

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> | | | | |
| | | j_1 | j_2 | j_k | n_i | |
| i = filas | <i>Clasificación</i> | i_1 | n_{11} | n_{12} | n_{1k} | $n_{1\cdot}$ |
| | | i_2 | n_{21} | n_{22} | n_{2k} | $n_{2\cdot}$ |
| | | i_k | n_{k1} | n_{k2} | n_{kk} | $n_{k\cdot}$ |
| | | i_j | $n_{\cdot 1}$ | $n_{\cdot 2}$ | $n_{\cdot k}$ | $n_{\cdot\cdot} = n$ |

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:

$$n_{i\cdot} = \sum_{j=1}^k n_{ij} \quad (4.34)$$

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:

$$n_{\cdot j} = \sum_{i=1}^k n_{ij} \quad (4.35)$$

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

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

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).

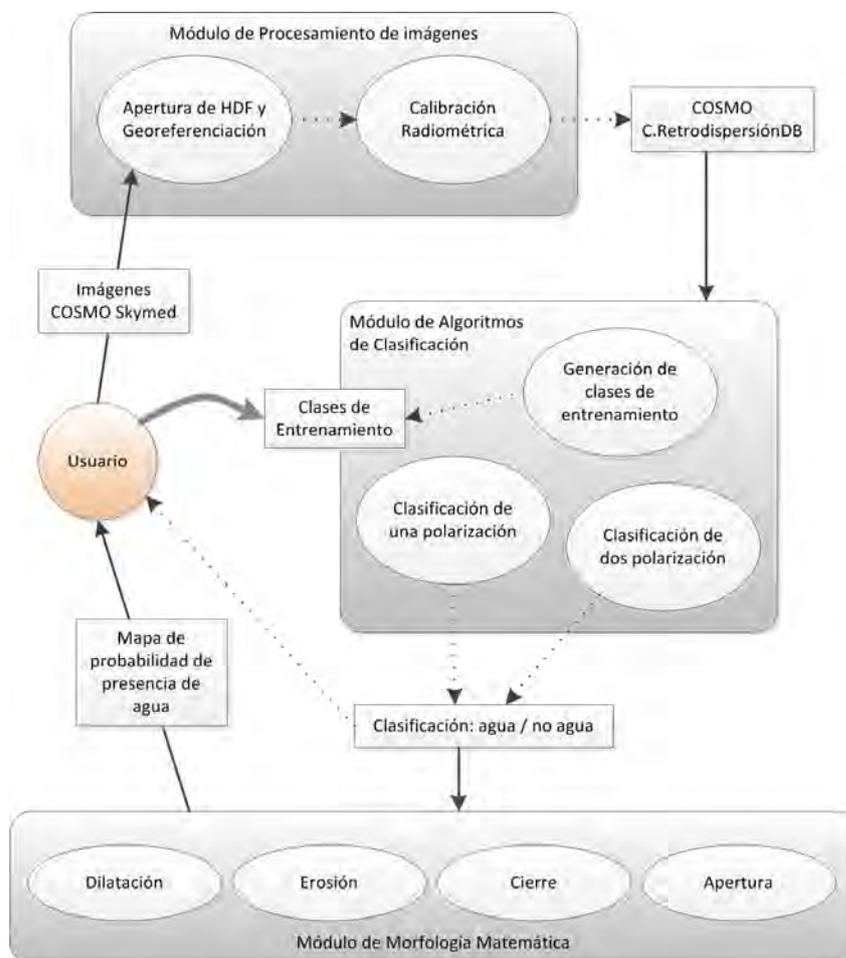


Figura 5.1: Esquema de los diferentes módulos y productos que forman parte del sistema de clasificación de COSMO-SkyMed desarrollado.

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

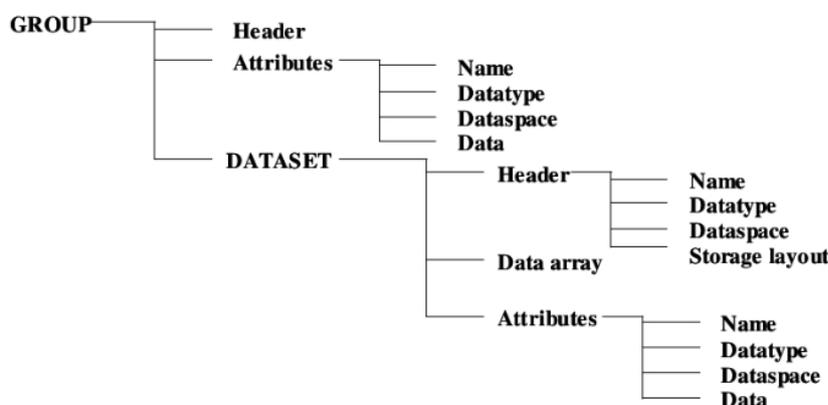


Figura 5.2: Organización jerárquica del *Hierarchical Data Format (HDF5)*, el cual es el formato de distribución de los datos COSMO-SkyMed.

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

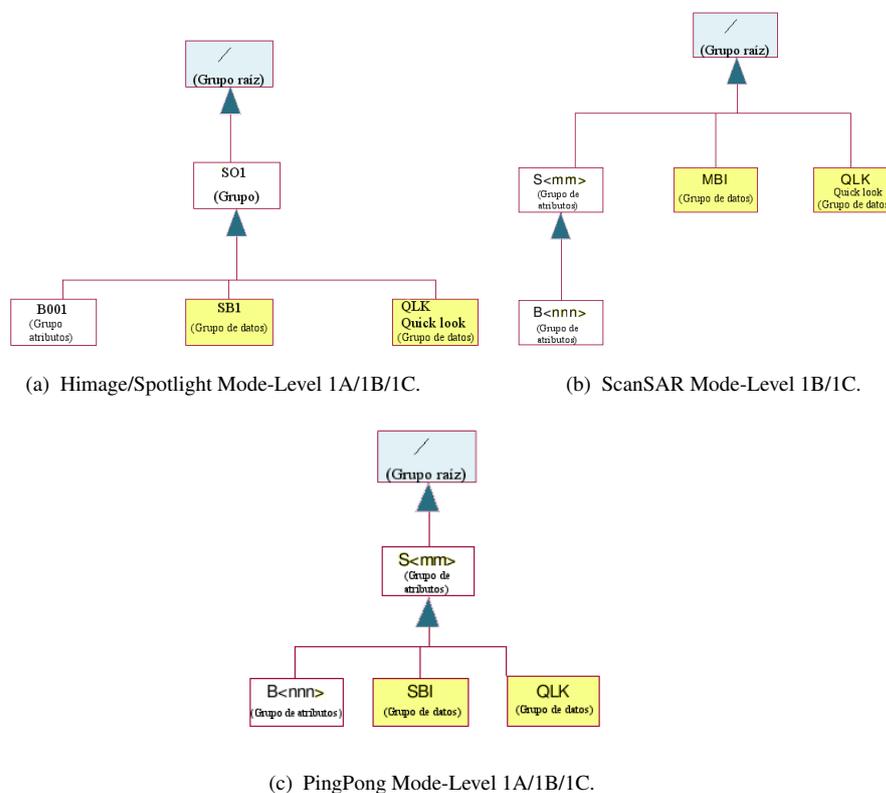


Figura 5.3: Organización jerárquica del formato de los distintos modos de adquisición de COSMO-SkyMed (Himage, Spotlight, ScanSAR, y PingPong).

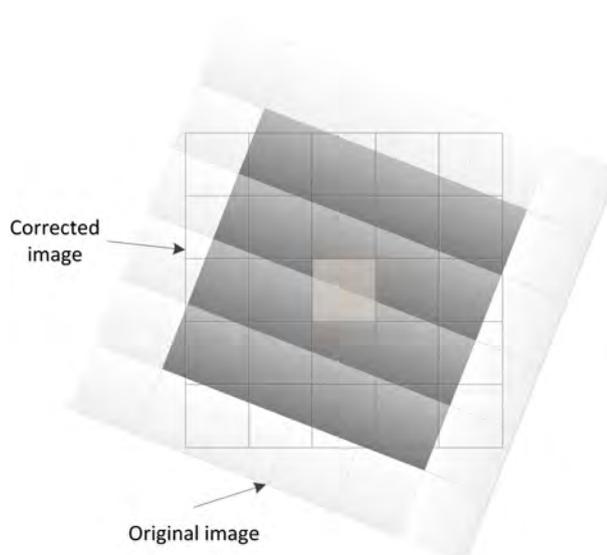


Figura 5.4: Esquema del funcionamiento del método de remuestreo por convolución cúbica empleado en el módulo de georeferenciación de las imágenes COSMO-SkyMed.

DN a datos de potencia del coeficiente de retrodispersión, σ° , 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 (σ°) 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*.
- α_{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](#).

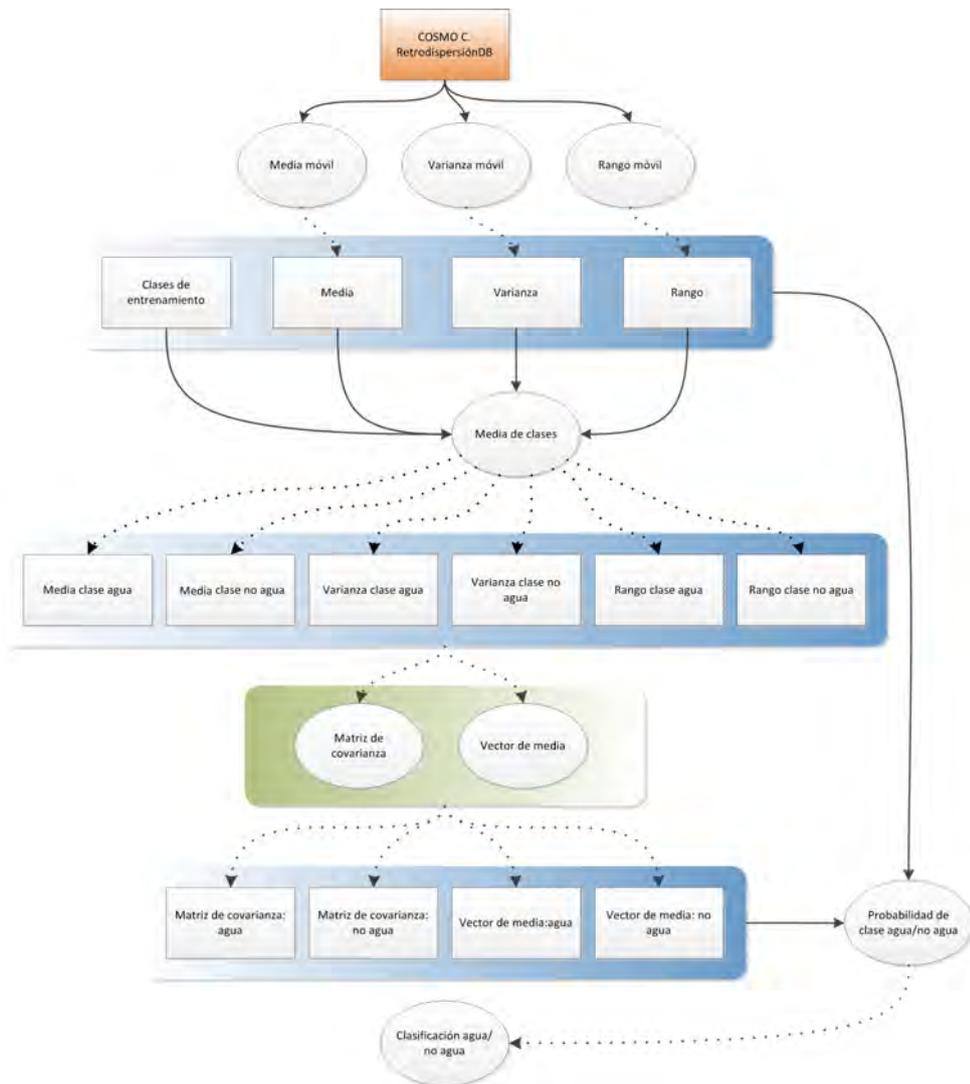


Figura 5.5: Esquema del clasificador 1 (dentro del *Módulo de algoritmos de clasificación*), el cual comparte la estructura general con el resto de los clasificadores.

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 ω_{na} y ω_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 μ_c y Σ_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.

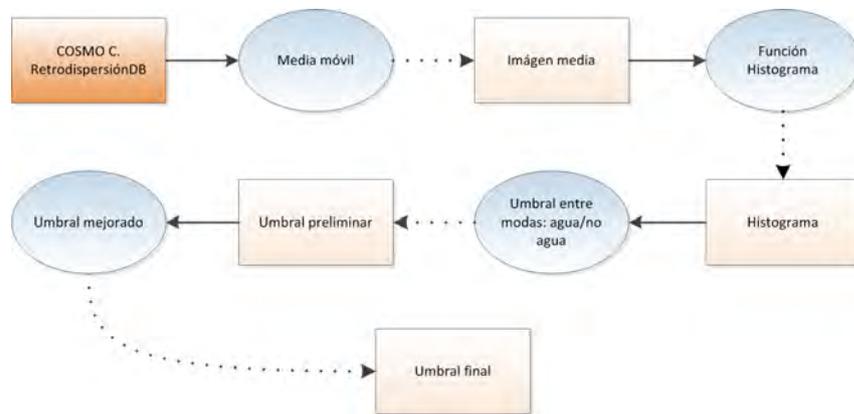


Figura 5.6: Esquema de la determinación del umbral para el entrenamiento automático de los clasificadores (dentro del *Módulo de algoritmos de clasificación*).

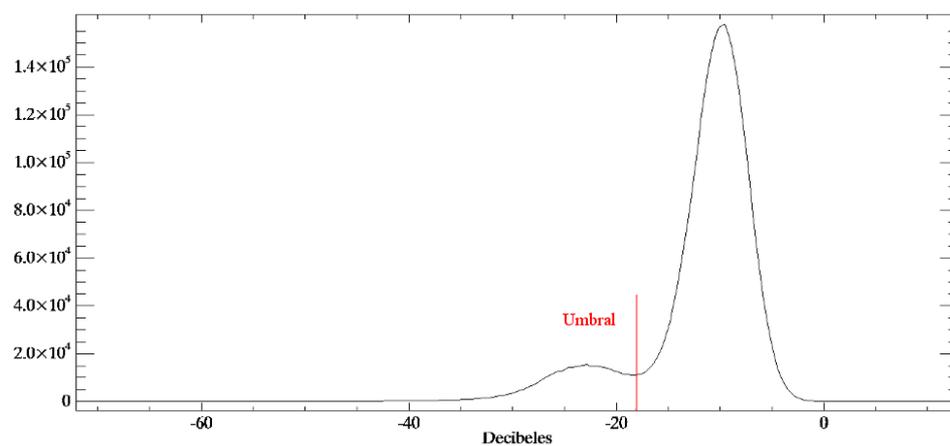


Figura 5.7: Histograma de una imagen COSMO-SkyMed en valores de σ^0 (en dB) que contiene clases: AGUA y NO-AGUA (abarca el resto de las coberturas que no pertenecen a la clase AGUA). La línea roja vertical muestra el umbral propuesto para la separación entre clases

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 ω_0 y ω_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** \mathbf{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 3×3 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 μ_c y Σ_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 μ_c y Σ_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 μ_i y Σ_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

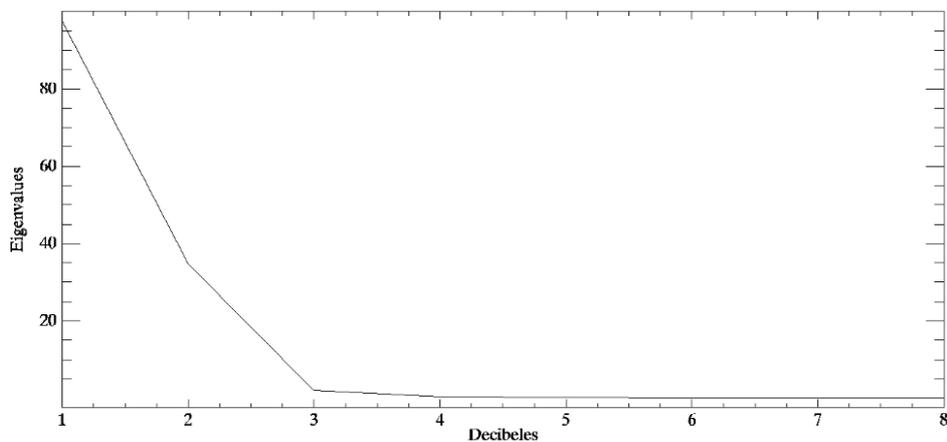


Figura 5.8: Eigenvalues resultantes del análisis de componentes principales de las 8 variables de textura: varianza, desviación estándar, skewness, rango, mediana, media, desviación media y curtosis.

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 1×1 : $E_{s1} = \{(1, 1)\}$.
 - Elemento estructurante de tamaño 2×2 : $E_{s2} = \{(1, 1), (1, 1)\}$.
 - Elemento estructurante de tamaño 3×3 : $E_{s3} = \{(1, 1, 1), (1, 1, 1), (1, 1, 1)\}$.
 - Elemento estructurante de tamaño 4×4 : $E_{s4} = \{(1, 1, 1, 1), (1, 1, 1, 1), (1, 1, 1, 1), (1, 1, 1, 1)\}$.
 - Elemento estructurante de tamaño 5×5 :
 $E_{s5} = \{(1, 1, 1, 1, 1), (1, 1, 1, 1, 1), (1, 1, 1, 1, 1), (1, 1, 1, 1, 1), (1, 1, 1, 1, 1)\}$.
- 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.

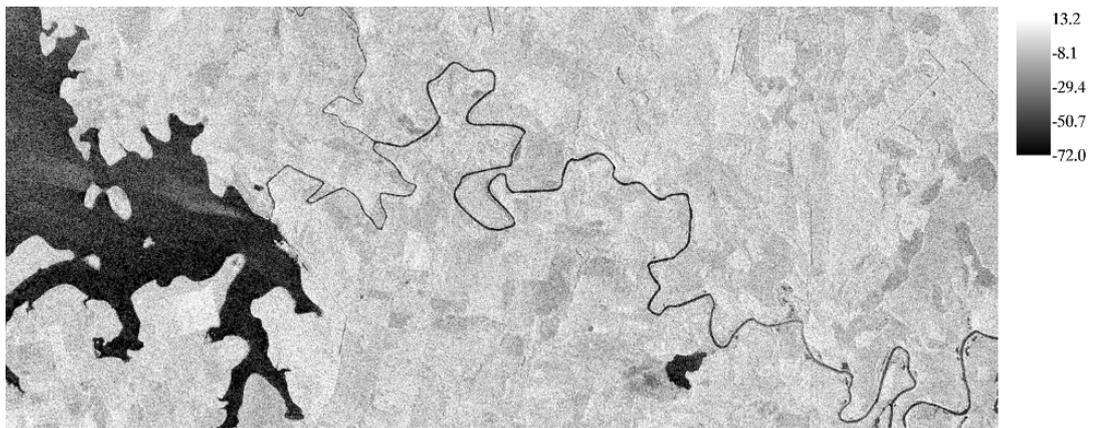
5.3. Resultados

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*.

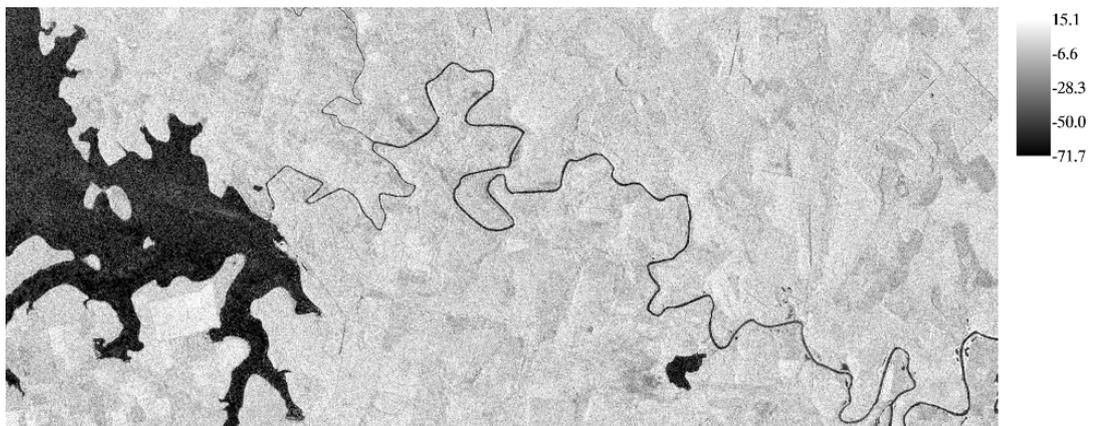
Selección automática de muestras: En la figura 5.10 se muestran los histogramas de la imagen completa y de cada clase (AGUA, NO-AGUA) según las dos bandas de diferente polarización (*HH*, *VV*). Estas clases son el resultado del algoritmo de selección automática de muestras. Se puede apreciar que en 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-



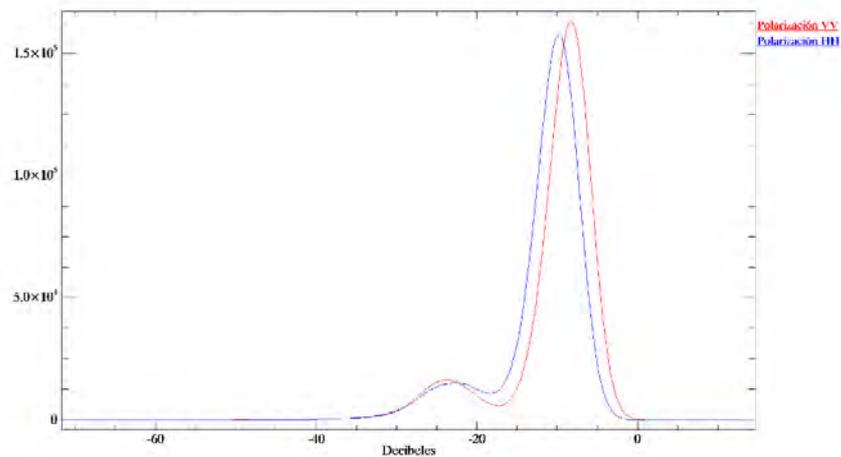
(a) Banda de polarización HH en valores de σ° en decibeles.



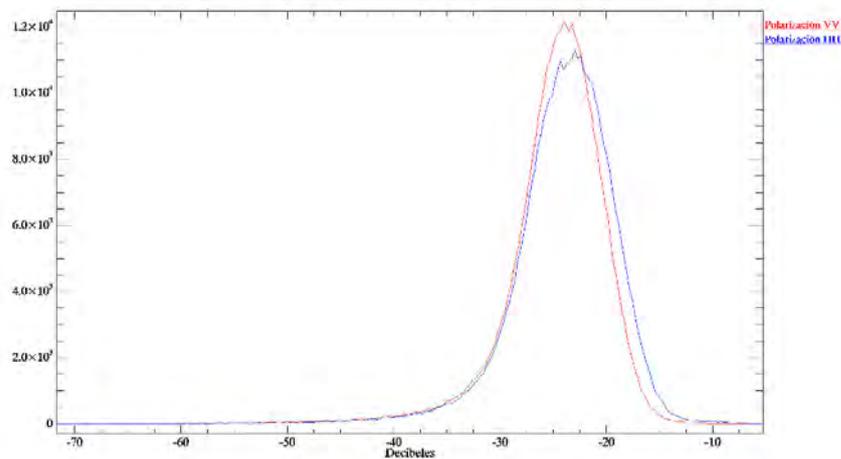
(b) Banda de polarización VV en valores de σ° en decibeles.

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 .

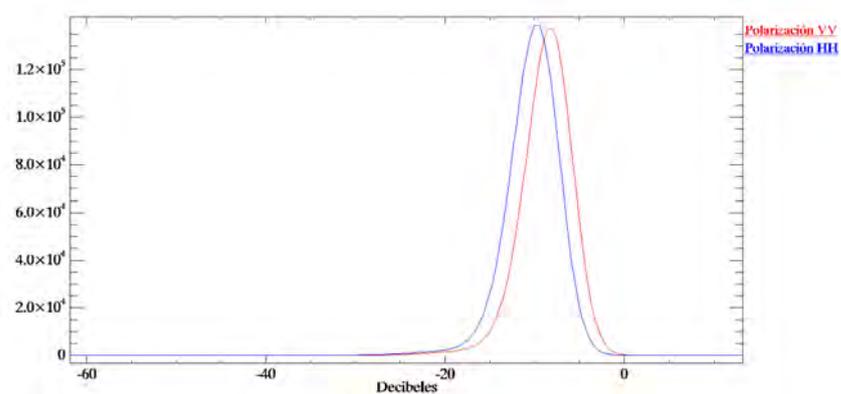
Módulo de algoritmos de clasificación:



(a) Histogramas de las bandas de polarización HH y VV de la imagen COSMO-SkyMed.

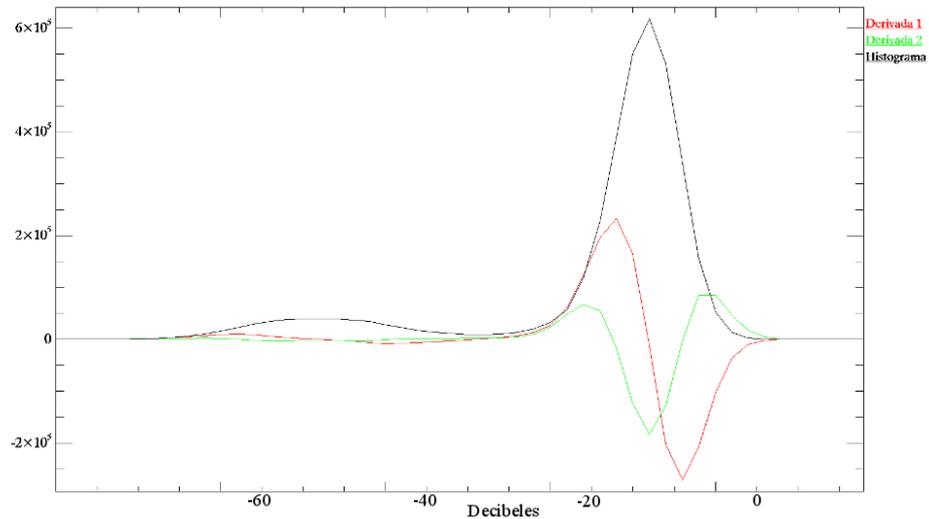


(b) Histograma de la clase AGUA seleccionada mediante el algoritmo automático, de las bandas de polarización HH y VV .



(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.

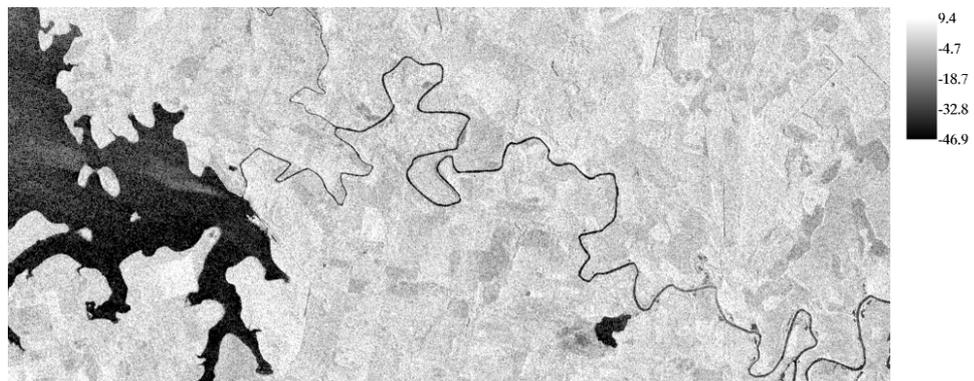


(b) Selección automática de muestras de clases AGUA y NO-AGUA en una banda de la imagen COSMO-SkyMed.

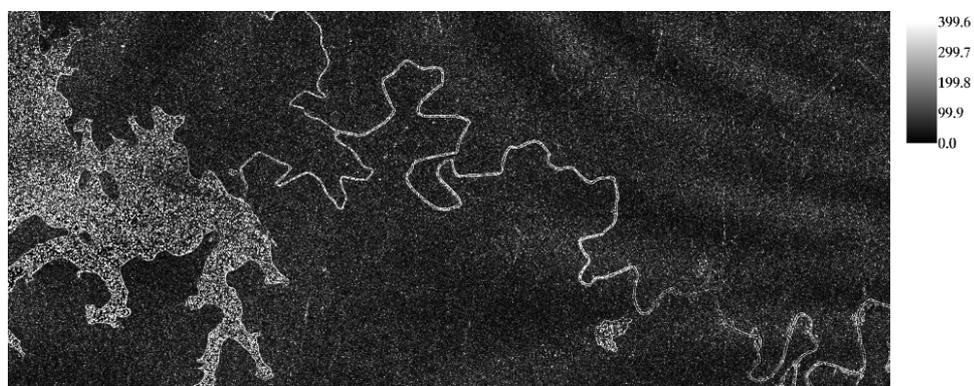
imagen

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.

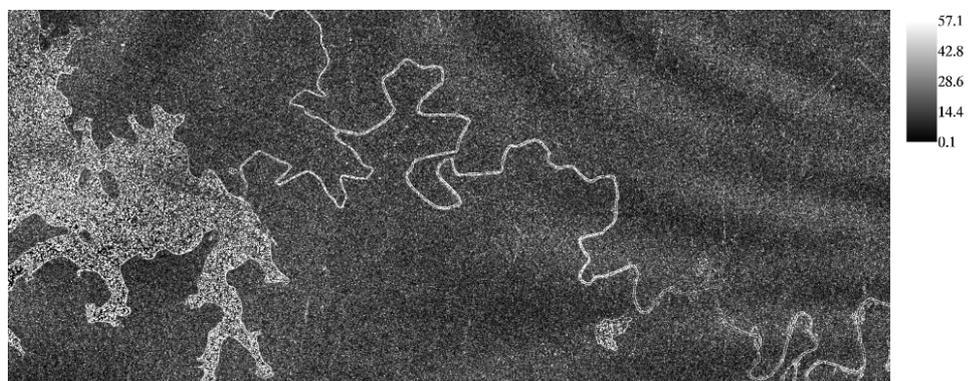
ra 5.13 se presenta la variable de textura B , *Curtosis*, correspondiente a la banda de polarización HH de la imagen COSMO-SkyMed.



(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

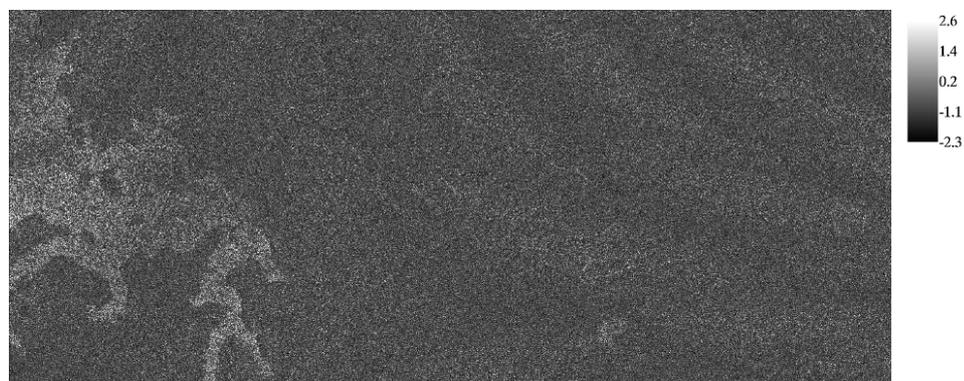
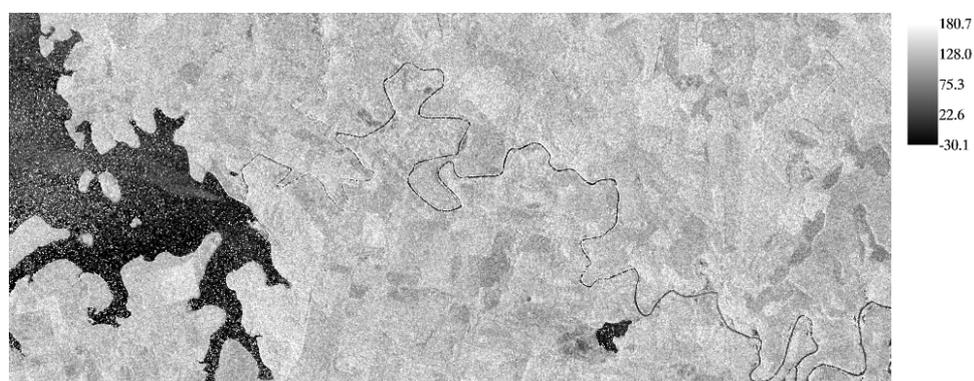


Figura 5.13: Variable de textura *Curtosis* de la banda de polarización HH de la imagen COSMO-SkyMed en decibeles. Esta variable pertenece junto con la *media* y la *varianza* a las variables de textura B y es obtenida mediante el clasificador 3 y 4.



(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*₂, *DualPol*₄, *DualPol*₆).

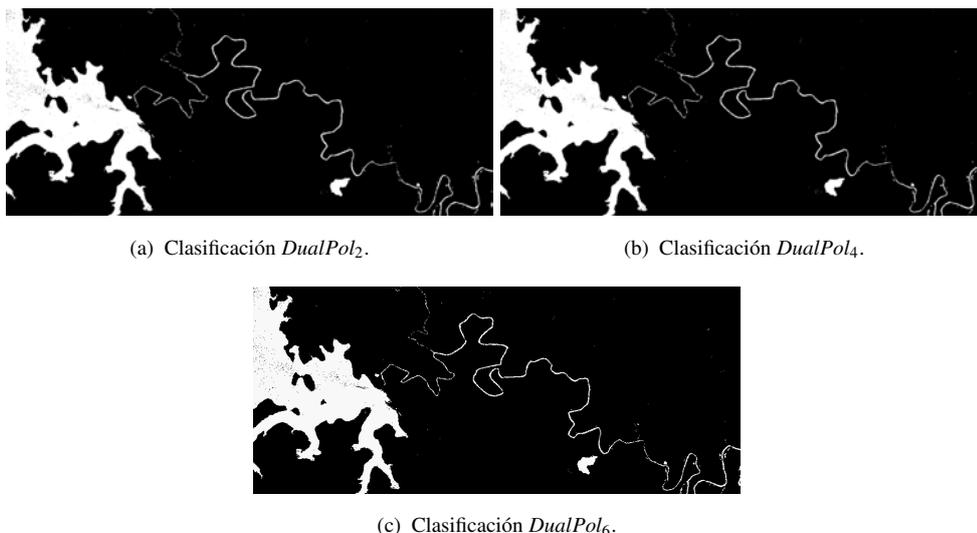


Figura 5.16: Resultados de las clasificaciones *DualPol* que involucran a las dos polarizaciones COSMO-SkyMed PingPong, es decir, *HH* y *VV*.

Mediante diferentes acercamientos en el producto *DualPol*₂, 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 *DualPol₂*.

Figura 5.17: Detalle 1 de la clasificación que involucra a las dos polarizaciones COSMO-SkyMed: *DualPol₂*.



(a) Imagen óptica de Google Earth correspondiente a la fecha 31-07-2006.

(b) Clasificación *DualPol₂*.

Figura 5.18: Detalle 2 de la clasificación que involucra a las dos polarizaciones COSMO-SkyMed: *DualPol₂*.

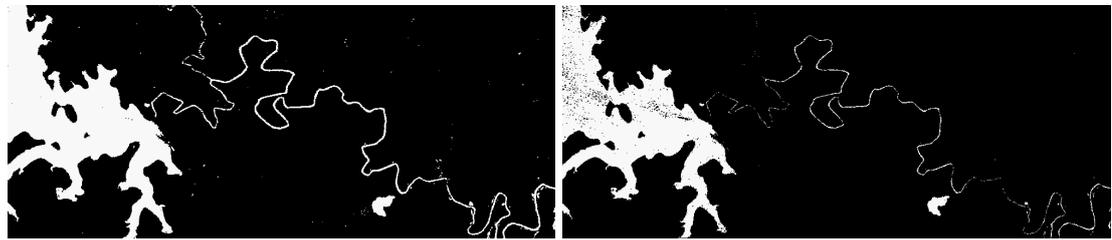


(a) Imagen óptica de Google Earth correspondiente a la fecha 29-04-2008.

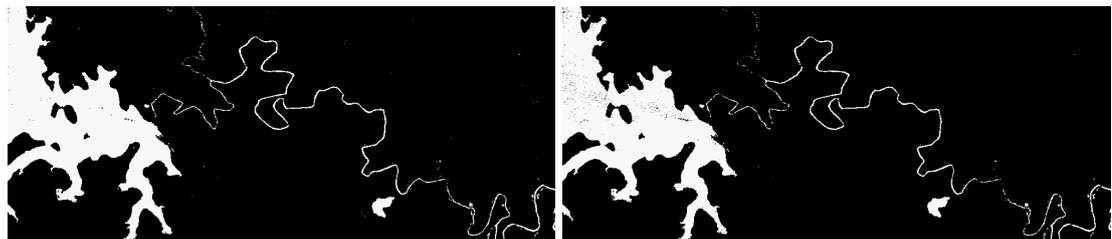
(b) Clasificación *DualPol₂*.

Figura 5.19: Detalle 3 de la clasificación que involucra a las dos polarizaciones COSMO-SkyMed: *DualPol₂*.

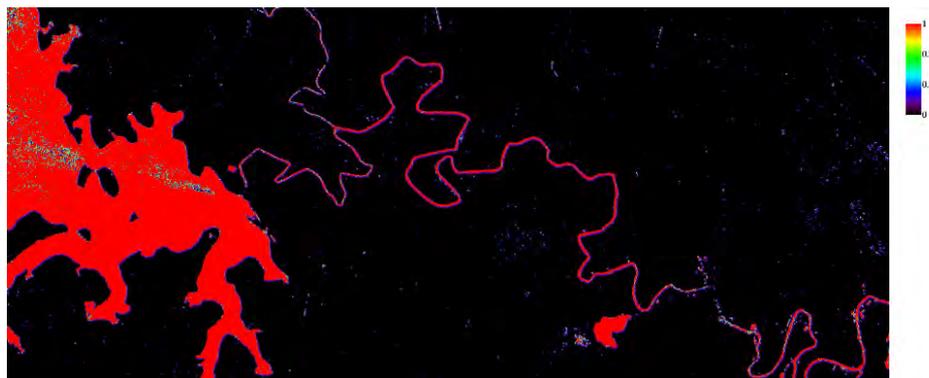
Módulo de morfología matemática: En la figura 5.20 son presentados distintos productos de morfología matemática aplicada al resultado de la clasificación *DualPol*₆, con elementos estructurantes de tamaño 3×3 .



(a) Operación morfológica: *Dilatación con kernel de tamaño 3×3* (elemento estructurante E_{s3}). (b) Operación morfológica: *Erosión con kernel de tamaño 3×3* (elemento estructurante E_{s3}).



(c) Operación morfológica: *Cierre con kernel de tamaño 3×3* (elemento estructurante E_{s3}). (d) Operación morfológica: *Apertura con kernel de tamaño 3×3* (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*₆. 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>PolHH₁</i> | 87.5829 | 0.4809 |
| <i>PolHH₃</i> | 87.4901 | 0.4815 |
| <i>PolHH₅</i> | 87.5787 | 0.4805 |
| <i>PolVV₁</i> | 98.3183 | 0.9248 |
| <i>PolVV₃</i> | 98.3467 | 0.9265 |
| <i>PolVV₅</i> | 98.3266 | 0.9253 |
| <i>DualPol₂</i> | 98.4283 | 0.9304 |
| <i>DualPol₄</i> | 98.4390 | 0.9309 |
| <i>DualPol₆</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° . 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.

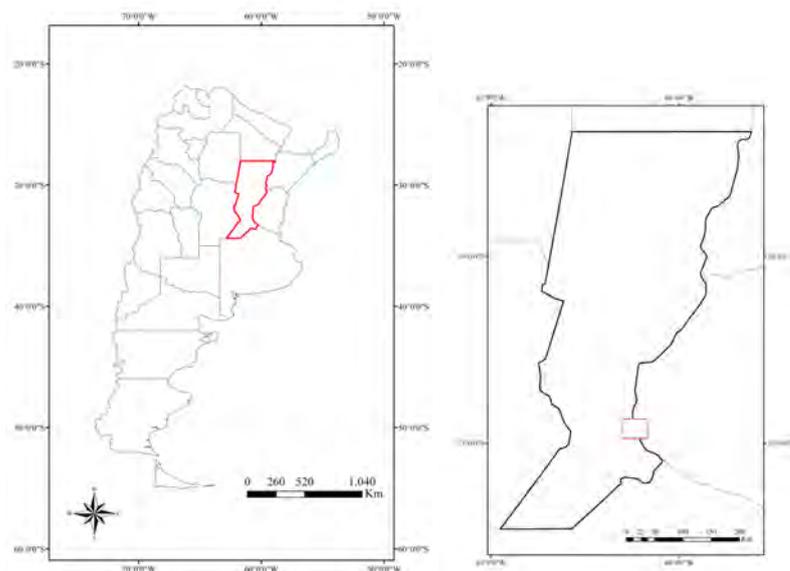
Se observa la existencia de especies nativas vinculadas con las eco-regiones ‘Paranaense’ y del ‘Espinal’: espinillo (*Acacia caven*), ombú (*Phytolacca dioica*), jacarandá (*Jacaranda mimosifolia*) y pata de vaca (*Bauhinia fortificata*). Ombú, ceibo, espinillo y timbó son especies tropicales que llegan 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 descriptos 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 39×39 .

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

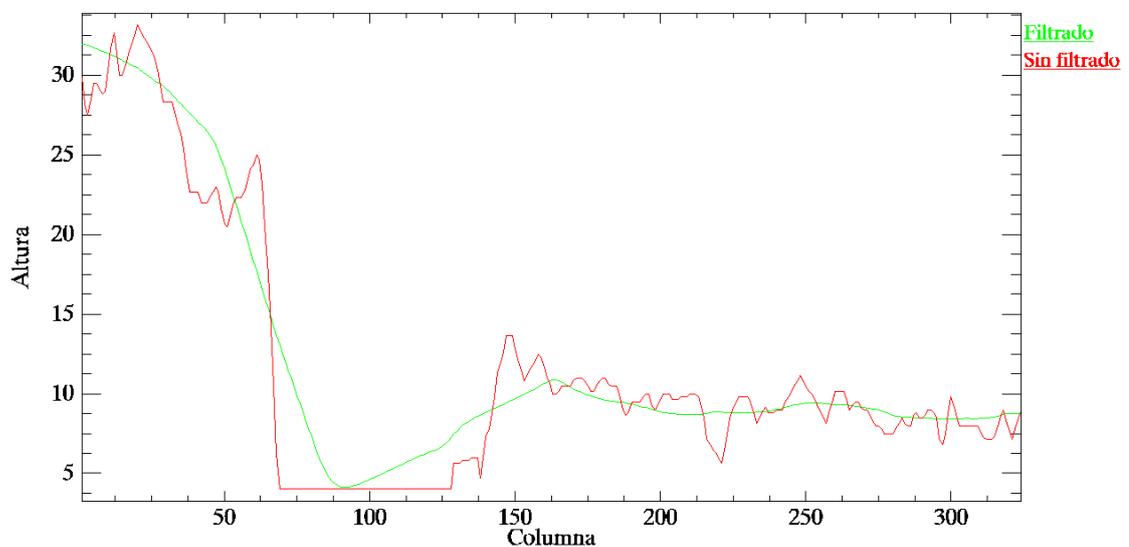
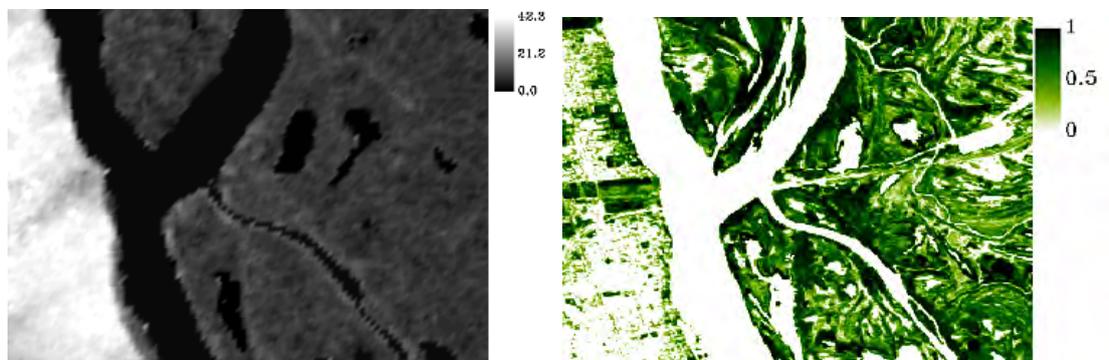


Figura 6.4: Perfiles horizontales del *ASTER GDEM* con distintos procesamientos. Este DEM es una matriz que posee 324 columnas y el rango de valores de altura va de 0 a 40 m. El perfil del DEM sin filtrar se muestra en rojo, mientras que el perfil del DEM luego de aplicar el filtro de media móvil con un tamaño de kernel de 39×39 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

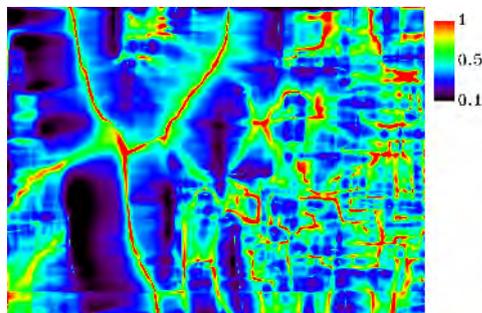


Figura 6.6: Índice topográfico de humedad (TWI_n) resultante del DEM filtrado.

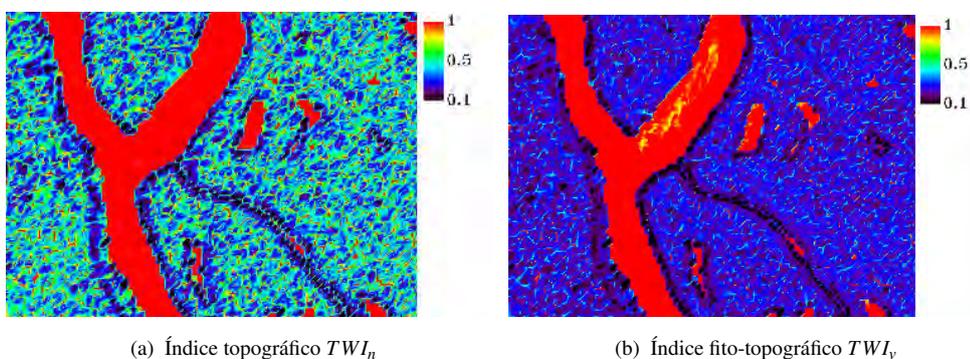


Figura 6.7: Índices topográficos de humedad (simple TWI_n y fito-topográfico TWI_v) resultantes del DEM no filtrado.



(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.



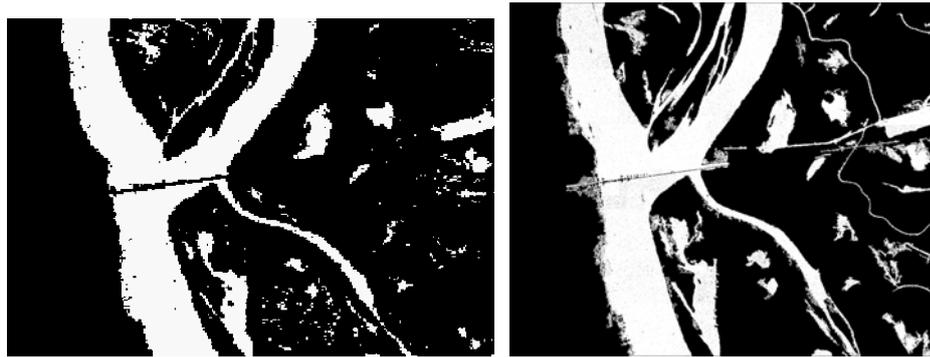
(b) Localización 6.



(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.



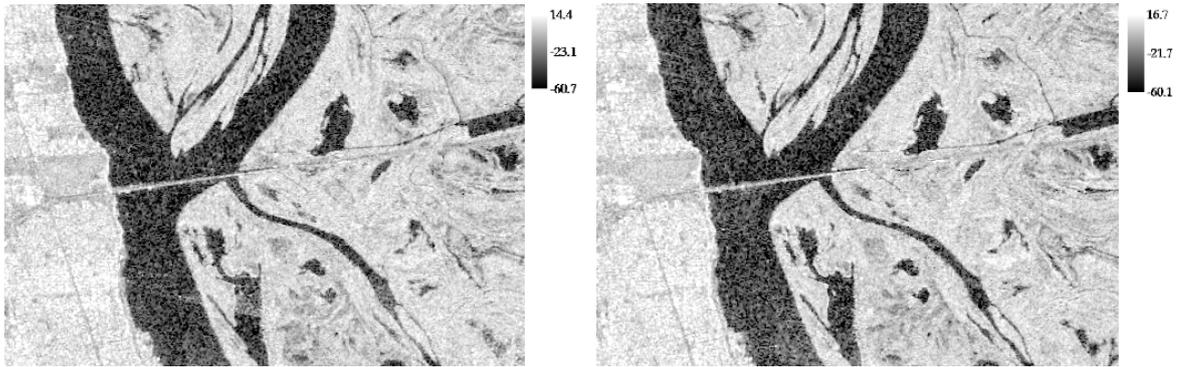
(a) Verdad de campo para validación de imagen COSMO-SkyMed PingPong. (b) Verdad de campo para validación de imagen COSMO-SkyMed Himage.

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.

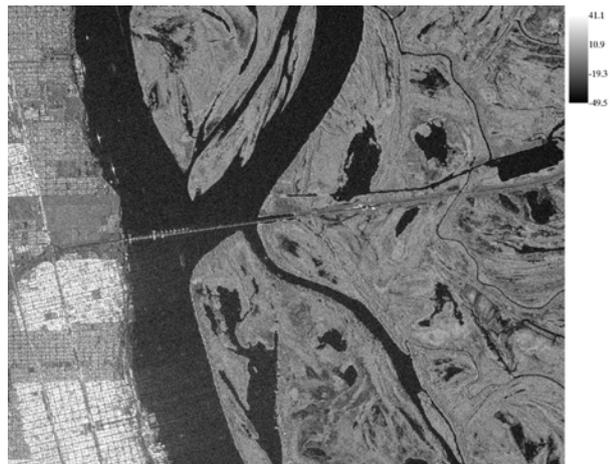
Delimitación automática de cuerpos de agua en imágenes COSMO-SkyMed: Los clasificadores empleados en este capítulo se basan en la determinación de la variable de textura C defini-



(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.

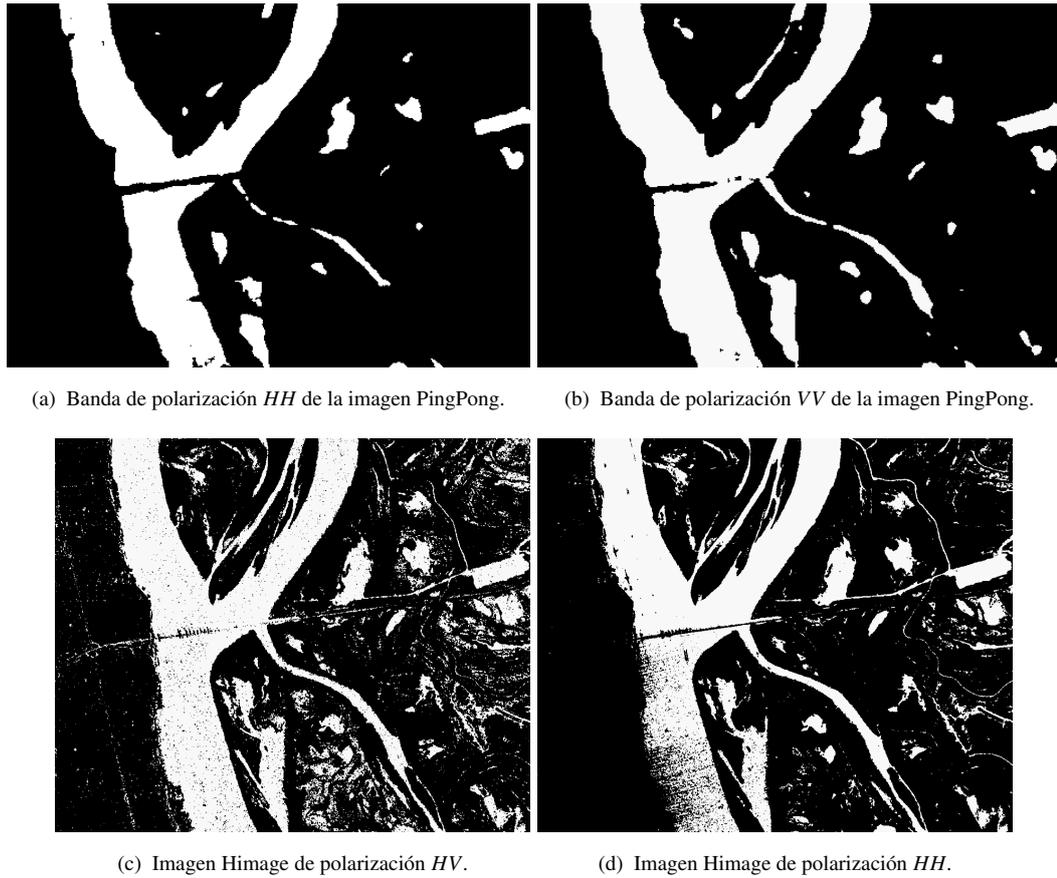


Figura 6.13: Matrices binarias resultantes de la selección automática de muestras de AGUA y NO-AGUA (clase que abarca el resto de las coberturas que no pertenecen a la clase AGUA) en las distintas imágenes COSMO-SkyMed: PingPong HH , PingPong VV , Himage HV e Himage HH .

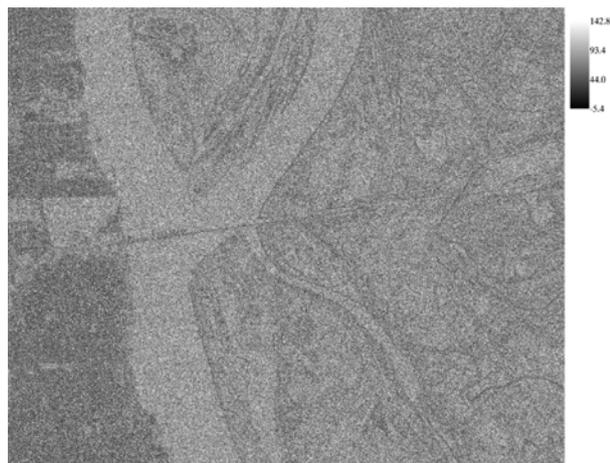
da en 5.2.4. A modo de ejemplo de estas características de textura se presenta, en la figura 6.14, las correspondientes a la imagen Himage de polarización HH .



(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*.

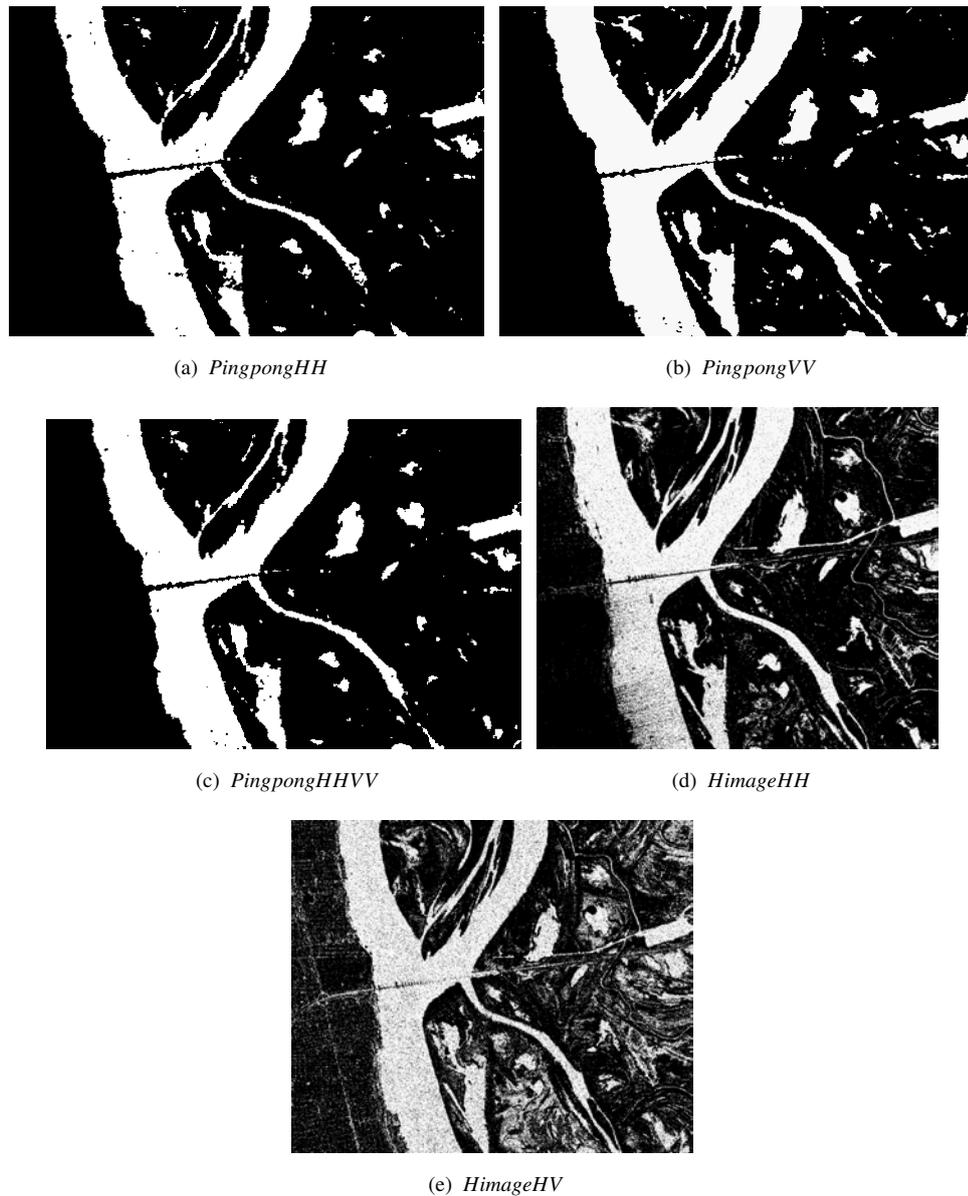


Figura 6.15: Resultados de las clasificaciones correspondientes a las distintas imágenes COSMO-SkyMed analizadas. Las clasificaciones 6.15(a), 6.15(b), 6.15(d) y 6.15(e) emplean clasificadores tridimensionales (utilizan 3 variables de textura), mientras que la clasificación 6.15(c) utiliza clasificadores 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

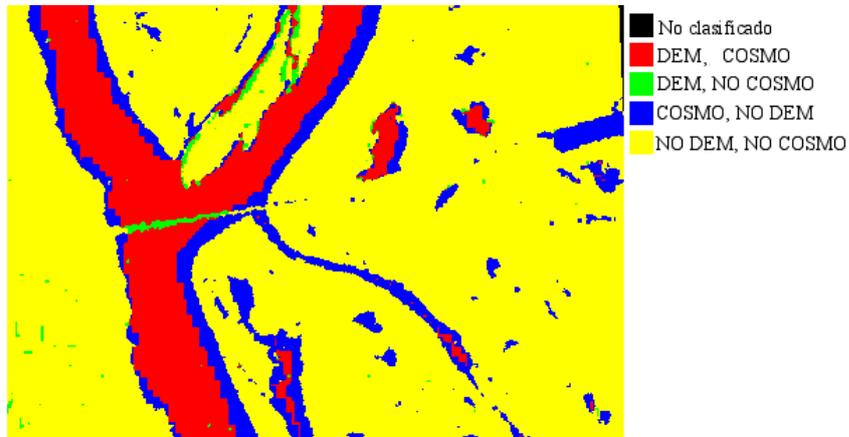


Figura 6.16: Clasificación basada en la integración de las dos metodologías: clasificación de la imagen SAR COSMO-SkyMed (denominada *COSMO* en la leyenda) y del modelo de elevación digital (denominada *DEM*). *DEM, COSMO* representa los píxeles clasificados según la clasificación de COSMO-SkyMed y la 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.

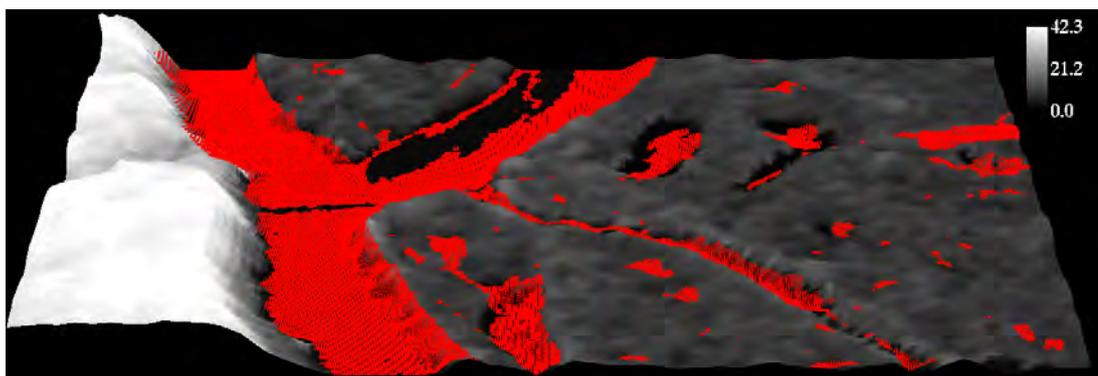


Figura 6.17: Superposición de la clasificación *PingpongHHVV* (en puntos de color rojo) sobre el DEM (en escala de grises). Los valores del DEM tienen un rango de 0 a 42 m. Se puede visualizar la coincidencia de los cuerpos de agua detectados con la imagen COSMO-SkyMed respecto a las depresiones del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