de flujo de las aproximaciones 2 y 3 es diferente a la interpretación de la primera aproximación, debido a que en estas el agua puede fluir hacia más de una dirección y cada dirección está representada por una de ocho bandas posibles. Por lo tanto, las subfiguras 2.8(b) y 2.8(c) representan la proporción de cada píxel que drena o fluye hacia la posición 0 (solo se muestra la banda cero de un conjunto de 8 bandas) según la codificación 2.3 y 2.4 respectivamente.

Las subfiguras 2.8(d), 2.8(e), y 2.8(f) exponen el índice topográfico de humedad (TWI) generado a partir de las aproximaciones 1, 2 y 3 respectivamente. El índice tiene un rango




que va de 0 a 1 y, como se mencionó en la sección 2.1.5, representa la capacidad espacialmente distribuida de acumulación de humedad o agua. Los tres resultados muestran el patrón simétrico esperado con la máxima humedad o acumulación en el pozo del DEM (2.7). En las dos primeras aproximaciones, en las cuales la dirección de flujo está limitada a la de mayor pendiente, se observa un fenómeno de líneas rojas de altos valores del índice (o probable acumulación) en las intersecciones donde las direcciones de flujo confluyen (2.8(a) y 2.8(b)). Mientras que con la tercer aproximación, este fenómeno no se presenta.

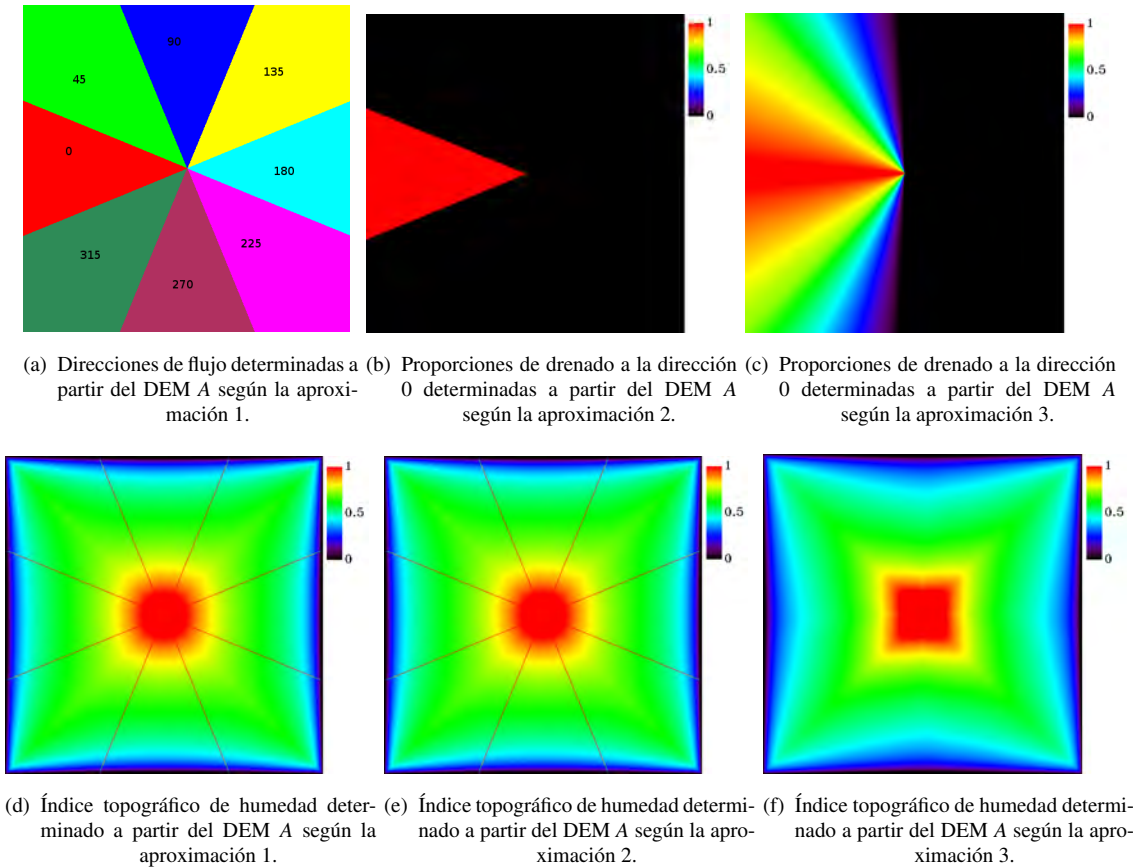
En la figura 2.9 se muestra la vista tridimensional de los índices topográficos generados a partir del DEM A, correspondientes a dos diferentes aproximaciones.

**DEM B:** El DEM B, simulado mediante una función Gaussiana inversa bidimensional a la que se le adiciona una función con forma de rampa o gradiente lineal, se muestra en la figura 2.10(a) y representa la topografía de un área de 512 m×512 m con un tamaño de píxel (resolución espacial) de 1 m. La altura del mismo tiene un rango que va desde 0 km a 1 km. La matriz de pendiente (en grados) derivada de este DEM se presenta en la subfigura 2.10(b). En este terreno, a diferencia del DEM A, el pozo (o zona de menor altura) se encuentra trasladado hacia el lado inferior de la rampa adicionada. La pendiente en consecuencia disminuye hacia el centro del DEM y hacia el extremo inferior de la rampa.


En la figura 2.11 se presentan los resultados de la aplicación de los diferentes algoritmos al DEM B. Las subfiguras 2.11(a), 2.11(b) y 2.11(c) corresponden a las direcciones de flujo definidas según las aproximaciones 1, 2 y 3 respectivamente. La subfigura 2.11(a) muestra la dirección de flujo única de cada píxel según la codificación 2.2. Las subfiguras 2.11(b) y 2.11(c) representan la proporción de cada píxel que drena o fluye hacia la posición 0




**Figura 2.7:** DEM A y su correspondiente matriz de pendiente. El DEM A fue simulado mediante una función proporcional a  $-e^{-(x^2+y^2)}$ , que representa la topografía de un área de 512×512 m con una resolución espacial de 1 m. La altura del mismo tiene un rango que va desde 0 a 1 km. La matriz de pendiente se presenta en grados y el rango de la misma va de 0 a 45.2 °.



**Figura 2.8:** Resultados de la aplicación de los diferentes algoritmos implementados al simulado DEM A. Se presentan las matrices de direcciones de flujo determinadas de acuerdo a cada aproximación. En el caso de la aproximación 1, cada píxel de la matriz indica la única dirección de flujo que le corresponde, codificada como grados de 0 a 315 crecientes en orientación horaria (ver 2.2). Para la aproximación 2 y 3, cada píxel representa las proporción de drenado hacia una determinada dirección (en este caso, dirección 0). La proporción hacia cada dirección en la aproximación 2 y 3 es almacenada en una de 8 posibles bandas. Se presentan además los índices topográficos derivados de cada aproximación. Se observa en los índices de aproximación 1 y 2 un patrón de líneas rojas de altos valores del índice en las intersecciones de las direcciones de flujo, el cual está ausente en el índice de aproximación 3.




(a) Índice topográfico de humedad generado mediante la aproximación 1.



(b) Índice topográfico de humedad generado mediante la aproximación 3.

**Figura 2.9:** Vista tridimensional de los índices topográficos generados a partir del DEM A. En estas figuras se puede apreciar, de manera más evidente, la distribución de probabilidad de acumulación de agua en el terreno.



(a) Vista tridimensional del DEM B.

(b) Pendiente en grados derivada del DEM B.

**Figura 2.10:** DEM B, simulado mediante una función proporcional a  $-(x + y) - e^{-(x^2+y^2)}$ , que representa la topografía de un área de  $512 \times 512$  m con una resolución espacial de 1 m. La altura del mismo tiene un rango que va desde 0 a 1 km.

(solo se muestra la banda cero de una matriz de 8 bandas) según la codificación 2.3 y 2.4 respectivamente. Debido a la configuración del DEM, se origina un patrón de distribución de las proporciones de flujo máximas (por ejemplo hacia la dirección 0) en forma de media luna, el cual se visualiza bajo las tres aproximaciones.

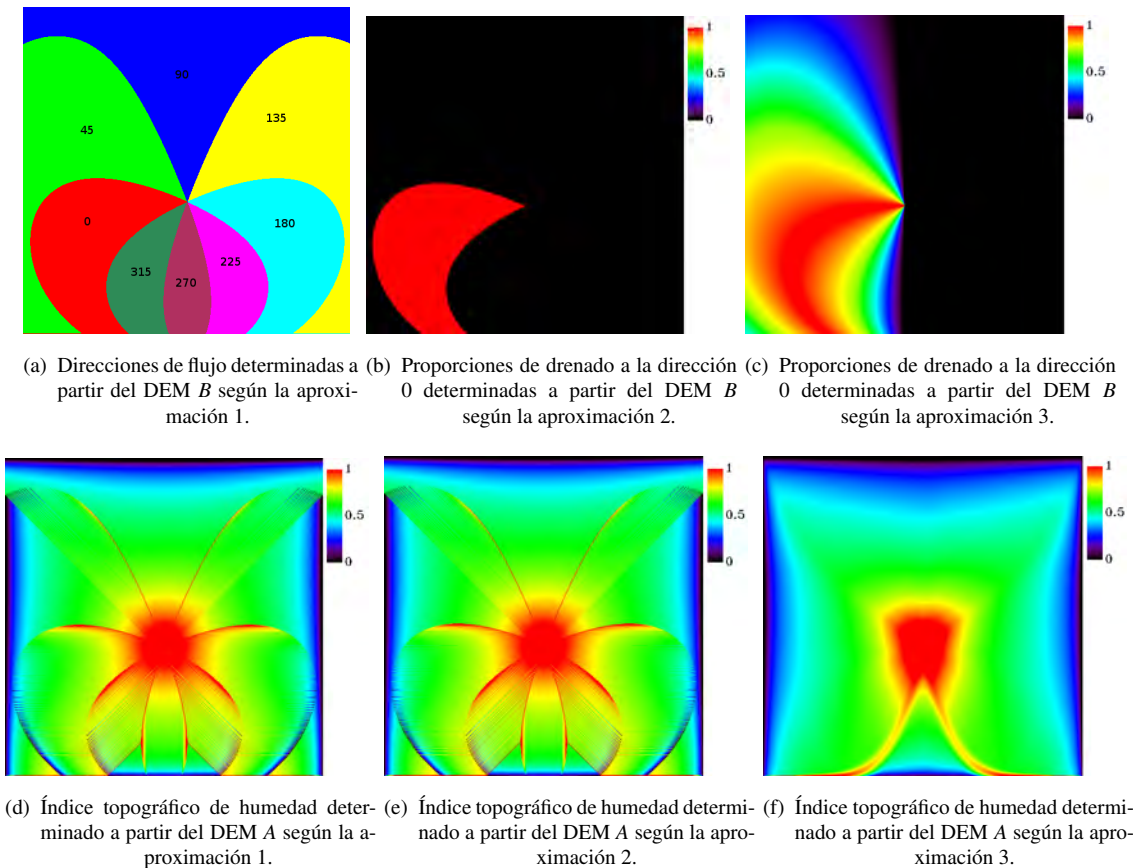
Las subfiguras 2.11(d), 2.11(e) y 2.11(f) exponen el índice topográfico de humedad (TWI) generado a partir de las aproximaciones 1, 2 y 3 respectivamente. Los tres resultados muestran la simetría lateral esperada con la máxima humedad o acumulación en el pozo del DEM (Fig. 2.10). En las dos primeras aproximaciones, en las cuales la dirección de flujo está limitada a la de mayor pendiente, se observa el mismo fenómeno que con el DEM A, de mayores valores en las intersecciones donde las direcciones de flujo confluyen (Figs. 2.11(a) y 2.11(b)). Además se visualiza otro patrón de líneas continuas de menor acumulación de humedad (TWI menor) que su contexto; el cual está ocasionado, dadas las características de las direcciones de flujo, por un déficit de drenaje por parte de sus píxeles vecinos. En la tercer aproximación, ninguno de los dos fenómenos mencionados se presenta. En esta última matriz, los máximos valores de TWI se encuentran en el hoyo del DEM y también en la zona de las diagonales de las esquinas inferiores con respecto al pozo. En esta última, confluye el agua que vendría de ambos lados superiores de las diagonales hacia el pozo.

En la figura 2.12 se muestra la vista tridimensional de los índices topográficos generados a partir del DEM B, correspondientes a dos diferentes aproximaciones.


**DEM C:** El DEM C es el DEM real del área de trabajo. Luego de realizar un minucioso análisis en distintos DEMs (correspondientes a distintas áreas y con distintas resoluciones) con el objeto de comprender el significado del índice TWI, se reconoció su particular sensibilidad a la escala de análisis. Para remarcar el patrón global de probabilidad de acumulación de humedad o agua, y no considerar la gran cantidad de mínimas depresiones determinadas por la alta resolución del ASTER GDEM, se decidió realizar el preprocesamiento detallado anteriormente que consiste en aplicar un filtro de media móvil al mismo.

En la figura 2.13 se aprecian los perfiles horizontales del ASTER GDEM correspondiente al área de estudio, sin filtrar y luego de aplicar el filtro de media móvil. En el DEM original se observan varias zonas planas y un relieve en general con cortes abruptos y picos. Si bien con el filtrado se pierden detalles, se conserva el patrón general del perfil y las primordiales depresiones para determinar el flujo principal de agua.


En la subfigura 2.14(a) se exhibe la vista tridimensional del ASTER GDEM sin filtrar, correspondiente a una sección del área de estudio. En la subfigura 2.14(b) se presenta la matriz de pendiente respectiva. La subfigura 2.14(c) representa la proporción de cada píxel que drena o fluye hacia la posición 0 (banda cero de una matriz de 8 bandas) según la codificación 2.4. Por último, en la subfigura 2.14(d) se expone el TWI resultante de acuerdo a la aproximación 3. Las zonas con valores del índice cercanos a 1 son las de mayor



**Figura 2.11:** Resultados de la aplicación de los diferentes algoritmos implementados al DEM *B*. Se presentan las matrices de direcciones de flujo determinadas de acuerdo a cada aproximación. En el caso de la aproximación 1, cada píxel de la matriz indica la única dirección de flujo que le corresponde, codificada como grados de 0 a 315 crecientes en orientación horaria (ver 2.2). Para la aproximación 2 y 3, cada píxel representa las proporción de drenado hacia una determinada dirección (en este caso, dirección 0). La proporción hacia cada dirección en la aproximación 2 y 3 es almacenada en una de 8 posibles bandas. Se presentan además los índices topográficos derivados de cada aproximación. Se observa en los índices de aproximación 1 y 2 un patrón de líneas de altos y bajos valores del índice el cual es consecuencia directa de estos modelos de direcciones de flujo. Dicho patrón está ausente en el índice de aproximación 3.




(a) Índice topográfico de humedad generado mediante la aproximación 1.




(b) Índice topográfico de humedad generado mediante la aproximación 3.

**Figura 2.12:** Vista tridimensional de los índices topográficos generados a partir del DEM *B*. En estas figuras se puede apreciar, de manera más evidente, la distribución de probabilidad de acumulación de agua en el terreno y el patrón de líneas mencionado anteriormente.

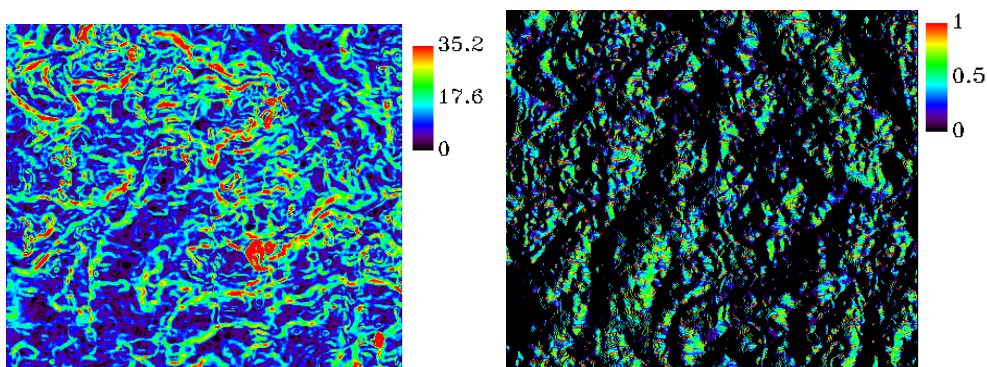


**Figura 2.13:** Perfiles horizontales del ASTER GDEM con distinto tipo de procesamiento, correspondiente al área de estudio. Este DEM es una matriz que posee 379 columnas y el rango de valores de altura va de 170 a 250 m. El perfil del DEM sin filtrar se visualiza en rojo y el perfil del DEM luego de aplicar un filtro de media móvil de tamaño de kernel  $39 \times 39$  se visualiza en verde. Se aprecia el suavizado del perfil que se logra al aplicar el filtro de media


acumulación de humedad y las mismas se corresponden con las depresiones observadas en el DEM respectivo.



(a) Vista tridimensional del DEM *C* sin filtrar.



(b) Pendiente en grados derivada del DEM *C* sin filtrar. (c) Proporción de drenaje de agua a la dirección '0' estimada según el algoritmo de determinación de direcciones de flujo de la aproximación 3.



(d) Índice topográfico de humedad, obtenido a partir del DEM *C* sin filtrar, según la aproximación 3.

**Figura 2.14:** Resultados de la aplicación de los algoritmos al DEM *C* sin filtrar, correspondiente al ASTER GDEM del área de trabajo (no simulado). Se muestra la vista tridimensional del DEM, cuyo rango de alturas va de 171 a 277 m. Se exponen las matrices de pendiente en grados con un rango de 0 a 35.2°, de dirección de flujo y de índice topográfico derivadas del ASTER GDEM sin filtrado. En el mapa de índice de humedad se observa gran cantidad de sitios con probabilidad de acumular agua que se encuentran ampliamente dispersos en el terreno.

En la subfigura 2.15(a) se exhibe la vista tridimensional del ASTER GDEM, luego de

aplicar el filtro de media móvil de tamaño de kernel 39, correspondiente a una sección del área de estudio. En la subfigura 2.15(b) se presenta la matriz de pendiente respectiva. La subfigura 2.15(c) representa la proporción de cada píxel que drena o fluye hacia la posición 0 (banda cero de una matriz de 8 bandas) según la codificación 2.4. Por último, en la subfigura 2.15(d) se expone el TWI resultante de acuerdo a la aproximación 3. Las zonas con valores del índice cercanos a 1 son las de mayor acumulación de humedad y las mismas se corresponden con las depresiones observadas en el DEM respectivo.

En la figura 2.16 se visualizan los índices topográficos de humedad, obtenidos mediante el DEM sin filtrar y el DEM filtrado, superpuestos a una superficie tridimensional del DEM correspondiente.


### 2.5. Discusión y conclusiones

Este capítulo estuvo dedicado a la implementación y al análisis de distintas metodologías de cálculo del índice topográfico de humedad (TWI). Se seleccionó una de estas como la que se supone que reproduce los patrones hidrológicos reales del terreno de manera más acertada. Se intentó que este índice capture las características hidrológicas espaciales básicas de un modo más eficiente, en términos de complejidad y número de variables determinantes consideradas, que empleando modelos dinámicos de simulación hidrológica. El índice topográfico se basa en el cálculo de acumulación de flujos y permite determinar la cantidad de agua que puede fluir hacia una celda determinada, asumiendo que llueve en toda la cuenca, que toda la lluvia se convierte en escurrimiento superficial y que no existe infiltración, evapotranspiración u otras pérdidas de agua. Por lo tanto, si bien este índice representa una simplificación de los fenómenos y factores hidrológicos, resulta apropiado como caracterización del terreno en términos de la localización de los principales cauces y zonas de probable acumulación de agua.


En este sentido, se comprobó la funcionalidad de un modelo de elevación digital (DEM) en la interpretación cualitativa del terreno en relación a la capacidad de recepción de flujo de agua y acumulación de humedad; permitiendo la estimación de la probabilidad relativa de acumulación de agua en una determinada unidad espacial.

Se pudo observar que las hipótesis asumidas en la formulación de los modelos de comportamiento de flujo del agua son determinantes en el patrón de acumulación de humedad resultante; por consiguiente, estos modelos son decisivos en el índice topográfico de humedad que originan. Es importante considerar que las direcciones de flujo de agua deben ser determinadas tratando de disminuir la generación de patrones artificiales típicamente ocasionada por la configuración en grilla, lo cual está condicionado por la discretización dada por el formato de matriz. Las aproximaciones que consideran una dirección de flujo única para cada píxel generaron patrones irreales en el producto de acumulación final. Se decidió seleccionar como metodología más adecuada, la aproximación que considera el flujo de agua como multidireccional. El aspecto del índice de esta última aproximación es el que se corresponde en mayor






(a) Vista tridimensional del DEM C filtrado.



(b) Pendiente en grados derivada del DEM C filtrado. (c) Proporción de drenaje de agua a la dirección '0' estimada según el algoritmo de determinación de direcciones de flujo de la aproximación 3.



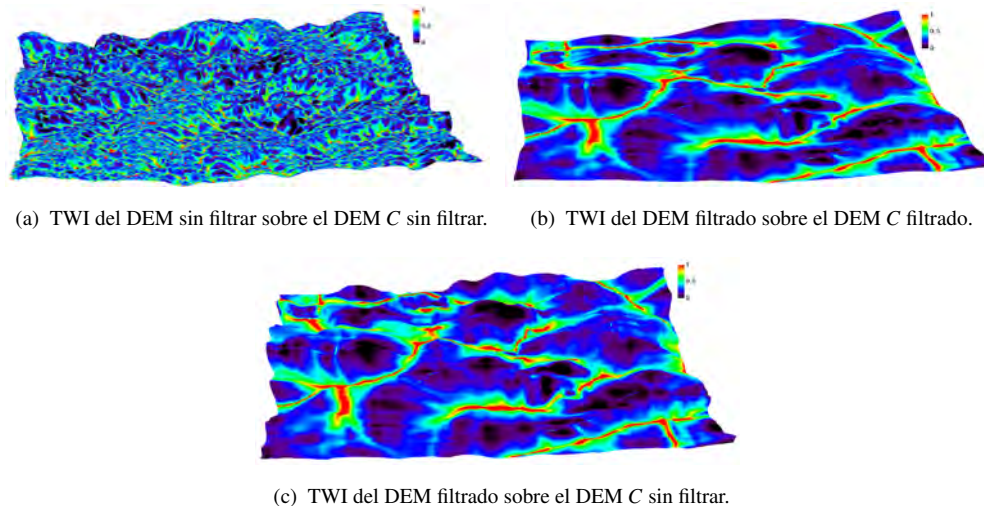
(d) Índice topográfico de humedad, obtenido a partir del DEM C filtrado, según la aproximación 3.

**Figura 2.15:** Resultados de la aplicación de los algoritmos al DEM C filtrado, correspondiente al ASTER GDEM del área de trabajo (no simulado). Se muestra la vista tridimensional del DEM, cuyo rango de alturas va de 171 a 277 m. Se exponen las matrices de pendiente en grados con un rango de 0 a 35.2°, de dirección de flujo y de índice topográfico derivadas del ASTER GDEM sin filtrado. En el mapa de índice de humedad se observa menor cantidad de sitios más extensos con probabilidad de acumular agua, respecto al mapa derivado del DEM sin filtrar.

medida con el comportamiento del flujo de agua que se espera de acuerdo a la configuración de los DEMs simulados. Del mismo modo, se pudo comprobar que el índice topográfico de dicha aproximación se correspondió con la configuración espacial del ASTER GDEM (no simulado).

Existen evidencias de que los modelos de determinación de direcciones de flujo difieren enormemente en su desempeño y la elección de uno de ellos podría tener un efecto significativo en los resultados de estudios ecológicos [Kopecky & Cizkova, 2010]. Kopecky & Cizkova [2010] argumentan que los modelos de múltiples direcciones de flujo, tales como el de Quinn et al. [1991], son los más poderosos y deberían ser preferidos en estudios ecológicos. La aproximación de flujo multidireccional seleccionada en este trabajo es equivalente al modelo de Quinn et al. [1991]. Si bien este tipo de algoritmos ha resuelto las limitaciones de los modelos de direcciones únicas de flujo, tiene las desventajas de producir excesiva dispersión del flujo de agua [Tarboton, 1997]. De acuerdo al objetivo de este trabajo, no resulta importante la dispersión que pueda generar ya que es preferible generar una sobreestimación de las áreas en las que es probable la acumulación de humedad o agua, antes que la subestimación de las mismas.

A modo de ejemplo de utilidades, el TWI ha sido empleado tanto para identificar las rutas de flujo hidrológico en modelado geoquímico [Robson et al., 1992], como para caracterizar los procesos biológicos (por ejemplo producción primaria neta, o patrones de vegetación [Zinko et al., 2005]). Las áreas con los valores más altos de TWI se saturarían de agua con mayor probabilidad que el resto, durante una lluvia. Esto define que el TWI podría, entre otras funcionalidades, proveer una descripción acerca de cómo la topografía afecta el riesgo de enfermedades transmitidas por vectores, tales como los mosquitos, a través de la facilitación de sitios de agua que



**Figura 2.16:** Índices topográficos de humedad superpuestos a una superficie tridimensional de DEM. En el TWI del DEM sin filtrar se observa que dadas las irregularidades del DEM empleado, el número de sitios con extensión reducida y de alta probabilidad de acumulación de agua es mucho mayor que en el correspondiente al DEM filtrado. Se observa que el TWI del DEM filtrado es coincidente con zonas del DEM que evidentemente acumularían agua, tanto si se analiza respecto al DEM filtrado como sin filtrar.

representan potenciales criaderos de los mismos. Por lo tanto, este índice representaría una herramienta adecuada en la identificación de áreas con alto riesgo de transmisión de enfermedades que son propagadas por vectores naturales.

De acuerdo al análisis realizado, se concluye que el significado del TWI varía en relación a la escala de análisis del mismo, la cual está determinada principalmente por la resolución espacial del DEM empleado. A una escala local, con alta resolución del modelo de elevación digital, se puede hablar del TWI como un indicador de la probabilidad de humedad, mientras que a una escala regional el índice demarcaría la probabilidad de acumulación de agua. En definitiva, la resolución de DEM requerida se debe evaluar en función de la escala conceptual de trabajo o del objetivo del análisis del índice topográfico. En el caso de que se pretenda analizar el comportamiento del flujo de agua a escala regional y acumulaciones de grandes volúmenes de agua, es quizás necesario el filtrado del DEM para lograr el suavizado necesario. De este modo, se evita la localización de depresiones pequeñas con significado local y se posibilita analizar el patrón global de flujo de agua en el DEM.

En este estudio fue posible utilizar un DEM de alta resolución espacial, el ASTER GDEM de 30 m de resolución, para obtener un índice topográfico de humedad con resultados cualitativamente aceptables. Considerando lo mencionado anteriormente y el objetivo de la localización de zonas de probable acumulación de agua, fue necesario aplicar un filtro de media al DEM para permitir un análisis a escala regional. Aquí surgen potenciales trabajos futuros en relación a evaluar distintos procedimientos para reducir las depresiones ‘artificiales’ del DEM. Las mismas pueden ser basadas en algoritmos de interpolación tales como curvas adaptativas (*splines*), Kriging, entre otros posibles.

Debido a que el TWI posee un significado ambiguo y relativo al área de análisis, la comparación cuantitativa del mismo con otras áreas debería ser razonada convenientemente. Del mismo modo, su validación puede ser aproximada a través de la correlación con variables hidrológicas que se suponen relacionadas.

Como propuesta a futuro, la pendiente definida en este trabajo podría estar sujeta a modificaciones dado que existen propuestas para el cálculo de pendiente que no solo consideran la celda de interés y sus vecinos (pendiente local) sino que la definen como la pendiente al punto más cercano que está a una determinada distancia abajo de la celda de interés [Hjerdt et al., 2004]. Se espera que esta pendiente origine resultados más ajustados a la realidad.

Por otro lado, sería adecuado comparar los resultados de la aproximación de múltiples direcciones de flujo seleccionada, con los resultados de modelos más complejos de cálculo de dirección de flujo que existen, tales como [Tarboton, 1997]. Según el modelo propuesto por este autor, se determina una dirección de flujo única, que está representada como una cantidad continua de 0 a  $2\pi$ , de mayor pendiente de acuerdo a facetas triangulares. El procedimiento planteado por Tarboton [1997] está basado en la representación de la dirección de flujo como un ángulo único tomado hacia la máxima pendiente decreciente en las ocho facetas triangulares centradas en cada punto de la grilla. El área de acumulación es luego calculada proporcionalmente al flujo entre dos píxeles, de acuerdo a la cercanía de la dirección de flujo con respecto al

ángulo que apunta directo hacia el píxel analizado. Este procedimiento es aparentemente más robusto y ofrecería mejoras respecto a procedimientos que restringen las direcciones de flujo a ocho posibles (que introducen error de grillado), o proporcionan el flujo de acuerdo a la pendiente (que introduce dispersión irreal). Resultaría de utilidad, en consecuencia, explorar la variedad de métodos existentes de cálculo de este índice topográfico, analizando la exactitud de los mismos en relación a variables hidrológicas medidas en el terreno.

A modo de cierre de este capítulo, propongo las siguientes potenciales aplicaciones de este índice topográfico (TWI):

- Identificación de áreas de muestreo de variables de interés relacionadas a la acumulación de agua en el terreno, tales como la presencia y cantidad de huevos o larvas de mosquitos transmisores de enfermedades, tipo y composición de vegetación, o calidad del agua.
- Comprensión de los mecanismos que intervienen en los patrones de distribución de la vegetación mediante el modelado de la relación entre la distribución espacial de especies plantas y las condiciones ambientales topográficas.
- Comprensión de los mecanismos y procesos que originan los patrones de distribución de contaminantes transportados por el agua.
- Predicción de la adecuación o capacidad de uso de suelos respecto a distintas actividades.
- Estimación de atributos del suelo.
- Comprensión de la relación entre incidencia de malaria con la predicción de acumulación de agua. Determinación de áreas con alto riesgo de malaria.
- Estimación de la relación de probabilidad de acumulación de agua con variables tales como la riqueza de plantas vasculares, el *pH* del suelo, el nivel de agua subsuperficial, la humedad de suelo, entre otras.

## Capítulo 3

# Índice fito-topográfico de humedad

### 3.1. Marco teórico

El flujo de agua a través de un ecosistema constituye uno de los aspectos fundamentales de su funcionamiento. Este flujo se esquematiza en la figura 3.1, la cual está basada en el trabajo de recopilación de Oki & Kanae [2006], y resume el recorrido y almacenamiento hidrológico global con ciclos naturales y antropogénicos interactuando entre sí. La principal entrada de agua al sistema es la precipitación. Considerando la existencia de una cobertura vegetal sobre el suelo, el agua de lluvia es primero interceptada por el dosel. El agua podrá también impactar directamente en el suelo o en cuerpos de agua. El agua interceptada puede ser evaporada. Del agua que alcanza la superficie del suelo, parte es infiltrada (ingresa en el perfil del suelo) y parte puede drenar superficialmente. El agua infiltrada se redistribuirá a lo largo del perfil de suelo. Simultáneamente a la entrada de agua en el suelo, ésta puede estar siendo evaporada desde la superficie o retirada del suelo por las raíces y transpiradas por las hojas del dosel. El agua puede descender a través del perfil de suelo y llegar a la capa freática o, en algunas ocasiones, puede haber flujo ascendente de agua en el suelo. En terrenos con pendiente, puede haber también flujo lateral subsuperficial. La mayor parte del agua de lluvia cae sobre el suelo, directamente o bien indirectamente a través de drenaje por las hojas y tallos de la vegetación. Una pequeña porción de ésta, permanece en las hojas (intercepción) y eventualmente se evapora. El agua que alcanza la superficie del suelo, es almacenada (infiltración) en el perfil de suelo o es drenada pendiente abajo como escorrentía superficial o puede percolar hacia un cuerpo de agua subterráneo.

La variación de humedad dentro de un perfil de suelo puede ser contabilizada a través de un balance de masa, donde son computadas las entradas y salidas de agua del sistema. De modo bastante simplificado, el balance de agua en el suelo, y por lo tanto el agua que se deposita en el terreno, puede ser modelado como:

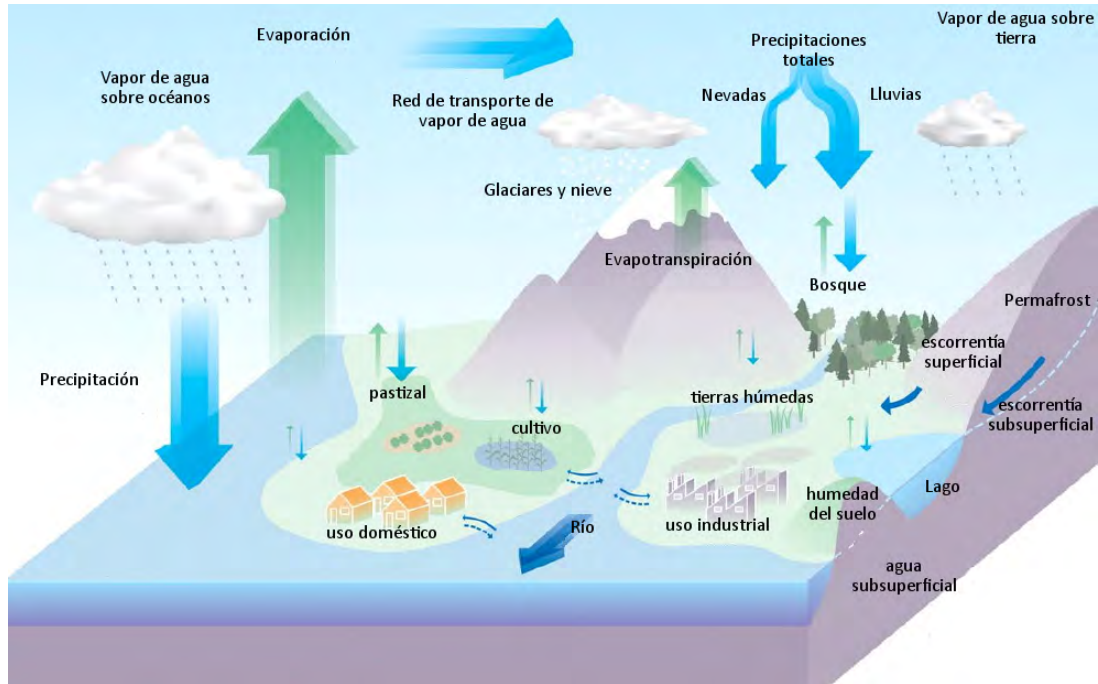
$$\phi\theta = P - E_{int} - E_s - E_p - Q_{salida} + Q_{entrada} \quad (3.1)$$

donde  $P$  es la precipitación (lluvia, nieve o neblina),  $E_{int}$  es el agua interceptada por el dosel que


### 3. Índice fito-topográfico de humedad

posteriormente se evapora,  $E_s$  es la evaporación del suelo,  $E_p$  es la transpiración por las plantas,  $Q_{salida}$  es el drenaje de agua por fuera del sistema,  $Q_{entrada}$  es el drenaje de agua dentro del sistema (flujo ascendente, drenaje superficial y subsuperficial) y  $\phi\theta$  es la variación de la reserva de agua en el suelo (Fig. 3.2).

El comportamiento hidrológico de una cuenca es controlado por factores tanto bióticos como abióticos que interactúan entre sí, tales como las características físicas y químicas de la



**Figura 3.1:** Diagrama de los principales componentes (factores y procesos) del ciclo hidrológico. Adaptado de Oki & Kanae [2006]. Se observa cuales son los procesos que permiten la entrada y salida de agua al sistema.



**Figura 3.2:** Representación esquemática de los principales procesos del ciclo hidrológico. Este diagrama consiste en una profundización de la figura 3.1.

superficie y subsuperficie, tipo y densidad de vegetación, y las características topográficas locales [Beguiría et al., 2006]. Los cambios en alguno de estos factores, probablemente afecten a los mecanismos de generación de flujo. Por ejemplo, la generación de escorrentía en pendientes montañosas se encuentra relacionada con el tipo de uso de la tierra [Harden, 1993]. La vegetación protege el suelo contra el impacto de las gotas de lluvia y disminuye su capacidad erosiva, aumenta la agregación del suelo mediante la incorporación de materia orgánica, reduce la velocidad de flujo superficial y aumenta la infiltración [Casermeiro et al., 2004].

Las características de infiltración del suelo están influenciadas por muchos factores, entre los cuales los más importantes son:

- El tipo y densidad de cobertura de vegetación [Chirino et al., 2006] y el sistema de raíces [Gyssels et al., 2005].
- La estructura del suelo [Ozta et al., 2003]: la textura, densidad, los minerales, las diferentes capas, la profundidad.
- La magnitud de la actividad biológica y la resultante macroporosidad [Dunne et al., 1991].
- Rugosidad del suelo [Poesen et al., 1990].
- Pendiente [Poesen, 1984].
- Porosidad y proporción de espacios estructurales [Mwendera & Feyen, 1994].

Según González & Jimeno [2007] la vegetación tiene un papel importante en el control de la erosión y la estabilización de laderas por la influencia que ejerce sobre el suelo, tanto en superficie, protegiéndolo y sujetándolo, como en profundidad, al incrementar la resistencia y la cohesión de los terrenos.

Los efectos de la vegetación sobre el suelo pueden ser divididos en dos grandes categorías: bioprotección y bioconstrucción [Naylor et al., 2002]. La vegetación protege contra la erosión del suelo mediante reducción de la erosión del agua e incrementa la tasa de infiltración en el suelo [Wainwright et al., 2002]. Las plantas fijan el suelo con sus raíces o reducen la energía de las gotas de lluvia con su canopia y actúan como una barrera física, alterando el flujo de sedimentos en la superficie. El modo en que la vegetación es distribuida a lo largo de las pendientes es un importante factor para la disminución del sedimento de escorrentía [Calvo-Cases et al., 2003]. Este efecto barrera puede conducir a la formación de estructuras llamadas ‘aglomeraciones fitogénicas’, las cuales son encontradas perpendicularmente a la pendiente y antes de la barrera de vegetación sobre la pendiente o bajo las plantas. Varios mecanismos están involucrados en la formación de montones:

- La deposición de partículas de suelo bajo la canopia de plantas (capa superior de sus hojas) luego de la disminución de viento.
- Las tasas de erosión diferenciales en el ambiente próximo a las plantas.
- La deposición de sedimento resultando en una disminución del flujo de agua.

Como se resume en la figura 3.3, la vegetación interfiere en la transferencia del agua desde la atmósfera al suelo, y modifica los sistemas de escorrentía superficial y drenaje profundo.





Respecto al tipo de vegetación, las cubiertas herbáceas continuas tienen una capacidad de intercepción máxima superior a las formaciones leñosas. Dentro de la vegetación leñosa, las masas arbóreas de hoja perenne interceptan un volumen de precipitación mayor que las planifolias de hoja caduca. Por lo tanto, diferentes coberturas vegetales (es decir diferente tipo y densidad de vegetación) producirán efectos diversos en el balance hidrológico de una superficie determinada.

- **Evapotranspiración:** La evapotranspiración (ETP) representa la evaporación de la lluvia interceptada por la vegetación y a la transpiración de las plantas, y uno de sus principales efectos sobre el suelo es que disminuye su contenido en humedad respecto a su máximo potencial. Esto determina que, en condiciones similares, el contenido de agua de los suelos desnudos es mayor que el de los suelos vegetados; y la frecuencia de saturación y encharcamiento en suelos desnudos, es mayor que en suelos vegetados.

El proceso de ETP tiene influencia en el régimen hidrológico superficial, debido a que disminuye el volumen total de escorrentía y retrasa su momento de generación.

- **Infiltración:**

Debido a una serie de efectos que interactúan entre sí (intercepción, transpiración de las plantas, etc.), la permeabilidad y la tasa de infiltración del suelo es mayor en los suelos provistos de vegetación que en los suelos desnudos. Esto determina que, bajo las mismas condiciones edáficas, de precipitación y de pendiente, los volúmenes de escorrentía generados durante una lluvia son menores en suelos con vegetación que en suelos desnudos, y que el momento de su generación se retrase. Es decir, para que se genere el mismo volumen de escorrentía en un suelo provisto de vegetación se requiere mayor volumen total y mayor intensidad de precipitación.

Sin embargo, el efecto que tiene la vegetación sobre la capacidad de infiltración del suelo es muy variable y depende de ciertas características de este (textura, estructura, etc.), de la topografía del terreno y de determinadas cualidades de la vegetación, como grado de cubierta, tipo morfológico, etc.

- **Escorrentía superficial:**

La vegetación actúa sobre el volumen y la velocidad de escorrentía, disminuyendo sus valores y, con ello, reduciendo el poder erosivo de la misma. La disminución del volumen de escorrentía es consecuencia de la combinación de varios factores: la intercepción y evaporación del agua de lluvia; la transpiración de las plantas; la gran capacidad de absorción de las cubiertas húmicas y de los restos vegetales (que retrasa el punto de encharcamiento); la formación del suelo por la vegetación; y la mayor rugosidad de las superficies vegetadas que disminuye la velocidad de circulación de la escorrentía favoreciendo su infiltración.

**Modificación de las propiedades mecánicas.** Se pueden mencionar los siguientes efectos mecáni-

COS:

- **Refuerzo del suelo por las raíces:**

El conjunto de las raíces y el suelo constituye una estructura mixta formada por una trama semicontinua de fibras (las raíces) ligada a una matriz (el suelo). En esta estructura mixta, las raíces actúan como un elemento equilibrador de fuerzas, transfiriendo una parte de la carga desde las zonas de mayores esfuerzos hacia otras en las que existen menos tensiones, de forma que el esfuerzo cortante al que está sometido el suelo queda repartido y se incrementa el nivel máximo de tensión admisible. Por otro lado, las raíces proporcionan al suelo una mayor resistencia al corte por el mayor grado de cohesión íntima que tiene la estructura raíces-suelo y la adhesión de las partículas de suelo a las raíces.

- **Anclaje, contención y arqueamiento:**

Las raíces mejoran la estabilidad de las laderas al sujetar de forma mecánica la masa superficial de suelo, evitando su desplazamiento ladera abajo. Penetran en profundidad y se insertan en las grietas y aberturas del macizo rocoso subyacente, permitiendo el anclaje entre las capas superficiales y las profundas.

## 3.2. Objetivos abordados en el capítulo

El objetivo planteado en este capítulo es desarrollar un índice fito-topográfico de humedad (índice de acumulación potencial de agua) que considere el efecto de la cobertura de vegetación en el patrón de acumulación de agua estimado. El propósito de este nuevo índice es llevar a cabo un modelado hidrológico que reproduzca de manera más completa el comportamiento hidrológico del complejo sistema real

#### 3.2.1. Aportes del capítulo

Este capítulo aporta en la comprensión del modo en que distintas variables espaciales ejercen efecto en las características hidrológicas del terreno. Específicamente, se evalúa la incorporación de la vegetación a la determinación topográfica de acumulación de agua.

Los índices de humedad clásicos basados en topografía presentan las siguientes características:

- No consideran el efecto de la vegetación en la organización espacial de la humedad de suelo.
- Son estáticos.
- No permiten capturar la variabilidad temporal de humedad de suelo.

En este estudio se sugiere superar estas limitaciones mediante la generación de un nuevo índice *fito-topográfico* de humedad. Este se basa en la hipótesis de que las variables geomorfométricas básicas, derivadas del DEM, tienen una mayor capacidad predictiva si se complementan con factores formadores del suelo, como el clima y la vegetación, que pueden ser derivados de información proveniente de sensores remotos.

Debido a que se llevó a cabo la implementación de la metodología de cálculo de TWI, explicada en el capítulo anterior, es posible incorporar las modificaciones pertinentes al nuevo índice generado en este capítulo. En este capítulo se propone e implementa en el lenguaje IDL un original índice fito-topográfico de humedad que considera tanto la topografía como la vegetación en el patrón de acumulación de agua.

### 3.3. Materiales y métodos

#### 3.3.1. Área de estudio

El área de estudio correspondiente a este capítulo, se detalla en la sección [2.3.1](#).

#### 3.3.2. Recolección y preprocesamiento de datos

##### 3.3.2.1. Datos de elevación digital

Los datos de elevación digital empleados en este capítulo, correspondientes al ASTER GDEM, son los detallados en la sección [2.3.3.1](#).

**Datos ópticos: Landsat 5 TM:** Los satélites Landsat están localizados en una órbita heliosincrónica, cerca de los polos, y poseen una extensión de sensado de 185 km. Los Landsat 4 y 5 tienen una inclinación de 98°, un ciclo orbital de 16 días, y cruzan el ecuador a las 9:45 (de hora local). La altitud de estos satélites es de 705 km. El sistema Landsat proporciona datos globales entre 82° latitud norte y 82° de latitud sur.

*Thematic Mapper (TM)* es un sensor a bordo de Landsat 4 and 5, cuya resolución es de 30 m para las bandas 1-5, y para la banda 7; mientras que la resolución de la banda 6 es de 120 m. Todas las bandas de TM están cuantificadas como datos de 8 bit. El TM es un escáner multiespectral avanzado diseñado para proveer imágenes de más alta resolución, mejor fidelidad geométrica y mayor exactitud radiométrica y resolución respecto al sensor MSS.

Las características de las diferentes bandas del sensor Landsat 5 TM son las mostradas en la tabla 3.1:

**Tabla 3.1:** Características de las diferentes bandas del sensor Landsat 5 TM

Sensor TM Misión 5	Sensibilidad espectral	Localización espectral nominal	Resolución espacial
Banda 1	0,45 – 0,52	Azul	30 × 30
Banda 2	0,52 – 0,60	Verde	30 × 30
Banda 3	0,63 – 0,69	Rojo	30 × 30
Banda 4	0,76 – 0,90	Infrarrojo cercano	30 × 30
Banda 5	1,55 – 1,75	Infrarrojo medio	30 × 30
Banda 6	10,4 – 12,5	Infrarrojo térmico	120 × 120
Banda 7	2,08 – 2,35	Infrarrojo medio	30 × 30

**Datos utilizados para este capítulo:** Los datos de Landsat 5 TM correspondientes a la zona de estudio (2.3.1) fueron solicitados al Catálogo de imágenes de INPE, Brasil: [dgi.inpe.br](http://dgi.inpe.br). Las características de la imagen adquirida se muestran en el apéndice A (ver página 176). Se trata de una imagen adquirida el 26 – 07 – 2010, corresponde al *Path*: 224 y *Row*: 78. Las coordenadas centrales de la escena son: latitud:  $-25,993180^\circ$ , longitud:  $-54,942613^\circ$ . El tamaño de píxel (resolución espacial) es de 30 m.

**Preprocesamiento de la imagen Landsat TM:** La señal recibida por los sensores se codifica en los diferentes valores de Números Digitales (ND) de acuerdo a la reflexión de la radiación electromagnética de las cubiertas. Los valores de los píxeles en las imágenes satelitales expresan la cantidad de energía radiante recibida por el sensor en la forma de valores relativos no calibrados simplemente llamados ND o brillo. El proceso inverso, es decir la conversión de los ND a reflectividades, se realiza en dos fases: primero pasar ND a valores de radiancia, a partir de los coeficientes de calibración, y luego estimar los valores de reflectividad aparente, conociendo la irradiancia solar y la fecha de adquisición de la imagen.

La radiancia es la cantidad de energía electromagnética que pasa a través o es emitida desde un área en particular, confinada en un ángulo sólido en una dirección específica; mientras que la reflectividad o reflectancia es el cociente entre la energía reflejada y la energía incidente.

Para convertir los *números digitales (DN)* de Landsat TM a radiancia espectral y posteriormente a reflectancia exoatmosférica (encima de la atmósfera), se utilizaron las siguientes ecuaciones implementadas en el software ENVI [ENVI, 2009].

La radiancia espectral ( $L_\lambda$ ) es calculada utilizando la siguiente función:

$$L_\lambda = L_{min_\lambda} + \left( \frac{L_{max_\lambda} - L_{min_\lambda}}{QCAL_{max} - QCAL_{min}} \right) (QCAL - QCAL_{min}) \quad (3.2)$$

donde  $QCAL$  es la radiancia escalada calibrada y cuantificada en unidades de números digitales (DN),  $L_{min_\lambda}$  es la radiancia espectral en  $QCAL = 0$ , y  $QCAL_{min} = 0$ .  $L_{max_\lambda}$  es la radiancia espectral en  $QCAL = QCAL_{max}$ .  $L_{min_\lambda}$  y  $L_{max_\lambda}$  son derivados de valores publicados en [Chander et al. \[2009\]](#).  $QCAL_{min}$  es el mínimo valor de píxel calibrado (correspondiente a  $L_{min_\lambda}$ ) en DN, siendo 0 y 1 valores válidos para este parámetro.  $QCAL_{max}$  es el máximo valor de píxel calibrado (correspondiente a  $L_{max_\lambda}$ ) en DN, siendo 127, 254 y 255 valores válidos para este parámetro.

La radiancia resultante ( $L_\lambda$ ) está en unidades de:  $W/(m^2 * sr * \mu m)$ .

La reflectancia exoatmosférica ( $\rho_P$ ) es calculada utilizando la siguiente función:

$$\rho_P = \frac{\pi \cdot L_\lambda \cdot d^2}{E_{sun_\lambda} \cdot \cos(\theta_s)} \quad (3.3)$$

donde  $L_\lambda$  es la radiancia espectral,  $d$  es la distancia tierra-sol en unidades astronómicas,  $E_{sun_\lambda}$  es la irradiancia exoatmosférica solar media. Para Landsat 5 los valores de  $E_{sun_\lambda}$  utilizados son obtenidos de [Chander & Markham \[2003\]](#) y  $\theta_s$  es el ángulo cenital en grados.

### 3.3.3. Especificación de la metodología

#### 3.3.3.1. Tecnología de desarrollo empleada

La tecnología utilizada para la implementación de los diferentes algoritmos fue explicada en la sección [2.3.4.1](#).

#### 3.3.3.2. Implementación de algoritmos

La implementación de los algoritmos que se exponen a continuación y sus respectivas interfaces gráficas de usuario fue llevada a cabo usando el IDE (Integrated Development Environment) IDL Workbench 7.1.1 sobre un sistema operativo GNU/Linux (Ubuntu 10.04, Kernel 2.6.32-31-generic-pae).

**Fracción de vegetación:** El índice normalizado de vegetación ( $NDVI$ : Normalized Difference Vegetation Index) es uno de los más viejos, mejor conocidos y más frecuentemente empleados índices de vegetación [[Rouse et al., 1974](#)]. Este índice estima la cobertura de vegetación verde y se determina mediante la siguiente ecuación:

$$NDVI = \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + \rho_{Red}} \quad (3.4)$$

donde  $\rho_{NIR}$ ,  $\rho_{Red}$  son las reflectancias medidas en el infrarrojo y rojo del espectro electromagnético respectivamente. El valor de este índice varía entre  $-1$  y  $1$ . El rango común para vegetación verde es  $0.2$  a  $0.8$

Se determinó la imagen de  $NDVI$  a partir de la imagen Landsat 5 TM empleada correspondiente a la zona de estudio.

Sin embargo, el efecto de la vegetación sobre la dinámica del agua en el terreno no será analizado a través del  $NDVI$  sino mediante la variable: cobertura de vegetación. Para transformar el índice de vegetación en un valor de cobertura vegetal se utilizó la relación lineal propuesta por Wittich & Hansing [1995], que ha sido empleada también con resultados aceptables por otros autores [Ramsey et al., 2004]. La ecuación de dicha transformación se puede expresar como:

$$f_v = \frac{NDVI - NDVI_0}{NDVI_{100} - NDVI_0} \quad (3.5)$$

siendo  $NDVI_0$  el  $NDVI$  correspondiente a suelo desnudo (determinado a criterio del analista, según el área de estudio),  $NDVI_{100}$  el  $NDVI$  correspondiente a una superficie completamente cubierta por vegetación, y  $f_v$  la fracción de cobertura vegetal del suelo. Para obtener  $NDVI_0$  y  $NDVI_{100}$  se extrajo, de la imagen de  $NDVI$  generada, el valor del índice en zonas con cobertura total y sin vegetación. Los parámetros utilizados para la imagen de  $NDVI$  empleada en este trabajo fueron:

$NDVI_0 = 0,3$  y  $NDVI_{100} =$  al máximo valor de la imagen de  $NDVI$ .

**Coregistración de imágenes:** La coregistración se refiere al proceso de alineación geométrica de las imágenes que están siendo comparadas, de tal modo que cada píxel represente el mismo objeto en ambas imágenes.

Se llevó a cabo la coregistración del DEM ASTGTM con respecto a la imagen de fracción de vegetación ( $f_v$ ) obtenida a partir de la imagen Landsat. La misma se realizó en el software ENVI [ENVI, 2009] mediante la selección de puntos de control que fueron definidos como objetos evidentes en ambas imágenes, tales como los cruces de caminos y bordes de ríos. La herramienta empleada para realizar la coregistración fue *SPEAR Image to Map Registration*, de ENVI [ENVI, 2009] cuyo acceso es: *Spectral*  $\rightarrow$  *SPEARTools*  $\rightarrow$  *Image - to - MapRegistration*. Se emplearon 125 puntos de control, el método *polynomial*, con la interpolación por convolución cúbica.

**Algoritmo desarrollado - Índice fito-topográfico de humedad-:** Como se indicó en la introducción, el tiempo que el agua permanece en superficie depende no sólo de la pendiente y características topográficas, sino también de variables estructurales del ambiente como la cobertura de vegetación. Considerando lo expuesto (ver sección 3.1) acerca del efecto de la vegetación sobre la posibilidad de acumular agua en un terreno determinado y con el objetivo de plantear una función que represente un modelo simplificado del mismo, se expone a continuación una propuesta de índice fito-topográfico de humedad.

**Hipótesis asumidas por el algoritmo:** En distintas zonas topográficas con diferentes características de altura y pendiente, los procesos predominantes que intervienen determinando el balance hidrológico son diversos. Se puede asumir, de manera simplificada, que en zonas de pendiente significativa el proceso predominante o determinante es la escorrentía frente al resto de los procesos (infiltración, evapotranspiración, intercepción). Del mismo modo puede asumirse que en zonas de pendiente baja o nula, el proceso determinante sería la infiltración (respecto de escorrentía, evapotranspiración e intercepción). Por lo tanto, en zonas caracterizadas por baja pendiente que por las características del terreno acumularían agua, el fenómeno a analizar respecto a la vegetación sería su efecto en la infiltración. En esta aproximación se adopta que en estos sectores la existencia de vegetación favorecería la presencia de suelos caracterizados (en general) por mayor capacidad de infiltración, dando lugar a una disminución en la capacidad de acumulación de agua respecto a la situación de ausencia de vegetación. Bajo el mismo razonamiento, en zonas caracterizadas por pendientes no nulas el fenómeno a analizar respecto a la vegetación sería la escorrentía. En esta aproximación se considera que en estos sectores la existencia de vegetación favorecería, mediante procesos hidrológicos sobre la escorrentía superficial anteriormente mencionados de disminución de la escorrentía, un aumento en la probabilidad de acumulación de agua.

El algoritmo que se presenta en este capítulo postula:

- El índice fito-topográfico de humedad que se propone como una innovación en este capítulo, denominado  $TWI_v$ , está determinado por la siguiente ecuación:

$$TWI_v = TWI_n + F_v \quad (3.6)$$

donde  $TWI_n$  es el índice topográfico de humedad normalizado, calculado a partir del DEM correspondiente al área de estudio y el cual representa la acumulación debida a la escorrentía en el terreno.  $F_v$  es una función que modela el efecto dependiente de la vegetación. Esta última se define como:

$$F_v = f_v \cdot a \cdot C_{twi} \quad (3.7)$$

donde  $f_v$  es la fracción de cobertura de vegetación que puede ser estimada a partir de imágenes satelitales ópticas por ejemplo; mientras que  $a$  es un parámetro que indica el grado o magnitud del efecto de la vegetación sobre el ciclo hidrológico. Este último es variable según el tipo de ambiente en cuestión y es determinado a criterio del analista, y el tipo de vegetación. La vegetación ejerce su efecto mediante esta función  $F_v$  que es proporcional a la cobertura de vegetación y tiene la forma de  $C_{twi}$ , con forma inversa al TWI de modo de corresponderse a las hipótesis especificadas anteriormente. Esto significa que en zonas de acumulación baja la vegetación aumenta más la acumulación que en zonas con acumulación elevada.

$C_{twi}$  se define como:

$$C_{twi} = TWI_m - TWI_n - U \quad (3.8)$$

donde  $TWI_m$  es el TWI máximo del área o sección de estudio,  $TWI_n$  es el índice topográfico de humedad normalizado y  $U$  es un parámetro umbral que determina el punto de pendiente a partir del cual la vegetación ejerce un efecto diferencial: disminución de acumulación en planicies, mesetas o zonas de baja pendiente y aumento de acumulación en zonas de terreno inclinado o pendiente significativa.

- En ausencia de vegetación, la capacidad de acumular humedad/agua del terreno está determinada por el  $TWI_n$  (Índice topográfico de humedad (especificado en el capítulo 2)).
- Los parámetros de la función deben ser ajustados debidamente mediante diferentes evaluaciones.

A continuación se presenta los pasos correspondientes al índice desarrollado:

- Se determina  $MAXIMO$ , el valor máximo de  $TWI_n$ .
- Se determinan los píxeles en los cuales la pendiente es menor que un límite definido como  $pendiente\_baja$  (pendiente a partir de la cual se considera declive bajo o nulo) y la localización de estos píxeles se almacena en un vector  $pb$ .
- Se determina el umbral  $U$  como el valor máximo del vector formado por los valores:

$$[MAXIMO - TWI_n[pb]] \quad (3.9)$$

donde  $pb$  es la localización de los píxeles de  $pendiente\_baja$ .

- Se calcula  $C_{twi} = TWI_m - TWI_n - U$ .
- Se calcula  $F_v = f_v \cdot a \cdot C_{twi}$ .
- Se obtiene finalmente:  $TWI_v = TWI_n + F_v$ .

**Evaluación del algoritmo desarrollado en diferentes perfiles:** El algoritmo planteado para la determinación del índice fito-topográfico de humedad se evaluó en los siguientes perfiles o terrenos:

- Perfil A: modelado mediante una función proporcional a  $-e^{-(x^2)}$ .
- Perfil B: modelado mediante una función proporcional a  $-e^{-(x^2)}$  a la que se le adicionan dos pozos en las zonas de pendiente elevada.
- Terreno C: ASTER GDEM, con filtro de media móvil de tamaño de kernel 39, de una sección del área de estudio.



## 3.4. Resultados

**Perfil A:** El perfil analizado, simulado mediante una función proporcional a  $-e^{-(x^2)}$ , se muestra en la subfigura 3.4(a) y representa un terreno (unidimensional) que contiene un pozo entre dos laderas de pendiente pronunciada.

Se aplicó el algoritmo para el cálculo del índice fito-topográfico de humedad y los valores de los parámetros fijados para el mismo fueron los siguientes:

- $pendiente\_baja = 0,1$ .
- $f_v = 0,6$  (constante).
- $a = 0,7$ .

La función  $C_{twi}$  resultante a partir del perfil A es expuesta en la subfigura 3.4(b). En la subfigura 3.4(c) se muestra el índice topográfico normalizado original sin consideración de la vegetación, y el  $TWI_v$  superpuestos. Es posible observar como el  $TWI_v$  representa un suavizado de la curva de índice de humedad original.

**Perfil B:** En la figura 3.5(a) se evidencia el perfil simulado mediante una función proporcional a  $-e^{-(x^2)}$  a la que se le adicionan dos pozos en zonas de pendiente elevada. Se aplicó el algoritmo para el cálculo del índice fito-topográfico de humedad y los parámetros fijados para el mismo fueron los siguientes:

- $pendiente\_baja = 0,1$ .
- $f_v = 0,6$  (constante).
- $a = 0,7$ .


Se puede apreciar en la subfigura 3.5(c) que se produce una disminución en el índice de fito-topográfico en la parte más baja del DEM y en los pozos, en relación al índice topográfico sin consideración de la vegetación. Esto cumple las condiciones impuestas en la determinación del nuevo índice.

**Terreno C:** El ASTER GDEM empleado se observa en la figura 3.6, mientras que en la figura 3.7 se presenta la matriz de fracción de vegetación del área de estudio empleada en el algoritmo.

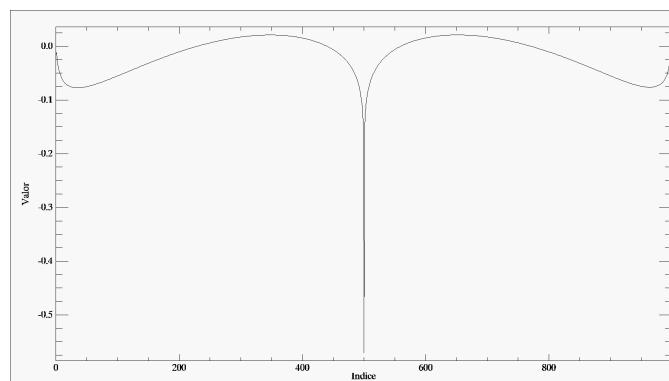
Se aplicó el algoritmo para el cálculo del índice fito-topográfico de humedad y los parámetros fijados para el mismo fueron los siguientes:

- $pendiente\_baja = 0,1$ .
- $a = 0,7$ .


El  $TWI_n$  resultante se presenta en la subfigura 3.8(a), mientras que el  $TWI_v$  se muestra en la subfigura 3.8(b). Las diferencias entre ambos índices son detalladas en la imagen 3.8(c), en la cual en color rojo están delimitadas las zonas en las cuales el índice de humedad



(a) Perfil simulado A.




(b) Función  $C_{Twi}$  derivada de la aplicación del algoritmo de cálculo del índice fito-topográfico al perfil A. Valores de los parámetro *pendiente\_baja* = 0,1.




(c) Comparación de los índices topográficos obtenidos a partir del perfil A:  $TWI_n$  (negro) y  $TWI_v$  (rojo).


**Figura 3.4:** Perfil topográfico A, simulado mediante una función proporcional a  $-e^{-(x^2)}$ , y los resultados de la aplicación del algoritmo de determinación de índice fito-topográfico de humedad sobre el mismo. A partir del perfil A, el cual representa la elevación de un terreno en una dimensión, se obtiene  $C_{Twi}$ , el cual es luego aplicado al perfil para obtener  $TWI_v$ . Se observa la diferencia entre el índice simple  $TWI_n$  y el fito-topográfico  $TWI_v$ . El efecto de la vegetación disminuye el índice en zonas del pozo del perfil y aumenta el mismo en zonas de ladera. Valores de los parámetros empleados para el cálculo de  $TWI_v$ : *pendiente\_baja* = 0,1, *fv* = 0,6 (constante), *a* = 0,7.



(a) Perfil simulado  $B$ .



(b) Función  $C_{twi}$  derivada de la aplicación del algoritmo de cálculo del índice fito-topográfico al perfil  $B$ .



(c) Comparación de los índices topográficos obtenidos a partir del perfil  $B$ :  $TWI_n$  (negro) y  $TWI_v$  (rojo).

**Figura 3.5:** Perfil topográfico  $B$ , simulado mediante una función proporcional a  $-e^{-(x^2)}$  a la que se le adicionan dos pozos en zonas de pendiente elevada, y los resultados de la aplicación del algoritmo de determinación de índice fito-topográfico de humedad sobre el mismo. A partir del perfil  $B$ , el cual representa la elevación de un terreno en una dimensión, se obtiene  $C_{twi}$ , el cual es luego aplicado al perfil para obtener  $TWI_v$ . Se observa la diferencia entre el índice simple  $TWI_n$  y el fito-topográfico  $TWI_v$ . El efecto de la vegetación disminuye el índice en zonas de pozos del perfil y aumenta el mismo en zonas de ladera. Valores de los parámetros empleados para el cálculo de  $TWI_v$ :  $pendiente\_baja = 0,1$ ,  $fv = 0,6$  (constante),  $a = 0,7$ .


fito-topográfico disminuyó respecto al normal, en azul las zonas en las cuales aumentó el mismo y en amarillo los píxeles que no cambiaron.

En la figura 3.9 se muestran los histogramas correspondientes a las imágenes de los índices: topográfico y fito-topográfico de humedad. En este último se puede observar que los valores de TWI se encuentran menos dispersos (más concentrados) alrededor de los valores bajos predominantes. Es por esto que el número de valores altos de TWI disminuye y la imagen, en consecuencia, presenta menor número de píxeles con valores mayores a 0.8 (Fig. 3.8(b)).

## 3.5. Discusión y conclusiones

Este capítulo se aproxima a la consideración del efecto de la cobertura de vegetación en el patrón de acumulación de agua y, en consecuencia, a la estimación de indicadores de humedad que capturen de manera mejorada la complejidad del sistema natural. Fue posible proponer una función que modela el efecto esperado, según las hipótesis planteadas, de la vegetación sobre el índice de acumulación potencial de agua en estudio.


Se asumió la hipótesis de que los procesos predominantes que intervienen determinando el balance hidrológico varían de acuerdo a la pendiente. Bajo esta hipótesis, en zonas de pendiente significativa el proceso predominante o determinante es la escorrentía frente al resto de los procesos (infiltración, evapotranspiración, interceptación); mientras que en zonas de pendiente baja




**Figura 3.6:** Terreno C correspondiente a un recorte del ASTER GDEM del área de estudio. Los valores de elevación van desde 182 a 261.4 m.



**Figura 3.7:** Fracción de vegetación obtenida a partir de una imagen Landsat 5 TM, correspondiente al Path: 224 y Row: 78 y la fecha 26 – 07 – 2010 del área de estudio.




(a) Índice topográfico  $TWI_n$  obtenido a partir del terreno C. (b) Índice topográfico  $TWI_v$  obtenido a partir del terreno C.



(c) Imagen de diferencias  $TWI_n/TWI_v$ : en rojo píxeles que disminuyeron el índice, en azul los que aumentaron, y en amarillo los que no cambiaron.

**Figura 3.8:** Índices topográficos  $TWI_n$  y  $TWI_v$  correspondientes al terreno C. Valores de los parámetros empleados para el cálculo de  $TWI_v$ :  $pendiente_baja = 0,1$ ,  $a = 0,7$ .



**Figura 3.9:** Histograma del índice topográfico de humedad normalizado ( $TWI_n$ ) y del índice fito-topográfico de humedad ( $TWI_v$ ) obtenidos. Se observa que la imagen de  $TWI_v$  presenta valores más concentrados.

o nula, el proceso determinante es la infiltración (respecto de escorrentía, evapotranspiración e intercepción). Por lo tanto, en zonas caracterizadas por baja o nula pendiente que topográficamente acumularían agua, se considera el fenómeno de la infiltración respecto a la vegetación. La existencia de la misma favorecería la presencia de suelos caracterizados (en general) por mayor capacidad de infiltración, dando lugar a una disminución en la capacidad de acumulación de agua respecto a la situación de ausencia de vegetación.

Según el mismo razonamiento, en zonas caracterizadas por pendientes significativas el fenómeno que se considera es la escorrentía respecto a la vegetación. La existencia de la misma favorecería, mediante procesos sobre la escorrentía superficial, un aumento en la probabilidad de acumulación de agua. La hipótesis fue plasmada en una ecuación con parámetros variables, que deben ser ajustados convenientemente en trabajos futuros a fin de modelar de manera adecuada el comportamiento hidrológico que se manifiesta en la realidad.

Del mismo modo que se planteo para el  $TWI_n$  del capítulo anterior, la validación de este índice debe ser llevada a cabo de manera indirecta a través del análisis de variables correlacionadas con la humedad, y la acumulación de agua.

Una condición que debe evaluarse en próximos trabajos es que el efecto modelado de la vegetación debe representar indirectamente la influencia de los tipos de suelo presentes en el flujo o comportamiento hidrológico. En el presente trabajo no se consideran variables como el tipo de suelo, el espesor del suelo, etc. En este sentido, el modelo propuesto representa una simplificación del complejo sistema de determinación de características hidrológicas de un terreno. En relación a la fracción de vegetación, sería adecuado incorporar las respectivas validaciones de esta variable. En consecuencia, se debería introducir la variable de vegetación que mejor represente la cobertura terrestre y su posibilidad de ejercer efecto sobre el ciclo hidrológico.

**Temimi et al. [2010]** es el único trabajo encontrado en la bibliografía que trata de incorporar la vegetación al índice topográfico de humedad mediante la generación de un nuevo índice. Se basa en los trabajos de **Canton et al. [2004]**; **Gómez-Plaza et al. [2001]**; **Grayson et al. [1997]**; **Qiu et al. [2001]** que sugieren que factores *de control no local* tales como la profundidad de suelo y el área de contribución controlan la distribución espacial de humedad de suelo bajo condiciones húmedas o con vegetación; mientras que factores *de control local* como la pendiente del terreno dominan en condiciones secas o ausencia de vegetación. En futuros estudios, sería adecuado evaluar la integración del índice fito-topográfico desarrollado en este trabajo con los conceptos asumidos para el planteo del índice de **Temimi et al. [2010]**.

# Capítulo 4

## Delimitación de cuerpos de agua: Introducción y definiciones

### 4.1. Marco teórico

#### 4.1.1. Sensado remoto de radares de apertura sintética

Según **Chuvienco [2000]**, un sistema de teledetección terrestre requiere al menos de tres componentes: 1) un foco energético que emita energía, 2) la superficie terrestre a ser sensada y 3) un sensor que reciba la energía reflejada. Una de las formas más habituales de clasificar a estos sensores remotos considera su mecanismo de recepción de la energía procedente de las distintas cubiertas. En este sentido, se habla de dos tipos de sensores:

- Pasivos: son los sensores que se limitan a recibir la energía proveniente de un foco exterior a ellos, ya sea reflejada de los rayos solares o emitida en función de la propia temperatura de la superficie.
- Activos: son los sensores que son capaces de emitir su propio haz de energía. Estos son más flexibles debido a que no dependen tanto como los primeros de las condiciones exteriores al sistema sensor-Tierra. El equipo activo más ampliamente conocido es el *RADAR (Radio Detection And Ranging)*, el cual trabaja en la región de las microondas y es utilizado en aplicaciones militares y en control del tráfico aéreo.

Las principales diferencias entre sistemas satelitales pasivos y activos son las siguientes:

#### 1. Respecto a la fuente irradiación:

- Los sensores pasivos miden la energía electromagnética que irradia la superficie terrestre, tanto la energía que emite por ser un objeto por encima de  $0^{\circ}\text{K}$ , es decir  $-273^{\circ}\text{C}$  (TIR, emisión termal) como la radiación solar reflejada. Esta última radiación es originada por una fuente generadora de energía incoherente y no polarizada: el sol. La radiación de onda corta emitida por el sol alcanza la atmósfera y

en parte es absorbida por los gases que la componen; llega a los diferentes niveles de la atmósfera y a la superficie de la tierra, y es reflejada.

- Los sistemas activos poseen su propia fuente de irradiación (emisor), y de recepción. Estos instrumentos, a diferencia de los pasivos, emiten una señal y miden la onda reflejada. El receptor registra la energía electromagnética retrodispersada por la escena y por lo tanto, mide la diferencia en potencia entre la señal emitida y recibida. Como la fuente generadora de energía es coherente y polarizada (como en Radar, LIDAR, etc), es necesario medir no solo la amplitud de la onda recibida, sino también su polarización y fase, ya que cualquier cambio en las mismas incluye información sobre el blanco retrodispersor. Los sistemas activos pueden operar de día y de noche (no necesita la iluminación solar). La presencia del sol no es relevante en el proceso de generación de la imagen, aunque esta puede afectar las características de retrodispersión del blanco. Los sistemas activos, a diferencia de los pasivos, son independientes del ángulo de iluminación solar debido a que poseen su propia fuente de iluminación.

#### 2. Respecto a los efectos atmosféricos:

La radiación electromagnética incidente de origen solar es afectada por la atmósfera a través de los procesos de transmisión, absorción, retrodispersión o difusión, y reflexión. La radiación de onda corta emitida por el sol alcanza la atmósfera. Parte de ella es absorbida por los gases que la componen. Otra parte, muy importante, es reflejada por las nubes, la tierra, el agua y es reenviada de nuevo al espacio.

Los sensores pasivos miden la energía electromagnética que intercepta la cobertura nubosa, por lo tanto la reflexión de la tierra no es distinguible por la interferencia de las nubes. Las nubes, precipitación y niebla no tienen efecto significativo sobre el rango de las microondas. Sin embargo, en este rango de longitud de onda, los sensores pasivos reciben poca energía y esto dificulta su uso.

Por el contrario, los sensores activos, que operan en la región de las microondas (las frecuencias principalmente usadas son las correspondientes a bandas K, L, X y C: ver tabla 4.1, página 66), posibilitan medir en todo tipo de clima, aún en condiciones de cobertura nubosa (baja sensibilidad a nubes y lluvia). Las nubes son transparentes para las longitudes de onda a las cuales miden los sensores activos. Como consecuencia, los sensores activos permiten obtener imágenes de la tierra en todas las condiciones meteorológicas. Al no ser afectados por efectos atmosféricos, los sensores activos facilitan el análisis multitemporal. Las frecuencias a las que los radares miden pueden ser seleccionadas de modo de que su atenuación (absorción) por moléculas atmosféricas (oxígeno o vapor de agua) sea baja.

#### 3. Respecto a la propiedad sensada del blanco:



Los sistemas pasivos, en particular los sistemas que miden en el rango óptico del espectro, son sensibles a resonancia molecular y retrodispersión a escala de micrómetros. Los objetos reflejan y emiten radiación electromagnética de acuerdo a su composición química y a su estado físico. Los sensores ópticos miden el **contenido** de componentes químicos de la superficie. A modo de ejemplo, al analizar la vegetación con sistemas pasivos, los componentes más importantes que afectan sus propiedades espectrales son las siguientes características de las hojas:

- Contenido de pigmentos.
- Contenido de agua.
- Contenido de carbón.
- Contenido de nitrógeno.

En los sistemas activos, las ondas de energía electromagnética interactúan con la superficie a través de una variedad de mecanismos, los cuales están relacionados con la **composición de la superficie y su estructura**. En la región de microondas en la cual operan los sistemas SAR, las características de la onda retrodispersada depende predominantemente de dos factores: las propiedades eléctricas (constante dieléctrica) y la rugosidad de la superficie.

#### 4. Respecto a los determinantes de la resolución espacial:

La resolución espacial de un sistema de sensado remoto indica el nivel de detalle que la imagen es capaz de brindar. Es decir, designa el objeto más pequeño que puede ser distinguido en una imagen y por lo tanto, es fundamental en la interpretación de la misma. En los sensores ópticos, la resolución depende de la altura de la plataforma y de la longitud de onda a la cual midan. En cambio, la resolución geométrica en sistemas activos es independiente de la altura del sensor o longitud de onda. La resolución en acimut (en la dirección paralela al movimiento del sensor) en SAR depende, por ejemplo, de:

- El ancho de emisión angular  $\beta$  (se deteriora a medida que el ancho de rayo aumenta).
- El largo de la antena sintética.
- Es inversamente proporcional al tamaño de la antena real.

Esta resolución se puede controlar mediante:

- a) El tamaño físico de la antena.
- b) Sintetizando un ancho de antena virtual (radar de apertura sintética, SAR – *Synthetic Aperture Radar*).

La resolución en la dirección en que mira la antena (resolución en *range* que se detallará posteriormente) aumenta a medida que se incrementa el ángulo de incidencia (definido en

la sección 4.1.1.4). Esta es independiente de la altura del satélite. La resolución en *range* puede mejorarse mediante el aumento del ancho de banda del radar, siendo este mayor a menor longitud de onda del pulso transmitido.

### 5. Respecto a los fenómenos físicos involucrados:

Los fenómenos que se consideran respecto al contacto de la energía electromagnética con el blanco son:

- a) En teledetección pasiva óptica: Reflexión, absorción y transmisión.
- b) En teledetección activa radar: reflexión, atenuación y penetración.

#### 4.1.1.1. Orígenes del sensado remoto y de radares de apertura sintética

El sensado remoto de la superficie terrestre fue primero llevado a cabo en el año 1960 mediante satélites de la NASA (National Aeronautics and Space Administration: [nasa.gov](http://nasa.gov)) usando cámaras y dispositivos como cámaras (radiómetros pasivos). Estos primeros sensores remotos en el espacio fueron utilizados para coleccionar y discriminar energía electromagnética irradiada y reflejada en el espectro visible o infrarrojo (aproximadamente a longitudes de onda  $\lambda$  de  $0.4 \mu\text{m}$  a  $20 \mu\text{m}$ ). En 1973, el satélite *Earth Resource Technology Satellite* (ERTS-1) de NASA, luego renombrado como Landsat, inició una serie de misiones caracterizadas por adquirir imágenes ópticas de fina resolución (decenas de metros) con muchos canales visibles e infrarrojos que fueron temáticamente asociados con específicas aplicaciones terrestres y que continúan operando hasta la actualidad.

Los primeros sensores de alta resolución fueron sistemas *ópticos o pasivos* de cámaras con detectores que fueron sensibles a la radiación solar reflejada o la radiación térmica emitida por la superficie de la tierra. Aunque estos radiómetros son capaces de proveer resolución espacial superficial elevada y excelentes detalles multi-espectrales, como se explicó anteriormente, están inhibidos por nubes y dependen de la iluminación global limitándose a observaciones diurnas. Es así que, un importante factor que interviene en la elección del rango de frecuencia de medición a utilizar es la influencia de los efectos atmosféricos sobre la propagación de la onda electromagnética, que actúan produciendo atenuaciones. Estas atenuaciones están ligadas a la interacción entre la onda y las moléculas que constituyen la atmósfera. Las limitaciones de la atmósfera y oscuridad pueden ser superadas analizando la región del espectro de las microondas. Las microondas son capaces de pasar a través de nubes y permitir observaciones no obstruidas de la superficie de la tierra, incluyendo la detección diurna y nocturna. Sin embargo, para un radiómetro de microondas pasivo, y debido a la poca energía reflejada en esta región del espectro, es imposible alcanzar la alta resolución generada por dispositivos operando a longitudes de onda del rango óptico.

Los SAR (*Synthetic Aperture Radars – SAR*) representan una técnica fundamentalmente diferente para la observación de la tierra, debido a que los radares son sistemas activos que

#### 4. Delimitación de cuerpos de agua: Introducción y definiciones

---

transmiten un pulso de radiación electromagnética (EM) en la región de microondas del espectro. Como sistema activo, el SAR proporciona su propia iluminación y no es dependiente de la luz del sol, y por lo tanto permite operatividad tanto diurna como nocturna. Además, ni las nubes ni precipitaciones tienen efecto significativo en las microondas, lo cual permite el sensado en todas las condiciones climáticas [Curlander & McDonough, 1991]. El resultado neto es un instrumento que es capaz de observar continuamente fenómenos dinámicos tales como cambios en patrones de la vegetación o corrientes oceánicas.

Algunas de las características que hacen del SAR un instrumento único en sensado remoto son:

- Sensado diurno/nocturno y en todas las condiciones climáticas.
- Resolución geométrica independiente de la altura del sensor o longitud de onda.
- Características únicas propias de los datos de la región de microondas del espectro electromagnético.

La medición de un radar se basa en 4 principios tecnológicos [Olmsted, 1993]:

- Capacidad de la antena de transmitir un pulso corto en una dirección precisa.
- Capacidad para detectar en una dirección precisa el eco dispersado, atenuado, de un blanco.
- Capacidad de medir el tiempo de retardo entre la emisión y la detección; y de este modo, la distancia al blanco.
- Capacidad para tomar muestras con un haz direccionado y así examinar blancos sobre grandes áreas.

Un sistema típico de radar consiste de un transmisor y un receptor que trabaja en la región de las microondas, operando sobre una plataforma en vuelo como un avión o un satélite. En la figura 4.1 se muestra el espectro electromagnético y la porción del mismo que ocupan las microondas, mientras que en la tabla 4.1 se especifican las bandas en las que se divide a la región de microondas. Por lo general, las radiaciones electromagnéticas se clasifican en base a su longitud de onda en los siguientes rangos: ondas de radio, microondas, infrarrojos, visible u óptico—que percibimos como luz visible—ultravioleta, rayos X y rayos gamma. Este espectro representa la distribución energética del conjunto de las ondas electromagnéticas. Las ondas electromagnéticas de alta frecuencia tienen una longitud de onda corta y mucha energía mientras que las ondas de baja frecuencia tienen grandes longitudes de onda y poca energía.

En el caso de radar más simple, y como se muestra en la figura 4.2, la antena está orientada paralela a la dirección de vuelo (en *Side-Looking Airborne Radar*: SLAR); es decir, mirando a la tierra perpendicularmente a la dirección de vuelo [Curlander & McDonough, 1991]. SLAR es uno de los primeros radares de apertura real (Real-Aperture Radar: RAR). Este requiere una antena razonablemente grande para lograr una resolución angular adecuada. La dirección en que mira la antena se denomina *range* o *slant range*. La plataforma (aeronave o satélite) de un SLAR viaja en la dirección de vuelo con el nadir directamente bajo la plataforma. El pulso de


## 4. Delimitación de cuerpos de agua: Introducción y definiciones

**Tabla 4.1:** Bandas en las que se divide a la región de microondas

Banda de radar	Longitud de onda (cm)	Frecuencia (GHz)
Ka	1,13 – 0,83	26,5 – 36,6
K	16,7 – 1,13	18 – 26,5
Ku	2,75 – 1,67	10,9 – 18
X	5,21 – 2,75	5,75 – 10,9
C	7,69 – 5,21	3,9 – 5,75
S	19,4 – 7,69	1,55 – 3,9
L	76,9 – 19,4	0,39 – 1,55
P	133 – 76,9	0,225 – 0,39

microondas es transmitido oblicuamente a ángulos perpendiculares a la dirección del vuelo iluminando un *swath*. El *range* se refiere a la dimensión a lo largo de la trayectoria perpendicular a la dirección de vuelo, mientras que *acimut* se refiere a la dimensión a lo largo de la trayectoria paralela a la dirección de vuelo. El *Swath width* se refiere a la faja de la superficie de la tierra para la cual los datos son recolectados por el SLAR. Este es el ancho de la escena observada en la dimensión de *range*. La extensión longitudinal del *swath* es definida por el movimiento de la aeronave con respecto a la superficie, mientras que el *swath width* es medido perpendicularmente a la extensión longitudinal del *swath*. Como puede observarse en la figura 4.2, la dirección *slant range* no es tangente a la superficie de la Tierra y por lo tanto para obtener una imagen de la superficie es necesario hacer una reproyección adecuada.

Los sistemas de radar están compuestos por un transmisor, un receptor, un modulador, un procesador y una antena. Las principales características y propiedades de antena de un sistema



**Figura 4.1:** Diagrama del espectro electromagnético. Se muestra el tipo, la longitud de onda, y la frecuencia de cada onda electromagnética. Adaptado de: Louis E. Kleiner, Coastal Carolina University.


## 4. Delimitación de cuerpos de agua: Introducción y definiciones

radar son: la polarización, el diagrama de radiación, los lóbulos laterales, la dirección, la ganancia, el área de recepción, etc. La polarización es definida como la orientación según la cual el vector de campo eléctrico de la onda electromagnética oscila en el tiempo. Esta orientación puede determinar una polarización de tipo lineal, circular o elíptica. Se dice que la polarización es lineal cuando la orientación del campo eléctrico varía según una línea recta que puede ser horizontal o vertical. La onda electromagnética es horizontalmente polarizada cuando el vector de campo eléctrico es perpendicular al plano de incidencia de la onda (plano que contiene un vector normal a la superficie o el vector de propagación de onda), o de manera general, cuando el vector de campo eléctrico es paralelo a la superficie observada. Usualmente los sistemas de radar utilizan polarizaciones lineales paralelas,  $HH$  e  $VV$ , o cruzadas,  $HV$  y  $VH$ . La primera letra se refiere a la polarización de la radiación transmitida y la segunda a la polarización de la radiación recibida por la antena.

Una función que describe el comportamiento de la potencia relativa de radiación de una antena de radar con relación a la dirección de propagación es llamado diagrama de radiación o patrón de radiación de la antena, el cual define la ganancia de la antena. Estas antenas son anisotrópicas, es decir que poseen una dirección preferencial de transmisión y recepción de radiación electromagnética que determina el lóbulo mayor o principal.

### 4.1.1.2. Proceso de emisión, interacción y recepción con radar

El sensado por radar consiste en la emisión de pulsos de microondas a intervalos regulares sobre una región de interés y la recuperación de las señales de retorno (ecos) provenientes de esta región, a medida que el sensor se mueve. La recepción de la señal de retorno puede ser realizada utilizándose la misma antena emisora (sistemas monoestáticos) o una segunda antena (sistemas biestáticos). Mediante la medición precisa de la diferencia de tiempo entre el pulso transmitido y el recibido de la energía reflejada, el radar es capaz de determinar la distancia al objeto reflectante (llamada *range* o *slant range*).



(a) Geometría de vuelo en SLAR.

(b) Resolución espacial en SLAR.

**Figura 4.2:** Geometría de vuelo en *Side-Looking Airborne Radar* (SLAR). Fuente: [Christian Wolff, 2008](#). En 4.2(a) se ilustran los principales términos relacionados a la geometría SLAR, mientras que en 4.2(b) se muestran las variables que determinan la resolución espacial en SLAR.

#### 4. Delimitación de cuerpos de agua: Introducción y definiciones

---

El transmisor emite hacia la tierra una secuencia de pulsos muy cortos con una frecuencia y duración muy precisa. La radiación interactúa con el medio según las leyes del electromagnetismo. Dado que la radiación es emitida en un haz, la interacción resultante es la suma de lo que le sucede a cada rayo. La radiación, al encontrar la superficie de la tierra, es reflejada en alguna proporción en todas las direcciones, dependiendo de la rugosidad de la superficie. Además, la retrodispersión puede darse en distintas capas, según la penetrabilidad de la radiación con el medio; que depende de su homogeneidad, la interfase y de la longitud de onda. En principio, se toma al aire como transparente a las microondas aunque es claro que los cambios de densidad del aire con la altura se traducen en cambios del índice de refracción y entonces habrá alguna dispersión en el mismo. Por otro lado, dependiendo de la conductividad del medio no solamente cambia la proporción de radiación reflejada sino que puede producir un cambio en la fase de la onda.

La resolución en rango (*Range resolution: RR*) de un sistema radar es su habilidad de distinguir dos objetos separados por alguna determinada distancia. Si los objetos están adecuadamente separados, cada uno estará localizado en una celda de resolución diferente y entonces, será distinguible. En caso contrario, el retorno del radar será una compleja combinación de la energía reflejada desde los dos objetos. La resolución espacial en la dirección del rango no es dependiente del rango o directamente de la longitud de onda, sino que es una función del ancho del pulso efectivo ( $\tau$ ) multiplicado por la velocidad de la luz ( $c$ ) y dividido 2. La resolución en rango ( $RR$ ) puede también ser expresada como el recíproco del ancho de pulso efectivo (el ancho de banda del pulso ( $\beta$ )) multiplicado por la velocidad de la luz:

$$RR = \frac{c \cdot \tau}{2} = \frac{c}{2 \cdot \beta} \quad (4.1)$$

Para que la resolución en rango sea mayor, el ancho de banda del pulso debe crecer en concordancia. Los radares más modernos (incluyendo a los SAR) transmiten un pulso llamado *Chirp* de frecuencia modulada (FM). El transmisor varía la frecuencia del pulso de radar linealmente sobre un particular rango de frecuencias (un incremento en frecuencia es denominado *up-chirp*). Tal variación en frecuencia determina el ancho de banda de la frecuencia de radio (RF) del sistema. La longitud y pendiente del *chirp* están basados en las capacidades de *hardware* de radar y el requerimiento de resolución en rango. Tanto RAR como SAR adquieren su resolución espacial de este modo.

La resolución espacial de una apertura angular es directamente proporcional a la longitud de onda e inversamente proporcional a la dimensión de la apertura. Desde una órbita espacial, unas decenas de metros de resolución a longitudes de onda en el visible e infrarrojo pueden ser alcanzadas con una apertura de solo unas pocas decenas de centímetros. Cuando la longitud de onda aumenta desde el visible e infrarrojo a microondas (micrones a centímetros), la resolución disminuirá a menos de que la apertura de la antena sea incrementada una cantidad equivalente. Para lograr la misma resolución de decenas de metros en las frecuencias de microondas, un satélite necesitaría una apertura de antena en el orden de decenas de kilómetros. En el diseño de

un sensor satelital, esta dimensión de antena es impracticable.

### 4.1.1.3. Radar de Apertura Sintética

Tanto instrumentos de microondas activos como pasivos sufren el problema de resolución mencionado anteriormente, sin embargo, para instrumentos de microondas activos (por ejemplo: radar), ha sido desarrollada una técnica para superar esta limitación. El factor limitante para una antena de microondas, es decir la escasa resolución espacial resultante de un gran ancho haz o campo angular de visión, puede ser transformado en una ventaja para un radar que tiene la habilidad de medir la fase y el efecto *Doppler*. Los radares SAR emplean la ventaja de la historia *Doppler* de los ecos del radar generada mediante el movimiento hacia adelante del satélite para sintetizar una gran antena. Esto permite una alta resolución en acimut en la imagen resultante a pesar de la antena físicamente pequeña. A medida de que el radar se mueve, un pulso es transmitido en cada posición. Los ecos que retornan pasan a través del receptor y son grabados en un almacenador de ecos.

Para un radar que tiene su haz dirigido ortogonalmente a su dirección de recorrido, el gran ancho del haz causará que un objeto (o localización) en la superficie sea iluminado y linealmente atravesado por el haz del radar durante un extenso período de tiempo (de décimas de segundos a segundos dependiendo de la velocidad del satélite). Durante este tiempo, el radar colecciona medidas de fase y corrimientos *Doppler* que, a través del procesamiento de la señal, permite que sea construida una apertura para el haz. Los métodos de elaboración digital de los datos SAR se basan en la medida de un efecto similar al cambio de frecuencia (*shift*) debido al efecto *Doppler*, principio aplicable a todas las ondas armónicas comprimidas en el radar. Este es el concepto básico de SAR; no obstante, más detalle puede ser encontrado en [Curlander & McDonough \[1991\]](#).


Por lo tanto, el SAR es un radar de dimensiones relativamente pequeñas que es capaz de obtener imágenes como si estas hubiesen sido adquiridas por una antena mucho mayor. Para ello el sensor debe volar en una forma particular y la forma de los pulsos deben estar modulados de forma conveniente. Además los pulsos deben guardar una muy alta coherencia, lo que implica que el generador de pulsos debe ser muy estable. Cada punto en tierra es iluminado varias veces por distintos pulsos (del orden de 1000) pero sus retornos tendrán amplitudes, frecuencias y fases características que dependerán de la geometría del sensor respecto del punto en tierra y de las propiedades dieléctricas de la superficie. Estas características permiten luego, de procesar la señal con filtros adecuados, sintetizar la información con mucho mayor resolución espacial que la dada simplemente por la apertura de la antena [[Olmsted, 1993](#)]. Este procesamiento se realiza en tierra. La nueva apertura sintetizada, la cual puede ser varios ordenes de magnitud más grande que la antena que transmite y recibe, hace posible producir imágenes de radar de alta resolución (del orden de unos pocos metros).

Esto significa que un radar de apertura sintética utiliza un sistema de adquisición y procesamiento de los datos que simula electrónicamente las capacidades de una antena más am-

#### 4. Delimitación de cuerpos de agua: Introducción y definiciones

plia que la física empleada. Esta particularidad en la adquisición de las imágenes se obtiene aprovechando la progresión misma de la plataforma del sensor, el tipo de elaboración de la señal recibida, y la particularidad del impulso (*chirp*). La longitud de la antena sintética, o apertura radar  $L$  corresponde a la distancia recorrida por la plataforma durante todo el tiempo en el cual el blanco es iluminado por el impulso de radar emitido por el sensor en movimiento.

En el caso de un SAR, el objeto, el cual es iluminado por el radar según diferentes posiciones a lo largo del recorrido por la órbita, reflejará una señal a distintas frecuencias por efecto del movimiento relativo entre la plataforma y el terreno. La información de frecuencia es obtenida comparando la señal de retorno con una señal de referencia, generada internamente en el sistema. En el sensado SAR (Fig. 4.3), un objeto simple producirá impulsos de retorno a distintas frecuencias por todo el tiempo en el cual resulte iluminado y en relación a su posición respecto de la antena; estos impulsos son registrados en modo coherente (amplitud y fase de la onda en función del tiempo) y combinados entre ellos de modo tal que la elaboración esté en grado de simular una antena sintética de una longitud igual al tiempo de iluminación del objeto.



**Figura 4.3:** Configuración del sensado de radares de apertura sintética (SAR). Se ilustran los principales términos relacionados a la geometría SAR.

Las figuras 4.4 permiten la comparación entre imágenes de radar SAR y ópticas/visibles correspondientes a la misma fecha para el área de estudio que será posteriormente descrita. En la imagen óptica pasiva es visible la cobertura nubosa, la cual imposibilita el sensado de la superficie terrestre, mientras que las nubes no son visibles para el sensor SAR. En la imagen óptica es posible visualizar el diferente contenido de pigmentación de las diversas coberturas, manifestado por la diferente reflectancia de las mismas en las bandas analizadas (correspondientes a los canales del rojo, verde y azul).

La capacidad de sensar en todos los climas, en horarios diurnos y nocturnos y la alta resolución hacen del radar un instrumento de sensado remoto ideal para muchas aplicaciones tanto en detección de objetos, como en manejo de recursos terrestres. Se observa el alto contraste de las superficies de agua respecto al resto de las superficies presente en la imagen radar. De esta




## 4. Delimitación de cuerpos de agua: Introducción y definiciones

manera, resultaría más simple la delimitación de los cuerpos de agua respecto a las imágenes ópticas. Debido a la sensibilidad del radar a la rugosidad en la superficie, se evidencia en la imagen de COSMO un patrón de zonas más claras sobre el cuerpo de agua que representan ondas de movimiento de la misma.



(a) Imagen Landsat 5 TM: combinación de bandas 3,2,1 (Rojo, Verde, Azul). Path: 224, Row: 78. Los valores de la imagen corresponden a valores de reflectancia.



(b) Imagen COSMO-SkyMed: modo de adquisición Pingpong, polarización VV. Los valores de la imagen corresponden a valores de decibelios y tienen un rango de  $-71,7$  a  $15,1$

**Figura 4.4:** Comparación entre imágenes ópticas Landsat (adquisición del 26-07-2010) y radar SAR COSMO-SkyMed (adquisición del 04-06-2010), correspondientes al área de estudio del capítulo 5.

### 4.1.1.4. Factores que influyen la característica de la señal

Un sensor radar es capaz de emitir un impulso de energía electromagnética y de recibir la señal de retorno debido al impacto de las microondas con los diferentes objetos presentes en la superficie de la tierra. Esta señal de retorno  $\sigma^0$ , o eco del radar, es registrada en términos de amplitud y fase de la onda reflejada. La amplitud de la señal está representada por la relación entre tiempo e intensidad: el tiempo requerido para cubrir el tramo de retorno del objeto a la antena y la intensidad de la energía electromagnética captada después de la interacción entre onda emitida y la materia de la superficie terrestre. Estos dos parámetros, unidos a la fase de la


#### 4. Delimitación de cuerpos de agua: Introducción y definiciones

onda que representa una información indirecta de la distancia cubierta por el impulso, permiten identificar la posición del objeto respecto de la antena, y su naturaleza física (forma, posición respecto a la iluminación del radar, características de la reflectividad de la superficie, etc.).

Algunos factores ligados a la naturaleza de la superficie indagada o dependientes del sistema tecnológico empleado, influyen en la capacidad del objeto de reflejar energía hacia el sensor, y por lo tanto, determinan diferencias en el valor de  $\sigma^{\circ}$  registrado, con la consecuente variación de las características de la imagen producida. Estos factores, junto con la forma y posición del objeto son:

- Frecuencia del impulso radar (longitud de onda).
- Polarización de la onda radar.
- Ángulo de incidencia del radar (definido en la sección 4.1.1.4).
- Grado de humedad de la superficie.
- Propiedades estructurales o geométricas de la superficie.

**Frecuencia del impulso radar:** La frecuencia utilizada por el sensor radar determina, como en el caso del sensado remoto óptico multi-espectral, el tipo de representación que tendrán los objetos observados en la imagen, debido a que la capacidad de la superficie terrestre de reflejar la energía electromagnética es de tipo selectivo. Esto significa que dos imágenes radar del mismo territorio, una adquirida en banda C (ver tabla 4.1) y otra en banda L tendrán evidentes diferencias en la representación de una superficie con una rugosidad determinada. La frecuencia utilizada además de determinar la percepción visible que se tendrá de la rugosidad de la superficie observada, influye en el grado de penetración de las ondas en el medio. La capacidad de penetración de las ondas de radar aumenta con la disminución de la frecuencia (con el aumento de la longitud de onda) como se puede observar en la figura 4.5.



**Figura 4.5:** Capacidad de penetración aproximada de las ondas de radar en la vegetación y en el suelo de acuerdo a su frecuencia ( $X : 5,21 - 2,75cm$ ,  $C : 7,69 - 5,21cm$ ,  $L : 76,9 - 19,4cm$ ).

**Grado de humedad (constante dieléctrica):** El contenido de humedad de la superficie expresado mediante la constante dieléctrica modifica significativamente la respuesta del radar.

La constante dieléctrica es un parámetro que mide las propiedades eléctricas superficiales de un medio y está constituido por dos términos: la permitividad y la conductividad. Los valores de constante dieléctrica del suelo aumentan de modo casi lineal con el aumento del contenido de agua, aumentando por lo tanto la reflectividad radar de la superficie. La constante dieléctrica es dependiente de la frecuencia utilizada por el sensor, y en los elementos más comunes presentes en la superficie terrestre, varía de 3 a 8, en ausencia de humedad. Por otro lado, el valor de constante dieléctrica del agua es aproximadamente de 80.

Las microondas pueden ser tomadas en consideración para el análisis de las propiedades de la superficie del suelo. En particular, la interacción de la onda electromagnética con el suelo depende de las propiedades eléctricas (constante dieléctrica) y de la rugosidad de la superficie.

**Propiedades Estructurales o Geométricas:** Las formas geométricas de un objeto pueden alterar la cantidad de dispersión que se produce. Por ejemplo, algunos factores que intervienen en las propiedades estructurales son: la rugosidad de la superficie del objeto, las diferentes alturas y densidades, la orientaciones de tronco, ramas o follaje, la distribución del tamaño de las partículas, la pendiente, etc.

##### ***Rugosidad de la superficie del objeto***

El grado de rugosidad de una superficie depende de la dimensión de la aspereza presente en relación a la longitud de onda de la energía electromagnética incidente y su ángulo de incidencia. La rugosidad media de un objeto está determinada por la dimensión de la aspereza (medida en cm) presente en la superficie, calculada en sentido vertical (altura de la aspereza) o en sentido horizontal (espacio entre aspereza).

Como en la realidad para muchas superficies esta definición resulta difícilmente caracterizable en términos cuantitativos. El criterio objetivo para establecer el grado de rugosidad de una superficie está definido por Rayleigh [Elachi, 1988; Hetch, 1998], teniendo en cuenta tanto la longitud de onda como el valor del ángulo de incidencia de la emisión, y se expresa del siguiente modo. La superficie de un objeto es considerada lisa (no es rugosa) si:

$$h < \frac{\lambda}{8 \cdot \cos(\theta)} \quad (4.2)$$

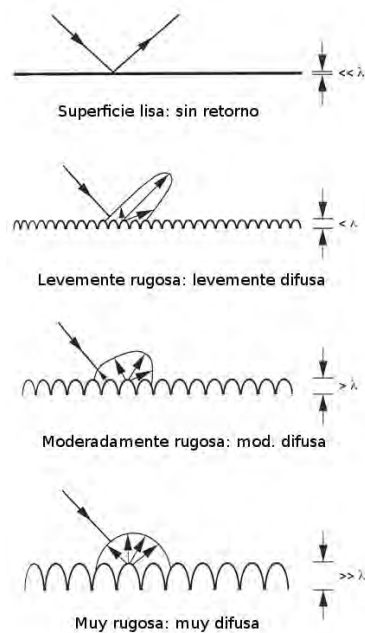
donde  $h$  es la altura media de la aspereza de la superficie (medida en cm),  $\lambda$  representa la longitud de onda de la energía de radar incidente (medida en cm), y  $\theta$  representa el valor del ángulo de incidencia de la onda sobre la superficie del objeto.

En términos de la reflectividad de radar, se debe tener en cuenta que una superficie lisa reflejará toda la energía incidente con un ángulo de reflexión similar pero opuesto al ángulo de incidencia; mientras que una superficie rugosa la difundirá a todas las direcciones incluso en la del sensor, el cual registrará un cierto porcentaje de energía (Fig. 4.6).

## 4. Delimitación de cuerpos de agua: Introducción y definiciones

Un aumento de la rugosidad de la superficie determina un aumento de la difusión y del porcentaje de energía reflejada hacia la antena, causando mayor luminosidad del píxel correspondiente sobre la imagen.

Como puede observarse en la figura 4.7, en el sensado remoto activo la retrodispersión de la onda del radar está relacionada a las características de textura de la superficie indagada. Por lo tanto, en la observación radar de la superficie terrestre, es posible notar que los elementos del territorio que presentan superficies lisas estarán representados sobre la imagen con tonos de grises más oscuros (calles, superficies de agua, pistas de aeropuerto, etc.) tendientes a negro. Esto significa que tales elementos se comportan como óptimos reflectores de la iluminación del radar y por lo tanto, retrodispersan muy poco la energía hacia la antena.



**Figura 4.6:** Retrodispersión de la superficie en función de su rugosidad. Adaptado de Farr [1993] ([history.nasa.gov/](http://history.nasa.gov/))

**Polarización de la onda:** Independientemente de la longitud de onda, una onda electromagnética posee dos tipos de polarizaciones respecto a la dirección de propagación: una eléctrica de tipo vertical y una magnética perpendicular a la primera. Los sistemas radar están configurados a diversas polarizaciones, ya sea en la emisión como en la recepción permitiendo el relevamiento de eventuales fenómenos de despolarización de la onda de retorno debido a las características superficiales y subsuperficiales de los objetos indagados.

Los elementos presentes en la escena sensada e iluminados por el radar tienden a despolarizar en modo selectivo la onda recibida, reflejando una intensidad de energía diferente según sea un vector de campo eléctrico horizontal o vertical. En algunos sistemas radar existe por ejemplo, la posibilidad de transmitir en una polarización vertical y recibir la señal de retorno en una polarización horizontal; tal modalidad es descripta con la sigla

## 4. Delimitación de cuerpos de agua: Introducción y definiciones


*HV* (transmisión en horizontal y recepción en vertical) o viceversa *VH*. Los procesos físicos básicos responsables del retorno polarizado (*HH* o *VV*) son la reflexión superficial quasi-especular; por ejemplo, el agua sin ondas aparece oscura. El retorno de polarización cruzada (*HV* o *VH*) es usualmente débil, y frecuentemente está asociado a la rugosidad superficial.

**Ángulo de incidencia:** El ángulo de incidencia  $\theta$  se define como el ángulo formado entre el haz de radar y una línea perpendicular a la superficie (*nadir*). Las interacciones de las microondas con la superficie son complejas, y pueden generarse diferentes reflexiones en diferentes regiones angulares. El retorno de la señal es normalmente fuerte a bajos ángulos de incidencia y disminuye con el aumento del ángulo de incidencia.

### 4.1.1.5. Interacción con la superficie

#### MECANISMOS DE RETRODISPERSIÓN

Las imágenes SAR representan una estimación de la retrodispersión de radar en un área determinada de la superficie. Las áreas oscuras en la imagen representan baja retrodispersión, mientras que áreas brillantes representan alta retrodispersión. Las zonas brillantes en la imagen se originan cuando una alta fracción de la energía de radar es reflejada hacia el radar, mientras que características oscuras implican que muy poca energía fue reflejada. Como puede apreciarse en la figura 4.7, la retrodispersión de una superficie sensada con una longitud de onda particular, y en consecuencia su apariencia en la imagen radar, varía dependiendo de condiciones como el tamaño físico de los retrodispersantes, las propiedades eléctricas, y el contenido de humedad.



**Figura 4.7:** Apariencia de diferentes tipos de superficies (bosque, agua, cultivos, ciudad) en una imagen radar TerraSAR de Bonn, Alemania. Fuente de la imagen TerraSAR: [rst.gsfc.nasa.gov](http://rst.gsfc.nasa.gov)

#### 4. Delimitación de cuerpos de agua: Introducción y definiciones

---

Como se puede observar en la figura 4.8, existen distintos tipos de retrodispersión o reflexión, de los cuales los principales son los siguientes:

- **Reflexión Difusa:** este tipo de interacción se produce cuando la superficie que se observa es rugosa. El grado de rugosidad va a influenciar la intensidad de la señal de retorno.
- **Reflexión Especular:** cuando la señal de radar interactúa con una superficie 'lisa', esta superficie se comporta como un espejo, es decir la señal incidente y la señal retrodispersada tienen direcciones opuestas. La señal de respuesta que recibe el radar es muy baja por lo tanto se visualiza como tonos oscuros en la imagen.
- **Retrodispersión en volumen:** es el resultado de la interacción con partículas dentro de un medio no-homogéneo. Se produce cuando existen muchas interacciones entre la señal de radar y un medio. La señal retrodispersada dependerá de la densidad del medio, la geometría de los elementos dispersores y las propiedades dieléctricas de los elementos. En este caso, la señal retrodispersada es media, y se ven niveles intermedios de brillo en la imagen radar. Algunos ejemplos de superficies con dispersión en volumen son: copa de árboles, pajonales, cultivos, etc.
- **Dispersión doble rebote:** es el resultado de la interacción de una señal de radar con dos superficies perpendiculares, conocidas como *corner reflector*. Cuando se produce un mecanismo de doble rebote se observa un tono muy brillante en la imagen de radar, ya que la señal retrodispersada es muy fuerte. Algunos ejemplos de elementos que generan doble rebote son: áreas urbanas, tronco de árboles sobre superficies inundadas y barcos en el agua.

Las superficies inclinadas hacia el radar tendrán una mayor retrodispersión que superficies con pendiente opuesta al radar y tenderán a aparecer más brillantes en una imagen radar. Algunas áreas no iluminadas por el radar, como laderas detrás de montañas, están bajo sombra y aparecerán oscuras.

La forma en que la señal de radar interactúa con el blanco depende de las características del blanco y de la señal y de la geometría señal-blanco. Por lo tanto, se puede decir que la predominancia de un determinado mecanismo de interacción depende de los parámetros propios del sistema satelital, de los parámetros del blanco (características geométricas y dieléctricas del medio) y de efectos ambientales. A continuación se detalla cada uno de ellos.

- **Parámetros del sistema satelital:**
  - Ángulo de incidencia de los pulsos emitidos.
  - Frecuencia (longitud de onda) de los pulsos emitidos.
  - Polarización de los pulsos emitidos.
- **Parámetros del blanco:**
  - Heterogeneidad y rugosidad de la superficie.


#### 4. Delimitación de cuerpos de agua: Introducción y definiciones

- Características del suelo: pendiente, orientación.
  - Características de la vegetación.
  - Propiedades dieléctricas (contenido de humedad).
- Cambio en las condiciones ambientales:
- Altura del nivel del agua (inundaciones).
  - Incendios.
  - Usos del suelo.

Así como los parámetros del radar afectan a los mecanismos de interacción, cabe destacar que los mecanismos de interacción pueden afectar a la polarización de la señal. Como resultado de una interacción compleja, la señal pasa por diferentes procesos de reflexión que pueden perturbar la polarización de la señal. Por ejemplo, las reflexiones simples no afectan la polarización de la señal (si se transmite en  $H$ , se recibirá en  $H$ ; si se transmite en  $V$ , se recibirá en  $V$ ), en cambio mecanismos de interacción más complejos (múltiples) pueden despolarizar la señal (se transmite en  $H$ , pero se recibe en  $V$  o viceversa). Un blanco aparece diferente en una imagen de radar según su efecto en la despolarización de la señal.

**Comportamiento de blancos:** La relación fundamental entre las características del sistema radar, del blanco y de la señal que es transmitida por la antena (interactúa con el blanco y retorna a la antena), puede ser resumida por la **ecuación de radar**, que para un sistema monoestático puede ser definida como:

$$\bar{P}_r = \frac{P_t \lambda^2 G_0^2 \sigma^\circ}{(4\pi)^3 R^4} \quad (4.3)$$



**Figura 4.8:** Esquema de los distintos tipos de retrodispersión o reflexión. Fuente de la imagen: [Martinis \[2010\]](#).

donde  $\bar{P}_r$  es la potencia media recibida por la antena,  $P_t$  es la potencia transmitida,  $\lambda$  es la longitud de onda,  $G_0$  es la ganancia máxima de la antena,  $R$  es la distancia entre la antena y el blanco,  $\sigma^\circ$  es el coeficiente de retrodispersión (o de *backscatter*).

### 4.1.1.6. Corrección radiométrica

El proceso de calibración radiométrica consiste en la evaluación de datos de calibración internos y externos, y la generación de los factores de corrección o calibración. Estos factores son usados para corregir los datos de la imagen, estableciendo una base común para relacionar los datos numéricos de píxeles al coeficiente de retrodispersión del objeto [Curlander & McDonough, 1991]. En general, se puede definir un procedimiento de calibración radiométrica mediante los siguientes pasos:

- Evaluación de datos de calibración interna.
- Evaluación de datos de calibración externa.
- Generación de factores de corrección.
- Corrección radiométrica de los datos de la imagen.

El factor de corrección es dependiente de:

- El patrón de elevación de antena.
- El *slant range*.
- El tamaño de la celda de resolución.
- La ganancia y pérdida del sistema.

### 4.1.1.7. Coeficiente de retrodispersión o *backscattering*

El coeficiente de retrodispersión (*sigma nought*:  $\sigma^\circ$ ) representa el efecto de la superficie terrestre sobre la señal de radar, es decir el porcentaje de la energía electromagnética que es reflejada de vuelta hacia el radar desde una ‘celda o unidad de resolución’. El mismo se calcula como:

$$\sigma^\circ = \frac{\sigma}{Area} \quad (4.4)$$

El valor de  $\sigma^\circ$  para una superficie en particular depende de diversos parámetros del terreno (como la geometría, la rugosidad, el contenido de humedad) y parámetros del radar (longitud de onda, ángulo de incidencia, polarización). El coeficiente de retrodispersión es proporcional a la intensidad ( $I$ ) incidente.

Los valores de retrodispersión de las imágenes de radar pueden ser expresados de diferentes formas, tal como se muestra en la tabla 4.2. La potencia ( $P$ ), es el flujo promedio por unidad de tiempo que recibe la antena y es la representación de  $\sigma^\circ$  en potencia del coeficiente de retrodispersión. A su vez, la potencia ( $P$ ) es proporcional al cuadrado de la amplitud de la onda ( $A$ ) y por lo tanto la raíz cuadrada del  $\sigma^\circ$  en potencia es el  $\sigma^\circ$  en amplitud:

$$P \propto I \propto A^2 \quad (4.5)$$



Finalmente,  $\sigma^\circ$  puede ser también expresado en forma logarítmica, por ejemplo en decibeles ( $\sigma^\circ_{dB}$ ). Esta última representación es útil debido a que la intensidad de la respuesta del radar tiene un rango dinámico que puede alcanzar varios órdenes de magnitud en potencias de diez.

**Tabla 4.2:** Diferentes modos en que pueden ser expresados los valores de coeficiente de retrodispersión de las imágenes de radar

Potencia	Amplitud	Decibeles
$\sigma^\circ$	$\sqrt{\sigma^\circ}$	$10 \cdot \log \sigma^\circ$

### 4.1.1.8. Modelado estadístico de imágenes SAR

Sea  $X$  una variable aleatoria y  $g : \mathbb{R} \rightarrow \mathbb{R}$  una función monótona derivable, la distribución de  $X$  está caracterizada por su función de distribución acumulada  $F_X : \mathbb{R} \rightarrow [0, 1]$ . Si suponemos que la variable es continua, su distribución está también caracterizada por su densidad  $f_x : \mathbb{R} \rightarrow \mathbb{R}_+$ .

La gran mayoría de los datos provenientes de imágenes de radar de apertura sintética (SAR) no obedece la distribución Gaussiana. Esto se debe a que la iluminación que se utiliza para formar tales imágenes es de tipo coherente, en el que aparecen fenómenos de interferencia constructiva y destructiva de la señal que retorna al sensor [Frery et al., 1997]. El modelo multiplicativo, del cual se derivan las distribuciones: Gamma, Rayleigh, Raíz de Gamma, Exponencial, y las distribuciones  $\mathcal{K}$ , ha sido adecuado para modelar la señal devuelta al sensor [Frery et al., 1997].

El modelo multiplicativo supone que el valor observado en cada coordenada de la imagen es el resultado de observar la variable aleatoria  $Z$ , que a su vez es el producto de dos variables  $X$  e  $Y$  independientes ( $Z = X \cdot Y$ ).  $X$  modela el *backscatter* del terreno, mientras que  $Y$  modela el ruido *speckle* característico de estas imágenes. El modelo de *speckle* es tomado como un caso especial de un modelo multiplicativo con RCS (*radar cross section*:  $\sigma$ ) constante. El modelo estadístico para el *backscatter* dependerá de varios parámetros que están relacionados a la rugosidad y la textura del objeto [Ulaby et al., 1986]. Los datos de SAR pueden ser ajustados mediante varias distribuciones dependiendo, entre otros factores, del grado de homogeneidad de las áreas en estudio.

Para reducir el ruido *speckle*, puede ser aplicada una técnica llamada *multilook*. En este tipo de preprocesamiento,  $n$  imágenes estadísticamente independientes son generadas a partir del mismo conjunto de datos *raw* y luego, es generado un promedio de esas  $n$  imágenes que se llama imagen *multi-look*.

Según Gao [2010] los distintos formatos de *speckle* de imágenes SAR, con la hipótesis de RCS constante, pueden ser modelados por diferentes distribuciones estadísticas como se detalla a continuación:

- *Speckle* en números complejos pueden ser modelados mediante una distribución normal multivariada.

#### 4. Delimitación de cuerpos de agua: Introducción y definiciones

- *Speckle* ‘single-look’ de intensidad pueden ser modelados mediante una distribución exponencial negativa de media unitaria [Oliver, 1998].
- *Speckle* ‘single-look’ de amplitud pueden ser modelados mediante una distribución Rayleigh [Oliver, 1998].
- *Speckle* ‘multi-look’ de intensidad pueden ser modelados mediante una distribución Gamma (o Nakagami-Gamma) con media unitaria [Goodman, 1975; Moser et al., 2006a,b; Oliver, 1998]: En áreas homogéneas se observa que  $Y \sim \Gamma'(L, L)$  cuando se trata de *speckle* de intensidad padronizado, es decir de media unitaria, la distribución tiene densidad:

$$f_Y(t) = \frac{L^L}{\Gamma(L)} t^{L-1} \exp\{-Lt\}, \quad t, L > 0 \quad (4.6)$$

- *Speckle* ‘multi-look’ de amplitud pueden ser modelados mediante una distribución ‘raíz cuadrada de Gamma’.

Debido a que  $X$  para áreas homogéneas puede asumirse como constante,  $Z = a \cdot Y$ ; donde  $a > 0$  e  $Y \sim \Gamma'(L, L)$ . Esto deriva en las siguientes distribuciones para imágenes ‘multi-look’:

- Si los datos están en formato de intensidad, la distribución  $Z$  tiene la densidad:

$$f_Z(t) = \frac{L^L}{a^L \Gamma(L)} t^{L-1} \exp\left\{-\frac{L}{a}t\right\}, \quad t, L > 0 \quad (4.7)$$

la cual representa una distribución Gamma de media  $a$ .

- Si los datos están en formato de amplitud  $Z_A = \sqrt{Z}$ , siendo  $Z$  los valores en intensidad, la distribución  $Z_A \sim$  tiene la densidad:

$$f_{Z_A}(t) = \frac{2L^L}{a^L \Gamma(L)} t^{2L-1} \exp\left\{-\frac{L}{a}t^2\right\}, \quad t, L > 0 \quad (4.8)$$

la cual representa una distribución raíz cuadrada de Gamma.

- Datos en formato del logaritmo de la intensidad, tales como datos en decibeles, es decir  $Z_L = \ln Z$ , se podrían modelar mediante distribución de densidad:

$$f_{Z_L}(t) = \frac{L^L}{a^L \Gamma(L)} e^{tL} \exp\left\{-\frac{L}{a}e^t\right\}, \quad t, L > 0 \quad (4.9)$$

La aplicación del logaritmo es una transformación simple que vuelve más simétricos los datos y, por lo tanto, estos se ajustan más a una distribución Gaussiana.

Cada formato del coeficiente de retrodispersión (o *backscatter*) es útil en diferentes etapas del procesamiento de los datos. Por ejemplo, para visualizar las imágenes se utilizan en general las imágenes en valores de amplitud; mientras que para realizar procedimientos de extracción de información (clasificaciones y otros), o para hacer gráficos se usan los valores de coeficiente de retrodispersión en decibeles. La extracción de muestras de píxeles debería hacerse siempre sobre las imágenes en potencia y transformar los datos a otras magnitudes posteriormente.

### 4.1.2. COSMO-SkyMed SAR

El SIASGE (Sistema Ítalo-Argentino de satélites para beneficio de la Sociedad, Gestión de las emergencias y desarrollo Económico) será una constelación binacional que incluirá a COSMO-SkyMed ([de la Agenzia Spaziale Italiana, ASI](#)), el cual es un SAR operando en banda X (8 GHz), y a SAOCOM ([de CONAE](#)), el cual será un SAR en banda L (1.3 GHz). Los seis satélites se encontrarán ubicados en órbitas polares a la misma altura, en distintos planos orbitales, de tal manera que el conjunto funcione como un instrumento con un enorme ancho de visión sobre la tierra. Esto permitirá un monitoreo en tiempo casi real, ya que se obtendrá una frecuencia de actualización de la información menor a 12 horas, lo cual es especialmente necesario para el monitoreo y seguimiento de la evolución de catástrofes.

El sistema COSMO-SkyMed ([CONstellation of small Satellites for Mediterranean basin Observation](#)) es la mayor inversión italiana en sistemas espaciales de observación de la tierra, fundado por la 'ASI' y el ministerio italiano de defensa ('MoD'). Este sistema consiste de una constelación de cuatro satélites de tamaño medio, y se caracteriza por: cobertura global y en todas las condiciones climáticas, adquisición diurna y nocturna, alta resolución espacial, exactitud (geolocalización, radiometría, etc) y calidad de imágenes, alta resolución temporal (frecuencia de revisita/respuesta) y capacidad para interferometría.

Los tipos de productos de COSMO-SkyMed disponibles, de acuerdo al nivel de procesamiento, son los siguientes:

- **Nivel 0**, datos crudos (RAW): definido como datos crudos a bordo (después del descifrado y antes del desempaquetamiento) asociados con datos auxiliares incluyendo datos de calibración requeridos para producir productos de niveles mayores. Los datos son números complejos de fase y cuadratura ( $I$  y  $Q$ ). En el contexto de SAR, un número complejo está representado por un par de números: el componente en-fase real ( $I$ ) y el componente de cuadratura imaginario ( $Q$ ).

El procesamiento aplicado a los datos originales para conseguir este nivel de procesamiento consiste en:

- Eliminación del protocolo de transmisión.
  - Descompresión de datos.
  - Estimación de estadísticas.
  - Formateo de datos.
- **Nivel 1A**, producto *Single-look Complex Slant* (SSC): definido como datos crudos enfocados en formato complejo, y en proyección *slant range-azimuth* (proyección de adquisición natural del sensor). El procesamiento aplicado a los datos de nivel 0 es:
    - Compensación de la ganancia del receptor.
    - Calibración interna.

#### 4. Delimitación de cuerpos de agua: Introducción y definiciones

- Enfoque de datos.
  - Estimación de estadísticas de los datos de salida.
  - Formateo de datos de salida.
- **Nivel 1B**, producto *Detected Ground Multi-look* (DGM): obtenido mediante la detección, el *multi-looking* y la proyección sobre una grilla regular de los datos *Single-look Complex Slant*. Este producto, consiste en datos enfocados SAR, ecualizados radiométricamente de manera interna, sin *speckle*, detección en amplitud. El procesamiento aplicado a los datos de nivel 1A es el siguiente:
- Reducción del ruido *speckle* mediante *multi-looking*.
  - Detección de imagen (amplitud): la detección remueve la información de fase del archivo de datos.
  - Proyección elipsoide.
  - Evaluación de estadística.
  - Formateo de datos.
- **Nivel 1C (GEC) y 1D (GTC)**, producto geocodificado: obtenido mediante la proyección del producto 1A sobre una grilla regular en un determinado sistema de referencia cartográfico. En el caso del nivel 1C la superficie es el elipsoide terrestre, mientras que en el nivel 1D un DEM es utilizado para aproximar la superficie terrestre real. El procesamiento llevado a cabo en datos de nivel 1B es el siguiente:
- Reducción de ruido *speckle* mediante *multi-looking*.
  - Proyección de mapa elipsoide.
  - Evaluación de estadística.
  - Formateo de datos.

Los modos de medición (adquisición) de COSMO-SkyMed SAR son los resumidos en la tabla 4.3 y se muestran en la figura 4.9. En el apéndice E (página 184) se presenta información más detallada acerca de estos distintos modos de adquisición de COSMO.

**Tabla 4.3:** Modos de adquisición de los satélites COSMO-SkyMed.

	<b>Spotlight</b>	<b>Stripmap</b>	<b>Stripmap</b>	<b>ScanSAR</b>	<b>ScanSAR</b>
		Himage	Pingpong	Wide Region	Huge Region
Polarización	Single	Single	Dual	Single	Single
Ancho de banda ( $km^2$ )	$10 \times 10$	$40 \times 40$	$30 \times 30$	$100 \times 100$	$200 \times 200$
Resolución geométrica ( $m$ )	1	3	15	30	100

Los parámetros de calidad comunes a todos los productos COSMO-SkyMed son los siguientes:

#### 4. Delimitación de cuerpos de agua: Introducción y definiciones

- PSLR (Peak to Side Lobe Ratio)  $\leq -22$  dB. Es la relación:

$$PSLR = \frac{PLL}{PLP} \quad (4.10)$$


donde  $PLL$  es la potencia dentro de lóbulos laterales, y  $PLP$  es la potencia dentro del lóbulo principal (Fig. 4.10).

- ISLR (Integrated Side Lobe Ratio)  $\leq -12$  dB. Es la relación:


$$ISLR = \frac{PLL}{PD} \quad (4.11)$$

donde  $PLL$  es la potencia dentro de lóbulos laterales y  $PD$  es la potencia dentro del diagrama (integrada a partir de varios lóbulos provenientes de ambos lados del principal) (Fig. 4.11).


- *Azimuth Point Target Ambiguity*  $\leq -40$  dB. La ambigüedad es una forma ‘fantasma’ que



**Figura 4.9:** Modos de adquisición de los distintos satélites COSMO-SkyMed: *Himage*, *PingPong*, *WideRegion*, *HugeRegion*, *Spotlight*. Adaptado de: [COSMO-SkyMed SAR Products Handbook](#).




**Figura 4.10:** Esquema de PSLR (Peak to Side Lobe Ratio): relación entre la señal retornada del lóbulo principal y la de lóbulos laterales.



**Figura 4.11:** Esquema de ISLR (Integrated Side Lobe Ratio): relación entre la energía retornada del lóbulo principal y la integrada a partir de varios lóbulos provenientes de ambos lados del principal.

ocurre cuando el muestreo de la señal retornada es demasiado bajo. En la figura 4.12 se muestra un ejemplo de ambigüedades en una imagen ENVISAT, producto IMS (Single Look Complex data).



**Figura 4.12:** Ambigüedades en una imagen ENVISAT, específicamente de un producto IMS (Single Look Complex data).

- *Radiometric Accuracy*  $\leq -1$  dB (single look): la exactitud radiométrica se define como el promedio (en una serie de tiempo) de la diferencia absoluta entre la  $\sigma^{\circ}$  nominal y la  $\sigma^{\circ}$  medida (empleando la misma constante de calibración) de un objeto de calibración.
- *Radiometric Linearity*  $\leq -1,5$  dB.
- *Radiometric Stability*  $\leq -1$  dB. La estabilidad radiométrica se define como la desviación estándar de las medidas (en una serie temporal) de  $\sigma^{\circ}$  de un objeto de calibración (empleando la misma constante de calibración).
- *Total Noise Equivalent (NE)  $\sigma^{\circ}$*   $\leq -19$  dB  $m^2/m^2$ . Es una medida de la sensibilidad, describe la fuerza del ruido del sistema en términos de la potencia promedio equivalente en el dominio de la imagen que resultaría de una retrodispersión distribuida idealmente. Valores chicos de  $\sigma^{\circ}$  son mejores. El límite superior del NE  $\sigma^{\circ}$  de una imagen puede ser estimado mediante medición de  $\sigma^{\circ}$  de regiones de baja intensidad (como océanos y cuerpos de agua internos).

### 4.2. Metodologías de detección de cuerpos de agua: estado del arte

Los sensores satelitales representan una herramienta de gran utilidad para el análisis de extensas regiones, incluso con compleja variabilidad estacional y de difícil acceso, reduciendo el costo de recursos y de tiempo.

El sensado remoto provee estimaciones hidrológicas indirectas a través, por ejemplo, de interferometría [Aldorf et al., 2001] o de imágenes visibles o radar [Smith, 1997]. Tanto los

#### 4. Delimitación de cuerpos de agua: Introducción y definiciones

---

sensores activos como los pasivos, en el rango de longitudes de onda de las microondas, son sensibles a cuerpos de agua en superficie y son adecuados para estudios multitemporales debido a su capacidad de funcionamiento en todas las condiciones meteorológicas y situaciones diurnas y nocturnas. Particularmente, los radares de apertura sintética (*satellite-borne Synthetic Aperture Radars: SAR*) han sido reconocidos como importantes instrumentos para el monitoreo de superficies con agua.

Según Jensen [2000] existen diversas ventajas del sensado remoto de radar, particularmente los radares de apertura sintética respecto al uso de imágenes ópticas, destacándose las siguientes:

- Funcionamiento en todas las condiciones meteorológicas: posibilidad de traspasar y analizar áreas cubiertas de nubes.
- Capacidad de penetración en la vegetación, aire, y superficies con capas de nieve.
- Funcionamiento tanto diurno como nocturno: capacidad de iluminación propia (sensor activo) posibilitando que el ángulo de iluminación sea controlado y que la cobertura se pueda llevar a cabo tanto en situaciones diurnas como nocturnas.

Además de las ventajas anteriormente mencionadas, una de las ventajas más importantes del uso de imágenes SAR radica en su habilidad de distinguir entre las clases *agua* y *tierra* (clase que abarca distintos tipos de cobertura), dada por el gran contraste que existe en el comportamiento de estas clases frente a la radiación de SAR. La clase *tierra* está definida como el conjunto de todas las coberturas que no corresponden a la clase *agua*. Los cuerpos de agua actúan como una superficie reflectora especular, su respuesta es baja (bajo coeficiente de retrodispersión en imágenes SAR) y entonces, luce como un área oscura. La tierra, por su parte, devuelve mucha mayor cantidad de energía al radar debido por ejemplo a la rugosidad de superficie y esto genera el alto contraste entre las superficies: *tierra* y *agua*. Este patrón puede observarse en la figura 5.7 en donde se muestra el histograma de valores de retrodispersión en dB para clase *agua* y *no-agua* en una imagen con proporciones similares de ambas clases. La moda de valores de dB más bajos corresponde a los píxeles con *agua*, mientras que el resto de las coberturas se concentran en la moda ubicada hacia valores más grandes de retrodispersión.

Es importante en este punto destacar que fuertes condiciones de vientos pueden dar lugar a perturbaciones, olas o movilización en el cuerpo de agua. Las longitudes de onda de la región de las microondas son sensibles a estas modificaciones en el cuerpo de agua, así como a todo tipo de escorrentía en la misma, dependiendo de la magnitud de las dichas modificaciones. Estas perturbaciones dan lugar a una mayor retrodispersión y, por lo tanto, disminuyen el contraste entre las superficies de *agua* respecto a las de otras coberturas. Esto está condicionado y directamente relacionado al tamaño del cuerpo de agua. Se puede considerar que este fenómeno no se aprecia o es casi imperceptible en superficies de *agua* pequeñas. Sin embargo, este fenómeno debe considerarse a la hora de analizar resultados provenientes de datos de sensores en microondas, tales como SAR.

Diferentes técnicas de procesamiento de imágenes son empleadas para delimitar áreas cu-

biertas de agua a partir de imágenes SAR [Brivio et al., 2002]. Entre los algoritmos de clasificación supervisada (es decir, que requieren supervisión del analista para la selección de muestras o para la clasificación en si) que han sido propuestos para la identificación de cuerpos de agua se pueden mencionar los siguientes: selección de umbrales, clasificación de máxima verosimilitud, técnica estadística de contornos activos, y análisis de medidas de textura [Giordano et al., 2005]. Aunque la mayor parte de los cuerpos de agua pueden ser fácilmente reconocidos visualmente, la detección automática continúa siendo una difícil tarea, y la creciente cantidad de datos SAR obliga al desarrollo de herramientas automáticas o semi-automáticas para lograr una rápida interpretación de los mismos.

Tradicionalmente, la detección de cuerpos de agua en SAR ha sido llevada a cabo mediante la selección de umbrales en la imagen de intensidad [Brivio et al., 2002]. Sin embargo, la selección de umbrales tiene problemas en la separación agua y tierra, por ejemplo, a diferentes ángulos de incidencia. Una metodología adecuada de detección de superficies de agua debería ser independiente del ángulo de incidencia del sensor.

En relación a la detección de cuerpos de agua en imágenes radar SAR, no existe un único método que pueda considerarse apropiado para todas las imágenes, no todos los métodos son igualmente buenos para los distintos tipos de imágenes [Pal & Pal, 1993].

Un cuerpo de agua cuya rugosidad es determinada por el criterio *Rayleigh* puede ser modelada como de dispersión especular (bajos valores de retrodispersión) y esta dominado por tonos oscuros en la imagen SAR [Horritt et al., 2003]. Debido a la naturaleza horizontal del agua, imágenes adquiridas con modo de polarización *HH* son preferidas antes que las de polarización *VV*. Del mismo modo, se supone que a mayor ángulo de incidencia se produce un mayor contraste entre el agua y el resto de las superficies de la tierra. Por otro lado, para detectar inundación bajo una algún tipo de canopia vegetal, sensores midiendo tanto en banda C como en banda L son adecuados; y la polarización *HH* es mejor que la *VV* [Bourgeau-Chavez et al., 2001]. Si existe vegetación en el cuerpo de agua analizado, se observa comúnmente un aumento en la retrodispersión del radar dependiente de la longitud de onda [Giacomelli et al., 1997]. Por ejemplo, en banda X y banda C (ver tabla 4.1) la señal es dispersada por las hojas, los tallos pequeños dentro de la canopia de los árboles. En banda P o L la señal obtiene una penetración mayor en la canopia pero interactúa fuertemente con troncos y largas ramas (Fig. 4.5).

Las diferentes metodologías utilizadas según la bibliografía para la detección de cuerpos de agua, sin vegetación emergente, en imágenes radar SAR son las siguientes:

### 1. Interpretación visual:

Información acerca de esta metodología se puede encontrar en Oberstadler et al. [1997]. Mediante esta aproximación, se digitalizan visualmente los límites de los cuerpos de agua y por lo tanto, no existe automatización en el proceso.

### 2. Selección de umbrales (*Thresholding*):

Información acerca de esta metodología se puede encontrar en Deshmukh & Shinde



[2005]; Otsu [1979].

La selección de un valor de gris *umbral* en una imagen en valores de grises es una técnica de segmentación ampliamente utilizada. Se basa en la clasificación de regiones uniformes dentro de una imagen mediante la determinación de un umbral con algún criterio. La operación de selección de un umbral puede ser vista como una operación que implica realizar comprobaciones frente a una función  $T$  de la forma:

$$T = T\{x, y, A(x, y), f(x, y)\} \quad (4.12)$$

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  $(x, y)$  [Belmonte & Caamaño, 2009].

Este es un método simple pero ampliamente usado y eficiente para generar una imagen binaria [Deshmukh & Shinde, 2005], el cual clasifica una imagen píxel a píxel dependiendo del valor del píxel. Los límites de las clases son típicamente seleccionados empíricamente evaluando el histograma de la imagen [Ahtonen & Hallikainen, 2005]. Un método de selección de umbral para niveles de grises de un histograma de una imagen es encontrado en Otsu [1979]. En este trabajo se determinan clases mediante un umbral calculado a partir de un histograma de niveles de grises de una imagen normalizada, evaluando la maximización de la varianza entre las clases definidas; es decir, su separabilidad.

Una desventaja de la selección de umbrales es su sensibilidad al disturbio o ruido causados por el característico patrón de *speckle* en imágenes SAR, o bien por la presencia de vegetación en estas imágenes.

### 3. Análisis de textura:

El análisis de la textura de una imagen se basa en el cálculo de un conjunto de métricas que brindan información acerca de la disposición espacial de intensidades en una imagen o en una región de la misma. La textura se puede definir como un atributo que representa la disposición espacial de los niveles de grises de los píxeles en una región [Castleman, 1996]. Ésta intenta cuantificar la naturaleza de la variación del nivel de grises dentro de un objeto. Una característica de textura, por lo tanto, es un valor que cuantifica en algún sentido la variación de nivel de gris en el mismo.

Mediante las técnicas de análisis de textura, se describe la distribución de niveles de grises del vecindario de cada píxel calculando variables estadísticas que cuantifican propiedades como la variabilidad, el contraste, valor medio, etc. y que permiten obtener nuevas bandas de información. Estas bandas de textura pueden utilizarse de forma aislada o combinadas con bandas espectrales para clasificar las imágenes originales [Fernández Sarría et al., 2003].

*Medidas de variación espacial*

Los índices numéricos de textura se orientan a medir la variedad espacial entre los DN (*digital numbers*) de los píxeles que forman la imagen. Se puede dividir a estos índices entre 1) los que operan sobre toda la imagen, por ejemplo la desviación estándar, dimensión fractal, autocorrelación espacial y semi-variograma, y 2) 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, etc.

La información sobre la textura de una imagen se utiliza tanto para la segmentación (división en segmentos homogéneos) como para la clasificación de imágenes. El análisis de textura en sensado remoto se basa en la extracción de características estadísticas [Ruiz Fernandez et al., 2001].

Para crear un sistema que distinga entre distintos objetos, primero se debe decidir qué características de los objetos deben ser medidas para generar parámetros descriptivos. Los atributos particulares que se miden se llaman ‘características 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 estos son utilizados para identificar los objetos. El valor medio y la desviación estándar son dos características muy utilizadas para la clasificación [Theodoridis & Koutroumbas, 2002].

En general, existen diferentes modos de calcular características de textura para la segmentación de imágenes. Sin embargo, para lograr buena precisión es importante elegir características de textura que permitan una buena separación entre diferentes clases, y por lo tanto den lugar a clasificadores simples y robustos [Theodoridis & Koutroumbas, 1999]. Algunos trabajos que se pueden citar en el contexto del uso de textura de la imagen en clasificaciones son los siguientes:

- Sali & Wolfson [1992] analizan la varianza de la imagen.
- Kokare et al. [2003] analizan la distancia Euclidiana.
- Ahtonen et al. [2004]; Belmonte & Caamaño [2009]; Solbø et al. [2004] implementan una clasificación de máxima verosimilitud (*ML*) basada en textura, la cual produce buenos resultados independientemente del ángulo de incidencia. No obstante, el problema que mencionan es la presencia de vegetación en agua, la cual genera suficiente variabilidad como para dificultar la caracterización de agua. El método propuesto por Ahtonen et al. [2004] impone una **pre-clasificación** basada en la determinación de un umbral a partir del histograma de la imagen SAR.

Para esta determinación, en Belmonte & Caamaño [2009] surge un método denominado **MIMO** (mínimo local entre modas), el cual resulta de estudiar diversas tipologías de histogramas y determinar sus patrones de formas. La implementación del Detector Automático de Agua (*AutomaticWaterDetector*) de ese trabajo se realizó en el lenguaje de programación Java y es una nueva funcionalidad para el software ImageJ (ver sección 4.2.0.1).

- Seiler et al. [2009] se basa en el cálculo de la **matriz de co-ocurrencia**, para cada posición de una ventana móvil. Por medio de esta matriz, diferentes parámetros estadísticos tales como la homogeneidad, el contraste, la varianza, la entropía y la correlación, son determinados siguiendo a Haralick et al. [1973].

### 4. Contornos activos:

Los algoritmos de contornos activos (o *Snakes*) usan estadísticas de la imagen para delinear objetos en la misma. La idea es que la serpiente (representado por un contorno cerrado discreto de nodos unidos) es colocada inicialmente sobre un área aproximadamente homogénea la cual será delimitada.

El contorno curvilíneo dinámico es representado como una serie de nodos ligados por segmentos de líneas [Horritt et al., 2001]. La ‘serpiente’ estadística es formulada como un proceso de minimización de energía [Ivins & Porrill, 1994].

La técnica implica la estimación de la intensidad media local (tono) y la varianza (textura) en un nodo usando los píxeles entre este y sus nodos adyacentes. La energía total es minimizada si el contorno incluye a una región de píxeles que son homogéneos en tono y textura. Esta energía también tiene contribución de la energía generada por tensión interna y restricción de curvatura [Mason et al., 2010].

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 de varianza, fue desarrollado por Kass et al. [1988]. El mismo 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* [Cohen & Cohen, 1993], *baloon snakes* [Cohen, 1991], contornos deformables [McInerney & Terzopoulos, 1997] y *gradient vector flow snakes* [Chenyang & Prince, 1997], que resultan muy poco robustos en imágenes con ruido y son muy sensibles a modificaciones en los parámetros, como se muestra en el artículo Dumitras & Venetsanopoulos [2001].

Otra clase de algoritmos de contornos activos son aquellos basados en regiones. En Germain & Refregier [2001] se presenta un algoritmo de este tipo para datos que siguen la ley de probabilidad Gamma ( $\Gamma$ ). 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 modelaría apropiadamente los datos SAR provenientes de regiones muy heterogéneas.

El modelo de contorno activo requiere que su polilínea sea inicializada sobre un área que contenga el tipo de píxeles deseados (localización de semillas). Por otra parte, un factor

importante que afecta la exactitud de este algoritmo es la selección de parámetros (seleccionados empíricamente). Algunos trabajos que se pueden citar en el contexto del uso de contornos activos en clasificación son los siguientes: [Ahtonen & Hallikainen \[2005\]](#); [Horritt \[1999\]](#); [Mason et al. \[2010\]](#). Este método ha sido satisfactoriamente usado para la delimitación de áreas inundadas [[Ahtonen et al., 2004](#)].

### 5. 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. Los procedimientos más usuales, dentro de este esquema, son el crecimiento de regiones (*region growing*) y el *split and merge*. Estos métodos comienzan por una región de píxeles ‘semilla’, la cual es seleccionada automáticamente o proporcionada por el usuario. Luego se examinan los píxeles vecinos para corroborar si tienen características similares al inicial y de ser así, el píxel vecino que cumpla con tal condición de similitud, es agrupado junto con los anteriores para conformar una región. Una crítica a estos procedimientos es que el resultado obtenido es demasiado dependiente de las condiciones iniciales.

Algunos trabajos que se pueden citar en el contexto del uso de crecimiento de regiones en clasificación son los siguientes: [Angiati & Dellepiane \[2010\]](#); [Dellepiane et al. \[2010\]](#); [Liebe et al. \[2009\]](#); [Marques Palha et al. \[2003\]](#); [Sousa Junior et al. \[2005\]](#); [Sousa Júnior et al. \[2003\]](#). En este último se utilizaron imágenes COSMO-SkyMed (CSK) con los modos *Spotlight* y *Stripmap*.

### 6. Detección de bordes:

La detección de bordes es uno de los métodos más comúnmente usados en el análisis de imágenes. Un borde es el límite entre un objeto y el fondo. Técnicamente, la detección de bordes es el proceso de localización de los píxeles de borde y el realce de los mismos lo cual aumenta el contraste entre los bordes y el fondo de modo que estos se hagan más visibles.

Para localizar un borde o contorno en la imagen se debe 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.

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 o filtrado.

Uno de los trabajos que pueden citarse en el ámbito de la detección de bordes en imágenes SAR es [Gambini et al. \[2006\]](#), en el cual se propone una técnica para la detección

de límites en imágenes con *speckle* basada en contornos activos y en las propiedades estadísticas de datos con *speckle*. En [Gambini et al. \[2008\]](#) se compara la exactitud de cinco aproximaciones para la detección de contornos en imágenes con *speckle*, mientras que en [Frery et al. \[2010\]](#) se presenta una aproximación para la detección de límites de regiones en imágenes SAR polarimétricas basada en el uso de contornos activos *B-Spline*.

### 4.2.0.1. Tecnologías existentes para clasificación de imágenes SAR

A continuación se listan los programas actualmente disponibles que poseen algún tipo de algoritmo de clasificación o segmentación de imágenes SAR.

- **SegSAR software:** Se trata de un software diseñado para imágenes satelitales ópticas y radar. SegSAR es un clasificador híbrido que utiliza técnicas de crecimiento de regiones, detección de bordes, test de homogeneidad para regiones (*split*), y test de homogeneidad entre regiones (*merging*). Es un clasificador jerárquico y multi-nivel que no fue desarrollado específicamente para imágenes SAR. Del mismo modo, no posee un algoritmo específico para la detección automática de agua.
- **SPRING Software [Camara et al. \[1996\]](#):** Es un producto desarrollado por el Instituto Nacional de Investigaciones Espaciales (INPE). Este programa no posee un algoritmo específico para la detección automática de agua.
- **ImageJ Software:** Es un programa de dominio público de procesamiento de imágenes desarrollado 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. Este software posee un algoritmo específico para la detección automática de agua [[Belmonte & Caamaño, 2009](#)].
- **InfoPACK:** está especializado en datos SAR. Este paquete proporciona algoritmos avanzados para imágenes SAR junto con una simple interfaz de usuario. Algunas aplicaciones incluyen: *Intensity Segmentation (single image; multitemporal; multipolarisation)*, *Speckle Reduction*, *Texture Segmentation*, *Segmentation Postprocessing*, *classification*, *Edge detection*, *Point Target detection (CFAR-based)*, *Large Area Change detection*. Este programa no posee un algoritmo específico para la detección automática de agua.
- **CAESAR:** especializado en datos SAR. Los algoritmos MUM (*Merge Using Moments*) [[Cook et al., 1994](#)] y RWSEG [[White, 1986](#)] son implementados y fueron desarrollados específicamente para datos SAR. Este software no posee específicamente un algoritmo para la detección automática de agua.
- **PolSARpro:** fue desarrollado por la ESA (*European Space Agency*: Agencia espacial europea). Es una herramienta de educación y procesamiento de datos SAR polarimétricos, cuyo objetivo es facilitar la accesibilidad y explotación de conjunto de datos SAR multipolarizados incluyendo a ALOS PALSAR, Envisat ASAR, RADARSAT-2 y TerraSAR-X.

## 4.3. Conceptos empleados en la metodología

### 4.3.1. Modelo Gaussiano multivariado

En teoría de probabilidad, la distribución normal multivariada o distribución Gaussiana multivariada es una generalización de la distribución normal unidimensional (o univariada) a mayores dimensiones. Se dice que un vector aleatorio es distribuido de manera normal multivariada si cada combinación lineal de sus componentes tiene una distribución normal univariada. Una variable aleatoria  $X = [X_1 \cdots X_n]^T$  se dice que tiene una distribución Gaussiana multivariada ( $X \sim N(\mu, \Sigma)$ ) con media  $\mu \in \mathbb{R}^n$  y matriz de covarianza  $\Sigma$  si su función de densidad de probabilidad para  $n$  dimensiones está dada por:

$$p(x | \omega_c) = \frac{\exp\left\{-\frac{1}{2}(x - \mu_c)^T \Sigma_c^{-1} (x - \mu_c)\right\}}{(2\pi)^{\frac{n}{2}} |\Sigma_c|^{\frac{1}{2}}} \quad (4.13)$$

donde  $T$  indica la matriz transpuesta,  $n$  es el número de dimensiones, y  $\mu_c$  y  $\Sigma_c$  son el vector de media y la matriz de covarianza de la clase  $\omega_c$  [Frery et al., 2009]. La matriz de covarianza debe ser positiva y definida, tal que  $\Sigma^{-1}$  existe.

### 4.3.2. Clasificación de Máxima verosimilitud

La máxima verosimilitud es un método supervisado de clasificación ampliamente utilizado en sensado remoto, en la cual una distribución es asociada a cada región de entrenamiento y son estimados sus correspondientes parámetros de distribución. Los píxeles son clasificados en la clase a la cual poseen mayor probabilidad de pertenecer, maximizando una función que para cada píxel depende sólo de su nivel de gris y la probabilidad de distribución asignada a cada clase [Mejail et al., 2000].

La regla de clasificación de máxima verosimilitud empleada en este trabajo asume que los datos están distribuidos según un modelo Gaussiano (ver sección 4.3.1) y que existe independencia entre los diferentes píxeles. Dadas dos clases  $\omega_a$  y  $\omega_b$ , la clasificación asigna cada píxel  $x_{i,j}$  a una clase según:

$$x_{i,j} \in \begin{cases} \omega_a; & p(x_{i,j} | \omega_a) \geq p(x_{i,j} | \omega_b) \\ \omega_b; & p(x_{i,j} | \omega_b) > p(x_{i,j} | \omega_a) \end{cases} \quad (4.14)$$

donde  $\omega_a$  y  $\omega_b$  indican clases diferentes ( $\omega_a \neq \omega_b$ ) y  $p(x_{i,j} | \omega_c)$  es la probabilidad del píxel de pertenecer a la clase  $\omega_c \in \{\omega_a, \omega_b\}$ .

### 4.3.3. Medidas muestrales de textura

Sea  $x = (x_1, \dots, x_N)$  un vector real de datos de la imagen, algunas medidas estadísticas que pueden utilizarse como medidas de textura se mencionan a continuación.

- Media ( $\bar{x}$ ): la media aritmética (también llamada promedio o simplemente media) de un conjunto finito de números es igual a la suma de todos sus valores dividida entre el número de sumandos. Cuando el conjunto es una muestra aleatoria recibe el nombre de media muestral siendo uno de los principales estadísticos muestrales. Expresada de forma más intuitiva, podemos decir que la media (aritmética) es la cantidad total de la variable distribuida a partes iguales entre cada observación.

La media ( $\bar{x}$ ) se define como:

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (4.15)$$

Esta medida de textura se utiliza, para la clasificación de cuerpos de agua, en el trabajo de [Solbø et al. \[2004\]](#).

- Varianza ( $S^2(x)$ ): es una medida de dispersión definida como la esperanza del cuadrado de la desviación de dicha variable respecto a su media. Está medida en unidades distintas de las de la variable. La varianza tiene como valor mínimo 0. Hay que tener en cuenta que la varianza puede verse muy influida por los valores atípicos.

La varianza ( $S^2(x)$ ) se define como:

$$S^2(x) = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 \quad (4.16)$$

Esta medida de textura se utiliza, para la clasificación de cuerpos de agua, en el trabajo de [Solbø et al. \[2004\]](#).

- Desviación estándar ( $S(x)$ ): La desviación estándar o desviación típica es una medida de centralización o dispersión, de gran utilidad en la estadística descriptiva. Se define como la raíz cuadrada de la varianza. La desviación típica es una medida (cuadrática) que informa de la media de distancias que tienen los datos respecto de su media aritmética, expresada en las mismas unidades que la variable.

La desviación estándar ( $S(x)$ ) se define como:

$$S(x) = \sqrt{S^2(x)} \quad (4.17)$$

- Coeficiente de asimetría estadística (*Skewness*:  $\hat{\gamma}_1(x)$ ): Las medidas de asimetría son indicadores que permiten establecer el grado de simetría que presenta una distribución de probabilidad de una variable aleatoria sin tener que determinarla mediante su representación gráfica. Como eje de simetría consideramos una recta paralela al eje de ordenadas que pasa por la media de la distribución. Si una distribución es simétrica, existe el mismo número de valores a la derecha que a la izquierda de la media, por tanto, el mismo número de desviaciones con signo positivo que con signo negativo. Decimos que hay asimetría

positiva (o a la derecha) si la *cola* a la derecha de la media es más larga que la de la izquierda, es decir, si hay valores más separados de la media a la derecha. Diremos que hay asimetría negativa (o a la izquierda) si la *cola* a la izquierda de la media es más larga que la de la derecha, es decir, si hay valores más separados de la media a la izquierda.

El coeficiente de asimetría estadística ( $\hat{\gamma}_1(x)$ ) se define como:

$$\hat{\gamma}_1(x) = \frac{\hat{\mu}_3(x)}{S^3(x)} \quad (4.18)$$

donde

$$\hat{\mu}_3 = \frac{N}{(N-1)(N-2)} \sum_{i=1}^N (x_i - \bar{x})^3 \quad (4.19)$$

- Rango ( $DR(x)$ ): En estadística descriptiva se denomina rango estadístico o recorrido estadístico al intervalo de menor tamaño que contiene a los datos; es calculable mediante la resta del valor mínimo al valor máximo; por ello, comparte unidades con los datos. Permite obtener una idea de la dispersión de los datos. El rango se define como:

$$DR(x) = Max(x) - Min(x) \quad (4.20)$$

donde  $Max$  selecciona el valor máximo del vector  $x$  y  $Min$  determina el valor mínimo de este vector. Esta medida de textura se utiliza, para la clasificación de cuerpos de agua, en el trabajo de [Solbø et al. \[2004\]](#).

- Desviación media ( $D_m(x)$ ): La desviación media es la media de las diferencias en valor absoluto de los valores a la media.

La desviación media ( $D_m(x)$ ) se define como:

$$D_m(x) = \frac{1}{N} \sum_{i=1}^N |x_i - \bar{x}| \quad (4.21)$$

- Curtosis ( $\hat{\gamma}_2(x)$ ): es una medida de la forma o apuntamiento de las distribuciones. Así las medidas de curtosis (también llamadas de apuntamiento o de concentración central) tratan de estudiar la mayor o menor concentración de frecuencias alrededor de la media y en la zona central de la distribución.

La curtosis ( $\hat{\gamma}_2(x)$ ) se define como:

$$\hat{\gamma}_2(x) = \frac{\hat{\mu}_4(x)}{S^4(x)} \quad (4.22)$$

donde

$$\hat{\mu}_4(x) = \frac{N^2 - 2N + 3}{(N-1)(N-2)(N-3)} \sum_{i=1}^N (x_i - \bar{x})^4 - \frac{3(S^2(x))^2(N-1)(2N-3)}{N(N-2)(N-3)} \quad (4.23)$$



- Mediana ( $Q_2(x)$ ): En el ámbito de la estadística, la mediana es el valor de la variable que deja, una vez ordenados los datos, el mismo número de datos antes y después que él. De acuerdo con esta definición, el conjunto de datos menores o iguales que la mediana representarán el 50% de los datos, y los que sean mayores que la mediana representarán el otro 50% del total de datos de la muestra. La mediana coincide con el percentil 50, con el segundo cuartil y con el quinto decil. Sea el vector  $x$ . el vector  $x$  ordenado ascendentemente, tal que se escribe  $a(\cdot) = (a_{N:1}, \dots, a_{N:N})$ . La mediana se define como:

$$Q_2(x) = \begin{cases} x_{N:[\frac{N}{2}]+1} & \text{si } N \text{ es impar} \\ \frac{1}{2}(x_{N:\frac{N}{2}} + x_{N:\frac{N}{2}+1}) & \text{si } N \text{ es par} \end{cases} \quad (4.24)$$

#### 4.3.4. Matriz de correlación

Para evaluar el grado de correlación entre las distintas medidas de textura, se realizó una matriz de correlación para las mismas.

La correlación indica la fuerza y la dirección de una relación lineal entre dos variables aleatorias. Se considera que dos variables cuantitativas están correlacionadas cuando los valores de una de ellas varían sistemáticamente con respecto a los valores homónimos de la otra: si tenemos dos variables ( $X$  y  $Y$ ) existe correlación si al aumentar los valores de  $X$  lo hacen también los de  $Y$  y viceversa. La correlación entre dos variables no implica, por sí misma, ninguna relación de causalidad. Una matriz de correlación es una tabla de doble entrada, que muestra una lista multivariable horizontalmente y la misma lista verticalmente y con el correspondiente coeficiente de correlación llamado  $r$ , es decir la relación entre cada pareja de variables, en cada celda con un rango de valores de  $-1$  a  $1$ .

Sea una muestra de  $n$  observaciones o muestra de tamaño  $n$  para dos variables  $X$  e  $Y$ , denotada por:

$$M = \{(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n)\} \quad (4.25)$$

donde cada par  $(X_i, Y_i)$  representa los valores de cada variable para la  $i$ -ésima observación, con  $i = 1, 2, \dots, n$ . El coeficiente de correlación de *Pearson* ( $r$ ) es un índice que mide la relación lineal entre dos variables aleatorias cuantitativas. El coeficiente de correlación  $r$  se define como:

$$r_{xy} = \frac{n(\sum_{i=1}^n x_i y_i) - (\sum_{i=1}^n x_i)(\sum_{i=1}^n y_i)}{\sqrt{n(\sum_{i=1}^n x_i^2) - (\sum_{i=1}^n x_i)^2} \sqrt{n(\sum_{i=1}^n y_i^2) - (\sum_{i=1}^n y_i)^2}} \quad (4.26)$$

**Interpretación** El valor del índice de correlación varía en el intervalo  $[-1, 1]$ :

- Si  $r = 1$ , existe una correlación positiva perfecta. El índice indica una dependencia total entre las dos variables denominada relación directa: cuando una de ellas aumenta, la otra también lo hace en proporción constante.
- Si  $0 < r < 1$ , puede existir una correlación positiva.
- Si  $r = 0$ , no existe relación lineal. Pero esto no necesariamente implica que las variables

son independientes: pueden existir todavía relaciones no lineales entre las dos variables.

- Si  $-1 < r < 0$ , puede existir una correlación negativa.
- Si  $r = -1$ , existe una correlación negativa perfecta. El índice indica una dependencia total entre las dos variables llamada relación inversa: cuando una de ellas aumenta, la otra disminuye en proporción constante.

### 4.3.5. Análisis de Componentes Principales (ACP)

El Análisis de Componentes Principales (ACP) es una técnica estadística de síntesis de la información, o reducción de la dimensión (es decir, el número de variables). Es decir, el objetivo de esta técnica es reducir un conjunto de datos con muchas variables, a un menor número de variables perdiendo la menor cantidad de información posible. Esto significa, que representa una metodología utilizada para reducir la dimensionalidad de un conjunto de datos. Los nuevos componentes principales o factores serán una combinación lineal de las variables originales, y además serán independientes entre sí. Un aspecto clave en ACP es la interpretación de los factores, ya que ésta no viene dada a priori, sino que será deducida tras observar la relación de los factores con las variables iniciales (habrá, pues, que estudiar tanto el signo como la magnitud de las correlaciones).

La técnica sirve para hallar las causas de la variabilidad de un conjunto de datos y ordenarlas por importancia. El ACP construye una transformación lineal que escoge un nuevo sistema de coordenadas para el conjunto original de datos en el cual la varianza de mayor tamaño del conjunto de datos es capturada en el primer eje (llamado el Primer Componente Principal), la segunda varianza más grande es el segundo eje, y así sucesivamente. Para construir esta transformación lineal debe construirse primero la matriz de covarianza o matriz de coeficientes de correlación. Debido a la simetría de esta matriz existe una base completa de vectores propios de la misma. La transformación que lleva de las antiguas coordenadas a las coordenadas de la nueva base es precisamente la transformación lineal necesaria para reducir la dimensionalidad de datos. Una de las ventajas del ACP para reducir la dimensionalidad de un grupo de datos, es que retiene aquellas características del conjunto de datos que contribuyen más a su varianza.

Un análisis de componentes principales tiene sentido si existen altas correlaciones entre las variables, ya que esto es indicativo de que existe información redundante y, por tanto, pocos factores explicarán gran parte de la variabilidad total.

### 4.3.6. Morfología matemática

La morfología matemática (*MM*) puede ser definida como la teoría para el análisis espacial de estructuras. Es llamada morfología porque tiende a analizar la forma de los objetos y es matemática en el sentido de que el análisis es basado en la teoría de conjuntos, la geometría integral, y el álgebra matricial. *MM* no es sólo una teoría, sino también una poderosa técnica de análisis de imágenes [Soille, 2004]. De hecho, los operadores morfológicos están entre los

primeros operadores de imágenes utilizados.

Para imágenes binarias se definen operaciones morfológicas que constituyen una herramienta de extracción de componentes de la imagen útiles en la representación y descripción de la forma de las regiones. Las operaciones de la morfología matemática, apropiadamente usadas, tienden a simplificar los datos de la imagen preservando sus características de forma esenciales y eliminando irrelevancias.

La descripción básica de la morfología matemática está basada en la ‘teoría de conjuntos’. Estos conjuntos en morfología matemática representan las formas que son manifestadas en una imagen binaria o en tonos de grises. La mayor parte de su teoría ha sido desarrollada en el *Centre de Morphologie Mathématique (CMM) de l’Ecole des Mines de París*. Actualmente, el ámbito y alcance de los procesamientos morfológicos es tan amplio como el procesamiento de imágenes. Se pueden encontrar aplicaciones tales como la segmentación, restauración, detección de bordes, aumento de contraste, análisis de texturas, compresión, etc.

En morfología matemática, los objetos de la imagen son considerados como conjuntos y otros conjuntos de formas como discos y líneas son utilizadas para investigar su morfología [Soille, 2004].

**Imágenes binarias:** El valor de un píxel en una imagen binaria es 1 o 0 y un ejemplo es mostrado en la figura 4.13. Una imagen binaria  $f$  es una representación de un subconjunto  $D_f$  de  $\mathbb{Z}^n$  tal que para todos los píxeles  $p$  de la definición del dominio de la imagen,  $f(p)$  es igual a 0 o a 1. Una imagen  $n$ -dimensional ( $n - D$ ) se refiere a una imagen cuyo dominio de definición es un subconjunto del espacio discreto  $\mathbb{Z}^n - D$ .

**Transformaciones morfológicas elementales:** El objetivo de las transformaciones morfológicas es la extracción de estructuras geométricas en los conjuntos sobre los que se opera, mediante la utilización de otro conjunto de forma conocida denominado elemento estructurante ( $ES$ ). El tamaño y la forma de este elemento se escoge a priori de acuerdo a la morfología del conjunto sobre el que interactúa y de acuerdo a las formas que se pretende extraer. Por lo tanto, la forma y el tamaño de los elementos estructurantes deben ser adaptados a las propiedades geométricas de los objetos de la imagen a ser procesados.

Los operadores morfológicos fundamentales requieren la definición de un origen para cada  $ES$ . Este origen permite el posicionamiento del  $ES$  en un dado punto o píxel.

**Dilatación:** Comúnmente conocida como expansión, o crecimiento, puede ser utilizada para rellenar ‘huecos’ de un tamaño igual o menor que el elemento estructurante.

La dilatación es un conjunto de operaciones teóricas que fueron propuestas por Minkowski [1903] y fueron empleadas por diversos investigadores en procesamiento de imágenes como operaciones de suavizado [Unger, 1958]. Esta técnica fue empleada por Matheron [1965] como un operador de imágenes para extracción de forma y de parámetros.

#### 4. Delimitación de cuerpos de agua: Introducción y definiciones

La dilatación es la transformación morfológica que combina dos conjuntos usando la adición de vectores del conjunto de elementos. Si  $A$  y  $B$  son conjuntos en un  $N$ -espacio ( $E^N$ ) con elementos  $a$  y  $b$  respectivamente,  $a = (a_1, \dots, a_N)$  y  $b = (b_1, \dots, b_N)$  siendo  $N$ -tuplas de coordenadas de los elementos. La dilatación de  $A$  por  $B$  es por lo tanto, el conjunto de todas las sumas posibles de vectores de los pares de elementos.

Siendo  $A$  y  $B$  subconjuntos de  $E^N$ . La dilatación de  $A \oplus B$  es definida por:

$$A \oplus B = \{c \in E^N | c = a + b\} \quad (4.27)$$

para algún  $a \in A$  y  $b \in B$ . El ejemplo que sigue ilustra la operación de dilatación. El sistema de coordenadas utilizado en el mismo es (**filas, columnas**).

$$A = \{(0, 1), (1, 1), (2, 1), (2, 2), (3, 0)\} \quad (4.28a)$$

$$B = \{(0, 0), (0, 1)\} \quad (4.28b)$$

Siendo A:	$\begin{matrix} \times & \bullet & \times & \times \\ \times & \bullet & \times & \times \\ \times & \bullet & \bullet & \times \\ \bullet & \times & \times & \times \\ \times & \times & \times & \times \end{matrix}$	y siendo B:	$\begin{matrix} \bullet & \bullet \end{matrix}$	A $\oplus$ B resulta:	$\begin{matrix} \times & \bullet & \bullet & \times \\ \times & \bullet & \bullet & \times \\ \times & \bullet & \bullet & \bullet \\ \bullet & \bullet & \times & \times \\ \times & \times & \times & \times \end{matrix}$
-----------	--	-------------	---	-----------------------	--

$$A \oplus B = \{(0, 1), (1, 1), (2, 1), (2, 2), (3, 0), (0, 2), (1, 2), (2, 2), (2, 3), (3, 1)\} \quad (4.29)$$

Usada en imágenes binarias, la dilatación es similar a la convolución. Sobre cada píxel de la imagen, el origen del elemento estructurante es superpuesto. Si el píxel de la imagen no es cero, cada píxel del elemento estructurante es adicionado utilizando el operador lógico ‘o’.

**Erosión:** La erosión provoca que pequeños elementos aislados menores que el elemento estructurante sean removidos.

La transformación de erosión es el resultado de comprobar si el elemento estructurante  $ES B$  está totalmente incluido dentro del conjunto  $x$ . Cuando esto no ocurre, el resultado de la erosión es el conjunto vacío.

La erosión es el complemento de la dilatación, ya que es la transformación morfológica que combina dos conjuntos usando la sustracción vectorial del conjunto de elementos. Si  $A$  y  $B$  son dos conjuntos de elementos en el  $N$ -espacio euclidiano, la erosión de  $A$  por  $B$  es el conjunto de elementos  $x$  para los cuales  $x + b \in A$  para cada  $b \in B$ .

La erosión de  $A \ominus B$  es definida por:

$$A \ominus B = \{x \in E^N | x + b \in A\} \quad (4.30)$$

para todo  $b \in B$ . El ejemplo siguiente ilustra la operación de erosión. El sistema de coordenadas

utilizado en el mismo es (filas, columnas).

$$A = \{(1,0), (1,1), (1,2), (1,3), (1,4), (1,5), (2,1), (3,1), (4,1), (5,1)\} \quad (4.31a)$$

$$B = \{(0,0), (0,1)\} \quad (4.31b)$$

	$\begin{matrix} \times & \times & \times & \times & \times & \times \\ \bullet & \bullet & \bullet & \bullet & \bullet & \bullet \\ \times & \bullet & \times & \times & \times & \times \\ \times & \bullet & \times & \times & \times & \times \\ \times & \bullet & \times & \times & \times & \times \\ \times & \bullet & \times & \times & \times & \times \end{matrix}$		$\begin{matrix} \times & \times & \times & \times & \times & \times \\ \bullet & \bullet & \bullet & \bullet & \bullet & \times \\ \times & \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times & \times \\ \times & \times & \times & \times & \times & \times \end{matrix}$
Siendo A:	y siendo B: $\bullet \bullet$		A $\ominus$ B resulta:

$$A \ominus B = \{(1,0), (1,1), (1,2), (1,3), (1,4)\} \quad (4.32)$$

Sobre cada píxel de la imagen, el origen del elemento estructurante es superpuesto. Si cada elemento no cero del elemento estructurante es contenido en la imagen, el píxel resulta uno 1.

**Filtrado morfológico:** Según Soille [2004] un filtro morfológico es una transformación no lineal que puede ser empleada en dos funciones principales: 1) restaurar una imagen degradada por algún tipo de ruido o 2) remover selectivamente estructuras u objetos de la imagen al tiempo que se preservan otros. Los dos filtros morfológicos más elementales son la apertura y el cierre. La apertura es un filtro morfológico anti-extensivo, mientras que el cierre es un filtro morfológico extensivo. Las aplicaciones básicas de los filtros morfológicos son la atenuación del ruido y la extracción selectiva de objetos en la imagen.

**Apertura y Cierre:** Las dilataciones y las erosiones son utilizadas de a pares, o bien dilatación es seguida por erosión o viceversa. Tanto el operador de apertura como de cierre tienen efecto de suavizado de la imagen. La operación de apertura remueve píxeles y la operación de cierre adiciona píxeles. Por ejemplo, la apertura de una imagen con un elemento estructurante en forma de disco, suaviza los contornos, y elimina pequeñas islas de píxeles. El cierre de una imagen con un elemento estructurante en forma de disco, fusiona redes rotas y rellena o completa pequeños huecos.

La apertura de una imagen  $B$  por un elemento  $K$ , definido como  $B \circ K = (B \ominus K) \oplus K$ , es una operación de erosión seguida por una operación de dilatación. El cierre de una imagen  $B$  por un elemento  $K$ , definido como  $B \bullet K = (B \oplus K) \ominus K$ , es una operación de dilatación seguida por una operación de erosión.

Tanto la operación de apertura como la de cierre son operadores ‘idempotente’ y por lo tanto su aplicación iterativamente más de una vez no produce efecto diferenciado, sino que se obtendrá el mismo resultado que si se realizase una sola vez.

## 4. Delimitación de cuerpos de agua: Introducción y definiciones

En las figuras 4.13 se ejemplifica una imagen binaria y los resultados de aplicar en ésta diferentes operadores morfológicos con un elemento estructurante de tamaño  $5 \times 5$  y de la forma:  $E_{s5} = \{(1, 1, 1, 1, 1), (1, 1, 1, 1, 1), (1, 1, 1, 1, 1), (1, 1, 1, 1, 1), (1, 1, 1, 1, 1)\}$  En la subfigura 4.13(a) se presenta la imagen binaria original, mientras que en las subfiguras siguientes se muestran las imágenes resultantes de aplicar un operador morfológico de dilatación, erosión, cierre y apertura respectivamente, con el definido elemento estructurante.

### 4.3.7. Matriz de confusión

La matriz de confusión es una herramienta adecuada para caracterizar la exactitud de las asignaciones temáticas y puede resumirse por medio de índices, tales como el índice Kappa.

Una matriz de confusión contiene información acerca de las clasificaciones predichas por un sistema de clasificación y las clasificaciones observadas [Kohavi & Provost, 1998]. La tabla 4.4 muestra la matriz de confusión para un clasificador de dos clases.

Las entradas en la matriz de confusión tienen el siguiente significado en el contexto de la evaluación de la clasificación que pretendemos realizar:

- $a$ : es el número de predicciones correctas de que una instancia es negativa,
- $b$ : es el número de predicciones incorrectas de que una instancia es positiva,
- $c$ : es el número de predicciones incorrectas de que una instancia es negativa, y
- $d$ : es el número de predicciones correctas de que una instancia es positiva.

**Tabla 4.4:** Ejemplo de una matriz de confusión para un clasificador de dos clases

		Predicción	
		Negativo	Positivo
Observación	Negativo	a	b
	Positivo	c	d

La exactitud (*accuracy*:  $AC$ ) es la proporción del número total de las predicciones que fueron correctas y es determinada por la siguiente ecuación:


$$AC = \frac{a+d}{a+b+c+d} \quad (4.33)$$

siendo  $a$  y  $d$  las predicciones correctas como se menciona anteriormente.

EL índice *Kappa* de concordancia para datos categóricos fue desarrollado por Cohen [1960, 1968], y fue adoptado por la comunidad de sensado remoto como una útil medida de exactitud de clasificaciones. El estadístico Kappa ( $k$ ), mide el grado de ajuste debido solo a la exactitud de la clasificación, prescindiendo del causado por factores aleatorios.


Dada la matriz de error o confusión que se muestra en la tabla 4.5:

En esta matriz, las filas representan los valores predichos, mientras que las columnas los valores observados. Cada celda representa el número de puntos que fueron clasificados como



(a) Ejemplo de una imagen binaria.

(b) Resultado de la aplicación de un operador morfológico de dilatación con el elemento estructurante  $E_{3,5}$



(c) Resultado de la aplicación de un operador morfológico de erosión con el elemento estructurante  $E_{3,5}$

(d) Resultado de la aplicación de un operador morfológico de cierre con el elemento estructurante  $E_{3,5}$



(e) Resultado de la aplicación de un operador morfológico de apertura con el elemento estructurante  $E_{3,5}$

**Figura 4.13:** Ilustración de una imagen binaria y los resultados correspondientes a la aplicación diferentes operadores morfológicos (dilatación, erosión, cierre, y apertura).

#### 4. Delimitación de cuerpos de agua: Introducción y definiciones

**Tabla 4.5:** Matriz de confusión para la determinación del estadístico *Kappa*

		j = columnas				
		<i>Datos de referencia</i>				
		<i>j</i> <sub>1</sub>	<i>j</i> <sub>2</sub>	<i>j</i> <sub><i>k</i></sub>	<i>n</i> <sub><i>i</i></sub> ·	
i = filas	<i>Clasificación</i>	<i>i</i> <sub>1</sub>	<i>n</i> <sub>11</sub>	<i>n</i> <sub>12</sub>	<i>n</i> <sub>1<i>k</i></sub>	<i>n</i> <sub>1</sub> ·
		<i>i</i> <sub>2</sub>	<i>n</i> <sub>21</sub>	<i>n</i> <sub>22</sub>	<i>n</i> <sub>2<i>k</i></sub>	<i>n</i> <sub>2</sub> ·
		<i>i</i> <sub><i>k</i></sub>	<i>n</i> <sub><i>k</i>1</sub>	<i>n</i> <sub><i>k</i>2</sub>	<i>n</i> <sub><i>k</i><i>k</i></sub>	<i>n</i> <sub><i>k</i></sub> ·
		<i>i</i> · <i>j</i>	<i>n</i> · <sub>1</sub>	<i>n</i> · <sub>2</sub>	<i>n</i> · <sub><i>k</i></sub>	<i>n</i> · <sub>·</sub> = <i>n</i>

*i* y observados como *j*. La diagonal, donde *i* = *j*, representa casos donde los valores predichos coinciden con los valores observados. Todas las celdas que no están ubicadas en la diagonal contienen valores mal clasificados, y la fila y columna describe como ese valor fue mal clasificado.

Las filas totales son el número de puntos clasificados dentro de la categoría *i* por el modelo de clasificación, y son calculadas como:

$$n_{i\cdot} = \sum_{j=1}^k n_{ij} \tag{4.34}$$

Las columnas totales son el número de puntos clasificados dentro de la categoría *j* por el testeo a campo u observación, y son calculadas como:

$$n_{\cdot j} = \sum_{i=1}^k n_{ij} \tag{4.35}$$

El estadístico *Kappa* proporciona una medida de concordancia entre los valores predichos y observados, y se calcula como:

$$k = \frac{n \sum_{i=1}^k n_{ij} - \sum_{i=1}^k n_{i\cdot} n_{\cdot j}}{n^2 - \sum_{i=1}^k n_{i\cdot} n_{\cdot j}} \tag{4.36}$$



**Tabla 4.5:** Matriz de confusión para la determinación del estadístico *Kappa*

		j = columnas				
		<i>Datos de referencia</i>				
		<i>j</i> <sub>1</sub>	<i>j</i> <sub>2</sub>	<i>j</i> <sub><i>k</i></sub>	<i>n</i> <sub><i>i</i></sub>	
i = filas	<i>Clasificación</i>	<i>i</i> <sub>1</sub>	<i>n</i> <sub>11</sub>	<i>n</i> <sub>12</sub>	<i>n</i> <sub>1<i>k</i></sub>	<i>n</i> <sub>1.</sub>
		<i>i</i> <sub>2</sub>	<i>n</i> <sub>21</sub>	<i>n</i> <sub>22</sub>	<i>n</i> <sub>2<i>k</i></sub>	<i>n</i> <sub>2.</sub>
		<i>i</i> <sub><i>k</i></sub>	<i>n</i> <sub><i>k</i>1</sub>	<i>n</i> <sub><i>k</i>2</sub>	<i>n</i> <sub><i>k</i><i>k</i></sub>	<i>n</i> <sub><i>k</i></sub>
		<i>i</i> <sub><i>j</i></sub>	<i>n</i> <sub>.1</sub>	<i>n</i> <sub>.2</sub>	<i>n</i> <sub>.<i>k</i></sub>	<i>n</i> <sub>.. = <i>n</i></sub>

*i* y observados como *j*. La diagonal, donde *i* = *j*, representa casos donde los valores predichos coinciden con los valores observados. Todas las celdas que no están ubicadas en la diagonal contienen valores mal clasificados, y la fila y columna describe como ese valor fue mal clasificado.

Las filas totales son el número de puntos clasificados dentro de la categoría *i* por el modelo de clasificación, y son calculadas como:

$$n_{i.} = \sum_{j=1}^k n_{ij} \tag{4.34}$$

Las columnas totales son el número de puntos clasificados dentro de la categoría *j* por el testeo a campo u observación, y son calculadas como:

$$n_{.j} = \sum_{i=1}^k n_{ij} \tag{4.35}$$

El estadístico *Kappa* proporciona una medida de concordancia entre los valores predichos y observados, y se calcula como:

$$k = \frac{n \sum_{i=1}^k n_{ij} - \sum_{i=1}^k n_{i.} n_{.j}}{n^2 - \sum_{i=1}^k n_{i.} n_{.j}} \tag{4.36}$$

# **Capítulo 5**

## **Delimitación de cuerpos de agua: Algoritmos**

### **5.1. Objetivos abordados en el capítulo**

El objetivo definido en este capítulo fue desarrollar una metodología para la clasificación automática de cuerpos de agua en imágenes SAR COSMO-SkyMed.

### 5.1.1. Aportes del capítulo

En el contexto de la aplicación de sensado remoto a la protección civil frente a inundaciones, el problema de detectar superficies de agua con imágenes radar SAR de alta resolución (tal como COSMO-SkyMed), es abordado en este capítulo. El uso de sensado remoto radar como una herramienta para el monitoreo de recursos hídricos es prometedor debido a su habilidad de penetrar las nubes. De la misma manera, sería deseable la extracción automática, con mínima intervención del usuario, de agua de las imágenes radar.

Tradicionalmente, la detección de cuerpos de agua basada en SAR ha sido llevada a cabo mediante la selección de umbrales en la imagen de intensidad [Brivio et al., 2002]. Sin embargo, esta aproximación, para ser aplicable, requiere datos de imágenes con ángulos de incidencia elevados, debido a que el contraste entre agua y tierra disminuye con la disminución del ángulo de incidencia [Malnes et al., 2002]. Por lo tanto, la cantidad de datos SAR adecuados para la detección de superficies con agua mediante selección de umbrales está efectivamente limitada y se deberían desarrollar métodos alternativos que detecten agua independientemente del ángulo de incidencia disponible.

Otra técnica ampliamente difundida son los modelos de contornos activos. La desventaja de estos es que requieren ser inicializados en áreas de entrenamiento de cuerpos de agua conocidos; lo cual implica que otro método de detección debe ser utilizado para este fin. Adicionalmente, estos métodos de contornos requieren que sus parámetros sean ajustados dependiendo del cuerpo de agua [Ahtonen et al., 2004].

Resulta necesario evaluar la utilidad y limitaciones de COSMO-SkyMed para aplicaciones de tipo operativo de monitoreo de cuerpos de agua. Es decir, la utilización de sus datos en sistemas de detección de cuerpos de agua que sean automáticos, robustos, e independientes del entrenamiento, la polarización o el ángulo de incidencia.

El presente capítulo consiste en el desarrollo e implementación en el lenguaje IDL de un método automático para la detección de agua en SAR COSMO-SkyMed, que puede ser capaz de formar parte de un sistema operativo de respuesta temprana y alerta a emergencias relacionadas a cuerpos de agua.

El código desarrollado en este capítulo es de dominio público y una de las ventajas de la implementación aquí realizada es la posibilidad de incorporar modificaciones en los distintos algoritmos y componentes del sistema de clasificación. De esta manera, y a diferencia de la utilización de software con clasificadores estándar, se puede lograr tanto un mejor entendimiento del sistema de detección así como también mejores resultados del mismo.

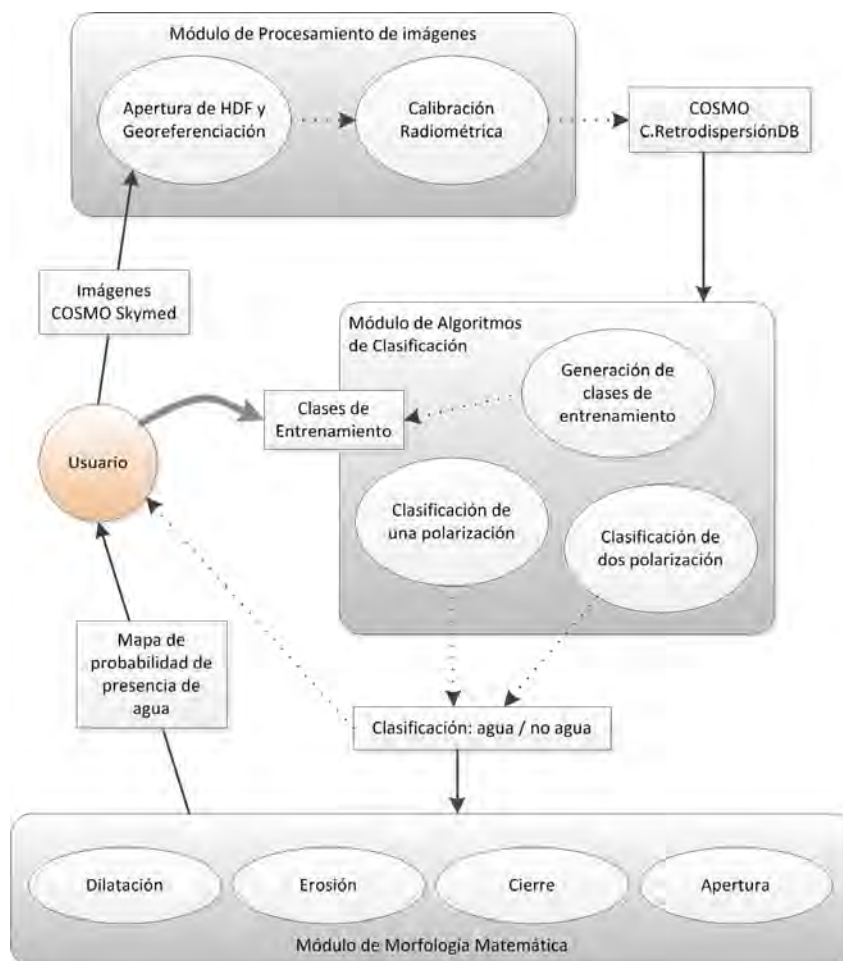
## 5.2. Materiales y métodos

### 5.2.1. Área de estudio

El área de estudio, se detalla en la sección 2.3.1.

## 5.2.2. Diagrama metodológico

En la figura 5.1, se observa el esquema general del procedimiento desarrollado. Cada paso del esquema es explicado en la sección 5.2.4.2. Todos los algoritmos de cada módulo y su respectivas interfaces gráficas (ver página 183) fueron desarrollados en el lenguaje IDL (ver 2.3.4.1).



**Figura 5.1:** Esquema de los diferentes módulos y productos que forman parte del sistema de clasificación de COSMO-SkyMed desarrollado.

## 5.2.3. Recolección y preprocesamiento de datos

### 5.2.3.1. Datos de radar

La imagen COSMO SkyMed empleada cuyo nombre de archivo es *CSKS2\_GEC\_B\_PP\_06\_CO\_RA\_SF\_20100604101137\_20100604101143.h5*, fue provista por [CONAE](#) en el contexto de la maestría en Aplicaciones Espaciales de Alerta y Respuesta Temprana a Emergencias. Los valores originales de la imagen son correspondientes a amplitud en DN (*digital numbers*). Los metadatos relativos a esta imagen son detallados en el apéndice B (ver página 177). Corresponde a una imagen PingPong con configuración de polarizaciones *HH/VV*, de aproximadamente 20 m de resolución espacial.

### 5.2.3.2. Datos ópticos

Los datos ópticos empleados, correspondientes al sensor Landsat 5 TM, son los detallados en la sección 3.3.2.1.

### 5.2.4. Especificación de la metodología

#### 5.2.4.1. Tecnología de desarrollo utilizada

La tecnología de desarrollo utilizada para la implementación de los diferentes algoritmos fue explicada en la sección 2.3.4.1.

#### 5.2.4.2. Módulos desarrollados

La implementación de los algoritmos que se exponen a continuación y sus respectivas interfaces gráficas de usuario fue llevada a cabo usando el IDE (Integrated Development Environment) IDL Workbench 7.1.1 sobre un sistema operativo GNU/Linux (Ubuntu 10.04, Kernel 2.6.32-31-generic-pae).

**Módulo de procesamiento de imágenes COSMO-SkyMed:** Este módulo realiza el preprocesamiento de imágenes COSMO requerido para su utilización en los algoritmos de clasificación posteriores.

1. Lectura y conversión de formato COSMO-SkyMed HDF a formato ENVI [ENVI, 2009]. El formato de los datos de distribución de COSMO es el HDF5 (*Hierarchical Data Format*), el cual fue desarrollado por *National Centre for Supercomputing Applications University of Illinois* y es ampliamente utilizado en muchas áreas de estudio. Algunos proyectos que usan el formato HDF son el *NASA's Earth Observing System* y el *Department of Energy's Accelerated Strategic Computing Initiative*. Los archivos HDF5 están organizados en una estructura jerárquica, la cual se representa en la figura 5.2, con dos estructuras principales: grupos y datos. Un grupo es una estructura que contiene objetos HDF5 y consta de dos partes:
  - Un *header*, el cual contiene un nombre del grupo y una lista de atributos del grupo.
  - Una tabla de símbolos, la cual es una lista de los objetos HDF5 que están dentro del grupo.

Un grupo de datos es un arreglo multidimensional de elementos de los datos, junto con metadatos correspondientes. Un set de datos es almacenado en un archivo en dos partes:

- Un *header*.
- Un arreglo de datos.

Los datos y metadatos de la imagen COSMO-SkyMed son extraídos del formato HDF5. Se genera una o varias imágenes con formato ENVI [ENVI, 2009] de acuerdo al número de bandas de datos de diferente polarización que almacena el HDF5. Se crea un archivo de texto con los metadatos correspondientes a la imagen COSMO (un ejemplo del mismo se muestra en el apéndice B: ver página 183). En este archivo de texto se incluye además la constante de calibración final, obtenida a partir de datos incluidos en los metadatos respectivos. Esta constante será posteriormente utilizada para la calibración radiométrica de la imagen COSMO-SkyMed.


Esta función de lectura y conversión de datos trabaja con cualquier modo de adquisición de los niveles de procesamiento 1A,1B,1C de COSMO-SkyMed.

La representación gráfica de la organización jerárquica de los distintos modos de adquisición del instrumento de COSMO-SkyMed que son trabajados mediante esta función se detalla en las figuras 5.3.

2. Georeferenciación de la imagen con datos de geolocalización provistos como metadatos en el HDF.

La georeferenciación es el proceso por el cual se relaciona la posición de un objeto o superficie en el plano, archivo raster y vectorial con su posición en la superficie terrestre, en el cual se requiere una superficie de referencia, con proyección y *datum*.

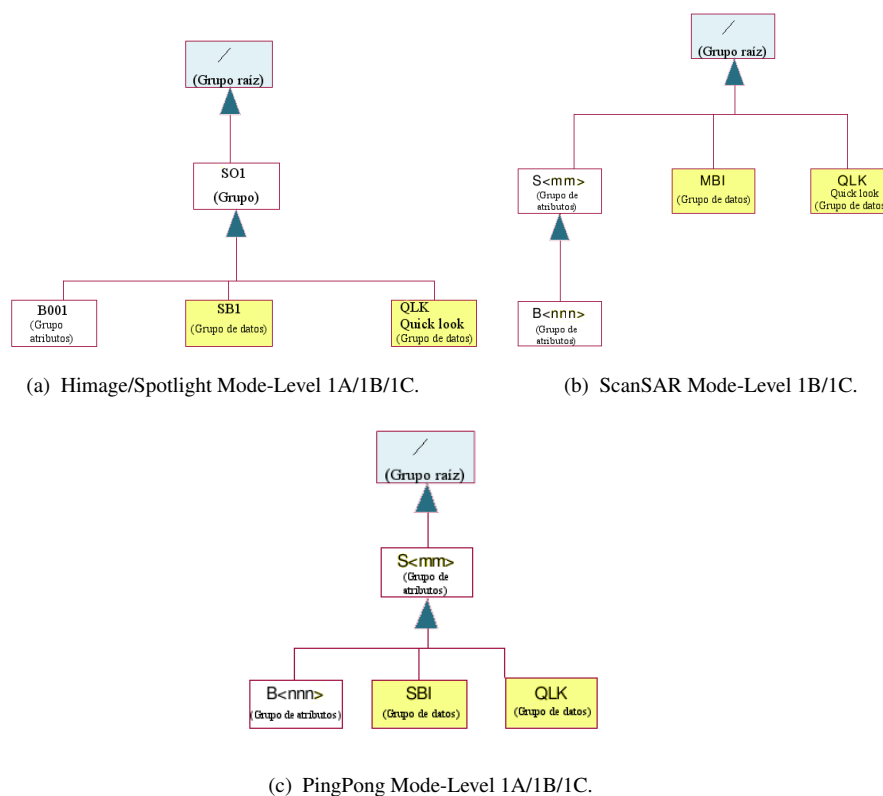
En el caso de productos COSMO-SkyMed sin geocodificación, de nivel de procesamiento 1B (4.1.2), la matriz de datos es georeferenciada mediante una función de ENVI que emplea un método de remuestreo, escalado y translación (*resampling, scaling and translation: RST*), con el remuestreo realizado a través de una convolución cúbica. El remuestreo es el proceso que calcula los nuevos valores de píxeles a partir de los valores originales en la imagen no georeferenciada. El remuestreo por convolución cúbica calcula un promedio ponderado por distancia del valor de los 16




**Figura 5.2:** Organización jerárquica del *Hierarchical Data Format (HDF5)*, el cual es el formato de distribución de los datos COSMO-SkyMed.

píxeles más cercanos de la imagen original que rodean a la nueva localización del píxel (Fig. 5.4).

3. Calibración radiométrica de COSMO-SkyMed: La calibración es el proceso por el cual se convierten los datos de amplitud medidos por el detector y guardados como



**Figura 5.3:** Organización jerárquica del formato de los distintos modos de adquisición de COSMO-SkyMed (Himage, Spotlight, ScanSAR, y PingPong).



**Figura 5.4:** Esquema del funcionamiento del método de remuestreo por convolución cúbica empleado en el módulo de georeferenciación de las imágenes COSMO-SkyMed.

DN a datos de potencia del coeficiente de retrodispersión,  $\sigma^\circ$ , corregidos por rango. La corrección por rango se realiza en los sistemas SAR porque el ángulo local del haz incidente aumenta gradualmente entre los puntos situados en el rango cercano y el lejano. Esto produce una atenuación en la respuesta para los puntos situados en el rango.

Para imágenes COSMO-SkyMed, y de acuerdo a [e-GEOS \(Compañía de Telespazio y ASI\)](#) textitSigma Nought ( $\sigma^\circ$ ) es obtenido como:

$$\sigma^\circ = \frac{1}{K} \sin(\alpha_{REF}) R_{REF}^{2j} \frac{1}{F_R^2} P_i^2 \quad (5.1)$$

donde los parámetros necesarios involucrados en el coeficiente de retrodispersión y contenidos en los metadatos de la imagen son:

- $R_{REF}$ : *slant-range reference distance*.
- $j$ : *reference slant range exponent*.
- $\alpha_{REF}$ : *reference incidence angle*.
- $F_R$ : *rescaling factor*.
- $K$ : *calibration constant*.
- $P_i$ : *image amplitude, values of COSMO-SkyMed image Level 1B (Digital numbers of amplitude, multi-look)*.

Por otro lado, la conversión a valores en decibeles ( $dB$ ) se lleva a cabo de la siguiente manera:

$$\sigma_{dB}^\circ = 10 \log_{10}(\sigma^\circ) \quad (5.2)$$

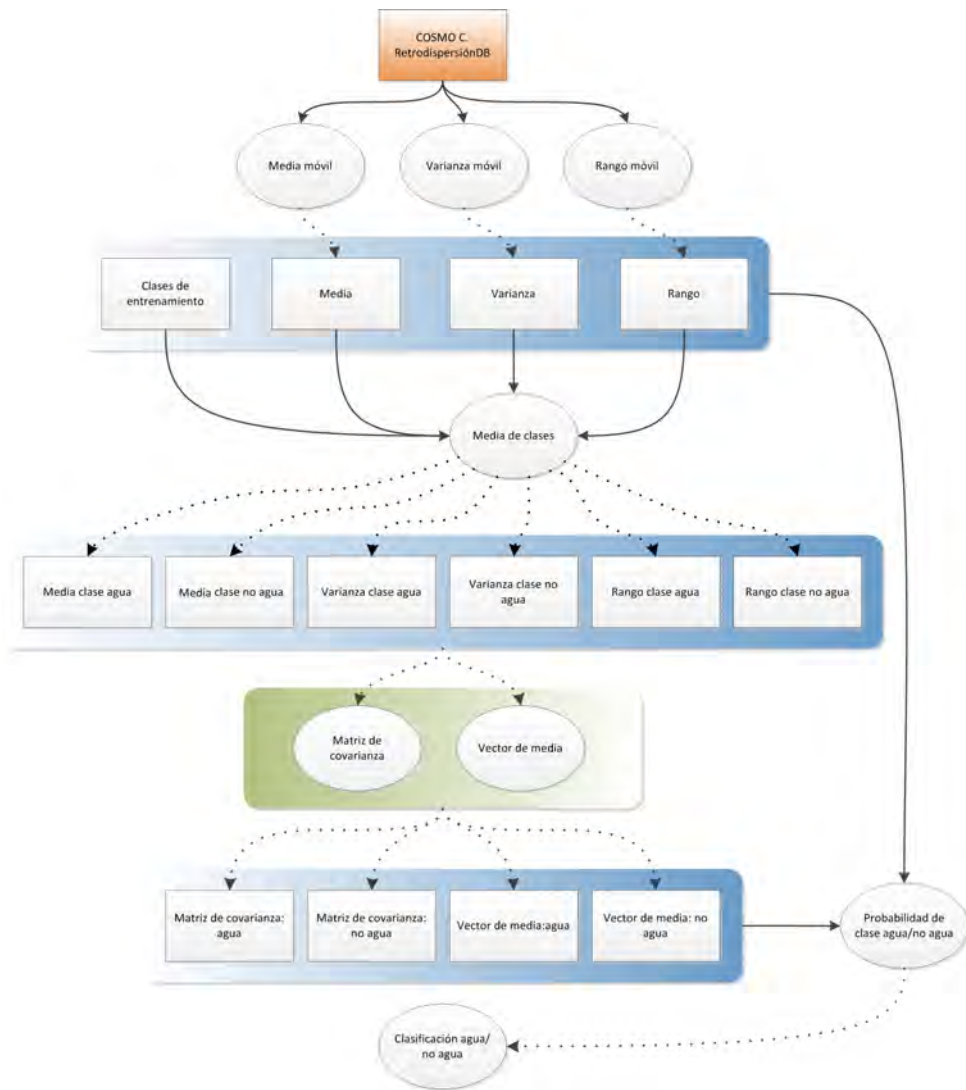
**Módulo de algoritmos de clasificación:** El sistema general de clasificación que se plantea en este capítulo consta de los siguientes pasos:

- Selección de muestras de entrenamiento.
- Estimación de parámetros necesarios para la clasificación.
- Clasificación de máxima verosimilitud, *Maximum Likelihood: 'ML'* (ver [4.3.2](#)).
- Evaluación de la matriz de confusión por medio de la determinación del porcentaje de exactitud de clasificación y *Kappa*.

El procedimiento general del clasificador 1, el cual comparte la estructura general con el resto de los clasificadores implementados, es esquematizado en la figura [5.5](#).

Las diferentes metodologías para la delimitación de cuerpos de agua en imágenes SAR COSMO-SkyMed expuestas a continuación están basadas en la determinación de variables de textura (ver sección [3](#)) de las mismas, las cuales son incluidas como entradas en clasificadores de máxima verosimilitud (ver subsección [4.3.2](#)). Los diferentes clasificadores implementados, cada uno de los cuales delimitan las mismas clases: AGUA y NO-AGUA, se resumen en la tabla [5.1](#).





**Figura 5.5:** Esquema del clasificador 1 (dentro del *Módulo de algoritmos de clasificación*), el cual comparte la estructura general con el resto de los clasificadores.

**Tabla 5.1:** Características de los seis clasificadores implementados

Clasificador n°	variables de Textura	N° de bandas COSMO-SkyMed
1	Media, Varianza, Rango (textura A)	1 de cualquier polarización
2	Media, Varianza, Rango (textura A)	2 de diferente polarización
3	Media, Varianza, Curtosis (textura B)	1 de cualquier polarización
4	Media, Varianza, Curtosis (textura B)	2 de diferente polarización
5	PCA de 8 variables de textura (textura C)	1 de cualquier polarización
6	PCA de 8 variables de textura (textura C)	2 de diferente polarización

Considerando lo expuesto en la subsección 4.1.1.8, los datos de la imagen en valores de intensidad pueden ser modelados mediante una distribución Gamma (o Nakagami-Gamma) con media unitaria. Si a estos se les aplica un logaritmo, los datos se vuelven más simétricos y estos se ajustan más a una distribución Gaussiana. Por lo tanto, se asume que los datos de las variables de textura de ambas clases (AGUA y NO-AGUA) en una imagen SAR en valores de dB pueden ser modeladas mediante una distribución de probabilidad (pdf) **Gaussiana multidimensional** (ver subsección 4.3.1).

Se denominará  $x(i, j)$ , para cada píxel  $(i, j)$ , al vector de medidas de textura de ese píxel determinado. Los diferentes clasificadores asignan el vector  $x$  a la clase con mayor probabilidad según lo especificado en la subsección 4.3.2, donde  $\omega_{na}$  y  $\omega_a$  indican las clases NO-AGUA y AGUA respectivamente.

**Entrenamiento automático: muestras de AGUA y NO-AGUA:** El entrenamiento representa un paso dentro del procedimiento de clasificación que está sujeto a errores ya que depende de múltiples fuentes de posibles incertidumbres e información contradictoria (análisis visual, experiencia previa, datos adquiridos por otros sensores en momentos diferentes) [Frery et al., 2009]. Dado que el resultado de la clasificación final es sumamente dependiente del entrenamiento, la elección del mismo es un punto crítico del algoritmo.


**Selección del umbral 1:** En este trabajo se implementa un sistema de determinación automática de muestras de entrenamiento; es decir, sin intervención del usuario. En la figura 5.6 se visualiza el esquema de la determinación del umbral para el módulo de entrenamiento automático mediante el cual se obtienen las muestras de AGUA y NO-AGUA. El umbral es definido como el mínimo entre modas, en el histograma típicamente bimodal (una moda correspondiente a la clase AGUA y otra moda correspondiente a la clase NO-AGUA) de la variable de textura **media** de la imagen.

Luego se estiman los parámetros de la distribución de probabilidad Gaussiana multidimensional  $\mu_c$  y  $\Sigma_c$  mediante las clases de entrenamiento que son determinadas por la selección de este umbral. Una imagen con este umbral aplicado es usada para delimitar los vectores de características  $x(i, j)$ , correspondientes a cada clase, los cuales son utilizados en la estimación de 5.12a y 5.12b.


Este sistema detector de agua selecciona automáticamente un umbral  $t$  para los valores de la variable **media** a través de la determinación de derivadas en el histograma. En imágenes que contienen tanto agua como sectores de superficie terrestre, sus correspondientes histogramas tendrán en general una moda correspondiente a píxeles de AGUA y una moda correspondiente a píxeles de todas las superficies que corresponden a la clase NO-AGUA (Fig. 5.7). El umbral, por lo tanto se determina analizando el histograma como una función y localizando el ‘mínimo local entre modas’, el cual cumple la condición de que: la derivada primera de la función en esa posición es cero y la derivada segunda es positiva. Definiendo la derivada primera como:

$$f'(x) = \lim_{h \rightarrow 0} \frac{f(x+h) - f(x)}{h} \quad (5.3)$$

y la derivada segunda como la derivada del resultado de la primera.



**Figura 5.6:** Esquema de la determinación del umbral para el entrenamiento automático de los clasificadores (dentro del *Módulo de algoritmos de clasificación*).



**Figura 5.7:** Histograma de una imagen COSMO-SkyMed en valores de  $\sigma^{\circ}$  (en dB) que contiene clases: AGUA y NO-AGUA (abarca el resto de las coberturas que no pertenecen a la clase AGUA). La línea roja vertical muestra el umbral propuesto para la separación entre clases

**Selección del umbral 2:** La selección automática de umbral mejorada se logra mediante el desarrollo de un algoritmo que maximiza la varianza entre las clases definidas según el histograma [Guo & Pandit, 1998].

Si se denota  $n_i$  al número de píxeles para el nivel de gris  $i$ . El número total de píxeles en una imagen dada es  $N = \sum_{i=1}^M n_i$ . El histograma es  $h_i = n_i$  y la probabilidad de ocurrencia de un nivel de gris  $i$  está definido como:

$$p_i = \frac{n_i}{N} \quad (5.4)$$

Para casos bimodales, los píxeles son divididos en dos clases  $C_0$  y  $C_1$ , mediante un umbral  $t$ :  $C_0 = \{1, 2, \dots, t\}$  y  $C_1 = \{t+1, t+2, \dots, M\}$ . El criterio discriminante es maximizar la varianza entre clases  $VAR_B$  con respecto a  $t$ , de modo que el umbral óptimo  $t^*$  está determinado por [Otsu, 1979]:

$$VAR_B(t^*) = \max_{t \in S^*} VAR_B(t) \quad (5.5)$$

lo cual satisface la medida de uniformidad de las regiones bajo separación. El rango de la variable  $t$  está restringido a

$$S^* = \{t; n_1^H < t < n_2^L\} \quad (5.6)$$

donde  $n_1^H$  y  $n_2^L$  son los niveles de grises límites rodeando al primer umbral encontrado. El cálculo de maximizar  $VAR_B$  se reduce sustancialmente cuando el rango de la variable  $t$  es restringido a  $n_1^H$  y  $n_2^L$ .

La varianza entre clases es expresada como

$$VAR_B = \omega_0 (\mu_0 - \mu_T)^2 + \omega_1 (\mu_1 - \mu_T)^2 \quad (5.7)$$

donde  $\omega_0$  y  $\omega_1$  son las probabilidades de ocurrencia de clases, y son obtenidas mediante:

$$\omega_0 = \sum_{i=1}^t p_i; \quad \omega_1 = \sum_{i=t+1}^{M-1} p_i \quad (5.8)$$

y los niveles medios de clases y total son:

$$\mu_0 = \sum_{i=1}^t \frac{ip_i}{\omega_0}; \quad \mu_1 = \sum_{i=t+1}^M \frac{ip_i}{\omega_1}; \quad \mu_T = \sum_{i=1}^M ip_i \quad (5.9)$$

**Selección del umbral final:** El umbral final es seleccionado como consecuencia de promediar el umbral 1 y el umbral 2 determinados mediante las metodologías detalladas anteriormente.

**Clasificador 1:** Características de textura A, polarización simple.

**Extracción del vector de características:** Para el clasificador 1, se calcula el siguiente vector de **características de textura A**  $x(i, j)$  para cada píxel  $(i, j)$  de una imagen COSMO-SkyMed de cualquier polarización, calibrada y en valores de  $dB$ .

$$x(i, j) = \begin{bmatrix} DR(n(i, j)) \\ \bar{n}(i, j) \\ S^2(n(i, j)) \end{bmatrix} \quad (5.10)$$

donde  $DR(n)$  es el rango de los datos,  $\bar{n}$  es la media,  $S^2(n)$  es la varianza y  $n(i, j)$  es un vector que contiene valores de la imagen en  $dB$  en un vecindario de  $3 \times 3$  centrado alrededor del píxel  $(i, j)$ .

La media se define como 4.15 y la varianza se define como 4.16. Se eligieron las características de textura: *rango*, *media* y *varianza*, debido a que en trabajos previos, tales como en el de Solbø et al. [2004], resultaron adecuados en la descripción de las clases AGUA y NO-AGUA. Si bien en Solbø et al. [2003] la media y la varianza local han demostrado ser capaces de distinguir entre estas clases; la característica rango de los datos, definida como 4.20, mejoraría la discriminación entre clases, debido a que la contribución del *speckle* multiplicativo conduce a regiones homogéneas en las clases NO-AGUA y AGUA con igual varianza, mientras que su rango difiere.

En el algoritmo de clasificación 1 para una imagen COSMO de una sola polarización, la distribución que modela las clases es una Gaussiana tridimensional (4.3.1) como se especifica en la fórmula siguiente:

$$p(x | \omega_c) = \frac{\exp\left\{-\frac{1}{2}(x - \mu_c)^T \Sigma_c^{-1} (x - \mu_c)\right\}}{(2\pi)^{\frac{3}{2}} |\Sigma_c|^{\frac{1}{2}}} \quad (5.11)$$

donde  $\mu_c$  y  $\Sigma_c$  son el vector de media y la matriz de covarianza de la clase  $\omega_c \in \{\omega_a, \omega_{na}\}$ . Los parámetros en  $p(x | \omega_c)$  son estimados a partir de datos de entrenamiento usando estimadores ML, los cuales son la media y la covarianza de la muestras.

$$\hat{\mu}_c = \frac{1}{N_c} \sum_{n=1}^{N_c} x_n \quad (5.12a)$$

$$\hat{\Sigma}_c = \frac{1}{N_c} \sum_{n=1}^{N_c} (x_n - \hat{\mu}_c) (x_n - \hat{\mu}_c)^T \quad (5.12b)$$

donde  $x_1, x_2, \dots, x_{N_c}$  son **vectores de entrenamiento** correspondientes a la clase  $c$ . A estas muestras para el entrenamiento es posible obtenerlas mediante incorporación externa al algoritmo, por ejemplo delimitadas mediante el conocimiento del área de estudio o por la existencia de catálogos de información de cuerpos de agua. O bien,

se pueden obtener mediante la selección del umbral en el histograma de la imagen en valores de ‘media’ que divide las clases AGUA y NO-AGUA, como fue explicado anteriormente en la sección 5.2.4.2, página 111.

Para mejorar la exactitud de la clasificación, se quitan los valores extremos de ambas clases, y se re-estiman  $\mu_c$  y  $\Sigma_c$ . Se define un valor extremo como vectores característicos,  $x$ , cuya **distancia de Mahalanobis** es mayor que 3 desviaciones estándar de los vectores medios de las clases:

$$(x - \hat{\mu}_c)^T \hat{\Sigma}_c^{-1} (x - \hat{\mu}_c) > 3 |\hat{\Sigma}_c|^{1/2} \quad (5.13)$$

**Resumen del algoritmo automático de detección de agua:**

- Para cada píxel  $(i, j)$  se utiliza el vecindario  $n_{i,j}$  para computar el vector característico:

$$x(i, j) = [DR(n(i, j)), \bar{n}(i, j), S^2(n(i, j))]^T \quad (5.14)$$

- Se genera el histograma de  $x(i, j) = \bar{n}(i, j)$  y se encuentra el umbral  $t$  (mínimo local entre modas, Fig. 5.7).
- Se clasifica  $\bar{n}(i, j)$  para obtener dos grupos que contienen píxeles de AGUA ( $a$ ) y NO-AGUA ( $na$ ) pre-clasificados:

$$X_{na} = \{(i, j) \mid \bar{n}(i, j) > t\} \quad \text{y} \quad X_a = \{(i, j) \mid \bar{n}(i, j) \leq t\} \quad (5.15)$$

- Se estima  $\hat{\mu}_c$  y  $\hat{\Sigma}_c$  de  $X_{na}$  y  $X_a$ .
- Se quitan valores extremos, dejando solo:

$$\tilde{X}_c = \left\{ X_c \mid (x(i, j) - \hat{\mu}_c)^T \hat{\Sigma}_c^{-1} (x(i, j) - \hat{\mu}_c) \leq 3 \sqrt{|\hat{\Sigma}_c|} \right\} \quad (5.16)$$

- Se re-estima  $\hat{\mu}_c$  y  $\hat{\Sigma}_c$  de  $\tilde{X}_{na}$  y  $\tilde{X}_a$ .
- Se clasifica un píxel  $(i, j)$  como agua si:

$$p\left(x(i, j); \hat{\mu}_a, \hat{\Sigma}_a\right) > p\left(x(i, j); \hat{\mu}_{na}, \hat{\Sigma}_{na}\right), \quad \forall x. \quad (5.17)$$

**Clasificador 2:** Características de textura  $A$ , polarización dual, 6 dimensiones.

El clasificador 2 sigue el procedimiento descrito para el clasificador 1 pero se distingue del mismo por ser un clasificador que utiliza 6 características de textura, es decir 3 características para cada banda de diferente polarización de la imagen COSMO-SkyMed. Por lo tanto este clasificador es adecuado para imágenes COSMO-SkyMed de polarización dual, las cuales son de modo de adquisición Ping-Pong.

**Extracción de vector de características:** Para el detector de agua para dos imágenes de 2 polarizaciones diferentes, se calcula el siguiente vector de características:  $x(i, j)$  para cada píxel  $(i, j)$

$$x(i, j) = \begin{bmatrix} DR_1(n(i, j)) \\ \bar{n}_1(i, j) \\ S_1^2(n(i, j)) \\ DR_2(n(i, j)) \\ \bar{n}_2(i, j) \\ S_2^2(n(i, j)) \end{bmatrix} \quad (5.18)$$

donde  $DR_1$  es el rango de la banda de polarización 1,  $\bar{n}_1$  es la media de la banda de polarización 1,  $S_1^2$  es la varianza de la banda de polarización 1,  $DR_2$  es el rango de la banda de polarización 2,  $\bar{n}_2$  es la media de la banda de polarización 2,  $S_2^2$  es la varianza de la banda de polarización 2, y  $n(i, j)$  es un vector que contiene valores de intensidad en un vecindario de tamaño variable centrado alrededor del píxel  $(i, j)$ .

En el algoritmo de clasificación 2, la distribución que modela las clases es una Gaussiana de 6 dimensiones como se especifica en la fórmula siguiente:

$$p(x | \omega_i) = \frac{\exp\left\{-\frac{1}{2}(x - \mu_i)^T \Sigma_i^{-1} (x - \mu_i)\right\}}{(2\pi)^{\frac{6}{2}} |\Sigma_i|^{\frac{1}{2}}} \quad (5.19)$$

donde  $\mu_i$  y  $\Sigma_i$  son el vector de media y la matriz de covarianza de la clase  $i \in \{a, na\}$ .

**Clasificador 3:** Características de textura  $B$ , polarización simple.

Algunas medidas estadísticas de la imagen que pueden utilizarse como filtros o medidas de textura fueron mencionadas en la sección 4.3.3.

**Matriz de correlación:** Con el objetivo de evaluar el grado de correlación entre las distintas medidas de textura definidas y seleccionar la terna menos correlacionada, se realizó una matriz de correlación (ver sección 4.3.4) de las mismas. La matriz de correlación ( $M_C$ ) resultante para las 8 variables de textura, de una imagen COSMO-SkyMed modo PingPong, polarización  $HH$ , anteriormente

citadas fue la siguiente:

$$M_C = \begin{pmatrix} 1,00 & 0,89 & -0,20 & 0,88 & -0,39 & -0,44 & 0,86 & 0,14 \\ & 1,00 & -0,21 & 0,98 & -0,43 & -0,46 & 0,98 & 0,09 \\ & & 1,00 & -0,24 & 0,02 & 0,09 & -0,17 & -0,34 \\ & & & 1,00 & -0,43 & -0,47 & 0,94 & 0,22 \\ & & & & 1,00 & 0,99 & -0,41 & -0,12 \\ & & & & & 1,00 & -0,44 & -0,13 \\ & & & & & & 1,00 & -0,03 \\ & & & & & & & 1,00 \end{pmatrix} \quad (5.20)$$

siendo el orden de las variables de textura:  $S^2(x)$ ,  $S(x)$ ,  $\hat{\gamma}_1(x)$ ,  $DR(x)$ ,  $Q_2(x)$ ,  $\bar{x}$ ,  $D_m(x)$ ,  $\hat{\gamma}_2(x)$ .

Considerando que las variables  $S^2(x)$  y  $DR(x)$  utilizadas en el clasificador 1 se encontraron altamente correlacionadas (coeficiente de correlación= 0,88), para el clasificador 3 se decidió utilizar una terna cuya tercer variable de textura tuviera la menor correlación con las dos primeras ( $\bar{x}$  y  $S^2(x)$ ). Luego de diferentes pruebas y evaluaciones de la exactitud de clasificación, se decidió seleccionar la terna:  $\bar{x}$ ,  $S^2(x)$  y  $\hat{\gamma}_2(x)$  como entrada para el algoritmo clasificador 3. Por lo tanto, el vector de **características de textura**  $B$   $x(i, j)$  para cada píxel  $(i, j)$  de una imagen COSMO-SkyMed de cualquier polarización, calibrada y en valores de dB, es el siguiente:

$$x(i, j) = \begin{bmatrix} \hat{\gamma}_2(n(i, j)) \\ \bar{n}(i, j) \\ S^2(n(i, j)) \end{bmatrix} \quad (5.21)$$

donde  $\hat{\gamma}_2(n(i, j))$  es la curtosis,  $\bar{n}(i, j)$  es la media y  $S^2(n(i, j))$  es la varianza. En el algoritmo de clasificación 3, la distribución que modela las clases es una Gaussiana de 3 dimensiones (Eq. 5.11).

**Clasificador 4:** Características de textura  $B$ , polarización dual.

El clasificador 4 utiliza las variables de textura que se seleccionaron para el clasificador 3 pero se distingue del mismo debido a que el 4 es un clasificador que utiliza 6 características de textura, es decir 3 características para cada banda de diferente polarización de una imagen COSMO-SkyMed. Por lo tanto este clasificador es adecuado para imágenes COSMO-SkyMed de polarización dual, las cuales son de modo de adquisición PingPong.

**Extracción de vector de características:** Para el detector de agua para dos imágenes de 2 polarizaciones diferentes, se calcula el siguiente vector de características



$x(i, j)$  para cada píxel  $(i, j)$ :

$$x(i, j) = \begin{bmatrix} (\hat{\gamma}_2)_1(n(i, j)) \\ \bar{n}_1(i, j) \\ S_1^2(n(i, j)) \\ (\hat{\gamma}_2)_2(n(i, j)) \\ \bar{n}_2(i, j) \\ S_2^2(n(i, j)) \end{bmatrix} \quad (5.22)$$

donde  $(\hat{\gamma}_2)_1$  es la curtosis de la banda de polarización 1,  $\bar{n}_1$  es la media de la banda de polarización 1,  $S_1^2$  es la varianza de la banda de polarización 1,  $(\hat{\gamma}_2)_2$  es la curtosis de la banda de polarización 2,  $\bar{n}_2$  es la media de la banda de polarización 2,  $S_2^2$  es la varianza de la banda de polarización 2, y  $n(i, j)$  es un vector que contiene valores de intensidad en un vecindario de tamaño variable centrado alrededor del píxel  $(i, j)$ .

En el algoritmo de clasificación 4, la distribución que modela las clases es una Gaussiana de 6 dimensiones (Eq. 5.19).

**Clasificador 5:** Características de textura  $C$ , polarización simple.

**Análisis de Componentes Principales (ACP):** Con el objetivo de sintetizar la información reduciendo el número de variables de textura empleadas, se decidió realizar un ACP (ver sección 4.3.5) de las 8 variables de textura (*varianza, desviación estándar, skewness, rango, mediana, media, desviación media y curtosis*). Se seleccionaron las tres primeras componentes principales como terna de entrada para el clasificador 5, debido a que dichas componentes concentran la mayor parte de los *eigenvalues* (Fig. 5.8), luego de ordenar a estos en orden de significancia. Los correspondientes autovalores dan una indicación de la cantidad de información representada por el respectivo Componente Principal. Los Componentes Principales correspondientes a autovalores mas grandes dan mayor información sobre los datos. Esto implica que puede realizarse una buena aproximación de las variables de textura analizadas utilizando solo un subconjunto de *eigenvectors* y *eigenvalues*. Estas bandas o componentes seleccionados explicarían la mayor parte de la tendencia de las variables resumidas.

Por lo tanto, el vector de **características de textura**  $C$   $x(i, j)$  para cada píxel  $(i, j)$  de una imagen COSMO-SkyMed de cualquier polarización, calibrada y en valores de dB, es el siguiente:

$$x(i, j) = \begin{bmatrix} PCA1(n(i, j)) \\ PCA2(n(i, j)) \\ PCA3(n(i, j)) \end{bmatrix} \quad (5.23)$$

donde  $PCA1$ ,  $PCA2$  y  $PCA3$  son las componentes principales 1, 2 y 3 respectivamente, resultantes del análisis de componentes principales.

En el algoritmo de clasificación 5, la distribución que modela las clases es una Gaussiana de 3 dimensiones (Eq. 5.11).


**Clasificador 6:** Características de textura  $C$ , polarización dual.

El clasificador 6 utiliza las variables de textura que se seleccionaron para el clasificador 5 pero se distingue del mismo debido a que el 6 es un clasificador que utiliza 6 características de textura, es decir 3 características para cada banda de diferente polarización de una imagen COSMO-SkyMed. Por lo tanto este clasificador es adecuado para imágenes COSMO-SkyMed de polarización dual, las cuales son de modo de adquisición PingPong.

**Extracción de vector de características:** Para el detector de agua para dos imágenes de 2 polarizaciones diferentes, se calcula el siguiente vector de características  $x(i, j)$  para cada píxel  $(i, j)$ :

$$x(i, j) = \begin{bmatrix} PCA1_1(n(i, j)) \\ PCA2_1(n(i, j)) \\ PCA3_1(n(i, j)) \\ PCA1_2(n(i, j)) \\ PCA2_2(n(i, j)) \\ PCA3_2(n(i, j)) \end{bmatrix} \quad (5.24)$$

donde  $PCA1_1$ ,  $PCA2_1$  y  $PCA3_1$  son las componentes principales 1, 2 y 3 respectivamente, resultantes del análisis de componentes principales de la imagen de polarización 1, y  $PCA1_2$ ,  $PCA2_2$  y  $PCA3_2$  son las componentes principales 1, 2 y 3 respectivamente, resultantes del análisis de componentes principales de la imagen de polarización 2, y  $n(i, j)$  es un vector que contiene valores de intensidad en un



**Figura 5.8:** Eigenvalues resultantes del análisis de componentes principales de las 8 variables de textura: varianza, desviación estándar, skewness, rango, mediana, media, desviación media y curtosis.

vecindario de tamaño variable centrado alrededor del píxel  $(i, j)$ .

En el algoritmo de clasificación 6, la distribución que modela las clases es una Gaussiana de 6 dimensiones (Eq. 5.19).

**Módulo de morfología matemática para análisis de clasificaciones:** Con el objetivo de extraer componentes de las clasificaciones que sean útiles en la representación y descripción de la forma de las regiones, se procedió a generar un módulo de morfología matemática.

**Algoritmos implementados en el módulo de morfología matemática:** (sección 4.3.6)

Se implementaron los siguientes veinte filtros morfológicos, con sus respectivos elementos estructurantes ( $E_s$ ):

- Dilatación.
  - Elemento estructurante de tamaño  $1 \times 1$ :  $E_{s1} = \{(1, 1)\}$ .
  - Elemento estructurante de tamaño  $2 \times 2$ :  $E_{s2} = \{(1, 1), (1, 1)\}$ .
  - Elemento estructurante de tamaño  $3 \times 3$ :  $E_{s3} = \{(1, 1, 1), (1, 1, 1), (1, 1, 1)\}$ .
  - Elemento estructurante de tamaño  $4 \times 4$ :  $E_{s4} = \{(1, 1, 1, 1), (1, 1, 1, 1), (1, 1, 1, 1), (1, 1, 1, 1)\}$ .
  - Elemento estructurante de tamaño  $5 \times 5$ :  
 $E_{s5} = \{(1, 1, 1, 1, 1), (1, 1, 1, 1, 1), (1, 1, 1, 1, 1), (1, 1, 1, 1, 1), (1, 1, 1, 1, 1)\}$ .
- Erosión: con los respectivos elementos estructurantes:  $E_{s1}, E_{s2}, E_{s3}, E_{s4}, E_{s5}$ .
- Apertura: con los respectivos elementos estructurantes:  $E_{s1}, E_{s2}, E_{s3}, E_{s4}, E_{s5}$ .
- Cierre: con los respectivos elementos estructurantes:  $E_{s1}, E_{s2}, E_{s3}, E_{s4}, E_{s5}$ .

Cada uno de estos filtros fue aplicado a las clasificaciones binarias (AGUA, NO-AGUA) resultantes de los clasificadores de cuerpos de agua. Posteriormente, se procedió a calcular un mapa de probabilidad de pertenencia a la clase AGUA para cada producto de clasificación.

**Mapa de probabilidad:** Se desarrolló una función que determina la probabilidad de cada píxel de la imagen de pertenecer a la clase AGUA, según la cantidad de veces que el píxel determinado es clasificado como AGUA al aplicar los veinte filtros morfológicos recién especificados.

### 5.2.5. Evaluación de los clasificadores

La exactitud de una clasificación 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 (ver subsección 4.3.7), también llamada matriz de error o de contingencia.

Se llevó a cabo la coregistración de la imagen COSMO-SkyMed con respecto a la imagen Landsat en el sistema de referencia *Geographic LAT LON, datum: WGS84*. Se realizó una clasificación supervisada de las 6 bandas de Landsat (Banda 1, 2, 3, 4, 5, 7. Con excepción de la banda térmica 6) con un clasificador *ML*, utilizando áreas de entrenamiento para las clases: AGUA y NO-AGUA que surgieron del estudio del área en análisis. El resultado de esta clasificación es una imagen binaria con las clases: AGUA y NO-AGUA que fue utilizado como *verdad de campo* durante la validación de clasificaciones de COSMO-SkyMed.

Los factores bajo evaluación, es decir los que fueron variables a lo largo de las distintas clasificaciones, correspondientes a los clasificadores de la tabla 5.1, fueron: el número de dimensiones del clasificador (3 o 6), las variables de textura utilizadas (textura *A*, *B* o *C*), y las polarizaciones (por analizarse una imagen COSMO-SkyMed con polarización dual).

La exactitud de las clasificaciones fue evaluada mediante matrices de confusión.


### 5.3. Resultados

**Módulo de procesamiento de imágenes:** En la figura 5.9 se presentan las figuras resultantes del procesamiento de la imagen COSMO-SkyMed PingPong: lectura, conversión de formato HDF a formato ENVI, y calibración radiométrica. En estas figuras se muestran las dos bandas *HH* y *VV* de la imagen calibradas radiométricamente expresadas en coeficiente de retrodispersión en decibeles. Los valores tienen un rango que va de  $-72$  a  $13,2$  para polarización *HH*, y de  $-71,7$  a  $15,1$  para polarización *VV*.


**Selección automática de muestras:** En la figura 5.10 se muestran los histogramas de la imagen completa y de cada clase (AGUA, NO-AGUA) según las dos bandas de diferente polarización (*HH*, *VV*). Estas clases son el resultado del algoritmo de selección automática de muestras. Se puede apreciar que en el histograma de la polarización *VV* las modas presentan una separación más marcada y por lo tanto, se estima que esta polarización pueda separar de manera más eficiente las clases correspondientes a estas modas.

En la subfigura 5.11(a) se muestran los gráficos de primera y segunda derivada calculadas a partir de la función del histograma de la imagen COSMO-SkyMed de polarización *HH* y el resultado de la selección automática de muestras de clases AGUA y NO-AGUA. Las funciones de la primera y segunda derivada son necesarias para determinar el primer umbral que divide las clases AGUA y NO-AGUA, luego este umbral es promediado con el que se obtiene mediante una función adicional (ver sección 5.2.4.2) y se genera la selección final de clases que se muestra en la subfigura 5.11(b).

**Variables de textura empleadas por los clasificadores:** En las subfiguras 5.12(a), 5.12(b) y 5.12(c) se presentan, a modo de ejemplificación, las variables de textura *A* correspondientes a la banda de polarización *HH* de la imagen COSMO-SkyMed. En la subfigu-




(a) Banda de polarización  $HH$  en valores de  $\sigma^\circ$  en decibeles.




(b) Banda de polarización  $VV$  en valores de  $\sigma^\circ$  en decibeles.

**Figura 5.9:** Imagen de COSMO-SkyMed-2 radiométricamente calibrada y en valores de decibeles, correspondiente al área de estudio. Modo de adquisición: PingPong. Fecha de adquisición: 04-06-2010. Resolución espacial: 20 m. El rango de valores va de  $-72$  a  $13,2$  decibeles en la banda de polarización  $HH$ , y de  $-71,7$  a  $15,1$  decibeles en la banda de polarización  $VV$ .


Módulo de algoritmos de clasificación:



(a) Histogramas de las bandas de polarización  $HH$  y  $VV$  de la imagen COSMO-SkyMed.




(b) Histograma de la clase AGUA seleccionada mediante el algoritmo automático, de las bandas de polarización  $HH$  y  $VV$ .



(c) Histograma de la clase NO-AGUA seleccionada mediante el algoritmo automático, de las bandas de polarización  $HH$  y  $VV$ .

**Figura 5.10:** Histogramas de la imagen COSMO-SkyMed-2 radiométricamente calibrada y en valores de decibels, correspondiente al área de estudio, de modo de adquisición PingPong y fecha de adquisición: 04-06-2010. Se detalla también el histograma de las clases AGUA y NO-AGUA (abarca el resto de las coberturas que no pertenecen a la clase AGUA) seleccionadas automáticamente.



(a) Primera y segunda derivada calculadas a partir del histograma de una banda de la imagen COSMO-SkyMed.




(b) Selección automática de muestras de clases AGUA y NO-AGUA en una banda de la imagen COSMO-SkyMed.


imagen

**Figura 5.11:** Ejemplo de resultados del algoritmo de selección automática de muestras de las clases AGUA y NO-AGUA (dentro del *Módulo de algoritmos de clasificación*). Se muestra el gráfico de la primera y segunda derivada calculadas a partir del histograma de una banda de la imagen COSMO-SkyMed. Estas derivadas son utilizadas para encontrar el valor *umbral* para la determinación de clases de entrenamiento.


ra 5.13 se presenta la variable de textura  $B$ , *Curtosis*, correspondiente a la banda de polarización  $HH$  de la imagen COSMO-SkyMed.



(a) Variable de textura *Media* de la banda de polarización  $HH$ .



(b) Variable de textura *Varianza* de la banda de polarización  $HH$ .



(c) Variable de textura *Rango* de la banda de polarización  $HH$ .

**Figura 5.12:** variables de textura  $A$  (media, varianza y rango) correspondientes a la banda de polarización  $HH$  de la imagen COSMO-SkyMed en decibeles, obtenidas mediante el clasificador 1 y 2.

Es posible observar en la subfigura 5.12(a) un patrón diagonal de retrodispersión mayor sobre el agua. Esto podría deberse al efecto del viento en la generación movimiento superficial del agua. De hecho, se comprobó mediante información proveniente del [NCEP FNL Operational Model Global Tropospheric Analyses](#) que durante el día y hora del sensado de COSMO-SkyMed correspondiente a esta imagen, la dirección del viento era Sureste.



En la figura 5.14 se presentan las variables de textura  $C$  correspondientes a la banda de polarización  $HH$  de COSMO-SkyMed .


Se observa en la tercer componente principal un fenómeno anormal en forma de lóbulos que se origina en la esquina superior derecha e izquierda. El mismo no puede corresponder a un patrón natural en terreno y se postula que podría deberse al patrón de antena mal corregido o bien a alguna distorsión geométrica originada en el proceso de corrección geométrica. La corrección del patrón de antena es un paso durante el procesamiento de las imágenes radar, para crear una imagen con niveles promedio de grises uniformes en la dirección del rango.

La codificación que será utilizada en esta sección de resultados de clasificaciones es la siguiente:

- $PolHH_1$ : Clasificación resultante de aplicar el clasificador 1 a la banda de polarización:  $HH$ .
- $PolHH_3$ : Clasificación resultante de aplicar el clasificador 3 a la banda de polarización:  $HH$ .
- $PolHH_5$ : Clasificación resultante de aplicar el clasificador 5 a la banda de polarización:  $HH$ .
- $PolVV_1$ : Clasificación resultante de aplicar el clasificador 1 a la banda de polarización:  $VV$ .
- $PolVV_3$ : Clasificación resultante de aplicar el clasificador 3 a la banda de polarización:  $VV$ .
- $PolVV_5$ : Clasificación resultante de aplicar el clasificador 5 a la banda de polarización:  $VV$ .
- $DualPol_2$ : Clasificación resultante de aplicar el clasificador 2 a la imagen de dos polarizaciones ( $HH$ ,  $VV$ ).
- $DualPol_4$ : Clasificación resultante de aplicar el clasificador 4 a la imagen de dos polarizaciones ( $HH$ ,  $VV$ ).
- $DualPol_6$ : Clasificación resultante de aplicar el clasificador 6 a la imagen de dos polarizaciones ( $HH$ ,  $VV$ ).

En las distintas figuras expuestas en resultados los colores siempre representarán: en blanco, AGUA, y en negro, NO-AGUA.


Para todas las clasificaciones se utilizó la misma muestra de clases AGUA y NO-AGUA como entrenamiento que se observa en la figura 5.15. Este muestreo se realizó en esta sección mediante análisis visual de la imagen COSMO-SkyMed en vez de su determinación



**Figura 5.13:** Variable de textura *Curtosis* de la banda de polarización  $HH$  de la imagen COSMO-SkyMed en decibeles. Esta variable pertenece junto con la *media* y la *varianza* a las variables de textura  $B$  y es obtenida mediante el clasificador 3 y 4.



(a) Primera componente principal de las 8 variables de textura.



(b) Segunda componente principal de las 8 variables de textura.



(c) Tercera componente principal de las 8 variables de textura.


**Figura 5.14:** Variables de textura  $C$  (PCA 1, PCA 2, PCA 3) correspondientes a la banda de polarización  $HH$  de la imagen COSMO-SkyMed en decibeles, obtenidas mediante el clasificador 5 y 6.

automática 5.2.4.2. De este modo se garantiza la ausencia de errores en la fase de entrenamiento, y por lo tanto que se analice el comportamiento de los diferentes clasificadores de manera fija y adecuada.



**Figura 5.15:** Muestras de clases AGUA y NO-AGUA utilizadas en todas las clasificaciones realizadas en este capítulo, obtenidas mediante análisis visual de la imagen COSMO-SkyMed. Se llevó a cabo esta determinación para no incluir en las clasificaciones la variabilidad ocasionada por el método de muestreo automático aquí desarrollado.

Con el objetivo de analizar los parámetros de precisión de cada clasificación, se detallarán en esta sección los correspondientes valores de porcentaje de exactitud e índice *Kappa* para cada una de ellas. En la figura 5.16, a modo de ejemplificación, se presentan los resultados de las clasificaciones que tienen como entrada las dos bandas de diferente polarización de la imagen COSMO-SkyMed (*DualPol*<sub>2</sub>, *DualPol*<sub>4</sub>, *DualPol*<sub>6</sub>).



**Figura 5.16:** Resultados de las clasificaciones *DualPol* que involucran a las dos polarizaciones COSMO-SkyMed PingPong, es decir, *HH* y *VV*.

Mediante diferentes acercamientos en el producto *DualPol*<sub>2</sub>, se puede observar en las figuras 5.17, 5.18 y 5.19 como es el comportamiento de la clasificación respectiva. En la figura 5.17 se visualiza la clasificación correcta del pequeño cuerpo de agua a la izquierda del río, pero también la falta de diferenciación del agua de la desembocadura de la represa hidroeléctrica en el río. En esta última zona, las turbulencias del agua ocasionan una respuesta diferente a la típica respuesta especular del agua en el radar y por lo tanto, el agua de este sector no es clasificada como tal. Por otro lado, en la figura 5.18 se observa

una discontinuidad en el cuerpo de agua detectado, quizás ocasionado por la cantidad de vegetación en los bordes del río que de alguna manera aún no comprendida, interfiere en la señal de retorno al radar. Esta interferencia originaría un aumento en la retrodispersión de esos sectores, ocasionando que se pierda el típico patrón de retrodispersión (bajo) de los cuerpos de agua. Por último, en la figura 5.19 la clasificación coincide significativamente con la imagen de alta resolución de la zona analizada.



(a) Imagen óptica de Google Earth correspondiente a la fecha 31-07-2006.

(b) Clasificación *DualPol<sub>2</sub>*.

**Figura 5.17:** Detalle 1 de la clasificación que involucra a las dos polarizaciones COSMO-SkyMed: *DualPol<sub>2</sub>*.



(a) Imagen óptica de Google Earth correspondiente a la fecha 31-07-2006.

(b) Clasificación *DualPol<sub>2</sub>*.

**Figura 5.18:** Detalle 2 de la clasificación que involucra a las dos polarizaciones COSMO-SkyMed: *DualPol<sub>2</sub>*.




(a) Imagen óptica de Google Earth correspondiente a la fecha 29-04-2008.


(b) Clasificación *DualPol<sub>2</sub>*.

**Figura 5.19:** Detalle 3 de la clasificación que involucra a las dos polarizaciones COSMO-SkyMed: *DualPol<sub>2</sub>*.


**Módulo de morfología matemática:** En la figura 5.20 son presentados distintos productos de morfología matemática aplicada al resultado de la clasificación *DualPol*<sub>6</sub>, con elementos estructurantes de tamaño  $3 \times 3$ .



(a) Operación morfológica: *Dilatación con kernel de tamaño  $3 \times 3$*  (elemento estructurante  $E_{s3}$ ). (b) Operación morfológica: *Erosión con kernel de tamaño  $3 \times 3$*  (elemento estructurante  $E_{s3}$ ).



(c) Operación morfológica: *Cierre con kernel de tamaño  $3 \times 3$*  (elemento estructurante  $E_{s3}$ ). (d) Operación morfológica: *Apertura con kernel de tamaño  $3 \times 3$*  (elemento estructurante  $E_{s3}$ ).



(e) Mapa de probabilidad de presencia de cuerpos de agua obtenido mediante la integración de los diferentes resultados de morfología matemática.

**Figura 5.20:** Ilustración de los resultados obtenidos mediante la aplicación de morfología matemática a la clasificación *DualPol*<sub>6</sub>. El mapa de probabilidad de presencia de cuerpos de agua es obtenido mediante el análisis de los resultados de los distintos operadores morfológicos, con distintos tamaños de kernel. Se calcula computando el número de veces que un píxel es clasificado como AGUA en las distintas matrices resultantes de operaciones de morfología. La probabilidad tiene un rango que va de 0 a 1, siendo 1 la máxima probabilidad de presencia.

**Evaluación de la exactitud de las clasificaciones:** En la figura 5.21 se muestra la clasificación supervisada de las 6 bandas de la imagen Landsat con un clasificador *ML*. Esta clasificación fue utilizada como *verdad de campo* durante la siguiente evaluación de las clasificaciones de cuerpos de agua en COSMO-SkyMed.

La tabla 5.2 resume la evaluación de exactitud de las diferentes clasificaciones, a través

de sus respectivos porcentajes de exactitud e índices Kappa.

**Tabla 5.2:** Evaluación de la exactitud de los diferentes clasificadores

Clasificación	Porcentaje de exactitud (%)	Índice Kappa
<i>PolHH<sub>1</sub></i>	87.5829	0.4809
<i>PolHH<sub>3</sub></i>	87.4901	0.4815
<i>PolHH<sub>5</sub></i>	87.5787	0.4805
<i>PolVV<sub>1</sub></i>	98.3183	0.9248
<i>PolVV<sub>3</sub></i>	98.3467	0.9265
<i>PolVV<sub>5</sub></i>	98.3266	0.9253
<i>DualPol<sub>2</sub></i>	98.4283	0.9304
<i>DualPol<sub>4</sub></i>	98.4390	0.9309
<i>DualPol<sub>6</sub></i>	98.4314	0.9306

## 5.4. Discusión y conclusiones

Imágenes adquiridas por la constelación de COSMO-SkyMed han sido analizadas con el objetivo de desarrollar un método automático para la detección de agua, que podría adecuarse para formar parte de un sistema operativo de respuesta temprana y alerta a emergencias relacionadas a cuerpos de agua.

En este capítulo, fue posible desarrollar un módulo programado en IDL que permite la apertura, calibración y clasificación de imágenes COSMO-SkyMed. Se generó un sistema de clasificación automática, no dependiente de la supervisión por parte del usuario, que a partir de una imagen COSMO-SkyMed como entrada, produce la delimitación de sus superficies con agua. Este sistema consta de un clasificador de máxima verosimilitud, basado en distintas variables de textura de la imagen, similar al implementado en el trabajo de [Solbø et al. \[2004\]](#), y que es entrenado automáticamente. El clasificador se basa en las diferencias, originadas por los diferentes mecanismos de retrodispersión, que presentan las variables estadísticas de textura de superficies de agua respecto al resto de las coberturas terrestres. Se generó un método de



**Figura 5.21:** Resultado de la clasificación supervisada *ML* de las 6 bandas de la imagen Landsat 5 TM (fecha: 26 – 07 – 2010) empleada. Se utilizó como regiones de entrenamiento a muestras determinadas de manera visual en la imagen óptica. Esta clasificación de la imagen Landsat fue empleada como verdad de campo a la hora de evaluar los clasificadores de imágenes COSMO-SkyMed desarrollados.

entrenamiento automático que resultó cualitativamente satisfactorio. Sin embargo, no se realizó una validación cuantitativa específica del mismo.

Es importante remarcar la importancia del entrenamiento automático, no solo debido a que el entrenamiento es una de las etapas fundamentales y determinantes en el proceso de clasificación, sino también por la posibilidad de incorporar el mismo en un sistema de alerta a emergencias automático.

Tradicionalmente, áreas abiertas de agua son detectadas en SAR mediante selección de umbrales [Ahtonen & Hallikainen, 2005], por lo que la metodología aquí propuesta representa una innovación en el área. La simple selección de umbrales de intensidad en la imagen es inadecuada, en primer lugar, debido a la alta dependencia de dicha técnica con respecto al ángulo de incidencia que caracteriza a la imagen. En segundo lugar, las características que distinguen a los cuerpos de agua no son solo las características de intensidad del píxel dado. Valores extremos u *outliers* pueden ser clasificados como agua sin analizar su entorno, lo cual sería un error. Una aproximación más completa es usar variables de textura, que no solo tienen en cuenta el valor de intensidad del píxel a clasificar sino las características estadísticas de el mismo con su entorno.

A diferencia de trabajos en los que se utilizan variables de textura, como el de Anys et al. [1994], en el presente estudio se evaluó la correlación de distintas variables de textura como posibles entradas en el clasificador, de modo de seleccionar las que no contengan información repetida o redundante de la superficie. Se utilizan características de textura, tales como *curtosis* y *skewness*, no empleadas previamente en la clasificación de imágenes SAR. También se generaron nuevas variables, con información no redundante, a partir de la aplicación de un análisis de componentes principales. Esto significa que se emplea el análisis de componentes principales de 8 variables de textura para la generación de información nueva útil como entradas en el clasificador.

Se implementó un clasificador de máxima verosimilitud que posibilita la utilización de 3 o 6 variables de textura (clasificación de 3 y 6 dimensiones), para imágenes de una polarización o polarización dual respectivamente. Por lo tanto, el sistema también presenta la posibilidad de clasificar las imágenes COSMO-SkyMed de polarización dual (PingPong) mediante la utilización de sus dos bandas de diferente polarización.

En general, fueron obtenidos buenos parámetros de precisión (índice *Kappa*) con todos los clasificadores propuestos: con diferentes variables de textura, polarización de la imagen COSMO-SkyMed y número de bandas de distinta polarización. Sin embargo se reconoció que todas las clasificaciones de 6 dimensiones (polarización dual) presentaron mayores valores *Kappa* que las de 3 dimensiones (polarización simple). De este modo se comprueba que los radares que poseen múltiples polarizaciones (combinaciones de *HH*, *HV*, *VV* y *VH*) proveen mayor cantidad de información y podrían resultar más útiles en sistemas de respuesta a emergencias en relación a superficies de agua. Los radares de múltiples polarizaciones, tales como los productos PingPong de COSMO-SkyMed, proveen mejor caracterización de la superficie sensada que los de polarización simple. Dentro de las clasificaciones de polarización dual, la incorporación

de la *curtosis* en la terna de variables de textura generó la más alta exactitud de clasificación.

En general, se considera que la polarización *HH* debería ser preferida ante la naturaleza horizontal del cuerpo de agua. La polarización *HH* proporciona la discriminación más obvia entre agua y otros tipos de clases de coberturas terrestres debido a que ésta ofrece el mejor rango radiométrico dinámico [Ahtonen et al., 2004; Henry et al., 2006; Malnes et al., 2002; Sarti et al., 2001; Schumann et al., 2007]. Esto es ocasionado por una baja retrodispersión del componente horizontal de la señal desde la superficie abierta de agua. Un incremento en la rugosidad de la superficie del cuerpo de agua reduciría la habilidad de discriminar entre agua y tierra en polarización *VV* más que en *HH*. En relación a las clasificaciones de polarización simple, y contrariamente a lo que se esperaba, se observó que la polarización *VV* tuvo significativamente mayor precisión en la separación de superficies con agua. Esta contradicción con lo esperado resulta un interesante punto para indagar en estudios posteriores.

La clasificación de polarización simple que utilizó a la *curtosis* como variable de textura fue más exacta (en términos de *Kappa*). La mejor clasificación de todas las analizadas resultó ser la de polarización dual que incorpora a la *curtosis* como variable de textura. Es esperable que a medida que un mayor número de bandas de diferente polarización sean utilizadas se disponga de mayor información para separar clases.

No obstante los resultados de precisión, la evaluación de los clasificadores debería ser repetida en diversas escenas de modo de poder, luego de un número consistente de pruebas, concluir acerca del mejor de los métodos planteados. Además se debería evaluar el cambio en el tamaño del kernel empleado en el análisis de textura, ya que este es un factor decisivo a la hora de caracterizar las superficies.

En este trabajo se aplican herramientas de morfología matemática con el fin de definir la clasificación final de agua preservando sus características de forma esenciales y eliminando irrelevancias. Se genera una imagen de probabilidad de presencia de agua, que considera el resultado de distintos operadores morfológicos sobre las clasificaciones binarias de cuerpos de agua. En relación a este punto, se origina la necesidad de indagar en profundidad este tipo de análisis morfológico de las clasificaciones.

Respecto a los errores en las clasificaciones, es posible que la mayor parte de las áreas no detectadas correspondan o bien a vegetación inundada o a cuerpos de agua cubiertos de vegetación vigorosa la cual no es atravesada por la longitud de onda de banda X característica de COSMO-SkyMed. En este sentido, se requiere un mejor entendimiento de los procesos físicos que gobiernan la retrodispersión de los pulsos emitidos por COSMO-SkyMed en zonas de vegetación inundada, para poder adaptar los algoritmos convenientemente. Por otra parte, los falsos píxeles de agua detectados aisladamente podrían corresponder a superficies lisas, que producen reflexión especular, artificialmente construidas, como rutas, asfalto, etc. En una futura aproximación, estos objetos podrían ser previamente eliminados empleando alguna característica que los diferencie respecto a los cuerpos de agua.

En el mismo sentido, y como fuente de error para la clasificación, fuertes condiciones de vientos, perturbaciones, olas o escorrentías en el cuerpo de agua pueden ser sensadas por las



longitudes de onda de la región de las microondas como una mayor retrodispersión y, por lo tanto, disminuyen el contraste entre las superficies de agua respecto a las de otras coberturas. No obstante, este fenómeno podría pasar desapercibido de acuerdo al tamaño del cuerpo de agua. Considero que debería analizarse, en posteriores estudios, la estabilidad de los clasificadores implementados respecto a este factor ambiental con incidencia en el cuerpo de agua.

Una aproximación complementaria que se comenzó a indagar en esta tesis pero no está plasmada en la misma, plantea un análisis de textura en las imágenes que involucra técnicas como las transformaciones espaciales de *Fourier*. Esto podría brindar información valiosa a la hora de caracterizar clases en la superficie. Por otro lado, alternativamente a estos clasificadores se podrían analizar clasificadores que trabajen con datos de imágenes COSMO-SkyMed en otras unidades y asuman otros modelos de distribución estadística de los mismos.

El detector de cuerpos de agua basado en textura expuesto en este capítulo permite delimitar los mismos con buena exactitud, al menos teóricamente con independencia del ángulo de incidencia del radar. Esto debería ser evaluado en trabajos posteriores mediante el análisis de la exactitud de las clasificaciones variando solo el ángulo de incidencia. En este capítulo se clasificó una imagen de dos bandas de polarización diferente, y ángulo de incidencia fijo correspondiente a  $40^\circ$ . Si la precisión de las clasificaciones fuera independiente del ángulo de incidencia de las imágenes de entrada correspondientes, este método convertiría a un mayor número de datos SAR en capaces de detectar agua. Esto último es fundamental en sistemas de respuesta a emergencias que necesitan que la mayor cantidad de datos sean procesados en tiempo real.

Del mismo modo, sería importante evaluar la diferencia en las clasificaciones provenientes de imágenes de dirección de órbita 1) descendente y 2) ascendente. Es posible que los resultados varíen respecto a este parámetro del sensor y esto representa un punto interesante a ser abordado a la hora de seleccionar el mejor conjunto de parámetros para la selección de imágenes para emergencias.

Existían evidencias de que la banda *X* sería más adecuada para el propósito de detección de cuerpos de agua que la banda *C* y *L*. A menor longitud de onda del sistema de sensado, existe mayor contraste entre el agua y las áreas terrestres. Esto es debido a que el número de posibles características que podrían aparecer sobre la tierra como suaves y similares en tono al agua es menor que a mayores longitudes de onda [Drake & Shuchman, 1974]. En este trabajo, se comprobó la efectividad de la banda de *X* de COSMO-SkyMed en la delimitación de cuerpos de agua abiertos. Esto, sumado a la excelente cobertura temporal de este sensor, lo convierte en un candidato importante para sistemas de control de emergencias hidrológicas. Posteriores trabajos deberían también analizar el comportamiento de clasificaciones de COSMO específicamente para el caso de vegetación inundada. A pesar de la menor penetración de las ondas de banda *X* respecto a bandas como *C* (característica por ejemplo de Radarsat) o *L* (característica por ejemplo de ALOS-PALSAR), COSMO-SkyMed podría representar un modo alternativo para el análisis de áreas de vegetación inundadas.

Si bien según Pal & Pal [1993] no existe un método particularmente apropiado para cualquier

imagen SAR, sería fundamental evaluar las distintas metodologías para la detección de superficies de agua presentes en la bibliografía en relación a su comportamiento con distintas configuraciones de imágenes COSMO-SkyMed. De esta manera, se podría seleccionar la más adecuada para cada tipo de imagen con características propias.

# Capítulo 6

## Evaluación e integración de las metodologías

### 6.1. Objetivos abordados en el capítulo

El objetivo abordado en este capítulo fue evaluar la integración de las metodologías generadas en un área con riesgo de inundación elevado.

#### 6.1.1. Aportes del capítulo

En el presente capítulo se lleva a cabo la formulación de una metodología de integración de las clasificaciones de cuerpos de agua de las imágenes radar COSMO-SkyMed con información proveniente de índices topográficos del área analizada.

### 6.2. Materiales y métodos

#### 6.2.1. Área de estudio

El área de estudio correspondiente al análisis de este capítulo se muestra en la figura 6.1 y sus coordenadas centrales son 32 °52 '20 S 60 °39 '32 O. La misma se localiza en el norte de la ciudad de Rosario, ubicada en el centro-este de Argentina, en la provincia de Santa Fe. Está situada sobre el margen occidental del río Paraná, en la Hidrovía Paraná – Paraguay, en la denominada Pampa Húmeda.

En el centro de la zona de estudio se encuentra el puente Rosario-Victoria. El Puente Rosario-Victoria, oficialmente denominado Puente Nuestra Señora del Rosario forma parte de la conexión vial de la Ruta Nacional 174, de 60 km que comunica las ciudades de Rosario, en la provincia de Santa Fe, y Victoria, en la provincia de Entre Ríos, de la República Argentina.

### 6.2.1.1. Topografía y cobertura del suelo

El relieve de la zona es de llanura ondulada, y su altura es de aproximadamente 22,5 a 24,6 msnm.

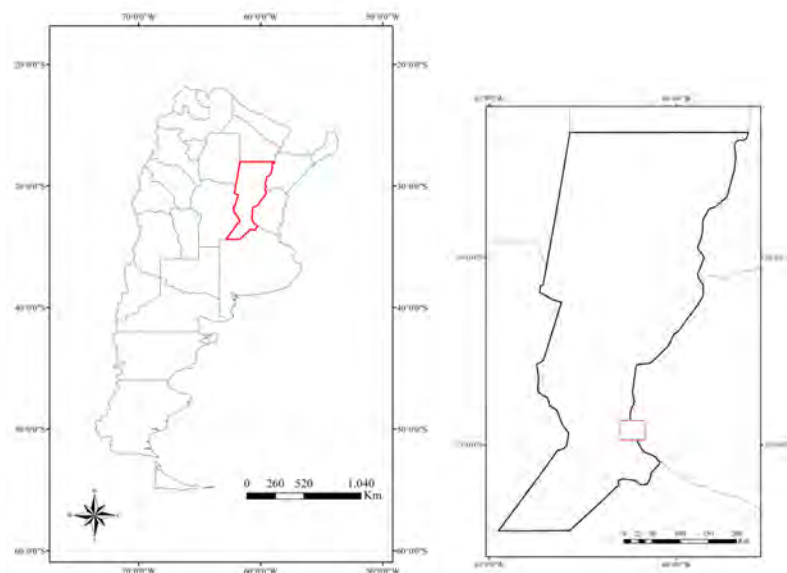
Se observa la existencia de especies nativas vinculadas con las eco-regiones ‘Paranaense’ y del ‘Espinal’: espinillo (*Acacia caven*), ombú (*Phytolacca dioica*), jacarandá (*Jacaranda mimosifolia*) y pata de vaca (*Bauhinia fortificata*). Ombú, ceibo, espinillo y timbó son especies tropicales que llegan naturalmente al entorno de la ciudad de Rosario.

El área presenta un intensivo uso del suelo especialmente agrícola-ganadero e importantes modificaciones antrópicas al medio físico que ha determinado la reducción de áreas de bosques y montes y alteraciones al escurrimiento del sistema natural.

### 6.2.1.2. Clima

Es una zona de transición climática entre la llanura chaqueña y llanura pampeana. El clima de la zona de estudio es húmedo y templado en la mayor parte del año. Se lo clasifica como clima templado pampeano por la presencia del importante curso de agua (el río Paraná). Las cuatro estaciones están medianamente definidas, aunque su invierno es bastante corto e irregular. Hay una temporada calurosa desde octubre a abril (de 18 °C a 32 °C, con picos que pueden superar los 40 °C) y una fría entre principios de junio y la primera mitad de agosto (con mínimas en promedio de 5 °C y máximas promedio de 16 °C), oscilando las temperaturas promedio anuales entre los 10 °C (mínima), y los 23 °C (máxima).

Llueve más en verano que en invierno, con un volumen de precipitaciones total de entre



(a) Provincia de Santa Fé, Argentina.

(b) Área de estudio en Rosario, Santa Fé.

**Figura 6.1:** Área de estudio en el norte de la ciudad de Rosario, ubicada en el centro-este de Argentina, en la provincia de Santa Fe.

800 y 1300 mm al año. El régimen de precipitaciones presenta alternancia de períodos hídricos secos, normales y húmedos.

La dinámica hídrica natural fue modificada significativamente por la construcción de obras que, en muchos casos, interfieren con el libre escurrimiento de las aguas [Girolimetto et al., 2007]. Un riesgo factible en la zona de análisis son los tornados y tormentas severas, con un pico de frecuencia entre octubre y marzo. Estos fenómenos se generan por los encuentros de un masa húmeda y calida del norte del país y una fría y seca del sector sur argentino. Las inundaciones ocasionalmente afectan a algunas de las zonas más bajas de la ciudad. Entre fines de marzo y principios de abril de 2007, una cantidad excepcional de lluvias (pero inferior a la potencialidad pluviosa de Rosario) inundaron partes de Rosario y forzaron a miles de personas a abandonar sus casas y a escuelas, y suspender las actividades de fábricas.



(a) Caracterización espacial de la zona de estudio. Fuente: Otogno-2008. (b) Puente Rosario-Victoria localizado en el centro del área en análisis. Fuente: Facundo A. Fernández.



(c) Caracterización espacial de la zona de estudio. Fuente: Otogno-2008. (d) Esquema geográfico del centro del área de estudio. Fuente: <http://www.rosariomapas.com/>

**Figura 6.2:** Caracterización del área de estudio en Rosario, Santa Fe, Argentina.

### 6.2.2. Recolección y preprocesamiento de datos

#### 6.2.2.1. Datos de radar

Tres imágenes del sensor COSMO-SkyMed, con los siguientes nombres de archivo, fueron provistas por CONAE en el contexto de la maestría en *Aplicaciones Espaciales de Alerta y Respuesta Temprana a Emergencias*:

1. CSKS1\_GEC\_B\_PP\_09\_CO\_RD\_SF\_20110510212014\_20110510212020.h5
2. CSKS2\_GEC\_B\_HI\_10\_HV\_RA\_SF\_20110508104210\_20110508104217.h5
3. CSKS4\_GEC\_B\_HI\_10\_HH\_RA\_FF\_20110512104207\_20110512104215.h5

Los metadatos relativos a estas imágenes son detallados en el apéndice C (ver página 179). Estas imágenes consisten en los siguientes modos de adquisición: PingPong *HH/VV*, Himage *HV*, e Himage *HH*.

### 6.2.2.2. Datos de elevación digital

Datos de ASTER GDEM correspondientes al área de estudio (Fig. 2.1) fueron provistos por CONAE en el contexto de la maestría en *Aplicaciones Espaciales de Alerta y Respuesta Temprana a Emergencias*.

### 6.2.2.3. Datos ópticos

Los datos provenientes del sensor Landsat 5 TM (ver sección 3.3.2.1), correspondientes al área de estudio, fueron solicitados a: [Earth Resources Observation and Science Center \(EROS\)](#).

Las características de la imagen Landsat adquirida se detallan en el apéndice C (ver página 179). La imagen corresponde a aproximadamente la misma época de adquisición de las imágenes COSMO-SkyMed y se ubica en Path: 226- Row: 083.

El preprocesamiento de esta imagen Landsat TM fue detallado en la sección 3.3.2.1.

## 6.2.3. Especificación de la metodología

El procedimiento llevado a cabo en este capítulo consistió en la aplicación de los siguientes pasos:



**Figura 6.3:** Imagen Landsat 5 TM correspondiente al área de estudio en Rosario, Santa Fe, Argentina. Path: 226, Row: 083. Fecha de adquisición: 04-06-2011

**Coregistración de imágenes:** Se llevó a cabo la coregistración de todas las imágenes empleadas: COSMO-SkyMed, ASTER GDEM y Landsat 5 TM.

**Cálculo de índices topográficos:** Índice topográfico de humedad e índice fito-topográfico de humedad.

**Preprocesamiento del DEM:** Las posibles depresiones que se mencionan en la sección 2.3.5 del DEM deberían ser rellenadas como un primer paso en el análisis del mismo. Sin embargo, cuando en el área a analizar existe presencia de lagos o ríos que corresponden a grandes cuerpos de agua, los mismos poseen un valor de DEM fijo y artificial con lo cual el aplicado de alguna de las metodologías descritas, produciría mayores errores en la determinación de direcciones de flujo y en consecuencia, en el modelado.

Debido a la presencia de grandes superficies de cuerpos de agua con valores fijos de DEM, se procedió a evaluar la metodología de determinación de TWI en dos configuraciones de este DEM, A) filtrado con media móvil para producir un tamaño de píxel de 1 km y B) no filtrado con original tamaño de píxel. Sin embargo, se seleccionó el DEM B como el más adecuado para ser utilizado en la metodología de integración de clasificaciones.

Se aplicó la metodología descrita en la sección 2.3.4 a las dos configuraciones del DEM (A y B) correspondiente al área de estudio. Específicamente, se ejecutó la aproximación 3 de dicho capítulo para generar las matrices de dirección de flujo, acumulación de flujo e índice topográfico de humedad normalizado. Se aplicó la metodología desarrollada en la sección 3.3.3, sólo al DEM B, para obtener el índice fito-topográfico de humedad del área en análisis.

**Clasificación binaria del TWI:** En el caso del DEM B, una vez obtenidos ambos índices, se los clasificó mediante un umbral en: 1) cuerpos de agua, 2) no agua. Como umbral se seleccionó al mayor valor de índice en cada imagen (es decir, al valor 1). A la clasificación binaria obtenida de este modo, se la comparó con una clasificación utilizada como verdad de campo. Esta última fue el resultado de clasificar en: 1) cuerpos de agua y 2) no agua, a una imagen de NDVI proveniente de la imagen Landsat de la zona.

**Determinación de *verdad de campo* para la evaluación de clasificaciones:** Datos de presencia y ausencia de cuerpos de agua fueron obtenidos mediante una salida de campo realizada en coincidencia con la fecha de sensado de las imágenes COSMO-SkyMed analizadas. Con este muestreo se generó la *verdad de campo* con las que se testeó a las clasificaciones obtenidas en el presente capítulo.

Para llevar a cabo la evaluación de las clasificaciones de los índices topográficos y de la imagen COSMO-SkyMed PingPong se generó como *verdad de campo* una clasificación supervisada de la imagen Landsat correspondiente al área de estudio, utilizando las regiones de presencia/ausencia obtenidas el muestreo a campo. Mientras que para llevar a

cabo la evaluación de las clasificaciones de las imágenes COSMO-SkyMed Himage se utilizó como *verdad de campo* el producto resultante de clasificar a una imagen COSMO-SkyMed Himage con la técnica de crecimiento de regiones a partir de semillas colocadas en las áreas de presencia y ausencia de agua conocidas mediante datos de campo.

**Procesamiento de imágenes COSMO-SkyMed:** Se realizó el procesamiento de las imágenes COSMO-SkyMed empleadas mediante el procedimiento descrito en 5.2.4.

**Selección automática de muestras:** Se llevó a cabo la selección automática de muestra en las imágenes COSMO-SkyMed empleadas mediante el procedimiento descrito en 5.2.4.

**Delimitación automática de cuerpos de agua en imágenes COSMO-SkyMed:** Se realizaron las clasificaciones que se detallan en la tabla 6.1.

**Tabla 6.1:** Clasificaciones de imágenes COSMO-SkyMed llevadas a cabo en este capítulo

Banda/Imagen	Clasificador n°	Codificación
HH de PingPong	5	PingpongHH
VV de PingPong	5	PingpongVV
HV de Himage	5	HimageHV
HH de Himage	5	HimageHH
HH,VV de PingPong	6	PingpongHHVV

Los clasificadores son descritos en la sección 5.2.4.

**Evaluación de las clasificaciones:** La exactitud de las clasificaciones fue evaluada, utilizando la *verdad de campo* anteriormente mencionada, mediante matrices de confusión. Se evaluaron las clasificaciones tanto de los índices topográficos como de las imágenes COSMO-SkyMed.

**Mapa de clasificación por integración de dos metodologías:** En este paso se realizó la integración de la clasificación de una imagen SAR COSMO-SkyMed con la generada mediante la aplicación de un umbral en el  $TWI_v$ . El producto de esta integración es una nueva clasificación que indica el comportamiento de cada píxel respecto a ambas metodologías de clasificación.

Se decidió emplear las clasificaciones de SAR *PingpongHHVV* y del índice  $TWI_v$  debido a que fueron las que presentaron el porcentaje de exactitud más elevado, dentro de cada metodología de clasificación.

### 6.3. Resultados

**Cálculo del índice topográfico de humedad e índice fito-topográfico de humedad.** En la figura 6.4 se aprecian los perfiles horizontales del ASTER GDEM, correspondiente al área de estudio, sin filtrar y luego de aplicar el filtro de media móvil con un tamaño de kernel de  $39 \times 39$ .




En la figura 6.5 se muestran las variables de entrada: el DEM *ASTER GDEM* y fracción de vegetación  $f_v$  para el cálculo de  $TWI_n$  y  $TWI_v$  correspondientes al área de estudio.


El índice topográfico de humedad normalizado resultante del DEM *A* (filtrado) se presenta en la figura 6.6. Se observa una subestimación del área cubierta de agua en la zona del río, debido al efecto del filtro y las consecuentes direcciones de flujo originadas.

El índice topográfico de humedad normalizado resultante del DEM *B* (no filtrado) se presenta en la subfigura 6.7(a), mientras que el índice fito-topográfico se visualiza en la subfigura 6.7(b).

Las subfiguras 6.8(b) y 6.8(c) evidencian el resultado de la aplicación del umbral a los



**Figura 6.4:** Perfiles horizontales del ASTER GDEM con distintos procesamientos. Este DEM es una matriz que posee 324 columnas y el rango de valores de altura va de 0 a 40 m. El perfil del DEM sin filtrar se muestra en rojo, mientras que el perfil del DEM luego de aplicar el filtro de media móvil con un tamaño de kernel de  $39 \times 39$  se visualiza en verde.



(a) ASTER GDEM correspondiente al área de estudio. El rango de valores de altura va de 0 a 42.3 m

(b) Fracción de vegetación obtenida a partir de la imagen Landsat 5 TM correspondiente al área de estudio. Valores cercanos a 0 indican nula presencia de vegetación.

**Figura 6.5:** Variables de entrada para el cálculo de  $TWI_n$  y  $TWI_v$ : ASTER GDEM y fracción de vegetación.

índices correspondiente al DEM  $B$  para la clasificación de cuerpos de agua. La tabla 6.2 muestra sus respectivos valores de precisión de clasificación luego de ser comparados con la *verdad de campo* asumida (subfigura 6.8(a)).


La clasificación resultante de aplicar el umbral a la imagen de  $TWI_v$  presenta valores de exactitud mayores. En las distintas figuras expuestas en resultados los colores siempre representarán: en blanco, AGUA, y en negro, NO-AGUA.

**Tabla 6.2:** Evaluación de la exactitud de las clasificaciones mediante selección de un umbral en los índices topográficos de humedad


Clasificación	Porcentaje de exactitud (%)	Índice Kappa
$TWI_n$	87.83	0.60
$TWI_v$	90.96	0.69

**Verdad de campo para la evaluación de clasificaciones:** En la subfigura 6.10(c) se observa la localización de las fotografías tomadas en el área de estudio durante la salida de campo. En estas fotografías (Fig. 6.9 y 6.10) se han registrado los distintos cuerpos de agua presenciados en la escena.

A partir de esta salida de campo, y las respectivas delimitaciones de presencia y ausencia de cuerpos de agua, se generaron las imágenes que posteriormente fueron empleadas como *verdad de campo* durante la evaluación de las clasificaciones (Fig. 6.11). Para validar



**Figura 6.6:** Índice topográfico de humedad ( $TWI_n$ ) resultante del DEM filtrado.



**Figura 6.7:** Índices topográficos de humedad (simple  $TWI_n$  y fito-topográfico  $TWI_v$ ) resultantes del DEM no filtrado.



(a) Clasificación de una imagen de  $NDVI$  utilizada como *verdad de campo*

(b) Clasificación según  $TWI_n$




(c) Clasificación según  $TWI_v$

**Figura 6.8:** Matrices binarias resultantes de la aplicación de un umbral en los índices  $NDVI$ ,  $TWI_n$  y  $TWI_v$  para clasificación de cuerpos de agua. La imagen de  $NDVI$  clasificada es empleada como *verdad de campo* para la evaluación de las clasificaciones mediante umbrales de 6.8(b)  $TWI_n$  y 6.8(c)  $TWI_v$ .



(a) Localización 1.



(b) Localización 2.



(c) Localización 3.



(d) Localización 4.

**Figura 6.9:** Fotografías tomadas en el área de estudio.



(a) Localización 5.




(b) Localización 6.



(c) Localización de fotografías tomadas en el área de estudio.

**Figura 6.10:** Fotografías tomadas en el área de estudio.

la clasificación de PingPong, se generó como *verdad de campo* una clasificación supervisada de la imagen Landsat correspondiente al área de estudio (Fig. 6.11(a)), utilizando las regiones de presencia y ausencia obtenidas el muestreo a campo. Para llevar a cabo la evaluación de las clasificaciones de las imágenes COSMO-SkyMed Himage se utilizó como *verdad de campo* el producto resultante de clasificar a una imagen COSMO-SkyMed Himage (Fig. 6.11(b)) con la técnica de crecimiento de regiones a partir de semillas colocadas en las áreas de presencia y ausencia de agua conocidas también mediante datos de campo.




(a) Verdad de campo para validación de imagen COSMO-SkyMed PingPong. (b) Verdad de campo para validación de imagen COSMO-SkyMed Himage.

**Figura 6.11:** Clasificaciones de la imagen Landsat y COSMO-SkyMed Himage, a partir de datos de entrenamiento obtenidos a campo, utilizadas como *verdad de campo* de la clasificación de la imagen COSMO-SkyMed PingPong y COSMO-SkyMed Himage respectivamente. Para validar la clasificación de PingPong, se generó como *verdad de campo* una clasificación supervisada de la imagen Landsat correspondiente al área de estudio, utilizando las regiones de presencia/ausencia obtenidas el muestreo a campo. Para llevar a cabo la evaluación de las clasificaciones de las imágenes COSMO-SkyMed Himage se utilizó como *verdad de campo* el producto resultante de clasificar a una imagen COSMO-SkyMed Himage con la técnica de crecimiento de regiones a partir de semillas colocadas en las áreas de presencia y ausencia de agua conocidas también mediante datos de campo.

**Procesamiento de imágenes COSMO-SkyMed:** En la figura 6.12 se presentan las imágenes resultantes del procesamiento de las imágenes COSMO-SkyMed: lectura, conversión de formato HDF a formato ENVI [ENVI, 2009], y calibración radiométrica. En estas figuras se muestran las imágenes calibradas radiométricamente expresadas en coeficiente de retrodispersión en decibeles.

**Selección automática de muestras:** En la figura 6.13 son presentadas las imágenes que son el resultado del algoritmo de selección automática de muestras y cuyas clases serán empleadas en cada respectiva clasificación.


**Delimitación automática de cuerpos de agua en imágenes COSMO-SkyMed:** Los clasificadores empleados en este capítulo se basan en la determinación de la variable de textura  $C$  defini-



(a) Banda de polarización  $HH$  de la imagen COSMO-SkyMed 1 PingPong, correspondiente a la fecha de adquisición: 10-05-2011. Resolución espacial: 20 m. (b) Banda de polarización  $VV$  de la imagen COSMO-SkyMed 1 PingPong, correspondiente a la fecha de adquisición: 10-05-2011. Resolución espacial: 20 m.




(c) Imagen Himage de polarización  $HV$ , correspondiente a la fecha de adquisición: 08-05-2011. Resolución espacial: 5 m.



(d) Imagen Himage de polarización  $HH$ , correspondiente a la fecha de adquisición: 12-05-2011. Resolución espacial: 5 m.


**Figura 6.12:** Imágenes COSMO-SkyMed en valores de decibeles calibradas radiométricamente.



**Figura 6.13:** Matrices binarias resultantes de la selección automática de muestras de AGUA y NO-AGUA (clase que abarca el resto de las coberturas que no pertenecen a la clase AGUA) en las distintas imágenes COSMO-SkyMed: PingPong  $HH$ , PingPong  $VV$ , Himage  $HV$  e Himage  $HH$ .




da en 5.2.4. A modo de ejemplo de estas características de textura se presenta, en la figura 6.14, las correspondientes a la imagen Himage de polarización  $HH$ .



(a) Primera componente principal de las 8 variables de textura.



(b) Segunda componente principal de las 8 variables de textura.




(c) Tercera componente principal de las 8 variables de textura.

**Figura 6.14:** Variables de textura  $C$  (PCA 1, PCA 2, PCA 3) correspondientes a la imagen COSMO-SkyMed Himage  $HH$ , obtenidas mediante el clasificador 5.

En la figura 6.15 se presentan los resultados de las clasificaciones:  $PingpongHH$ ,  $PingpongVV$ ,

*HimageHV*, *HimageHH*, *PingpongHHVV* obtenidos mediante el clasificador que utiliza la variable de textura *C*.



**Figura 6.15:** Resultados de las clasificaciones correspondientes a las distintas imágenes COSMO-SkyMed analizadas. Las clasificaciones 6.15(a), 6.15(b), 6.15(d) y 6.15(e) emplean clasificadores tridimensionales (utilizan 3 variables de textura), mientras que la clasificación 6.15(c) utiliza clasificadores de 6 dimensiones (6 variables de textura). Se puede observar como la precisión varía de acuerdo al modo y polarización de la imagen de entrada en el clasificador, así como a la muestra de entrenamiento utilizada (diferente entre PingPong e Himage).

**Evaluación de las clasificaciones:** La tabla 6.3 resume la evaluación de exactitud de las diferentes clasificaciones, a través de sus respectivos porcentajes de exactitud e índices Kappa.

**Mapa de clasificación basado en la integración de dos metodologías:** Esta sección se orien-

**Tabla 6.3:** Evaluación de la exactitud de las diferentes clasificaciones de COSMO-SkyMed.

Clasificación	Porcentaje de exactitud (%)	Índice Kappa
<i>PingpongHH</i>	95.03	0.85
<i>PingpongVV</i>	94.58	0.84
<i>PingpongHHVV</i>	96.32	0.88
<i>HimageHH</i>	92.04	0.80
<i>HimageHV</i>	84.30	0.63

ta a la comparación e integración de metodologías expuestas en este trabajo: clasificación de cuerpos de agua en 1) las imágenes COSMO-SkyMed SAR y 2) el DEM. Se integró a las clasificaciones de SAR (*PingpongHHVV*) y del DEM (índice  $TWI_v$ ) en una imagen que identifica los siguientes tipos de píxeles (ver tabla 7.1, página 152):

- Clasificados según COSMO-SkyMed y DEM como AGUA.
- Clasificados según COSMO-SkyMed y DEM como NO-AGUA.
- Clasificados según COSMO-SkyMed como AGUA y según DEM como NO-AGUA.
- Clasificados según DEM como AGUA y según COSMO-SkyMed como NO-AGUA.


En la figura 6.16 se presenta el mapa de la clasificación basado en la integración de las dos metodologías descritas anteriormente, mientras que en la figura 6.17 se muestra la clasificación *PingpongHHVV* superpuesta sobre el DEM correspondiente. En general, se observa la coincidencia del patrón de clasificación COSMO-SkyMed con las zonas donde por terreno de acumularse agua. Existen sin embargo, zonas que según la clasificación de COSMO-SkyMed son cuerpos de agua, pero según el DEM no es tan evidente que se debería acumular agua.

## 6.4. Discusión y conclusiones


En este capítulo se desarrolló una integración de las clasificaciones implementadas en los capítulos anteriores, de imágenes radar COSMO-SkyMed, con información proveniente de los índices topográficos de humedad del área analizada.

De acuerdo a lo analizado en relación al pre-procesamiento del modelo de elevación digital, dada la presencia de posibles patrones irreales en el mismo tales como depresiones, se concluye la necesidad de evaluar diferentes metodologías para preparar adecuadamente a los DEM y evitar errores en la posterior determinación de direcciones de flujo.

En este capítulo se clasificó a los índices topográficos  $TWI_n$  y  $TWI_v$  (resultantes del DEM correspondiente al área de estudio), de acuerdo a un umbral determinado, en zonas 1) que acumulan agua y 2) que no acumulan agua. Se determinó una mayor precisión de clasificación de aguas en la segmentación del  $TWI_v$ . De acuerdo al análisis de TWI en relación a la probabilidad de acumulación de agua, la medición de exactitud de su clasificación de grandes cuerpos



**Figura 6.16:** Clasificación basada en la integración de las dos metodologías: clasificación de la imagen SAR COSMO-SkyMed (denominada *COSMO* en la leyenda) y del modelo de elevación digital (denominada *DEM*). *DEM, COSMO* representa los píxeles clasificados según la clasificación de COSMO-SkyMed y la clasificación del DEM como AGUA; *DEM, NOCOSMO* representa los píxeles clasificados según la clasificación del DEM como AGUA pero no por la clasificación de COSMO; *COSMO, NODEM* representa los píxeles clasificados según la clasificación de COSMO como AGUA pero no por la clasificación del DEM; *NODEM, NOCOSMO* representa los píxeles no clasificados por ninguna clasificación como AGUA.



**Figura 6.17:** Superposición de la clasificación *PingpongHHVV* (en puntos de color rojo) sobre el DEM (en escala de grises). Los valores del DEM tienen un rango de 0 a 42 m. Se puede visualizar la coincidencia de los cuerpos de agua detectados con la imagen COSMO-SkyMed respecto a las depresiones del DEM.

de agua sería un posible mecanismo de validación de este índice topográfico.

Se clasificaron distintas imágenes COSMO-SkyMed, y se determinó una mayor exactitud en las clasificaciones de la imagen de modo PingPong, respecto a las de modo Himage. Comparando las PingPong, la clasificación de polarización dual fue más exacta que las de polarización simple. Se esperaba teóricamente y con respaldo de bibliografía pertinente [Ahtonen et al., 2004; Henry et al., 2006; Malnes et al., 2002; Sarti et al., 2001; Schumann et al., 2007] que la polarización  $HH$  proporcione una mejor discriminación entre agua y otros tipos de coberturas terrestres. Analizando las clasificaciones de polarización simple de las bandas de la imagen PingPong, pudo ser comprobada la mayor precisión de delimitación de cuerpos de agua en la banda  $HH$ .

Respecto a las imágenes modo Himage, la clasificación de la polarización  $HH$  obtuvo valores de precisión mayores que la de la polarización  $HV$ . La imagen COSMO-SkyMed de modalidad Himage y polarización  $HV$  resultó particularmente muy inadecuada para la separación entre las clases AGUA y NO-AGUA.

Debido a que la verdad de campo fue construida a partir de muestras *in situ*, las evaluaciones realizadas en este capítulo resultan más rigurosas. Se concluye que en general se obtuvieron resultados muy satisfactorios en casi todas las clasificaciones analizadas.

En este capítulo fue posible integrar los dos sistemas de clasificación, las clasificaciones de SAR y del DEM (índice  $TWI_v$ ), los cuales se basan en análisis de diferentes características del terreno, para la estimación de zonas de probable acumulación de agua. La clasificación del DEM se puede considerar como estática, debido a que no varía en el tiempo; mientras que la clasificación de COSMO-SkyMed permitiría la actualización temporal de la delimitación de cuerpos de agua. El producto obtenido del DEM permitiría definir una clasificación final, en el sentido de que posibilita descartar errores, de comisión u omisión, en la clasificación de COSMO-SkyMed. Este producto de integración de clasificaciones debe ser analizado posteriormente en función de los objetivos del estudio.

Es importante destacar que no se encontró, en la búsqueda bibliográfica realizada, aproximaciones similares a la llevada a cabo en este capítulo. Esto imposibilita la comparación con enfoques de otros autores.

Una aproximación interesante sería realizar un análisis multitemporal, durante un fenómeno de inundación, con imágenes clasificadas según la metodología propuesta en este estudio; comparándolo luego con la metodología realizada por Angiati & Dellepiane [2010] para imágenes COSMO-SkyMed. Esta última es la única encontrada en la bibliografía específicamente para imágenes COSMO-SkyMed y se basa en la utilización de crecimiento de regiones a partir de una semilla.

# Capítulo 7

## Conclusiones generales

La posibilidad de generar mapas de cuerpos de agua o mapas de extensión de inundaciones en tiempo casi real es primordial en agencias nacionales o internacionales para el monitoreo de desastres y distribución de esfuerzos o acciones. Dada la relevancia que posee la delimitación espacial de (1) cuerpos de agua continentales y (2) zonas anegables, se orientó esta tesis hacia la generación de metodologías para la detección automática de este tipo de superficies. Se pretende aportar al funcionamiento de un sistema operativo capaz de hacer frente a emergencias, tanto meteorológicas como epidemiológicas, que amenazan a la sociedad.

En este sentido, se buscó evaluar la utilidad y limitaciones de la constelación COSMO-SkyMed SAR para la utilización de sus datos en sistemas de detección de cuerpos de agua que sean automáticos, robustos, e independientes de características del sensor tales como la polarización o ángulos de incidencia. Posteriormente, se exploró la integración de parámetros hidrológicos, generados a partir de modelos de elevación digital (DEM) con datos de la clasificación de COSMO-SkyMed en una metodología de detección de superficies de agua.

Este trabajo define un sistema de clasificación basado en el complemento de dos métodos de clasificación que corresponden a análisis de diferentes características del terreno. El primer método consiste en la clasificación automática de imágenes COSMO-SkyMed, mientras que el segundo está basado en el análisis de un DEM. La clasificación de DEM se puede considerar como estática debido a que no varía en el tiempo, a menos que el modelo de elevación digital terrestre varíe; mientras que la clasificación de COSMO-SkyMed permitiría la actualización en el tiempo de la dinámica de la misma. Al mismo tiempo, el producto obtenido del DEM podría definir la delimitación final de cuerpos de agua, permitiendo el reconocimiento de errores en la clasificación de COSMO-SkyMed.

En el capítulo 2 se implementaron diferentes algoritmos de cálculo de un índice topográfico de humedad en base a un modelo de elevación digital y se seleccionó, de estos procedimientos, al que se consideró más ajustado a la realidad. En el capítulo 3 se planteó un índice fito-topográfico de humedad, que intenta mejorar el modelado hidrológico correspondiente al capítulo 2, en el cual se considera el efecto de la cobertura de vegetación en el patrón de acumulación de humedad. En el capítulo 5 se generó un sistema de clasificación de imágenes COSMO-SkyMed, basado en novedosas variables de textura y entrenado automáticamente. En

---

el capítulo 6 se integran las metodologías generadas y, mediante análisis de campo, se validan las mismas en un área altamente anegable. Todos los algoritmos desarrollados en esta tesis fueron implementados en el lenguaje de programación *IDL*.

Como se mencionó anteriormente, en el capítulo 1 se definió una metodología para el cálculo de un índice topográfico de humedad (TWI) que captura características esenciales del terreno en relación al flujo de agua, de un modo más simple y eficiente que usando modelos de simulación de dinámica hidrológica. El índice topográfico se basa en el cálculo de acumulación de flujos de agua y permite definir la cantidad de agua de lluvia que puede fluir hacia una celda dada. Esto determina que áreas con los valores más altos de TWI se saturarían de agua con mayor probabilidad que el resto, durante una lluvia o el acontecimiento de deshielo.

Una vez determinada una metodología para calcular el índice TWI, se consideró el efecto de la cobertura de la vegetación en el patrón de acumulación de agua, intentando mejorar la estimación de este parámetro hidrológico mediante una captura más completa de la complejidad del sistema natural. Fue posible proponer una función que modela el efecto esperado, de acuerdo a las hipótesis planteadas, de la vegetación sobre la acumulación potencial de agua. Esta ecuación posee parámetros variables que deben ser ajustados convenientemente a fin de modelar de manera adecuada el comportamiento hidrológico que se observaría en las situaciones reales. Este índice resultante puede ser clasificado, de acuerdo a un umbral determinado, en zonas 1) que acumulan agua y 2) que no acumulan agua, dando lugar a una clasificación binaria del mismo, útil al momento de analizar la presencia de superficies con agua.

Respecto al método de clasificación de radar, imágenes adquiridas por la constelación de COSMO-SkyMed han sido estudiadas con el objetivo de desarrollar un método automático para la detección de agua, que podría ser adecuado para formar parte de un sistema operativo de respuesta temprana y alerta a emergencias relacionadas a cuerpos de agua. Se generó un sistema de clasificación automática, no dependiente de la supervisión por parte del usuario; el cual a partir de una imagen COSMO-SkyMed como entrada produce la delimitación de sus superficies con agua. Este sistema se logró mediante un clasificador de máxima verosimilitud entrenado automáticamente, basado en textura. Se generó un método de entrenamiento automático que resultó cualitativamente satisfactorio. El sistema permite la clasificación de COSMO-SkyMed PingPong mediante la utilización de sus dos bandas de diferente polarización (polarización dual). Se basa en la utilización de características de textura, tales como *curtosis* y *skewness*, no empleadas previamente en clasificación de SAR. Además, emplea análisis de componentes principales de 8 variables de textura para la generación de información de textura nueva, útil como entrada alternativa para el clasificador. Por último, el método emplea herramientas de morfología matemática en la definición de la clasificación final. Estas herramientas son empleadas con el fin de evaluar los datos de la clasificación de agua preservando sus características de forma esenciales y eliminando irrelevancias. De manera que se genera una imagen de probabilidad de presencia de agua, considerando los operadores morfológicos sobre las clasificaciones binarias de cuerpos de agua.

El método, basado en textura, utiliza las diferencias estadísticas correspondientes a los dife-

---

rentes mecanismos de retrodispersión del agua respecto a las superficies que no corresponden a agua. El detector de textura permite delimitar superficies de agua con buena resolución espacial y exactitud, teóricamente independiente del ángulo de incidencia del radar. Un mayor número de datos SAR, por lo tanto, son apropiados para detectar agua, lo cual es fundamental en sistemas de respuesta a emergencias que necesitan que la mayor cantidad de datos sean procesados en tiempo real. Además, se comprobó la efectividad de la banda de X de COSMO-SkyMed en la delimitación de cuerpos de agua abiertos. Esto, sumado a la excelente cobertura temporal de este sensor, lo convierte en un candidato importante para sistemas de control de emergencias hidrológicas.

Por último, se planteó la integración de clasificaciones como una re-clasificación de ambos productos binarios: 1) la clasificación del índice topográfico de humedad y 2) la clasificación de COSMO-SkyMed. Este producto puede ser analizado y estructurado, eventualmente, en función de los objetivos del estudio para el que sea empleado.

Como producto final, fue posible generar módulos programados en el lenguaje IDL que permitan ejecutar todos los procedimientos desarrollados en esta tesis. Estas funciones abarcan desde el procesamiento inicial del formato de imágenes COSMO-SkyMed hasta la determinación de índices hidrológicos y clasificaciones SAR.

A modo de conclusiones generales, se pueden citar los siguientes aspectos que surgen de este trabajo de tesis:

- Se implementaron diferentes metodologías de cálculo de índice topográfico de humedad (TWI), el cual representa una estimación de la acumulación de agua en una determinada unidad espacial.
- Se seleccionó, de estas metodologías implementadas, la que generó estimaciones más acertadas respecto a la configuración del terreno evaluado.
- Se pudo comprobar la utilidad de los DEMs en la caracterización cuantitativa del terreno en términos de probabilidad de acumulación de agua en una determinada unidad espacial.
- El significado del TWI varía en relación a la escala de análisis del mismo, determinada por la resolución espacial del DEM empleado. A una escala local, se considera al TWI como un indicador de la probabilidad de humedad, mientras que a escala regional el índice demarca la probabilidad de acumulación de agua.
- Fue posible desarrollar e implementar un índice fito-topográfico de humedad, proponiendo una función que modela el efecto de la vegetación sobre la acumulación potencial de agua. Esta ecuación posee parámetros variables, que deben ser ajustados convenientemente a fin de modelar de manera adecuada el comportamiento hidrológico que se observa en las situaciones reales.
- Se generó una metodología de clasificación de cuerpos de agua en base a la determinación de un umbral en los índices topográficos generados, dando lugar a una clasificación binaria de los mismos.
- Se generó un sistema de clasificación automática de superficies con agua en imágenes



- COSMO-SkyMed, no dependiente de la supervisión por parte del usuario. Este sistema se basa en un clasificador de máxima verosimilitud, basado en textura, entrenado automáticamente.
- El detector basado en textura permite delimitar superficies de agua con buena resolución espacial y exactitud.
  - Se utilizaron características de textura, tales como *curtosis* y *skewness*, no empleadas previamente en clasificación de SAR.
  - Se empleó análisis de componentes principales de 8 variables de textura para la generación de información de textura nueva, la cual es una entrada alternativa para el clasificador.
  - El sistema de clasificación de COSMO-SkyMed puede emplear una o dos polarizaciones (clasificación de tres y seis dimensiones respectivamente) de COSMO-SkyMed, permitiendo la clasificación de PingPong mediante la utilización de sus dos bandas de diferente polarización (polarización dual).
  - El sistema de clasificación emplea además herramientas de morfología matemática en la definición de la clasificación final, con el fin de eliminar irrelevancias preservando las características de forma esenciales de los cuerpos de agua. De manera que se genera una imagen de probabilidad de presencia de agua considerando los operadores morfológicos sobre las clasificaciones binarias de cuerpos de agua.
  - Se comprobó la efectividad de la banda de X de COSMO-SkyMed en la delimitación de cuerpos de agua abiertos. Esto, sumado a la excelente cobertura temporal de este sensor, lo convierte en un candidato importante para sistemas de control de emergencias hidrológicas.
  - Se planteó una propuesta de integración de las clasificaciones como una re-clasificación de ambos productos binarios: la clasificación del índice y la de COSMO-SkyMed.
  - Se generaron módulos programados en el lenguaje *IDL* que permiten ejecutar todos los procedimientos desarrollados en esta tesis. Las funciones implementadas abarcan desde el procesamiento inicial del formato de imágenes COSMO-SkyMed hasta la determinación de índices hidrológicos y clasificaciones SAR.

### 7.1. Aportes a mi formación profesional

Mediante la realización de esta tesis de maestría he profundizado mi formación de base en el uso de la tecnología espacial; tanto en el procesamiento avanzado como en el análisis de información satelital. Particularmente, adquirí destrezas en el manejo de imágenes SAR (COSMO-SkyMed, un producto de la constelación SIASGE) y su aplicación a la detección de cuerpos de agua.

He afianzado conocimientos matemáticos básicos para la formulación de modelos; y asimilé herramientas de simulación y de implementación computacional de los mismos. He incorporado

técnicas de algoritmia aplicada al modelado de fenómenos físicos, y me capacité en herramientas informáticas de modelado y programación tales como el lenguaje IDL. Mi capacitación en lenguajes de desarrollo es fundamental en mi formación tanto para el procesamiento de imágenes como para el modelado. Esto me brinda la posibilidad de aumentar mis posibilidades en investigación, consolidando destrezas en la generación e implementación informática de modelos de simulación de procesos ambientales relacionados a emergencias.

Es importante resaltar la importancia que tuvo el hecho de trabajar de manera interdisciplinaria, con un director y un codirector de tesis de formación diversa a la mía; dando lugar a un trabajo de investigación multidisciplinario que contribuye al desarrollo de mis aptitudes para el análisis integrado de los problemas de investigación.

**Propuesta de trabajos futuros:** A partir de los conceptos desarrollados en esta tesis, puedo mencionar las siguientes propuestas de investigación a futuro:

- La epidemiología panorámica tiene como principal objetivo el análisis de parámetros ambientales relacionados con el desarrollo de enfermedades y los vectores de estas enfermedades. Se orienta a la comprensión de los sistemas socio-ambientales complejos implicados en las enfermedades que afectan a la población humana; esto es el análisis de la distribución e interacciones de los factores relacionados con dichas enfermedades.

En el marco de la epidemiología panorámica, específicamente del estudio de insectos vectores que transmiten enfermedades humanas, considero que sería altamente interesante evaluar la correlación de los índices topográficos aquí obtenidos, tanto del tradicional como del fito-topográfico, con variables relacionadas a estos vectores de enfermedades. En primer lugar, los índices podrían determinar las zonas adecuadas como sitios de muestreo. En segundo lugar, se podría analizar la correlación de zonas de potencial acumulación de agua, a través de la facilitación de hábitats de vectores, con el riesgo de brotes de los complejos sistemas de enfermedades vinculadas al ambiente.

Algunos ejemplos de enfermedades transmitidas por vectores en Argentina son: la malaria, la Leishmaniasis, el Hantavirus, la Fiebre Hemorrágica Argentina, el Dengue, y el Mal de Chagas.

La posibilidad de detectar y monitorear los sitios acuáticos de desarrollo de vectores, complementado con relevamientos epidemiológicos de terreno, información ambiental extra producida por sensores remotos y de sistemas de información geográfica, posibilitaría la producción de mapas de riesgo de transmisión de las enfermedades mencionadas.

Una vez generados los mapas y modelos de riesgo, sería más factible la gestión de los recursos hídricos con el fin de reducir la transmisión de enfermedades de transmisión vectorial. Un ejemplo de acciones de control epidemiológico de este tipo de enfermedades sería la aplicación de larvicidas en sectores detectados de modo de reducir la abundancia de formas inmaduras del mosquito transmisor.

Es importante considerar que las transmitidas por vectores no son las únicas enfermedades

relacionadas al agua, y la siguiente lista corrobora la importancia del conocimiento y monitoreo de superficies de agua. Las enfermedades humanas de origen hídrico pueden dividirse en cuatro categorías:

- Enfermedades transmitidas por el agua,
  - Enfermedades con base u originadas en el agua,
  - Enfermedades de origen vectorial relacionadas con el agua,
  - Enfermedades vinculadas a la escasez de agua,
- En relación al índice fito-topográfico de humedad desarrollado en esta tesis, una condición que debe confirmarse en próximos trabajos es que el efecto modelado de la vegetación sobre la acumulación potencial de agua debe representar indirectamente la influencia de los tipos de suelo presentes. En relación al modo de cuantificar la vegetación presente en el terreno, sería adecuado incorporar las validaciones de la variable ‘fracción de vegetación’ con medidas de campo. En consecuencia, se debería introducir la variable de vegetación que mejor represente la cobertura terrestre y su posibilidad de ejercer efecto sobre el ciclo hidrológico. En definitiva, deben regularse los parámetros que intervienen en la formulación del modelo de manera de ajustar de la manera más completa posible a la realidad del terreno.

Sería también adecuado evaluar la integración del índice fito-topográfico desarrollado en este trabajo con los conceptos asumidos para el planteo del índice de [Temimi et al. \[2010\]](#).

- Respecto al sistema de clasificación de COSMO-SkyMed, una aproximación interesante sería implementar un análisis de textura en las imágenes SAR que involucre técnicas como las transformaciones espaciales de *Fourier*. Esto podría brindar información valiosa a la hora de caracterizar clases en la superficie.

Por otro lado y alternativamente a estos clasificadores, se podrían plantear clasificadores que trabajen con datos de imágenes COSMO-SkyMed en otras unidades y ajusten otros modelos de distribución estadística.

Un evidente trabajo que surge es el de comparar la precisión resultante de los clasificadores propuestos respecto a la de otras aproximaciones, tales como contornos activos, crecimiento de regiones, clasificadores de forma, entre otros. Incluso se pueden plantear clasificadores integrando algunas de estas metodologías.

Es importante el análisis del comportamiento del clasificador aquí planteado en relación a las características de la imagen COSMO-SkyMed que es la variable de entrada para el mismo. Características tales como el ángulo de incidencia del sensor, el tipo de órbita del sensor (ascendente o descendente) podrían tener influencia en la separación de superficies de agua.

Del mismo modo, permanece pendiente la evaluación de los sensores COSMO-SkyMed respecto a la posibilidad de detectar y reconocer vegetación inundada o cuerpos de agua con vegetación superficial. Además se podría analizar la sensibilidad del mismo frente a presencia de olas o escorrentías en el cuerpo de agua.

- En esta tesis se utilizó el lenguaje IDL para la implementación de algoritmos, debido a que el mismo consiste en la plataforma del reconocido software ENVI, el más utilizado para procesamiento de imágenes en las instituciones donde se realizó este trabajo. Sin embargo, debido a los reconocidos cuestionamientos de IDL respecto a su precisión numérica [Bustos & Frery, 2005] y a su condición de software privativo, sería adecuado implementar todas las funciones desarrolladas a lo largo de esta tesis en el reconocido software R (R project). De esta manera, no solo se estarían reduciendo los errores de cálculo de los respectivos algoritmos, sino también se migraría hacia un ambiente específicamente diseñado para computación estadística. A modo de resumen, algunos de los beneficios del software R serían los siguientes:
  - Es completamente gratis.
  - Funciona en una variedad de plataformas incluyendo Windows, Unix, MacOS.
  - Contiene rutinas estadísticas avanzadas aún no disponibles en otros paquetes de software estadísticos.
  - Sus capacidades gráficas están ubicadas entre las mejores.
  - Proporciona una plataforma para programar nuevos métodos estadísticos de una manera sencilla.

# Referencias

- Ahtonen, P., Euro, M., Hallikainen, M., Solbø, S., & Johansen, B. & Solheim, I. (2004). SAR and optical based algorithms for estimation of water bodies. Technical report, FloodMan Project.
- Ahtonen, P. & Hallikainen, M. (2005). Automatic detection of water bodies from spaceborne SAR images. In *Geoscience and Remote Sensing Symposium, 2005. IGARSS '05. Proceedings. 2005 IEEE International*, volume 6, pages 3845 – 3848.
- Allan, R. P. & Soden, B. J. (2008). Atmospheric warming and the amplification of precipitation extremes. *Science*, 321(5895):1481–1484.
- Alsdorf, D. E., Smith, L. C., & Melack, M. J. (2001). Amazon floodplain water level changes measured with interferometric SIR-C radar. *IEEE Geoscience and Remote Sensing Society*, 39(2):423–431.
- Angiati, E. & Dellepiane, S. (2010). Flooding maps from COSMO-SkyMed images. In *Proceedings of IEEE GOLD 2010*.
- Anys, H., Bannari, A., He, D. C., & Morin, D. (1994). Texture analysis for the mapping of urban areas using airborne MEIS-II images. In *First International Airborne Remote Sensing Conference and Exhibition*, volume 3, pages 231–245.
- Aryal, S. & Bates, B. (2008). Effects of catchment discretization on topographic index distributions. *Journal of Hydrology*, 359(1-2):150–163.
- Bartak, V. (2009). How to extract river networks and catchment boundaries from DEM: a review of digital terrain analysis techniques. *Journal of Landscape Studies*, 2:57–68.
- Beguiría, S., López-Moreno, J., Gómez-Villar, A., Rubio, V., Lana-Renault, N., & García-Ruiz, J. M. (2006). Fluvial adjustments to soil erosion and plant cover changes in the central Spanish Pyrenees. *Geografiska Annaler*, 88A:177–186.
- Belmonte, I. & Caamaño, S. (2009). Una aplicación basada en imágenes SAR para el monitoreo y prevención de inundaciones en argentina. Tesis de grado, Facultad de Matemática, Astronomía y Física. Universidad Nacional de Córdoba, Argentina.

- Beven, K. J. & Kirkby, M. (1979). A physically based variable contributing area model of basin hydrology. *Hydrological Sciences Bulletin*, 24(1):43–69.
- Blasco, F., F., B. M., & Chaudhury, M. U. (1992). Estimating the extent of floods in bangladesh using SPOT data. *Remote Sensing of Environment*, 39:167–178.
- Bourgeau-Chavez, L. L., Kasischke, E. S., Brunzell, S. M., Mudd, J. P., Smith, K. B., & Frick, A. L. (2001). Analysis of space-borne SAR data for wetland mapping in virginia riparian ecosystems. *International Journal of Remote Sensing*, 22.
- Brivio, P. A., Colombo, R., Maggi, M., & Tomasoni, R. (2002). Integration of remote sensing data and GIS for accurate mapping of flooded areas. *International Journal of Remote Sensing*, 23(3):429–441.
- Bustos, O. H. & Frery, A. C. (2005). Statistical functions and procedures in IDL 5.6 and 6.0. *Computational Statistics and Data Analysis*, 50(2):301–310.
- Calvo-Cases, A., Boix-Fayos, C., & Imeson, A. (2003). Runoff generation, sediment movement and soil water behaviour on calcareous (limestone) slopes of some Mediterranean environments in southeast Spain. *Geomorphology*, 50:269–291.
- Camara, G., Souza, R. C. M., Freitas, U. M., & Garrido, J. (1996). SPRING: Integrating remote sensing and GIS by object-oriented data modelling. *Computers and Graphics*, 20(3).
- Canton, Y., Sole-Benet, A., & Domingo, F. (2004). Temporal and spatial patterns of soil moisture in semiarid badlands of SE Spain. *Journal of Hydrology*, 285(1–4):199–214.
- Casermeiro, M. A., Molina, J. A., Caravaca, M., Costa, J., Massanet, M., & Moreno, P. (2004). Influence of scrubs on runoff and sediment loss in soils of Mediterranean climate. *Catena*, 57:91–107.
- Castleman, K. R. (1996). *Digital image processing*. Prentice-Hall, New Jersey,.
- Chander, G. & Markham, B. (2003). Revised Landsat-5 TM radiometric calibration procedures and postcalibration dynamic ranges. *IEEE Transactions on Geoscience and Remote Sensing*, 41:2674 – 2678.
- Chander, G., Markham, B., & Helder, D. (2009). Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. *Remote Sensing of the Environment*.
- Chenyang, X. & Prince, J. (1997). Gradient vector flow: a new external force for snakes. In *Computer Vision and Pattern Recognition IEEE Computer Society Conference*, pages 66 – 71.

- Chirino, E., Vilagrosa, A., Cortina, J., Valdecantos, A., Fuentes, D., Trubat, R., Luis, V. C., Puértolas, J., Bautista, S., Baeza, M. J., Peñuelas, J. L., & Vallejo, V. R. (2006). *Forest Management*, chapter Ecological restoration in degraded drylands: the need to improve the seedling quality and site conditions in the field.
- Chuvieco, E. (2000). *Fundamentos de Teledetección Espacial*. Ediciones Rialp S.A, Madrid, España.
- Clennon, J. A., Kamanga, A., Musapa, M., Shiff, C., & Glass, G. E. (2010). Identifying malaria vector breeding habitats with remote sensing data and terrain-based landscape indices in Zambia. *International Journal of Health Geographics*, 9(58).
- Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educational & Psychological Measurement*, 20:37–46.
- Cohen, J. (1968). Weighted kappa: Nominal scale agreement with provision for scaled disagreement or partial credit. *Psychological Bulletin*, 70:426–443.
- Cohen, J. M., Ernst, K. C., Lindblade, K., Vulule, J. M., John, C. C., & Wilson, M. L. (2010). Local topographic wetness indices predict household malaria risk better than land-use and land-cover in the western Kenya highlands. *Malaria journal*, 9(1):328.
- Cohen, J. M., Ernst, K. C., Lindblade, K. A., Vulule, J. M., John, C. C., & Wilson, M. L. (2008). Topography-derived wetness indices are associated with household-level malaria risk in two communities in the western kenyan highlands. *Malaria Journal*, 7(40).
- Cohen, L. D. (1991). *On active contour models and balloons*. CVGIP: Image Understanding archive.
- Cohen, L. D. & Cohen, I. (1993). Finite-element methods for active contour models and balloons for 2-d and 3-d images. In *IEEE Transactions on Pattern Analysis and Machine Intelligence*, volume 15, pages 1131–1147.
- Cook, R., McConnell, I., & Oliver, C. J. (1994). MUM (Merge Using Moments) segmentation for SAR images. In *SPIE*, volume 2316, pages 92–103.
- Costa-Cabral, M. & Burges, S. (1994). Digital Elevation Model Networks (demon): a model of flow over hillslopes for computation of contributing and dispersal areas. *Water Resources Research*, 30(6):1681–1692.
- Curlander, J. & McDonough, R. (1991). *Synthetic Aperture Radar: Systems and Signal Processing*. John Wiley & Sons. New York.
- Dellepiane, S., Angiati, E., & Vernazza, G. (2010). Processing and segmentation of COSMO-SkyMed images for flood monitoring. In *Geoscience and Remote Sensing Symposium (IGARSS), 2010 IEEE International*, pages 4807 –4810.

- Deshmukh, K. & Shinde, G. (2005). An adaptive color image segmentation. *Electronic Letters on Computer Vision and Image Analysis*, 5(4):12–23.
- Drake, B. & Shuchman, R. A. (1974). Feasibility of using multiplexed slar imagery for water resources management and mapping vegetation communities. In *Proceedings of the 9th International Symposium on Remote Sensing of Environment*, pages 714–724. Environmental Research Institute of Michigan, Ann Arbor, USA.
- Drogue, G., Pfister, L., Leviandier, T., El Idrissi, A., Iffly, J. F., Matgen, P., Humbert, J., & Hoffmann, L. (2004). Simulating the spatio-temporal variability of streamflow response to climate change scenarios in a mesoscale basin. *Journal of Hydrology*, 293(1-4):255–269.
- Dumitras, A. & Venetsanopoulos, A. N. (2001). A comparative study of snake models with application to object shape description in bi-level and gray-level. In *Proceedings of IEEE-EURASIP Workshop on Nonlinear Signal and Image Processing, Baltimore, USA*.
- Dunne, T., Zhang, W., & Aubry, B. F. (1991). Effects of rainfall, vegetation, and Microtopography on infiltration and runoff. *Water Resources Research*, 27:2271–2285.
- Elachi, C. (1988). *Spaceborne radar remote sensing: applications and techniques*. New York: IEEE Press.
- ENVI (2009). Envi Version 4.7. Environment for Visualizing Images (ENVI). "<http://www.RSInc.com/envi>". ITT Visual Information Solutions.
- Farr, G. T. (1993). *Guide to Magellan Image Interpretation*, chapter Chapter 5: Radar Interactions With Geologic Surfaces. NASA.
- Fernández Sarría, A., Recio, J., & Ruiz Fernández, L. A. (2003). *Análisis de imágenes mediante texturas: aplicación a la clasificación de unidades de vegetación*. Geofocus: Revista Internacional de Ciencia y Tecnología de la Información Geográfica, ISSN 1578-5157. N°. 3.
- Florinsky, I. V. (1998). Combined analysis of digital terrain models and remotely sensed data in landscape investigations. *Progress in Physical Geography*, pages 33–60.
- Francis, D. & Hengeveld, H. (1998). *Extreme Weather and Climate Change*. Downsview, Ontario: Environment Canada.
- Frery, A. C., da C. F. Y., C., & Sidnei, J. S. S. (1997). El modelo multiplicativo para el análisis de imágenes SAR. In *First Latino-American Seminar on Radar Remote Sensing- Image Processing Techniques*. Buenos Aires, Argentina.
- Frery, A. C., Ferrero, S., & Bustos, O. H. (2009). The influence of training errors, context and number of bands in the accuracy of image classification. *International Journal of Remote Sensing*, 30(6):1425–1440.



- Frery, A. C., Jacobo-Berlles, J., Gambini, J., & Mejail, M. (2010). Polarimetric SAR image segmentation with B-Splines and a new statistical model. *Multidimensional Systems and Signal Processing*, 21:319–342.
- Gambini, J., Mejail, M., Jacobo-Berlles, J., & Frery, A. C. (2006). Feature extraction in speckled imagery using dynamic B-spline deformable contours under the G0 model. *International Journal of Remote Sensing*, 27(22):5037–5059.
- Gambini, J., Mejail, M., Jacobo-Berlles, J., & Frery, A. C. (2008). Accuracy of edge detection methods with local information in speckled imagery. *Statistics and Computing*, 18(1):15–26.
- Gao, G. (2010). Statistical modeling of SAR images: A survey. *Sensors*, 10:775–795.
- Germain, O. & Refregier, P. (2001). Edge location in SAR images: performance of the likelihood ratio filter and accuracy improvement with an active contour approach. *IEEE Transactions on image processing*, 10(1):72–78.
- Giacomelli, A., Mancini, M., & Rosso, R. (1997). Integration of ERS-1 PRI imagery and digital terrain models for the assessment of flooded areas. In *ESA Proceedings of the 3rd ERS symposium*. Florence, Italy.
- Gillies, M. T. & Coetzee, M. (1987). A supplement to the anophelinae of africa south of the sahara. Technical Report 55, Publications of the South African Institute for Medical Research, Johannesburg, SouthAfrica.
- Giordano, F., Goccia, M., & Dellepiane, S. (2005). Segmentation of coherence maps for flood damage assessment. *IEEE Int. Conference on Image Processing, ICIP 2005*, pages 11–14.
- Girolimetto, D., Venturini, V., & Rodríguez, L. (2007). *Teledetección - Hacia un mejor entendimiento de la dinámica global y regional*, chapter Influencia de la Resolución Espacial de la Temperatura de Superficie Teledetectada en el Contexto NDVI-To. Ed. Martin.
- Githeko, A. K., Lindsay, S. W., Confalonieri, U. E., & Patz, J. A. (2000). Climate change and vector-borne diseases: a regional analysis. *Special Theme Environment and Health Bulletin of the World Health Organization*, 78(9).
- Gómez-Plaza, A., Martínez-Mena, M., Albaladejo, J., & Castillo, V. (2001). Factors regulating spatial distribution of soil water content in small semiarid catchments. *Journal of Hydrology*, 253(1–4):211–226.
- González, C. M. & Jimeno, C. L. (2007). *Factores ambientales: funciones y uso de la vegetación en la estabilización de laderas*. Jornadas Técnicas sobre Estabilidad de Laderas en Embalses.
- Goodman, J. (1975). *Statistical Properties of Laser Speckle Patterns, Laser Speckle and Related Phenomena*. Springer Verlag: Heidelberg, Germany.