



UNIVERSIDAD NACIONAL DEL SUR

TESIS DOCTORAL EN INGENIERIA

**Procesamiento Inteligente de Imágenes
para el Modelado Geomorfológico**

Gisela N. Revollo Sarmiento

BAHIA BLANCA


ARGENTINA

2015

Prefacio

Esta Tesis se presenta como parte de los requisitos para optar al grado Académico de Doctor en Ingeniería, de la Universidad Nacional del Sur y no ha sido presentada previamente para la obtención de otro título en esta Universidad u otra. La misma contiene los resultados obtenidos en investigaciones llevadas a cabo en el Instituto Argentino de Oceanografía y el Departamento de Ingeniería Eléctrica, durante el período comprendido entre el 27 de Agosto del 2010 y el 10 de Febrero del 2015, bajo la dirección del Dr. Claudio A. Delrieux, Profesor Titular del Departamento de Ingeniería Eléctrica y de Computadoras e Investigador Independiente del CONICET y el Dr. Gerardo M. E. Perillo, Profesor Titular del Departamento de Geología e Investigador Superior del CONICET.

Gisela N. Revollo Sarmiento

	<p>UNIVERSIDAD NACIONAL DEL SUR Secretaría General de Posgrado y Educación Continua</p> <p>La presente tesis ha sido aprobada el/...../..... , mereciendo la calificación de(.....)</p>
-------------------------------------------------------------------------------------	---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

*Para
Adoralisa*

Agradecimientos

En primer lugar, mi más amplio agradecimiento a mis directores: Dr. Claudio Delrieux y Dr. Gerardo Perillo por el invaluable apoyo, paciencia y valiosa dirección. Quienes compartieron sus conocimientos y experiencias guiándome en todo momento para poder concluir esta etapa en mi formación.

Al Consejo Nacional de Investigaciones Científicas y Técnicas por la Beca Doctoral destinada al financiamiento de mis estudios de Posgrado.

Al Instituto Argentino de Oceanografía (IADO) por proporcionarme el lugar de trabajo.

A la Universidad Nacional del Sur, particularmente al Departamento de Ingeniería Eléctrica y de Computadoras.

A la Universidad Nacional de Jujuy por brindarme la oportunidad de conocer y empezar el camino del doctorado.

A mi mamá y papá por el apoyo incondicional y el gran amor de siempre en cada momento de mi vida.

A mi hermanita Elsa, por ser la chispita de todos los días en la familia.

Finalmente, hago extensivo el agradecimiento a Natalia y Carlos por la ayuda brindada y los conocimientos transmitidos. Andrea por su amistad, apoyo y consejos en todo momento y Ruben por sus constantes palabras de aliento y compañía.

Resumen

Las planicies de marea del estuario de Bahía Blanca se caracterizan por tener una amplia presencia de accidentes geográficos (cursos de marea y cuencos de agua) de diversos tamaños, formas y orientaciones. El estudio del origen de los mismos, su permanencia y los mecanismos de erosión durante la evolución de estos accidentes es importante para determinar futuros procesos dinámicos en el humedal costero. Sin embargo, el acceso directo para el monitoreo de estas regiones no es fácil, tiene un costo prohibitivo, no siempre es posible el acceso condicionado por las mareas y es ambientalmente dañino. El procesamiento digital de imágenes (PDI) de sensado remoto es una alternativa natural ante esta situación, dado que es una herramienta no invasiva para la extracción de datos cualitativos y cuantitativos sin alterar el estado natural del objeto bajo estudio.

La presente tesis tiene como objetivo principal desarrollar e implementar nuevas técnicas y metodologías de PDI que conformen la arquitectura de una aplicación que permita extraer la información necesaria y suficiente de los accidentes geográficos para que posteriormente, el experto pueda analizar y modelar la geomorfología de los mismos. La metodología desarrollada está compuesta por diferentes etapas de procesamiento, entre ellas la segmentación (identificación), medición, extracción de parámetros morfológicos (descriptores de forma) y la clasificación automática de los accidentes de interés.

En primera instancia, se caracterizó el tipo de ambiente y se seleccionaron 13 zonas del estuario para ser analizadas. Las mismas son representativas de la diversidad de cuencos y cursos de marea existentes en las planicies. En cada zona de estudio se aplicaron las distintas etapas del procesamiento y se discriminaron los objetos de interés. Seguida-

mente, se analizó su morfología individual en detalle. En este sentido, un conjunto de datos es obtenido para el análisis morfológico y, además es usado para definir las ecuaciones de un modelo estadístico de regresión, el cual permite diferenciar automáticamente los cuencos de agua y cursos de marea.

En principio, el clasificador se testeó en un conjunto de zonas usadas para su entrenamiento y posteriormente se usaron las restantes zonas como conjunto de validación. El desempeño del clasificador se evaluó de dos formas distintas, visual y cuantitativamente. El propósito fue determinar la variabilidad de los resultados según la apreciación del evaluador experto (supervisada) y la predicha por el clasificador (automática). En todos los casos se identificaron y clasificaron automáticamente los diferentes accidentes geográficos con una precisión superior al 86 %. Los resultados demuestran que es posible identificar y clasificar en forma automática los accidentes geográficos de formas complejas, como los cuencos de agua y cursos de marea a partir de imágenes de sensado remoto, en este caso particular, imágenes de Google Earth. Inclusive, la metodología puede ser aplicada en otras regiones de humedales costeros y con otros tipos de imágenes de sensado remoto.

Abstract

Tidal flats of the Bahía Blanca Estuary, generally exhibit ponds of diverse size, shape and orientation. The study of the origin, stability and erosive mechanisms during the evolution of these geographic features are important to determine dynamic processes in coastal wetlands. However, direct monitoring access to the locations is hard and expensive, not always feasible, and environmentally damaging. Remote sensing images may represent a natural alternative for this situation, since it is a noninvasive tool for qualitative and quantitative data extraction without altering the natural state of the object under study. The main aim of this thesis is to introduce and develop new techniques and DIP methodologies that integrate a framework application. In this sense, the expert is able to analyze the data set obtained. The methodology consists in different processing stages like segmentation, measurement, shape descriptors extraction and the automatic classification of geographic features. First, we characterize the environment type and 13 zones were selected to study. These zones are representative of ponds and tidal courses in tidal flats. The different processing stages were applied for each zone and geographic features were indentified. Then, the individual morphology in detail was analyzed. A data set for morphological analysis was provided and used to define the classifier model equations, which allow to automatically discriminate ponds against tidal courses. The classifier were tested in the training zones and then other zones were used to validate the performance of the classifier. To determine the variability of the results , supervise classification was compared against automatic classification. In all cases, it was possible to identify and automatically classify different geographic features with an accuracy higher than 86 %.

These results highlight the feasibility of using freely available Google Earth imagery for the automatic identification and classification of complex geographical features, as ponds and tidal courses. In addition, the methodology presented here could be applied in other wetlands of the world and to other remote sensing imagery.

Índice general

1. Introducción	15
2. Segmentación	21
2.1. Introducción	21
2.2. Antecedentes	22
2.3. Adquisición de imágenes de sensado remoto	23
2.4. Algoritmo Mean-Shift	24
2.4.1. Estimación del gradiente de densidad	24
2.5. Espacios de Color RGB - YIQ	26
2.6. YIQ Clustering - Operador distancia	28
2.7. Observaciones finales	33
3. Medición y Cálculo de Descriptores Morfológicos	34
3.1. Introducción	34
3.2. Antecedentes	35
3.3. Marching Squares Interpolado (MSI)	36
3.4. Teh-Chin Chain	38
3.5. Metodología de Medición	40
3.6. Descriptores de Forma	41
3.7. Observaciones finales	51

<i>ÍNDICE GENERAL</i>	9
4. Clasificación de Característicos Geográficos	52
4.1. Introducción	52
4.2. Antecedentes	53
4.3. Entrenamiento supervisado	55
4.3.1. Modelo de Regresión Logística Multinomial	56
4.3.2. Estimación de los coeficientes de las variables regresoras del modelo	58
4.4. Análisis de Desempeño de la Clasificación	59
4.4.1. Matriz de confusión	60
4.4.2. Nivel de concordancia entre clasificadores	62
4.5. Observaciones finales	63
5. Resultados y Discusión	64
5.1. Introducción	64
5.2. Procesamiento de nivel intermedio	65
5.3. Resultados obtenidos en las zonas de entrenamiento	73
5.4. Resultados obtenidos en las zonas de validación	80
5.5. Observaciones finales	92
6. Conclusiones	93
A. Zonas de validación	109

Índice de figuras

1.1. Distribución de las zonas de estudio en el estuario de Bahía Blanca	17
2.1. Diagrama de procesamiento para la identificación de característicos geográficos.	23
2.2. Aplicación del algoritmo Mean Shift.	26
2.3. Cubo de color RGB.	27
2.4. YIQ clustering.	30
2.5. Resultado de la segmentación.	31
2.6. Análisis de la segmentación.	32
3.1. Bit quad.	38
3.2. Representación de bordes.	39
3.3. Caja rectangular convexa.	42
3.4. Conjunto de figuras sintéticas visualmente diferentes pero con idénticos valores de factor de forma.	43
3.5. Diámetros de Feret máximo y mínimo.	45
3.6. Conjunto de figuras que tienen valores constantes en área con una leve variación en su forma, sin embargo con notables diferencias en sus valores de relación de aspecto.	46
3.7. Representación de los parámetros de longitud y ancho medio de la fibra de una figura.	48
3.8. Modelo geométrico de una fibra.	49

3.9. Conjunto de figuras con diferentes valores de curvatura.	50
5.1. Arquitectura del desarrollo de la aplicación PDI.	65
5.2. Segmentación de la Zona de entrenamiento 8a.	67
5.3. Segmentación de la Zona de entrenamiento 8b.	68
5.4. Segmentación de la Zona de entrenamiento 9a.	69
5.5. Segmentación de la Zona de entrenamiento 9b.	70
5.6. Segmentación de la Zona de Validación 5.	71
5.7. Segmentación de la Zona de Validación 6.	72
5.8. Segmentación de la Zona de Validación 10.	73
5.9. Resultados de la clasificación en las zonas de entrenamiento. Zona 8a y b.	74
5.10. Error de clasificación en la zona de entrenamiento.	78
5.11. Mosaic plot de las matrices de confusión de las zonas de entrenamiento. .	79
5.12. Porcentajes de clasificación global.	80
5.13. Resultados de la clasificación en la zona de validación 5.	81
5.14. Resultados de la clasificación en las zona de validación 6.	82
5.15. Resultados de la clasificación en las zona de validación 10.	83
5.16. Errores de clasificación de las zonas de validación.	88
5.17. Mosaic plot de las matrices de confusión de las zonas de validación. . . .	89
5.18. Porcentajes de clasificación global en las zonas de validación.	91
A.1. Segmentación de la Zona 1.	110
A.2. Resultados de la clasificación en la zona 1.	110
A.3. Mosaic plot de la matriz de confusión de la zona 1.	112
A.4. Segmentación de la Zona 2.	113
A.5. Resultados de la clasificación en la zona 2.	113
A.6. Mosaic plot de la matriz de confusión de la zona 2.	114
A.7. Segmentación de la zona 3.	115
A.8. Resultados de la clasificación en la zona 3.	115

A.9. Mosaic plot de la matriz de confusión de la zona 3. 116

A.10. Segmentación de la zona 4. 117

A.11. Resultados de la clasificación en la zona 4. 118

A.12. Mosaic plot de la matriz de confusión de la zona 4. 120

A.13. Segmentación de la zona 7. 121

A.14. Resultados de la clasificación en la zona 7. 121

A.15. Mosaic plot de la matriz de confusión de la zona 7. 122

A.16. Segmentación de la zona 11. 123

A.17. Resultados de la clasificación en la zona 11. 123

A.18. Mosaic plot de la matriz de confusión de la zona 11. 124

A.19. Segmentación de la zona 12. 125

A.20. Resultados de la clasificación en la zona 12. 126

A.21. Mosaic plot de la matriz de confusión de la zona 12. 128

A.22. Segmentación de la zona 13. 129

A.23. Resultados de la clasificación en la zona 13. 130

A.24. Mosaic plot de la matriz de confusión de la zona 13. 132

Índice de cuadros

1.1. Ubicación geográfica de las zonas de estudio.	19
3.1. Medición de perímetros sobre figuras sintéticas implementando los algoritmos MSI y TCC.	41
3.2. Shape descriptors and their analytical definition.	44
3.3. Valores de los distintos descriptores de forma aplicados a un conjunto de accidentes geográficos.	51
4.1. Matriz de confusión y parámetros de precisión.	61
4.2. Escala de Landis y Koch, 1977, índice Kappa.	63
5.1. Desempeño de la Zona 8a y b.	76
5.2. Desempeño de la Zona 9a y b.	77
5.3. Desempeño de la Zona 5.	84
5.4. Desempeño de la Zona 6.	85
5.5. Desempeño de la Zona 6c.	86
5.6. Desempeño de la Zona 10.	87
A.1. Desempeño de la Zona 1.	111
A.2. Desempeño de la Zona 2.	114
A.3. Desempeño de la Zona 3.	116
A.4. Desempeño de la Zona 4.	119
A.5. Desempeño de la Zona 7.	122

ÍNDICE DE CUADROS

14

A.6. Desempeño de la Zona 11.	124
A.7. Desempeño de la Zona 12.	127
A.8. Desempeño de la Zona 13.	131

Capítulo 1

Introducción

Los estuarios son sistemas dinámicos sujetos a grandes variaciones espaciales y temporales. Dentro de sus ambientes se distinguen las planicies de marea formadas por sedimentos no consolidados y carentes de vegetación vascular, las cuales quedan expuestas durante la bajamar. El estudio de los accidentes geográficos presentes en estas planicies es esencial para determinar los procesos dinámicos y cambios geomorfológicos que ocurren en los humedales costeros (Perillo et al., 2009). Tal es el caso de los cuencos de agua y cursos de marea que son unas de las más sorprendentes características fisiográficas de las marismas y planicies (Chapman, 1960).

El origen de los cuencos de agua y su relación con los canales o cursos de marea han sido objeto de varias controversias. Los primeros estudios fueron abordados por Yapp et al. (1916) quienes analizaron y caracterizaron la presencia de cuencos en las marismas del estuario de Dovey. Diversos autores coinciden ampliamente con la teoría acerca del proceso de formación (Steers, 1964; Pestrong, 1965; Packham y Liddle, 1970). En este contexto, los cuencos se originan en zonas donde la vegetación no es uniforme y el índice de compactación es mayor que el índice de sedimentación (Frey, 1985). Sin embargo, la discusión sobre la densidad de los cuencos por área genera discrepancias entre Pethick (1974) y la teoría original de Yapp et al. (1917). Por otro lado, los cuencos pequeños pueden evolucionar obteniendo una figura similar a los *channel pans* por el efecto de las

olas ultra-gravedad e integrarse a un canal por la erosión de microacantilados (Perillo et al., 1996a; Perillo e Iribarne, 2003).

A pesar de los debates de varios autores (Pethick, 1974; Kesel y Smith, 1978; Perillo et al., 1996b), existe poca evidencia empírica que avale el proceso de formación de estos accidentes geográficos. Escasos estudios han sido realizados durante un periodo suficiente como para observar la formación de los mismos. Cualquiera sea el origen, morfología y ubicación de los accidentes, están sometidos constantemente a cambios de distintas clases, pueden aumentar o disminuir en tamaño, cambiar de forma, de posición, o incluso aún desaparecer íntegramente (Boston, 1983).

La investigación específica del análisis cuantitativo y cualitativo de cuencos de agua en los ambientes de marismas es extensiva. Sin embargo, el análisis evolutivo de los mismos es muy limitado. A pesar de la amplia información existente, no se conocen estudios de estas características desarrollados en planicies de marea. Inclusive, es probable que la importancia relativa de los diferentes mecanismos de formación varíe entre dicho ambiente y las zonas de marismas.

En particular, el estuario de Bahía Blanca tiene características ambientales que lo hacen sumamente especial. El mismo está ubicado en el Suroeste de la Provincia de Buenos Aires ($-38.99^{\circ}S$, $-62.17^{\circ}W$) (Fig. 1.1). Este ambiente estuarino es un sistema de una dinámica muy compleja tanto en sus aspectos geológicos, físicos-químicos y biológicos influenciados por las mareas (Perillo et al., 2009). Según Perillo (1995), de acuerdo a su clasificación morfogenética es un estuario de planicie costera que corresponde a la formación del delta Pleistoceno-Holoceno (Melo et al., 2013) dominado por planicies, marismas y grandes cursos de marea. Así mismo, presenta una gran extensión de cuencos de agua distribuidos en sus planicies. Dadas las consideraciones anteriores se considera a las planicies del estuario representativas mundialmente y se caracterizan por la presencia de cuencos de agua y canales de marea de diversos tamaños, formas y orientaciones (p.e., Ria Formosa, estuario del río Gallego). La formación de estos característicos implica un mecanismo erosivo importante en las planicies.




Fig. 1.1. Distribución de las zonas de estudio en el estuario de Bahía Blanca

De acuerdo a lo expresado, el estudio de los accidentes geográficos presentes en las planicies del estuario de Bahía Blanca es de fundamental importancia. El mismo proporcionará nuevas líneas de percepción para entender el origen, comportamiento, evolución en el tiempo y la relación entre accidentes geográficos. Sin embargo, el estudio *in situ* produce modificaciones en el sistema, alterando su estado natural. Además, el mismo sería lógicamente imposible desde un punto de vista estadístico si se considera la extensión de las planicies y las dificultades de acceso en la mayoría de las zonas.

En contrapartida, el empleo de técnicas que no ejerzan una influencia negativa a partir de imágenes satelitales o aéreas es una alternativa justificada. El sensado remoto es una herramienta no invasiva que permite manipular imágenes para extraer información objetiva (Girard y Girard, 1999; Jensen, 2000; Campbell, 2002; Lillesand et al., 2004; Richards y Jia, 2006). El procesamiento digital de imágenes (PDI) aplicado a las imágenes de sensado remoto proporciona información, cualitativa y cuantitativa que facilita la comprensión de características geomorfológicas, lo que conlleva a poder descubrir y cuantificar mecanismos de interacción. Especialmente en estudios geomorfológicos y ambientales

donde la influencia del hombre en el área de trabajo altera el estado del fenómeno en estudio o es una zona inaccesible y/o de gran extensión (Yatabe y Fabbri, 1986; Raup et al., 2007).

En este contexto, son escasos los estudios donde se analizan la formación e identificación de cuencos de agua mediante imágenes aéreas o satelitales (Sridhar et al., 2008; Goudie, 2013). En estas investigaciones no se ha abordado en detalle la obtención del conjunto de datos que caracterizan el tipo de ambiente para segmentar (identificación), medir y calcular descriptores geomorfológicos. Incluso se observa que la clasificación de estos accidentes geográficos no es una tarea sencilla ya que requiere de un experto, tiene un costo y tiempo asociado.

La clasificación de imágenes de sensado remoto es un proceso complejo y requiere el empleo de distintas técnicas para mejorar la precisión de la clasificación (Gong y Howarth, 1992; Kontoes et al., 1993; Foody, 1996; San Miguel-Ayanz y Biging, 1997; Aplin et al., 1999; Stuckens et al., 2000; Franklin et al., 2002; Pal y Mather, 2003; Gallego, 2004). Sin embargo, clasificar datos de sensado remoto aún es un desafío y necesita de la consideración de varios factores, como la caracterización del ambiente en el área de estudio, el procesamiento de las imágenes y los enfoques de clasificación. Estos pueden afectar el éxito de una clasificación, aunque existen investigaciones específicas (Mather y Tso, 2003; Landgrebe, 2005), los algoritmos de clasificación y técnicas son específicos para cada caso de estudio.

El objetivo general de esta tesis consiste en desarrollar e implementar nuevas técnicas y metodologías de PDI que conformen la arquitectura de una aplicación con el propósito de identificar (segmentar), medir, extraer parámetros morfológicos (descriptores de forma) y clasificar automáticamente los accidentes geográficos (cuencos de agua y cursos de marea) presentes en las planicies del estuario. Esta aplicación permitirá que la intervención del experto esté centrada en la interpretación de los datos obtenidos y evite la pérdida de tiempo que conlleva realizar un análisis manual de las características de las imágenes.

En este contexto, la aplicación fue testeada sobre imágenes de sensado remoto del

estuario de Bahía Blanca. Se seleccionaron 13 zonas (Fig. 1.1) representativas de la diversidad de accidentes geográficos que caracterizan a las planicies del estuario. En la tabla 1.1 se indica cada zona estudiada con sus respectivas coordenadas. Cabe señalar que las técnicas y métodos desarrollados son aplicables a cualquier ambiente de humedales costeros ya sea mediante el uso de imágenes de Google Earth o cualquier otra imagen de sensado remoto con características similares a las estudiadas.

Tabla 1.1. Ubicación geográfica de las zonas de estudio.

Zonas	Latitud (S)	Longitud (W)
Zona 1	-38.898074°	-62.271961°
Zona 2	-38.901586°	-62.220930°
Zona 3	-38.959568°	-62.228577°
Zona 4	-38.912352°	-62.320609°
Zona 5	-39.008377°	-62.189156°
Zona 6	-39.212749°	-62.300189°
Zona 7	-38.952229°	-62.311871°
Zona 8	-39.001640°	-62.144144°
Zona 9	-39.019833°	-62.162218°
Zona 10	-38.918224°	-62.316328°
Zona 11	-38.947072°	-62.337702°
Zona 12	-39.002224°	-62.182938°
Zona 13	-39.032259°	-62.212384°

El desarrollo de esta tesis se organiza de la siguiente manera:

Capítulo 1: Se realiza una Introducción del tema a abordar y sus problemáticas. Además se realiza una descripción del área de estudio y se presenta el objetivo de la tesis.

Capítulos 2, 3 y 4: Estos capítulos conforman la metodología, en cada uno se describe el marco teórico en el que se desarrolla, además de especificar los métodos implementados. Cada capítulo conforma diferentes etapas del procesamiento: nivel bajo, intermedio

y alto.

Capitulo 5: Se presentan los resultados obtenidos en las etapas anteriores y el análisis de los mismos.

Capitulo 6: Corresponde a las conclusiones donde se sintetizan los aportes presentados, se enfatiza el alcance y aplicabilidad de las herramientas desarrolladas. Además se especifican algunas líneas futuras de investigación que surgen de este trabajo.

Durante el desarrollo de la tesis se presentaron resultados parciales en diversas comunicaciones científicas.

Capítulo 2

Segmentación

2.1. Introducción

La segmentación de imágenes es una tarea fundamental en el campo de visión por computador. Es un componente crítico y esencial para la extracción de características en el proceso de análisis de imágenes digitales. El propósito de la segmentación es separar los objetos de interés (figura) del resto (fondo), facilitando así el posterior procesamiento.

En este trabajo, las técnicas de segmentación desarrolladas permiten extraer información de los característicos geográficos presentes en las planicies del estuario de Bahía Blanca. Este proceso facilita el monitoreo y análisis de los cuencos de agua y cursos de marea en zonas de difícil acceso sin alterar el estado natural de los mismos.

El presente capítulo aborda los algoritmos de segmentación implementados sobre imágenes de sensado remoto, extraídas de la aplicación Google Earth. Inicialmente se realiza una pre-segmentación de las imágenes usando el algoritmo Mean Shift. En la segunda parte, se describen las especificaciones técnicas de los espacios cromáticos utilizados, un método supervisado de selección de píxeles prototipos y el método de segmentación basado en el concepto de distancias mínimas a múltiples prototipos.

2.2. Antecedentes

La segmentación es un problema clásico inverso en el procesamiento digital de imágenes (PDI). Consiste en descomponer una imagen digital en varias regiones (grupo de píxeles) que tienen atributos similares con el objetivo de facilitar el posterior análisis o reconocimiento automático. Concretamente, se basa en llevar a cabo un proceso de etiquetado, es decir, de asignar una etiqueta a cada pixel de la imagen, de forma que los píxeles con etiqueta común compartan cierto tipo de característica (color, nivel de gris, textura, etc.). En general, la segmentación es un factor importante que determina la calidad del resultado final en el proceso de análisis.

En los últimos años se desarrollaron diferentes técnicas de segmentación. Unnikrishnan et al. (2007) y Estrada y Jepson (2009) clasifican estas técnicas en cinco categorías: algoritmos de umbralización (Maitra y Chatterjee, 2008; Yuksel y Borlu, 2009), texturas (Zeng et al., 2004; Chen et al., 2007, 2008), métodos de agrupamiento o *clustering* (Shi y Malik, 2000; Wang y Sun, 2010), detección de bordes (Bao et al., 2005; Chung et al., 2008) y crecimiento de regiones (Garcia Ugarriza et al., 2009; Krinidis y Pitas, 2009). En particular, los métodos de agrupamiento han sido aplicados en distintos ámbitos, variando desde aplicaciones en ingeniería, ciencias de la computación, medicina y ciencias de la tierra, entre otras (Hartigan, 1975; Pratt, 1991; Hansen y Jaumard, 1997; Everitt et al., 2001). El estudio de los mismos ha sido expandido por diversos autores (Duran y Odell, 1974; Jain y Dubes, 1988; Gordon, 1999) hasta la actualidad (Xu y Wunsch, 2010; Xu y Wunsch II, 2011). Los algoritmos de agrupamiento organizan la información en grupos basados en el concepto de similaridad (Fisher, 1958; Friedman y Rubin, 1967; Yang, 1993; Jain et al., 1999; Gan et al., 2007). A pesar de la extensiva literatura existente en técnicas de segmentación, en la mayoría de los casos no existe un método único que pueda considerarse óptimo para todo tipo de imágenes (Bovik, 2009). Es por ello que existe un continuo desarrollo de estas técnicas.

En el presente capítulo, se describen las técnicas de segmentación implementadas en

imágenes de Google Earth con la finalidad de separar los cuencos de agua y cursos de marea (figura) del resto (fondo) para la posterior etapa de extracción de características. Con el fin de obtener mejores resultados, se presenta una técnica compuesta por dos etapas (Fig. 2.1). En un primer paso, se realiza una pre-segmentación utilizando el algoritmo Mean Shift sobre la zona de estudio. Este procedimiento reduce la dispersión entre las clases, lo cual facilita significativamente el subsecuente procesamiento. En el segundo paso para separar los característicos geográficos, se desarrolla un algoritmo de agrupamiento en el espacio de color YIQ y, mediante un operador distancia, se determina una medida de similitud entre clases y se realiza la clasificación final de los objetos de interés.

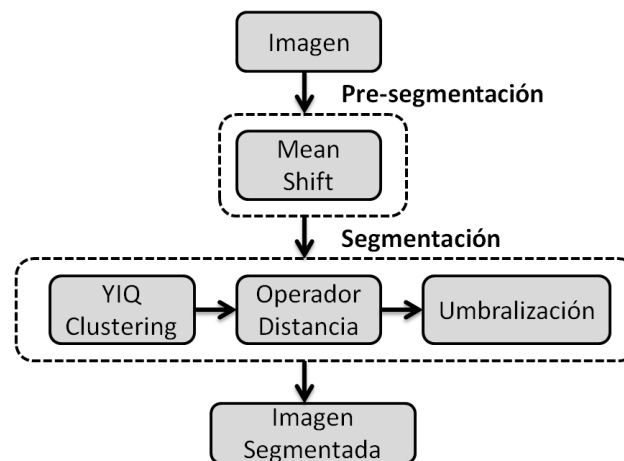


Fig. 2.1. Diagrama de procesamiento para la identificación de característicos geográficos: Pre-segmentación y Segmentación.

2.3. Adquisición de imágenes de sensado remoto

Para el monitoreo y extracción de características de los accidentes geográficos presentes en las planicies se usan imágenes de Google Earth. Las ventajas de usar este tipo de imágenes son varias, como por ejemplo la factibilidad de disponer de imágenes en diferentes series de tiempo, el fácil acceso sin costo asociado y la resolución, entre otras.

Estas imágenes se componen de 3 bandas de información en componentes de color ro-

jo, verde y azul (RGB) y se encuentran georeferenciadas en coordenadas esféricas (elipsoide WGS84). Existe un amplio rango de resoluciones espaciales en este tipo de imágenes, la mayoría de las áreas tienen 15 m/píxel de resolución. Sin embargo, imágenes con más detalles pueden alcanzar una resolución de hasta 15 cm/píxel. En particular, en este trabajo se usaron imágenes adquiridas con una resolución de 0.32 m/píxel y 0.33 m/píxel.

2.4. Algoritmo Mean-Shift

Mean shift es un algoritmo de agrupamiento no paramétrico, introducido por Fukunaga y Hostetler (1975) y adaptado por Cheng (1995). El mismo ha sido aplicado en varias tareas de visión por computador como en el análisis de imágenes (Comaniciu y Meer, 2002; Comaniciu, 2003), la segmentación de escenas (Yang y Liu, 2001; Kim et al., 2003), el seguimiento de objetos (Comaniciu et al., 2003; Debeir et al., 2005; Peng et al., 2005) y la fusión de datos (Chen y Meer, 2005), entre otros.

Este algoritmo reduce la dispersión en la distribución de intensidades de los píxeles de la imagen. El mismo se aplica iterativamente con el propósito de encontrar las modas principales en el histograma y luego clasificar los valores de intensidad de acuerdo a estas modas. Para la estimación de las mismas, el espacio de datos se puede caracterizar como una función de densidad de probabilidad de los niveles de intensidad sobre la imagen. Es decir, regiones densas en el espacio de características se corresponden con los máximos locales de la función de densidad, esto es, la ubicación de las modas desconocidas. Una vez que la ubicación de las modas es determinada, se asocian en un grupo común a todos los datos que se encuentren en un entorno determinado.

2.4.1. Estimación del gradiente de densidad

Cada punto x_i del conjunto de datos (píxeles de la imagen) es asociado al pico más cercano de la función de densidad de probabilidad. Para cada punto, se define una ventana S alrededor del mismo, y se calcula la media ponderada $m(x)$ de los datos en el subcon-

junto de píxeles interiores de la ventana, donde se parte de una estimación inicial x para la media. Los pesos para cada punto son establecidos a partir de su distancia respecto a la estimación inicial, es decir la diferencia $x_i - x$. El valor correspondiente a cada peso es una función de dicha distancia y se la denomina función Kernel $K(x_i - x)$. Generalmente se utiliza un kernel *Gaussiano*, de la forma

$$K(x_i - x) = e^{-c\|x_i - x\|^2} \quad (2.1)$$

donde $c > 0$ permite disminuir el peso exponencialmente cuando la distancia entre los puntos aumenta. Seguidamente, el centro de la ventana se desplaza al nuevo valor obtenido para la media, actualizando los datos e iterando hasta que el desplazamiento converja. De esta manera en cada iteración se calcula

$$m(x) = \frac{\sum_{x_i \in S(x)} K(x_i - x)x_i}{\sum_{x_i \in S(x)} K(x_i - x)} \quad (2.2)$$

En resumen, el algoritmo se puede describir de la siguiente manera:

1. Ubicar una ventana alrededor de cada punto.
2. Calcular la media ponderada de los datos contenidos dentro de la ventana.
3. Desplazar la ventana al nuevo valor de la media y repetir hasta que converja.

En la Figura 2.2 se muestra el resultado de la pre-segmentación. El algoritmo Mean Shift reduce notablemente la dispersión de la distribución de intensidades. El histograma de la imagen pre-segmentada (Fig. 2.2d) presenta picos más pronunciados en comparación con el histograma de la imagen original (Fig. 2.2b). Es decir, los niveles de gris de la imagen pre-segmentada se agrupan en la vecindad de los máximos locales de intensidad de la imagen original.




Fig. 2.2. Aplicación del algoritmo Mean Shift. (a) Imagen Original. (b) Histograma de la imagen original. (c) Imagen pre-segmentada. (d) Histograma de la imagen pre-segmentada.

2.5. Espacios de Color RGB - YIQ

Un espacio de color define un modelo de composición del color. Por lo general está determinado por una base de N vectores, cuyas combinaciones lineales generan todo el espacio de color. Los espacios de color más difundidos intentan englobar la mayor cantidad posible de colores visibles por el ojo humano.

El espacio de color RGB puede ser representado geométricamente en un cubo de tres dimensiones (Fig. 2.3) (Hoy, 1997), en donde todos los vectores fueron normalizados. Cada color aparece en sus componentes primarios: rojo, verde y azul y sus valores de

intensidad se encuentran a lo largo de los tres ejes. Los vértices del cubo representan el color rojo, verde, azul, cyan, magenta y amarillo. El color negro corresponde al origen y el blanco se sitúa en el vértice más alejado del origen. La escala de grises se extiende desde el negro al blanco a lo largo de la diagonal que une esos dos puntos.

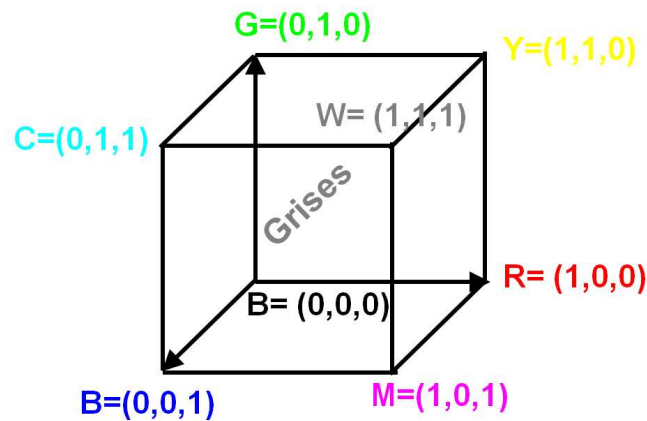


Fig. 2.3. Cubo de color RGB.

El modelo RGB comúnmente usado en la adquisición de imágenes en cámaras digitales y es apropiado para la visualización de colores, pero no es el espacio de color conveniente para la segmentación y análisis de imágenes por la alta correlación existente entre sus componentes rojo, verde y azul (Pietikainen et al., 1996; Littmann y Ritter, 1997). Por lo tanto, es imposible evaluar la similitud de dos colores desde su distancia en este espacio.

En el presente trabajo, las imágenes adquiridas en el espacio de color RGB son transformadas linealmente al espacio de color YIQ (*luminance, in-phase, quadrature*). El espacio de color YIQ fue una recodificación realizada para la televisión americana bajo la norma NTSC (National Television System Committee). La componente Y representa la luminancia en la imagen y la cromaticidad está contenida en I y Q (Robinson, 1977). El modelo YIQ fue diseñado para aprovechar la mayor sensibilidad del sistema visual humano a los cambios de luminancia. La ventaja principal del modelo YIQ en el procesamiento de imágenes es que la componente Y está desacoplada de las componentes I y

Q, por lo que la luminancia puede procesarse sin afectar su contenido cromático.

El espacio de color YIQ es obtenido mediante una transformación lineal del modelo RGB (Russ, 1993) y esta dada por

$$\begin{pmatrix} Y \\ I \\ Q \end{pmatrix} = \begin{pmatrix} 0.299 & 0.587 & 0.114 \\ 0.595716 & -0.274453 & -0.321263 \\ 0.211456 & -0.522591 & 0.311135 \end{pmatrix} * \begin{pmatrix} R \\ G \\ B \end{pmatrix}$$

donde las coordenadas R, G y B están normalizadas y pertenecen al intervalo $[0; 1]$ y las coordenadas normalizadas de Y, I y Q pertenecen al intervalo $[0; 1]$, $[-0.595; 0.595]$ y $[-0.522; 0.522]$, respectivamente.

En tanto, la matriz de transformacion inversa de YIQ a RGB se define como:

$$\begin{pmatrix} R \\ G \\ B \end{pmatrix} = \begin{pmatrix} 1 & 0.9563 & 0.6210 \\ 1 & -0.2721 & -0.6474 \\ 1 & -1.1070 & 1.7046 \end{pmatrix} * \begin{pmatrix} Y \\ I \\ Q \end{pmatrix}$$

2.6. YIQ Clustering - Operador distancia

Con el propósito de separar los cuencos de agua y cursos de marea (figura, f) del resto (fondo, b), los algoritmos desarrollados se basan en el concepto de agrupamiento y distancias mínimas a múltiples prototipos (Girard y Girard, 1999; Richards y Jia, 2006). El proceso caracteriza regiones relevantes de la imagen y mediante píxeles prototipos determina una medida de similaridad aplicando el operador distancia.

El método usual de selección de las áreas figura (p.e., cuencos) y fondo consiste en elegir sectores de la imagen que se correspondan con las zonas a segmentar y utilizar el valor medio (o centroide) de la firma espectral de los píxeles como prototipo (Friedman y Rubin, 1967; Haralick y Kelly, 1969; Saha y Bandyopadhyay, 2010). Sin embargo, las similitudes cromáticas entre las zonas de figura y fondo impiden utilizar esta técnica.

Inicialmente, se demarcan grupos de píxeles correspondientes a las zonas de figura y fondo indicados en rectángulos rojos y azules, respectivamente (Fig. 2.4a). Seguidamente,

se analiza la distribución de los píxeles de cada muestra en los planos Y vs. I, Y vs. Q e I vs. Q del espacio de color YIQ. La separación entre zonas figura y fondo es mayor en el plano Y vs. I, esto permite un mejor proceso de agrupamiento de píxeles y posibilita delinear una poligonal que separe las áreas que corresponden a los píxeles de figura y fondo, respectivamente. Con esta delimitación, el algoritmo multidistancia selecciona dos grupos de píxeles prototipos representativos de cada zona: r_i^f y r_j^b correspondiente a figura y fondo, respectivamente (Fig. 2.4b). El subíndice i corresponde al i -ésimo prototipo de figura, el cual varía entre $1 \leq i \leq F$, donde F es la cantidad total de píxeles prototipos de figura. Análogamente, el subíndice j corresponde al j -ésimo prototipo de fondo, el cual varía entre $1 \leq j \leq B$, siendo B la cantidad total de píxeles prototipos de fondo. El operador multi-distancia se define como

$$d_i^f = \sqrt{(x_Y - r_{(i)Y}^f)^2 + (x_I - r_{(i)I}^f)^2}, \quad (2.3)$$


$$D^f = \min_{1 \leq i \leq F} (d_i^f) \quad (2.4)$$

$$d_j^b = \sqrt{(x_Y - r_{(j)Y}^b)^2 + (x_I - r_{(j)I}^b)^2}, \quad (2.5)$$


$$D^b = \min_{1 \leq j \leq B} (d_j^b) \quad (2.6)$$

Donde el x_Y y x_I son las componentes Y,I del pixel, mientras que $r_{(i)Y}^f$ y $r_{(i)I}^f$ son las componentes Y,I del i -ésimo prototipo figura y, $r_{(j)Y}^b$ y $r_{(j)I}^b$ son las componentes YI del j -ésimo prototipo fondo. El operador distancia determina el grupo al que pertenece cada pixel, en función de las distancias mínimas a los prototipos. Seguidamente, el pixel es clasificado como figura si $D^f \leq D^b$ y fondo si $D^f > D^b$. Los coeficientes D^f y D^b son pseudocoloreados con una escala de gris. De esta forma, se construye una imagen distancia (ID), la cual agrupa sus niveles en dos modos dominantes, asignando negro a la

menor distancia a un pixel patrón de figura D^f y blanco a la menor distancia a un pixel patrón de fondo D^b . La imagen segmentada se construye binarizando la ID mediante un valor de umbral U que permita dividir la imagen en regiones de figura y fondo. El umbral óptimo U puede ser determinado en función del análisis del histograma de la imagen ID.



(a)



(b)


Fig. 2.4. YIQ clustering. (a) Zona de estudio con las regiones de referencia de figura/fondo delimitadas en color rojo y azul respectivamente. (b) Gráfico de dispersión en el espacio de color Y vs. I de las regiones seleccionadas en (a) y selección de los píxeles prototipos de figura y fondo en color verde (r^f) y magenta (r^b), respectivamente.

En la Figura 2.5 se muestra el resultado de la segmentación con la imagen distancia (ID) y la binarización (IM) de la misma con un valor de $U = 121$. Los histogramas de las imágenes original e ID se presentan en la Figura 2.6. Claramente se observa el alto contraste entre las zonas de figura/fondo, por lo que los coeficientes de D^f y D^b represen-

tados en escala de gris en ID se encuentran agrupados en los extremos del histograma, por lo tanto, determinar un valor de umbral adecuado no requiere mayor esfuerzo (Fig. 2.6b).



(a)



(b)

Fig. 2.5. Resultado de la segmentación. (a) Imagen Distancia de la Zona de estudio. (e) Binarización de la imagen Distancia.

Por otro lado, se analizan las curvas de frecuencia acumulativa de la imagen original y de la ID con el propósito de encontrar un valor de U que permita umbralizar ambas imágenes en donde cada una tenga la misma cantidad de píxeles. El valor de umbral es el punto en que se intersectan las dos curvas de frecuencia acumulativa (Fig. 2.6c). En la Fig. 2.6d se visualiza los resultados de la umbralización de ambas imágenes, en donde las áreas en color verde y rojo corresponden al resultado de la umbralización de la imagen ID y la imagen original, respectivamente. Las áreas en color amarillo son la intersección de las dos umbralizaciones. Se observa que la segmentación por distancias mínimas a múltiples prototipos obtiene mejores resultados ya que elimina los falsos positivos presentes en la umbralización de la imagen original (Fig. 2.6d).




Fig. 2.6. Análisis de la segmentación. (a) Histograma de la imagen original. (b) Histograma de la imagen ID. (c) Curvas de frecuencia acumulativa de la imagen original y la imagen ID en color rojo y verde, respectivamente. (d) Imagen resultante de sumar las umbralizaciones de la imagen original e ID en color rojo y verde, respectivamente. En color amarillo se visualiza la intersección de las umbralizaciones de ambas imágenes, las estructuras en rojo son los falsos positivos generados por umbralización de la imagen original.

2.7. Observaciones finales

Las técnicas de segmentación desarrolladas en este capítulo permiten separar los objetos figura del fondo. En particular, el algoritmo Mean Shift disminuyó la dispersión en la distribución de intensidades de los píxeles de la imagen. Por otro lado, el algoritmo de distancias mínimas a múltiples prototipos es un método semi-automático que requiere de la intervención del usuario para seleccionar los píxeles representativos de las zonas figura y fondo a segmentar. Además, el usuario debe determinar la cantidad necesaria de píxeles de referencia en función de cuan separadas estén las áreas que se corresponden a los grupos de píxeles de figura y fondo en el gráfico de dispersión Y vs. I .

Capítulo 3

Medición y Cálculo de Descriptores Morfológicos

3.1. Introducción

La extracción de valores característicos (features) de los objetos segmentados es un proceso esencial para obtener información que permita generar categorías de clasificación para la posterior etapa de reconocimiento. En este trabajo, la medición y el cálculo de descriptores robustos son importantes para caracterizar y clasificar los cuencos de agua y cursos de marea en el siguiente paso de procesamiento (Reconocimiento).

Este capítulo describe los métodos implementados para la representación de contornos y los distintos descriptores de forma calculados. Los algoritmos de medición se basan en aproximaciones poligonales, los cuales permiten obtener una mejor precisión en los resultados en comparación con los métodos clásicos de medición en imágenes digitales. Los descriptores de forma son seleccionados por un experto de manera tal que sean lo más representativos de los distintos característicos geográficos.

3.2. Antecedentes

La medición y el cálculo de descriptores de forma son métodos que permiten extraer información cuantitativa de los objetos en estudio. Estos métodos no son una tarea sencilla y han sido muy reconocidos en PDI y visión por computadora (González y Woods, 1996; Russ, 1999).

Los algoritmos de medición son métodos de representación de contornos que permiten identificar el borde de la figura a partir del conjunto de píxeles de frontera. La representación final de los mismos se puede generar mediante códigos de cadena o aproximaciones poligonales. Estas últimas rodean externamente a la figura suavizando las esquinas y teniendo así una mayor precisión en el resultado. En la literatura, existen diferentes métodos de representación de contornos, entre ellos, Chain Code (Freeman, 1961, 1970), Crack Code (Dunkelberger y Mitchell, 1985), Marching Squares (MS) (Pratt, 1991; Yang et al., 1994), Teh Chin Chain (TCC) (Teh y Chin, 1989) y Marching Squares Interpolado (MSI) (Cipolletti et al., 2012). Sin embargo, no todos proporcionan los mismos resultados.

En particular, el método MSI y Teh Chin Chain son algoritmos de aproximaciones poligonales. Por un lado, MSI es un algoritmo de medición súper resolución (Cipolletti et al., 2012). El mismo es la adaptación mejorada del método MS y el algoritmo de segmentación por distancia mínima a uno o múltiples píxeles prototipos que incluye la información de distancia utilizando la imagen en escala de grises y su binarización. Por otro lado, TCC se basa en la detección de puntos dominantes en una curva digital. Estos concentran la información más relevante sobre la forma de la curva (Teh y Chin, 1989). En general, los métodos de medición cumplen un rol importante en la determinación de los descriptores de forma.

La forma es una característica visual importante para el proceso de reconocimiento en imágenes digitales (Loncaric, 1998; da Fontoura Costa y Cesar Jr, 2000). Los descriptores de forma caracterizan numéricamente figuras y formas y se evalúan por cuánta precisión obtienen en recuperar formas similares desde un repositorio de imágenes.

La recuperación efectiva requiere un descriptor que sea capaz de encontrar similitudes perceptuales invariantes frente a transformaciones rígidas, es decir, que estén rotadas, trasladadas, escaladas, etc. (Kim y Kim, 2000). También es importante la precisión con que pueda encontrar similitud entre formas distorsionadas que para el ojo humano son parecidas. Durante las últimas décadas, varios métodos de descriptores de formas han sido propuestos. Por un lado están los descriptores basados en contornos, entre ellos, Fourier (Zhang y Lu, 2003), wavelets (Maitre y Do, 2010), curvatura (Kerautret y Lachaud, 2009; Liu et al., 2008). Por otro lado, los descriptores basados en regiones exploran el contorno y los píxeles interiores de la figura. En general, estos tipos de descriptores son aplicables a figuras genéricas y son más robustos. Entre ellos se pueden mencionar los invariantes algebraicos (Hu, 1962), los invariantes integrales (Manay et al., 2006), fractales (Imre, 2009), geometría computacional (Zunic y Rosin, 2003). Sin embargo, dada la diversidad de figuras y formas existentes, no existe una única metodología aceptada para la descripción de las formas. Estas pueden ser de utilidad en mayor o menor grado, de acuerdo con el tipo de estudio realizado y el propósito del mismo (Bedoya et al., 2002).

Particularmente, en este capítulo se describen las técnicas de representación y descripción de objetos desarrollados para caracterizar individualmente a los cuencos y cursos de marea presentes en las planicies del estuario. Los algoritmos de medición MSI y TCC proporcionan una mejor precisión en los resultados. Así mismo, los descriptores de forma se seleccionan y calculan de manera tal que sean lo más representativos de las formas de los cuencos y cursos de marea con el propósito de establecer patrones para la posterior etapa de clasificación. Los descriptores de forma utilizados en este trabajo se basan en regiones y contornos.

3.3. Marching Squares Interpolado (MSI)

El algoritmo MSI (Cipolletti et al., 2012) es un método de representación de bordes que utiliza en forma conjunta la técnica Marching squares (Pratt, 1991) con interpolación

lineal y el algoritmo de segmentación por distancia mínima a uno o múltiples píxeles prototipos. El método aproxima la forma del contorno con una poligonal de segmentos de longitud variable. Para ello, utiliza una imagen distancia D en escala de grises y su imagen binarizada B con un determinado umbral U . La imagen binaria está compuesta por píxeles blancos que corresponden a los píxeles de figura (objeto a medir) y píxeles negros que corresponden a los píxeles de fondo. El proceso consiste en recorrer la imagen B y analizar las propiedades locales, es decir, píxeles prendidos (blancos) o apagados (negros) de cada sub imagen contenida en una ventana de 2×2 pixels (llamada *bit-quad* o simplemente *quad*) (Fig. 3.1a) en busca de configuraciones de borde. La longitud y dirección de cada segmento que reconstruye el contorno del objeto a medir depende de la configuración de cada *bit-quad*. Existen 16 configuraciones posibles de *bit-quad*, Q_1, Q_2, Q_3 y Q_D pertenecen a zonas de borde y Q_0 y Q_4 corresponden a zonas de fondo y figura, respectivamente (Fig. 3.1b). Las configuraciones de borde poseen al menos un par de coordenadas que corresponden al segmento de borde (Fig. 3.1c, d y e), excepto las del tipo Q_D que poseen dos pares (Fig. 3.1f). Las coordenadas de cada segmento se sitúan en la línea que une los puntos medios de los píxeles que lo contiene. La suma de todos los segmentos de recta calculados constituye el perímetro total. En la Figura 3.2a se muestra el contorno de un cuenco dibujado con el algoritmo MSI.

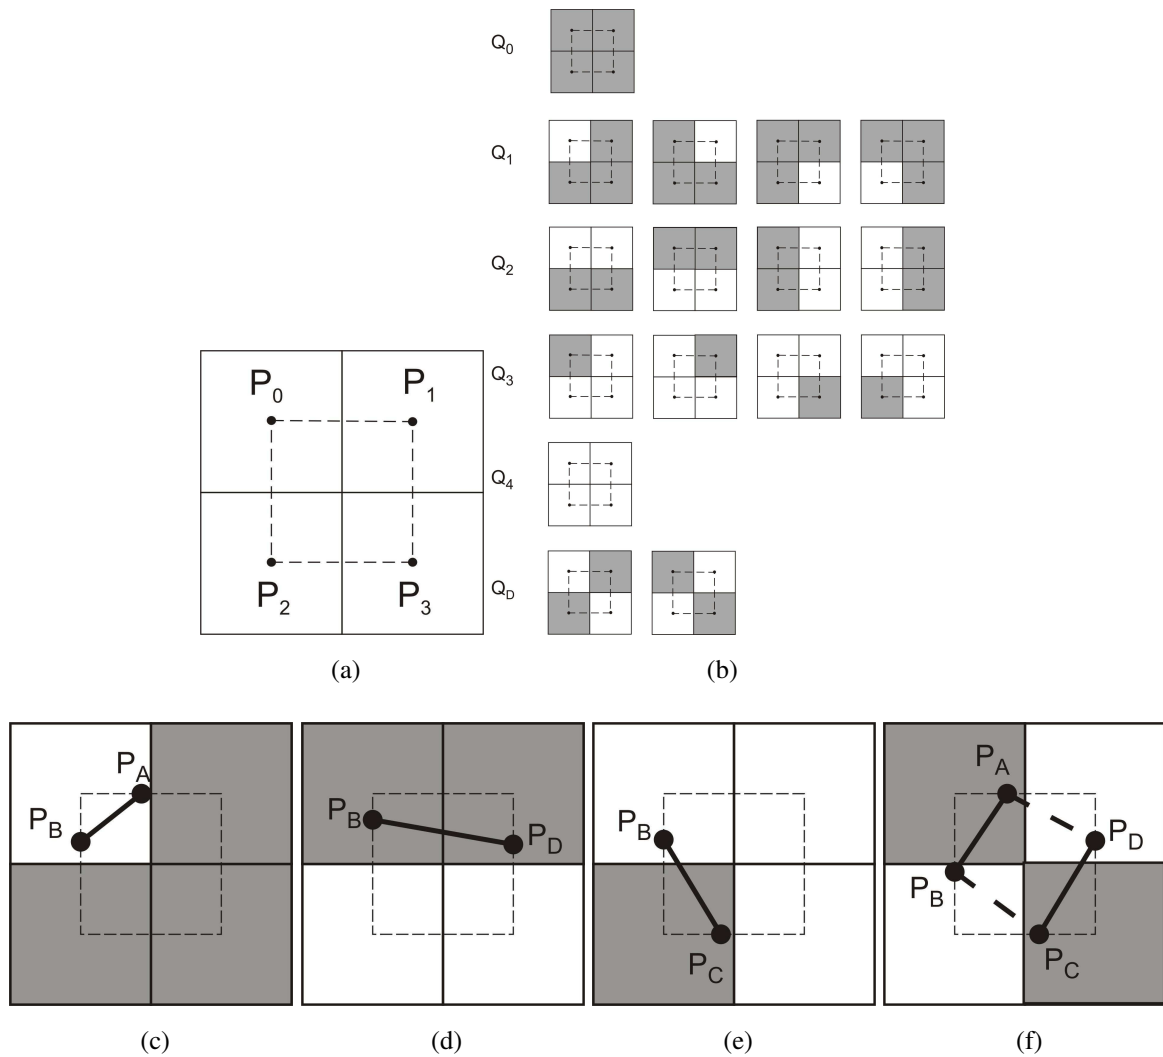


Fig. 3.1. Bit quad. (a) Definición de un Bit quad. (b) Configuraciones posibles de Bit quads. (c) MSI sobre un Bit quad Q_1 . (d) MSI sobre un Bit quad Q_2 . (e) MSI sobre un Bit quad Q_3 . (f) MSI sobre un Bit quad Q_D . (Extraído de Cipolletti et al. (2012))

3.4. Teh-Chin Chain

El algoritmo de aproximación de cadena propuesto por Teh y Chin (1989) (Teh-Chin Chain) es un método basado en la detección de puntos dominantes en una curva digital C




Fig. 3.2. Representación de bordes. (a) Implementación del algoritmo MSI, los puntos rojos representan las coordenadas de frontera de cada segmento. (b) Implementación del algoritmo TCC en donde los puntos dominantes marcados en círculos rojos representan la forma de la curva digital. Se observa que ambos métodos producen resultados muy similares.

definida por n puntos de coordenadas enteras,

$$C = \{p_i = (x_i, y_i), i = 1, \dots, n\}$$

Inicialmente, el método determina la región de soporte para cada punto p_i de la curva en base a sus propiedades locales. La región de soporte consiste en el conjunto de puntos adyacentes a p_i que satisfacen alguna de las condiciones

$$(a) \quad l_{ik} \geq l_{i,k+1}$$

or

$$(b) \quad \begin{aligned} \frac{d_{ik}}{l_{ik}} &\geq \frac{d_{i,k+1}}{l_{i,k+1}} & \text{si } d_{ik} > 0 \\ \frac{d_{ik}}{l_{ik}} &\leq \frac{d_{i,k+1}}{l_{i,k+1}} & \text{si } d_{ik} < 0 \end{aligned}$$

donde $l_{ik} = |\overline{p_{i-k}p_{i+k}}|$ y d_{ik} es la distancia perpendicular del punto p_i al segmento




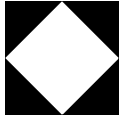
$\overline{p_{i-k}p_{i+k}}$. Seguidamente, se calcula una medida de relevancia para cada punto (p.e., su curvatura) y, finalmente, se seleccionan los puntos dominantes mediante un proceso de extracción de máximos locales. La unión de estos puntos dominantes forman los segmentos que aproximan la forma de la figura (Fig. 3.2b). Este método no requiere parámetros de entrada. Una consideración importante del método es que no precisa la selección del factor de escala porque los resultados en la detección de puntos dominantes no sólo dependen de la medida de relevancia, sino también de la determinación precisa de la región de soporte. Existen tres versiones, en función de los diferentes grados de precisión en la medición de la curvatura: k-coseno, k-curvatura y 1-curvatura. Dependiendo de cada versión, la curvatura puede evaluarse tomando como referencia los vecinos más inmediatos o vecinos más alejados.

3.5. Metodología de Medición

Luego de la etapa de segmentación, en la cual quedan discriminados los objetos figura (cuencos y cursos de marea), se procede a la representación y descripción de los mismos de una forma apropiada para su posterior procesamiento. La representación del contorno de los característicos geográficos se realiza mediante la implementación de los algoritmos MSI y TCC. Ambos son métodos de aproximación de poligonales que producen menor error en comparación con los algoritmos tradicionales de medición.

En la tabla 3.1 se muestra la comparación de medidas de perímetro implementando ambos métodos. Para ello se mide el perímetro en imágenes sintéticas con propiedades geométricas conocidas. Si bien ambos métodos producen buenos resultados, en la presente metodología se utiliza el algoritmo TCC por tener implementado un índice en la secuencia de códigos de los segmentos que conforman el borde de cada objeto a medir. Esto reduce el tiempo de procesamiento en comparación con el método MSI, en el cual hay que extraer cada objeto a medir para realizar la medición del perímetro.

Tabla 3.1. Medición de perímetros sobre figuras sintéticas implementando los algoritmos MSI y TCC. La resolución de las imágenes es de 1 m.

Figura	Valor real	Perímetro [m]	
		MSI	TCC
	588	654.32	616.3
	31.4	31.33	31.31
	278.4	284.97	278.93
	673.16	675.75	674.94

3.6. Descriptores de Forma

Los descriptores de forma son magnitudes adimensionales que describen numéricamente la forma de un objeto, independientemente de su tamaño. Estos descriptores son usados en el análisis de imágenes y microscopía. Los mismos se calculan a partir de medidas, tal como diámetro, área, perímetro, centroide, momentos, etc.

Las magnitudes adimensionales a menudo representan el grado de desviación de una forma ideal, tal como un círculo, esfera o poliedro equilátero (Wojnar y Kurzydłowski, 2000). Los valores de los descriptores de forma generalmente están normalizados en el intervalo [0,1]. Un descriptor de forma igual a uno representa un caso ideal o máxima simetría, tal como un círculo, esfera, cuadrado o cubo.


En particular, dada la variedad de formas que tienen los característicos bajo estudio, se analizan varios descriptores de forma. Los mismos, se seleccionan bajo la examinación subjetiva humana de manera tal que en conjunto puedan ser capaces de discriminar numéricamente a los cuencos de agua y cursos de marea. Los descriptores de forma in-

Introducidos en esta sección se basan en métodos de contornos y regiones (Russ, 2010) y se detallan a continuación.


Área de la caja rectangular convexa (*bounding box*)

Es el área de la caja rectangular convexa que encierra a la figura (Ec. 3.1). La misma se representa con 4 puntos correspondientes a las coordenadas (x,y) en el espacio que definen los vértices de la caja que contiene al objeto (Fig. 3.3a). En este caso se implementa una caja que es sensible a la rotación de la figura (Fig. 3.3b).

$$abox = d(x_1, x_2) * d(x_2, x_3) \quad (3.1)$$



(a)



(b)

Fig. 3.3. Caja rectangular convexa. (a) Determinación de los puntos de la caja. (b) Característicos geográficos delimitados por sus respectivas cajas convexas rotados.

Factor de forma

El factor de forma (ff) es uno de los parámetros más usado como descriptor de circularidad (Schwarz, 1980). Las medidas del área neta y el perímetro de la figura son usados para caracterizar este índice (Ec. 3.2). El mismo proporciona un número adimensional que describe formalmente la desviación de una figura con respecto a un círculo ideal. El valor de dicho índice para cualquier figura está comprendido entre 0 y 1. Para un círculo ideal con una perfecta medición el ff es igual a uno, valores menores indican una mayor desviación de este ideal.

$$ff = \frac{4\pi A_{neta}}{P^2} \quad (3.2)$$

No obstante hay que tener en cuenta que varias figuras pueden tener el mismo valor de ff y, sin embargo, ser de formas muy diferentes entre sí (Fig. 3.4). Al cambiar el tamaño de las figuras, cambian sus relaciones perímetro/área.

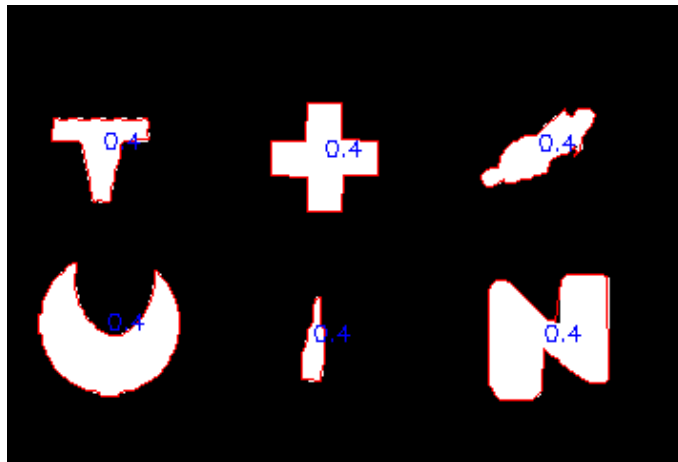


Fig. 3.4. Conjunto de figuras sintéticas visualmente diferentes pero con idénticos valores de factor de forma.

Tabla 3.2. Shape descriptors and their analytical definition.

Nombre	Símbolo	Definición Matemática
Área de la caja rectangular convexa	$abox$	$d(x1, x2) * d(x2, x3)$
Factor de forma	ff	$\frac{4\pi A_{neta}}{P^2}$
Relación de aspecto	ar	$\frac{F_{m\acute{a}x}}{F_{m\acute{i}n}}$
Redondez	rd	$\frac{4A_{neta}}{\pi F_{m\acute{a}x}^2}$
Extensión	ext	$\frac{A_{neta}}{abox}$
Compacidad	cp	$\sqrt{\frac{\frac{4}{\pi} A_{neta}}{F_{m\acute{a}x}}}$
Elongation	elg	$\frac{L}{W}$
Curvatura	cr	$\frac{F_{m\acute{a}x}}{L}$
Amd	amd	$\frac{A_{neta}}{F_{m\acute{a}x}}$

Diámetro de Feret

El diámetro de Feret es la distancia que existe entre dos tangentes a la figura, paralelas entre sí y perpendiculares al eje de medida (Feret, 1931). También es llamado diámetro de calibrador, por ser la medida que se obtiene usando ese instrumento. Inicialmente, su definición se limitaba a la medida de distancia de las tangentes paralelas a un sistema de coordenadas cartesianas. En la actualidad, al mencionar los diámetros de Feret en forma genérica, se hace referencia al conjunto de proyecciones sobre uno de los ejes de coordenadas, haciendo girar el objeto sobre su centro de masa (Fig. 3.5). De todas las proyecciones del objeto, las de mayor y menor magnitud se denominan Feret máximo y Feret mínimo, respectivamente. En ocasiones, suele emplearse también una media aritmética, calculando los diámetros de Feret para un determinado número de ángulos de rotación. En esta tesis, la medida se obtiene mediante la rotación de la figura respecto a su centroide, tomando ángulos de rotación en el intervalo $[0, \Pi]$. La discretización del intervalo se realiza en pasos de $\Pi/180$ (1 grado).




Fig. 3.5. Diámetros de Feret máximo y mínimo. (a) Medidas de los diámetros de Feret. (b) Diámetros de Feret para una rotación de 30° . (c) Diámetros de Feret para una rotación de 80° .



Fig. 3.6. Conjunto de figuras que tienen valores constantes en área con una leve variación en su forma, sin embargo con notables diferencias en sus valores de relación de aspecto.

Relación de Aspecto

La relación de aspecto (ar) es el descriptor de forma más común. A pesar de ser tan conocido, no existe una definición universalmente aceptada de la relación de aspecto (Almeida-Prieto et al., 2007). En esta tesis, el descriptor ar se define como la razón entre la medida de los diámetros de Feret máximo y mínimo (Ec. 3.3).

$$ar = \frac{F_{\text{máx}}}{F_{\text{mín}}} \quad (3.3)$$

Este descriptor brinda información de cuánto está estirada la figura. El valor numérico de la relación de aspecto de la figura no cambia si se modifica el tamaño de la misma. No obstante, si se realiza un proceso de alargamiento a la misma figura manteniendo constante su área el valor del descriptor ar cambia notablemente (Fig. 3.6).

Redondez

La redondez (rd) es un descriptor que mide cuánto se aproxima la forma de una figura a la de un círculo (Wadell, 1933). Este descriptor cuantifica, a gran escala, las características de la forma, teniendo en cuenta las medidas del área y el diámetro de Feret máximo y no tanto la nitidez de los bordes y esquinas de la figura (Ec. 3.4). Los valores

CAPÍTULO 3. MEDICIÓN Y CÁLCULO DE DESCRIPTORES MORFOLÓGICOS 47

numéricos de este descriptor están normalizados en el intervalo [0,1].

$$rd = \frac{4A}{\pi F_{\text{máx}}^2} \quad (3.4)$$

Extensión

La extensión (*ext*) de una figura se define como el cociente entre el área de la figura y el área de la caja rectangular convexa (Ec. 3.5) . Los valores de este descriptor están normalizados en el intervalo [0,1].

$$ext = \frac{A_{\text{figura}}}{A_{\text{caja}}} \quad (3.5)$$

Un valor de $ext = 1$ significa que la figura es un rectángulo y valores menores indican el grado de desviación del rectángulo.

Compacidad

La compacidad (*cp*) de una figura es una característica intrínseca de la forma de la figura. Este descriptor es sensible a los cambios morfológicos y se calcula en función del área, una constante π y el máximo caliper de la figura (Ec. 3.6).

$$cp = \frac{\sqrt{\frac{4}{\pi}A}}{F_{\text{máx}}} \quad (3.6)$$

Los valores de *cp* estan normalizados en el intervalo [0,1].

Elongación

La elongación (*elg*) es un descriptor de forma que mide cuan alargada puede ser una figura. Este descriptor se define como la razón entre la longitud a lo largo de la línea media de la figura (longitud de la fibra *L*) y el ancho medio de la misma (ancho de la fibra *W*) (Ec. 3.7).

$$elg = \frac{L}{W} \quad (3.7)$$

CAPÍTULO 3. MEDICIÓN Y CÁLCULO DE DESCRIPTORES MORFOLÓGICOS 48

Por un lado, el proceso para obtener la longitud de la fibra consiste en eskeletonizar la figura obteniendo así su esqueleto y considerando solo los píxeles que conforman la fibra para medir su distancia. El concepto de esqueleto fue planteado por Blum et al. (1967) con el nombre de *medial axis transformation*. El mismo representa la estructura de la figura mediante píxeles que conservan su conectividad. El ancho del esqueleto es de un píxel y está en posición central en la figura conservando la extensión geométrica de la misma (Fig. 3.7). En esta tesis, el esqueleto de la figura se obtiene mediante la implementación del algoritmo de adelgazamiento propuesto por Zhang y Suen (1984). Sin embargo del resultado del esqueleto sólo se considera la longitud de su fibra.

Por otro lado, la estimación del ancho medio de la figura se realiza mediante su aproximación geométrica. Para ello, se asume que la figura es una cinta de ancho uniforme (Fig. 3.8), de dimensiones L (longitud de la fibra) y W (ancho de la fibra). Por lo tanto, el área (A) se puede estimar aproximadamente como $A \approx W * L$, obteniéndose así el valor de W .




Fig. 3.7. Representación de los parámetros de longitud y ancho medio de la fibra de una figura.

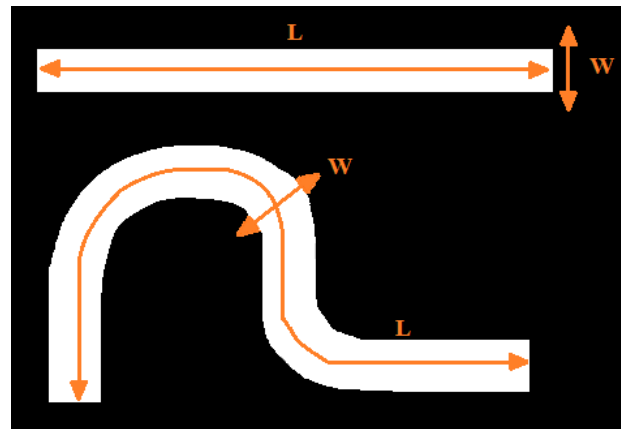


Fig. 3.8. Modelo geométrico para una fibra considerada como una cinta de longitud F con terminaciones cuadradas y un ancho medio constante W . El valor de W es calculado desde el área de la figura basada en el rectángulo mostrado en la parte superior. El valor de W es aproximadamente correcto para la figura curva mostrada en la parte inferior.

Curvatura

La curvatura (cr) es una medida que proporciona información acerca del grado de torcedura en una figura. Este descriptor se define como la razón entre la medida de Feret máximo de la figura y la longitud de su fibra (Ec. 3.8). Por ejemplo, en la figura 3.9 se muestra un grupo de objetos con diferentes valores de curvatura. Los objetos que visualmente tienen un grado de torcedura mayor en su forma se corresponden con valores menores de curvatura.

$$cr = \frac{F_{\text{máx}}}{L} \quad (3.8)$$




Fig. 3.9. Conjunto de figuras con diferentes valores de curvatura, los valores de cr indican el grado de torcedura de las figuras.







amd

El descriptor (amd) se define como la razón entre el área de la figura y su medida de longitud de Feret máximo (Ec. 3.9).

$$amd = \frac{A_{neta}}{F_{m\acute{a}x}} \quad (3.9)$$

A continuación, se muestran los valores de los distintos descriptores de formas aplicados a un conjunto de característicos geográficos (Tabla. 3.3).

Tabla 3.3. Valores de los distintos descriptores de forma aplicados a un conjunto de accidentes geográficos.

Figura	Descriptores								
	<i>abox</i>	<i>ff</i>	<i>ar</i>	<i>rd</i>	<i>ext</i>	<i>cp</i>	<i>elg</i>	<i>cr</i>	<i>amd</i>
	170.02	0.38	1.39	0.49	0.59	0.70	4.28	0.60	6.28
	242.93	0.19	2.76	0.15	0.34	0.39	10.37	0.82	3.11
	69.36	0.67	1.35	0.64	0.81	0.80	1.82	1.08	5.33
	112.17	0.25	2.19	0.26	0.48	0.51	6.98	0.70	3.32
	368.02	0.05	6.33	0.03	0.17	0.18	48.67	0.78	1.27
	137.30	0.57	1.65	0.49	0.68	0.70	3.14	0.81	6.03

3.7. Observaciones finales

La representación y descripción de objetos que han sido segmentados desde una imagen son los primeros pasos en el proceso de automatización de los sistemas de análisis de imágenes. En esta tesis, la representación de las figuras se lleva a cabo implementando el algoritmo de contornos TCC. Cuantitativamente este algoritmo produce un menor error en comparación con métodos tradicionales de medición. Por otro lado, los descriptores de forma calculados fueron seleccionados por expertos con el propósito de capturar las esenciales diferencias entre las clases de los característicos geográficos (cuencos de agua y cursos de marea). En este contexto, la información obtenida de los tests de descriptores es útil para la posterior etapa de entrenamiento de un sistema de clasificación automática.

Capítulo 4

Clasificación de Característicos Geográficos

4.1. Introducción

El proceso de clasificación es esencial en el reconocimiento de patrones en imágenes digitales. Clasificar significa asociar a cada elemento de una colección con una categoría o clase (de entre un conjunto predeterminado o desconocido, según sea el caso). Esta asociación se realiza en base a las características o propiedades de los objetos que están representados por un conjunto de descriptores (patrones). La clasificación de objetos geométricos en general, y visuales en particular, ha sido tradicionalmente una de las áreas más estudiadas en el PDI, pero las soluciones de propósito general aún están fuera de la frontera del conocimiento, requiriéndose, como en este trabajo, el diseño de soluciones específicas para nuestro problema en particular.

En el presente capítulo se aborda el diseño y desarrollo de un clasificador supervisado específicamente entrenado para la clasificación de los accidentes geográficos de nuestro interés. El clasificador requiere una fase inicial de entrenamiento, en la cual expertos humanos proveyeron la clasificación a priori de dichos accidentes. Con este etiquetado y el conjunto de característicos de forma vistos en el capítulo anterior, se procedió, por medio

de un modelo de regresión, a elaborar un mecanismo de clasificación automático que permitiese la ulterior clasificación masiva en grandes volúmenes de imágenes. La performance del modelo de clasificación automático se evalúa mediante la matriz de confusión. El índice Kappa determina el nivel de concordancia entre las clasificaciones (supervisada y no supervisada).

4.2. Antecedentes

Desde la antigüedad el hombre ha buscado clasificar a los diferentes objetos naturales y artificiales de su alrededor y, de esta forma, ha logrado grandes avances en el entendimiento y estudio de la naturaleza y del mundo en general. Con el avance de la informática y la tecnología se ha despertado la inquietud por lograr automatizar los procesos de clasificación.

En particular, la clasificación de datos en imágenes de sensado remoto es una tarea fundamental en el proceso de reconocimiento de patrones. Se requiere el uso de diferentes técnicas para lograr una precisión adecuada en la clasificación de objetos en imágenes digitales (Gong y Howarth, 1992; Kontoes et al., 1993; Foody, 1996; San Miguel-Ayanz y Biging, 1997; Aplin et al., 1999; Stuckens et al., 2000; Franklin et al., 2002; Pal y Mather, 2003; Gallego, 2004). Los métodos de clasificación han demostrado su utilidad en el marco de diversas investigaciones geológicas, geofísicas y ambientales entre otras, no sólo por el ahorro en tiempo y recursos que han significado, sino también porque han permitido una mejor calidad de los resultados. Cualquiera sea el campo de aplicación, un método de clasificación debe ser fiable, reproducible por otros dadas las mismas variables de entrada, robusto y objetivo (Chuvieco, 2008). Por esta razón, la clasificación de datos en imágenes de sensado remoto es aún un desafío y requiere la consideración de diversos factores (Tou y Gonzalez, 1974; Neal y Russ, 2012).

Los métodos de clasificación se dividen en dos categorías (Duda et al., 2001; Bow, 2002; Chuvieco, 2008): los supervisados o con aprendizaje (Chen y Fu, 1986) y los no

supervisados. Los primeros son aquellos que requieren de la intervención humana para el control en el proceso de determinación de las categorías, aprovechando la información contenida en la muestra de entrenamiento. La misma consiste en un conjunto de casos de ejemplo, en donde cada patrón ha sido evaluado por un especialista y ha recibido una identificación que acredita qué clase representa dentro de la muestra de entrenamiento. Los segundos son métodos en los que no existen o no se conocen las categorías previas, por lo que el modelo de aprendizaje las descubre.

En la actualidad, existen numerosos métodos de clasificación que se pueden agrupar en clasificadores estadísticos, sintácticos y basados en técnicas de Inteligencia Artificial, entre otros. A pesar de los grandes avances existentes relacionados con la clasificación, no existe actualmente ningún sistema de clasificación de propósito general que se aplique a cualquier imagen, sino más bien un conjunto de métodos y flujos de trabajo genéricos, que pueden adaptarse con mayor o menor éxito en determinados contextos (Chuvieco, 2008). Por dicha razón, cada algoritmo de clasificación generalmente requiere una metodología diferente y cada metodología probablemente genere distintos resultados (Mather y Tso, 2003; Landgrebe, 2005).

En particular, los métodos de regresión logística multinomial son modelos estadísticos para el análisis de datos categóricos (Hosmer y Lemeshow, 2000). En ellos, se evalúa la influencia de las variables regresoras en la probabilidad de ocurrencia de un suceso particular. De hecho, estos modelos son implementados como métodos estadísticos de clasificación porque además de predecir la probabilidad de un evento de interés en una investigación, identifican también las variables relevantes para tal predicción.

Particularmente, en este capítulo se aborda el entrenamiento supervisado de un clasificador y el desarrollo de un modelo de regresión logística multinomial. El propósito de este último es el de clasificar automáticamente a cada característico geográfico, además de cuantificar la importancia de la relación existente entre cada una de las variables explicativas (descriptores de forma) y la variable dependiente (clase). También se describen los métodos de validación del modelo.

4.3. Entrenamiento supervisado

La clasificación supervisada es el procedimiento más usado para el análisis cuantitativo de datos de imágenes de sensado remoto (Richards y Jia, 2006). El proceso de clasificación se lleva a cabo para encontrar propiedades comunes entre el conjunto de datos de característicos geográficos y poder así separarlos en diferentes categorías o clases. Esta etapa requiere de la intervención de un experto para determinar el área de entrenamiento o muestra y discriminar a nivel visual cada característico geográfico. El proceso de selección de la muestra es muy importante ya que las estimaciones posteriores se basan sobre la misma. La muestra debe ser elegida adecuadamente porque los resultados de la clasificación están más influidos por la definición previa de las clases y no tanto por el criterio por el cual estas son diferenciadas en la imagen.

Para este trabajo, inicialmente se seleccionó una muestra de entrenamiento compuesta por 1507 observaciones (Apéndice B) y mediante el criterio del experto se identifican los característicos geográficos según su clase. Seguidamente, se definen tres clases: cuencos (P), cursos de marea (C) y estructuras espurias (O). La clasificación supervisada se realiza sobre las imágenes segmentadas, por lo que surge la clase estructuras espurias que son remanentes de la segmentación. A partir de la selección de la muestra de entrenamiento y la definición de clases se pretende formular un modelo lineal para cada clase. Se hace uso del set de datos obtenido en la etapa anterior (descriptores de forma) como patrones para el desarrollo del modelo clasificador.

A partir de este punto, comienza la fase de aprendizaje del clasificador. Para lo cual resulta adecuado seleccionar varias áreas de entrenamiento por clase para reflejar correctamente su variabilidad en la zona de estudio. Las descripciones de las clases son usadas para clasificar futuros datos de prueba. Para el desarrollo del modelo se utiliza una herramienta estadística de regresión.

4.3.1. Modelo de Regresión Logística Multinomial

Los modelos de regresión logística son técnicas estadísticas en los que se pretende conocer la relación entre una variable dependiente cualitativa, dicotómica (regresión logística binaria o binomial) y variables explicativas independientes, que pueden ser cualitativas o cuantitativas. Los modelos de regresión logística con más de dos categorías (variables dependientes) son denominados multinomiales.

El modelo de regresión logística multinomial (Hosmer y Lemeshow, 2000) es un método estadístico de clasificación, en el que se desea estimar la probabilidad de éxito en un evento específico, dado un conjunto de variables que explican sus características particulares. Por dicha razón, es una de las herramientas más usadas para analizar datos categóricos (Agresti, 1996). En el modelo multinomial, la variable dependiente tiene más de dos alternativas a considerar como posibles respuestas, por lo cual la distribución de probabilidad adecuada para modelar este fenómeno es la distribución multinomial. Se debe tener en cuenta que la regresión logística multinomial difiere de la regresión logística condicional y ordinal, pues en la regresión condicional las variables explicativas hacen referencia a atributos de las alternativas, variando sus valores para cada una de ellas, mientras que pueden o no variar para cada individuo. Además sólo se estima un vector de parámetros, a diferencia del caso multinomial en el que se calculan tantos vectores (i.e., los coeficientes regresores β) como categorías menos uno. Por otra parte en la regresión ordinal, las estimaciones no se pueden realizar con los modelos mencionados anteriormente, ya que esta tiene como particularidad el uso de la información adicional suministrada por el orden de las categorías de la variable respuesta.

Sea una muestra de N observaciones, donde cada observación i ($i \in [1..N]$) tiene asociado un conjunto de m variables independientes $X_i = (x_{1,i}, \dots, x_{m,i})$, también llamadas explicativas. Sea Y_i la variable respuesta del modelo correspondiente a la observación i con distribución multinomial, que frente al conjunto de variables explicativas X_i puede tomar un valor k que representa alguna de las K categorías o clases respecto de la cual se desea clasificar cada observación ($k \in [1..K]$). La ecuación de partida del modelo

es:

$$\begin{aligned}
 p[Y_i = k|X_i] &= \beta_{0,k} + \beta_{1,k}x_{1,i} + \beta_{2,k}x_{2,i} + \cdots + \beta_{m,k}x_{m,i}, \\
 p[Y_i = k|X_i] &= \beta_k \cdot X_i.
 \end{aligned}
 \tag{4.1}$$

donde $p[Y_i = k|X_i]$ es la probabilidad condicional de que Y dada la observación i tome el valor k en presencia de las variables explicativas X_i , y β_k es el vector de los coeficientes de regresión asociado a la k -ésima categoría. Para una notación más sencilla, se denota $p[Y_i = k|X_i]$ como

$$p_k(Y_i) := \beta_k \cdot X_i
 \tag{4.2}$$

Dadas K categorías se tiene $K - 1$ modelos independientes de regresión, en los cuales una categoría es elegida como pivote y los restantes $K - 1$ modelos son ajustados por separado frente a la categoría pivote, siendo esta generalmente la última categoría (K).

$$\begin{aligned}
 \ln \frac{p(Y_i = 1)}{p(Y_i = K)} &= \beta_1 \cdot X_i, \\
 \ln \frac{p(Y_i = 2)}{p(Y_i = K)} &= \beta_2 \cdot X_i, \\
 &\dots\dots \\
 \ln \frac{p(Y_i = K - 1)}{p(Y_i = K)} &= \beta_{K-1} \cdot X_i.
 \end{aligned}
 \tag{4.3}$$

Si se exponencia ambos lados de la ecuación 4.3 y se resuelven las probabiliades, se obtiene

$$\begin{aligned}
 p(Y_i = 1) &= p(Y_i = K)e^{\beta_1 \cdot X_i}, \\
 p(Y_i = 2) &= p(Y_i = K)e^{\beta_2 \cdot X_i}, \\
 &\dots\dots \\
 p(Y_i = K - 1) &= p(Y_i = K)e^{\beta_{K-1} \cdot X_i}.
 \end{aligned}
 \tag{4.4}$$

Usando la premisa de que las probabilidades de todas las variables deben sumar uno, se tiene

$$p(Y_i = K) = \frac{1}{1 + \sum_{k=1}^{K-1} e^{\beta_k \cdot X_i}}
 \tag{4.5}$$

siendo las otras probabilidades

$$\begin{aligned}
 p(Y_i = 1) &= \frac{e^{\beta_1 \cdot X_i}}{1 + \sum_{k=1}^{K-1} e^{\beta_k \cdot X_i}}, \\
 p(Y_i = 2) &= \frac{e^{\beta_2 \cdot X_i}}{1 + \sum_{k=1}^{K-1} e^{\beta_k \cdot X_i}}, \\
 &\dots\dots\dots \\
 p(Y_i = K - 1) &= \frac{e^{\beta_{K-1} \cdot X_i}}{1 + \sum_{k=1}^{K-1} e^{\beta_k \cdot X_i}}.
 \end{aligned}
 \tag{4.6}$$

4.3.2. Estimación de los coeficientes de las variables regresoras del modelo

La estimación de los coeficientes de las variables regresoras del modelo se realiza usando la herramienta estadística IBM SPSS Statistics[®]. El tamaño de la muestra es de 1507 observaciones y está compuesta por el conjunto de descriptores de forma calculados en la etapa anterior.

Inicialmente se eligen tres tipos diferentes de morfologías: cuencos (*P*), cursos de marea (*C*) y estructuras espurias (*O*) como variables categóricas, siendo ésta última la clase pivote. Dado que *K* es igual a tres se generan dos modelos independientes de regresión para la estimación de los coeficientes de regresión asociados a las categorías (*P*) y (*C*).

Bajo el criterio de que el modelo sea el más reducido posible que explique los datos (principio de parsimonia) se utiliza el método de selección hacia adelante para la inclusión de las variables explicativas al modelo utilizando la herramienta SPSS Statistics[®]. En particular, las variables *ff*, *rd*, *ar*, *amd*, *ext*, *cr*, *elg* y *a_box* son las que demuestran ser fuertes predictoras de la variable dependiente al tomarlas en conjunto. En este contexto, siguiendo la ecuación (4.3) los vectores de los coeficientes regresores β tal cual fueron calculados por la herramienta son:

$$Z_{P,O} = 2.6 ff - 0.8 rd - 0.02 ar + 1.2 amd + 2.3 ext - 0.1 cr - 0.13 elg + 0.006 a_{box} - 2.04
 \tag{4.7}$$

y

$$Z_{C,O} = -6.6 ff - 33.6 rd - 0.3 ar + 1.1 amd + 4.5 ext + 0.7 cr + 0.01 elg + 0.02 a_{box} + 1.2 \quad (4.8)$$

en donde $Z_{P,O}$ y $Z_{C,O}$ son los dos vectores estimados de los coeficientes de regresión asociados a la categoría P y C , respectivamente, usando como pivote la clase O . Los valores -2.04 y 1.2 son las constantes y los valores restantes son los coeficientes de regresión computados del modelo. El índice de calidad del ajuste del modelo R^2 es 0.93 . El hecho de que R^2 tenga un valor suficientemente cercano a uno significa que la regresión es estadísticamente significativa.

Las ecuaciones 4.7 y 4.8 son usadas para formular el modelo probabilístico y obtener así la probabilidad de las variables categóricas.

$$\mathcal{P}_O(ff, rd, ar, amd, ext, cr, elg, a_{box}) = \frac{1}{1 + e^{Z_{C,O}} + e^{Z_{P,O}}}, \quad (4.9)$$

$$\mathcal{P}_P(ff, rd, ar, amd, ext, cr, elg, a_{box}) = \frac{e^{Z_{P,O}}}{1 + e^{Z_{C,O}} + e^{Z_{P,O}}}, \quad (4.10)$$

$$\mathcal{P}_C(ff, rd, ar, amd, ext, cr, elg, a_{box}) = \frac{e^{Z_{C,O}}}{1 + e^{Z_{C,O}} + e^{Z_{P,O}}}. \quad (4.11)$$

4.4. Análisis de Desempeño de la Clasificación

La capacidad del modelo para representar confiablemente el sistema real se relaciona esencialmente con la exactitud. Existen diferentes enfoques que pueden ser empleados como métrica, entre ellas una evaluación cualitativa basada en el conocimiento de un experto y una evaluación cuantitativa basada en estrategias de muestreo.

Según sea el caso, la medida de evaluación de clasificación seleccionada dependerá del dominio del problema. Por ejemplo, el porcentaje de casos bien clasificados mide la bondad (exactitud) del clasificador. La bondad de un clasificador es una estimación de la probabilidad de la clasificación correcta de una instancia elegida al azar (Kohavi, 1995).

En este contexto para evaluar la performance del clasificador es importante que el conjunto de prueba o validación sea diferente del de entrenamiento. Inclusive debe ser lo suficientemente grande para evitar los resultados denominados optimistas.

4.4.1. Matriz de confusión

La matriz de confusión o matriz de error es el enfoque más utilizado en la evaluación de la precisión de una clasificación (Foody, 2002; Congalton y Green, 2008; Lunetta y Lyon, 2004). La misma es un arreglo cuadrado de números ordenados en columnas y filas. Las columnas corresponden a las clases predichas en el proceso de clasificación y, las filas al conjunto de referencia. En la diagonal principal se reportan los casos correctamente clasificados y en la opuesta se detallan los errores de la predicción. En la tarea de clasificación con dos valores, dado un clasificador y una instancia se producen cuatro valores de salida:

- Verdadero positivo (T_p) si la instancia es clasificada correctamente y su clase pertenece a la positiva.
- Verdadero negativo (T_n) si la instancia es correctamente clasificada con la clase de valor negativo.
- Falso positivo (F_p) cuando la instancia es de la clase negativa y es clasificada como clase positiva.
- Falso negativo (F_n) se presenta cuando el clasificador clasifica erróneamente una instancia de la clase positiva como un caso de la clase negativa.

En base a estas cuatro salidas se construye la matriz de confusión (Tabla 4.1a).

Tabla 4.1. Medida de desempeño: (a) Matriz de confusión. (b) Parámetros de precisión.

		Predicción		
		Negativo	Positivo	Total
Actual	Negativo	Tn	Fp	$An = Tn + Fp$
	Positivo	Fn	Tp	$Ap = Fn + Tp$
	Total	$Pn = Tn + Fn$	$Pp = Fp + Tp$	T

(a)

Definición	Símbolo	Definición Matemática
Precisión global	A_g	$Tn + Tp / (An + Ap)$
Índice de verdaderos positivos	R_{Tp}	Tp / Ap
Índice de verdaderos negativos	R_{Tn}	Tn / An
Índice de falsos negativos	R_{Fn}	Tn / Pn
Índice de falsos positivos	R_{Fp}	Tp / Pp
Parámetro auxiliar	$P_r(a)$	$(Tn + Tp) / T$
Parámetro auxiliar	$P_r(e)$	$(An * Pn + Ap * Pp) / T^2$

(b)

A partir de la matriz de confusión se calculan diversos parámetros (Tabla 4.1b) que estiman su precisión respecto del total de característicos en estudio (T). La precisión global (A_g) cuantifica el número de característicos correctamente clasificados. La precisión de clases es la proporción de verdaderos positivos y negativos (R_{Tp} y R_{Tn}), indica el porcentaje de característicos de la k -ésima clase correctamente clasificados. La precisión de asignación es la proporción de falsos positivos y negativos (R_{Fp} y R_{Fn}), indica el porcentaje de característicos clasificados como clase k que realmente corresponden a dicha clase. Los coeficientes R_{Fp} y R_{Fn} están relacionados con los errores de “asignación” y “omisión”, respectivamente. Es decir, los errores que cuantifican el número de característicos clasificados como la k -ésima clase que corresponden a una clase diferente y

el número de característicos pertenecientes a la k -ésima clase que no fueron clasificados como dicha clase.

4.4.2. Nivel de concordancia entre clasificadores

La medida de consenso entre los resultados del modelo y la evaluación del experto es esencial. Esta evalúa la variabilidad de los resultados entre la imagen clasificada según la apreciación humana (supervisada) y la realidad observada debido a la exactitud de la clasificación del modelo (no supervisada). El índice Kappa (κ) introducido por Cohen (1960) es una medida de consenso entre dos o más “opiniones”, y no tiene en cuenta las coincidencias que pueden ocurrir por puro azar. Este índice únicamente tiene en consideración si hay o no acuerdo, es decir, si se clasifica o no la instancia en la misma clase. Además es insensible al desbalanceo de clases, es el caso en este contexto porque las cantidades de P, C, y O en las imágenes son muy desproporcionadas. Así mismo es necesario un criterio para interpretar su valor.

El coeficiente Kappa puede tomar valores entre -1 y +1. Mientras más cercano a +1, mayor es el grado de concordancia inter-observador, por el contrario, mientras más cercano a -1, mayor es el grado de discordancia inter-observador (Tabla. 4.2).

La ecuación para Kappa (κ) está dada por

$$\kappa = \frac{\text{Pr}(a) - \text{Pr}(e)}{1 - \text{Pr}(e)}, \quad (4.12)$$

donde $\text{Pr}(a)$ es proporción de coincidencias frente al total de sujetos:

$$\text{Pr}(a) = (Tn + Tp)/T,$$

y $\text{Pr}(e)$ es la probabilidad hipotética de la posibilidad de acuerdo entre los observadores (concordancia esperada)

$$\text{Pr}(e) = \frac{An * Pn + Ap * Pp}{T^2}$$

Tabla 4.2. Escala de (Landis y Koch, 1977) para medir el grado de concordancia del índice Kappa.

Kappa	grado de acuerdo
< 0.00	<i>sin acuerdo</i>
0.01 - 0.20	<i>insignificante</i>
0.20 - 0.40	<i>bajo</i>
0.40 - 0.70	<i>bueno</i>
0.70 - 1.00	<i>óptimo</i>

4.5. Observaciones finales

A partir de la clasificación supervisada de cada característico geográfico y con el conjunto de datos (descriptores de forma) disponible es posible diseñar un modelo estadístico (regresión logística multinomial). Este último es preciso dado que el valor de su bondad de ajuste es suficientemente alto y posibilita la clasificación automática de los característicos bajo estudio. Inclusive cuantifica la relación existente entre cada descriptor de forma (variables explicativas) y cada clase (variable dependiente) asociada a los característicos.

Por otro lado, la matriz de confusión y el índice Kappa son usados como métrica para validar el modelo teniendo en cuenta que las clases en las imágenes están desbalanceadas. En este contexto, la implementación del clasificador facilita el estudio de los datos, ya que la intervención humana sólo se enfoca en la interpretación de los mismos, minimizando de esta forma costos y tiempos.

Capítulo 5

Resultados y Discusión

5.1. Introducción

El presente capítulo presenta los resultados obtenidos en la aplicación de las diferentes líneas desarrolladas en esta tesis. El desempeño de las técnicas de PDI se evalúa sobre imágenes de sensado remoto correspondientes a diferentes sectores del estuario de Bahía Blanca.

Para el análisis de los resultados, las áreas de estudio están divididas en dos grupos, uno para entrenamiento y otro para validación. Inicialmente, se ilustran y describen los resultados de los procesos de segmentación, representación y descripción de cada zona. En segundo lugar, se muestran los resultados de la clasificación supervisada frente a la automática. La clasificación manual realizada en las zonas de entrenamiento es utilizada para encontrar el conjunto de variables regresoras (descriptores) con el que se entrena el clasificador, en función de lo visto en los dos capítulos anteriores. Así mismo, la clasificación manual llevada a cabo en las zonas de validación se utiliza con el propósito de evaluar la sensibilidad del clasificador en un conjunto de datos diferente al utilizado para el entrenamiento. Eventualmente podría utilizarse la técnica de *cross-fold* para mejorar la performance (es decir, entrenar al clasificador con los datos de aquella zona que luego genere la mejor performance en las demás zonas). Sin embargo, hemos preferido presentar

en esta tesis una técnica de entrenamiento más simple a efectos de hacer más comprensible la exposición, dejando la aplicación de la *cross-fold validation* para trabajos futuros.

Para cada caso se presenta un análisis de la performance del clasificador en dos formas distintas, visual y cuantitativamente. El propósito es determinar la variabilidad de los resultados entre la imagen clasificada según la apreciación del evaluador experto (supervisada) y la obtenida por medio del modelo (automática). Ante la situación planteada, se implementan como métrica la matriz de confusión y el coeficiente Kappa. Este último evalúa el nivel de concordancia entre las clasificaciones (supervisada y automática) sin tener en cuenta el desbalanceo de clases existentes. Las etapas mencionadas anteriormente integran la arquitectura del desarrollo de la aplicación PDI de la metodología expuesta (Fig. 5.1).

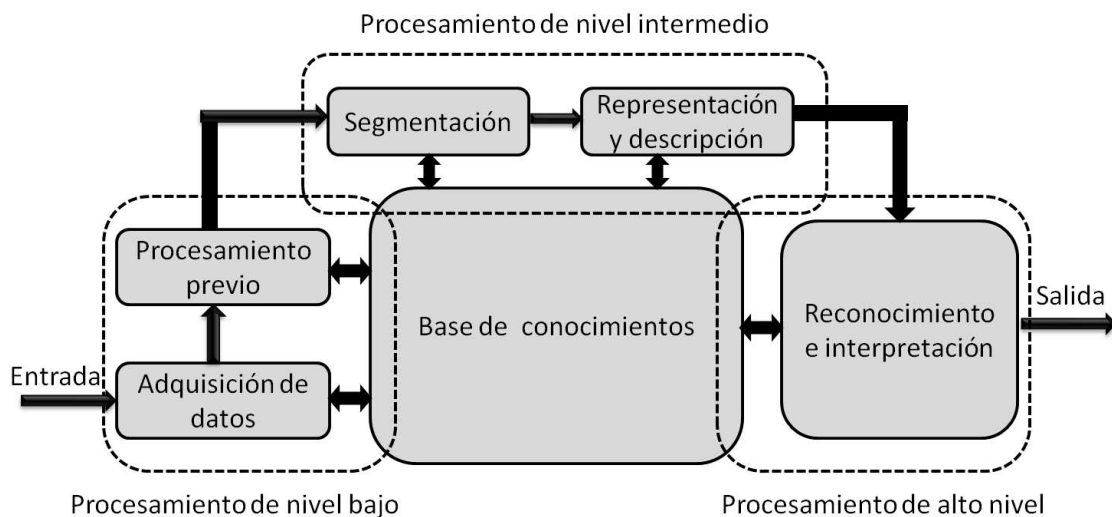


Fig. 5.1. Arquitectura del desarrollo de la aplicación PDI.

5.2. Procesamiento de nivel intermedio

En esta sección se presentan los resultados obtenidos en la etapa de segmentación, representación y descripción. En las zonas definidas para el área de trabajo se aplican las

técnicas de procesamiento Mean Shift y distancias mínimas a múltiples prototipos. Dada la cantidad de zonas analizadas para este estudio, en este capítulo sólo se muestran los resultados de las zonas de entrenamiento (8 y 9) y tres de validación (5, 6 y 10). En el apéndice A se presentan los resultados de las restantes zonas.

En las figuras (5.2, 5.3, 5.4 y 5.5) y (5.6, A.13 y A.16) se muestran los resultados correspondientes a las zonas de entrenamiento y validación. La segmentación aplica la metodología detallada en las secciones 2.4 y 2.6. La selección de los píxeles figura y fondo que se corresponden con las zonas a segmentar se determinan en forma supervisada y se obtienen en el espacio de color YIQ. La distribución de los píxeles en el plano Y vs I permite un mejor proceso de agrupamiento en dos sectores bien definidos y posibilita delinear una poligonal que separe las áreas correspondientes a los píxeles de figura y fondo. Estos últimos se marcan en rojo y azul, respectivamente. Los píxeles prototipos se eligieron de forma supervisada de ambas zonas de interés: figura y fondo, y se marcan en verde y magenta, respectivamente (Figs. 5.2c, 5.3c, 5.4c, y 5.5c). El operador distancia determina el grupo al que pertenece cada pixel, en función de las distancias mínimas a los prototipos. A partir de los coeficientes de distancia se construye la imagen ID (Figs. 5.2d, 5.3d, 5.4d, y 5.5d). El análisis visual de su histograma refleja claramente dos grupos de datos y, por lo tanto es posible fijar un valor de umbral que divida a la imagen en regiones de figura y fondo (Sección 2.6). En las figuras (5.2e, 5.3e, 5.4e, 5.5e) y (Figs. 5.6e y f, 5.7g, h e i, 5.8e y f) se visualizan los resultados de la binarización. En todas las imágenes, se observa que quedan discriminadas las estructuras de figura y fondo. Los objetos de figura están integrados por cuencos de agua, cursos de marea y estructuras espurias, siendo estas últimas residuos de la segmentación. Cabe aclarar que los gráficos de dispersión correspondientes a las zonas de validación no se visualizan porque presentan rasgos similares a los obtenidos en las imágenes de entrenamiento.

El proceso de medición y el cálculo de los descriptores morfológicos se realiza implementando los algoritmos desarrollados en el capítulo 3. El perímetro (P) se mide empleando el algoritmo de aproximación de contornos TCC. Asimismo, el área se mide

con una adaptación del mismo algoritmo que calcula la superficie delimitada por la frontera. Finalmente se computan los diversos descriptores: (ff) , (rd) , (ext) , (ar) , $(abox)$, $(Feret_{m\acute{a}x}$ y $Feret_{m\acute{i}n})$, (cp) , (amd) , (cr) y (elg) .

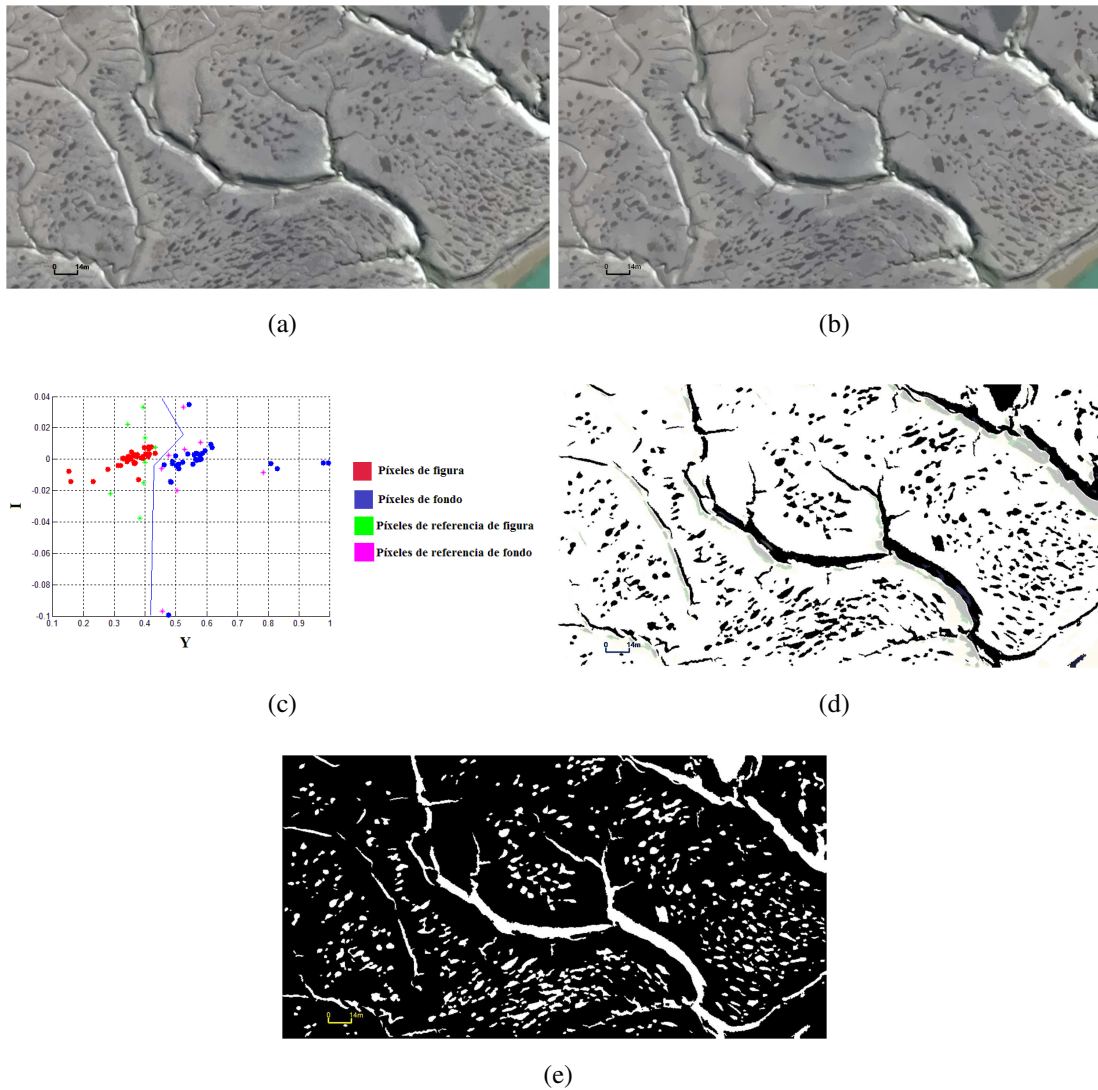


Fig. 5.2. Zona de entrenamiento 8a. (a) Imagen original. (b) Imagen pre-segmentada con el algoritmo Mean Shift. (c) YIQ clustering y píxeles prototipo de figura y fondo en color verde y magenta, respectivamente en el espacio de color Y vs. I. (d) Imagen segmentada con el algoritmo Distancias mínimas a múltiples prototipos. (e) Imagen Binaria.

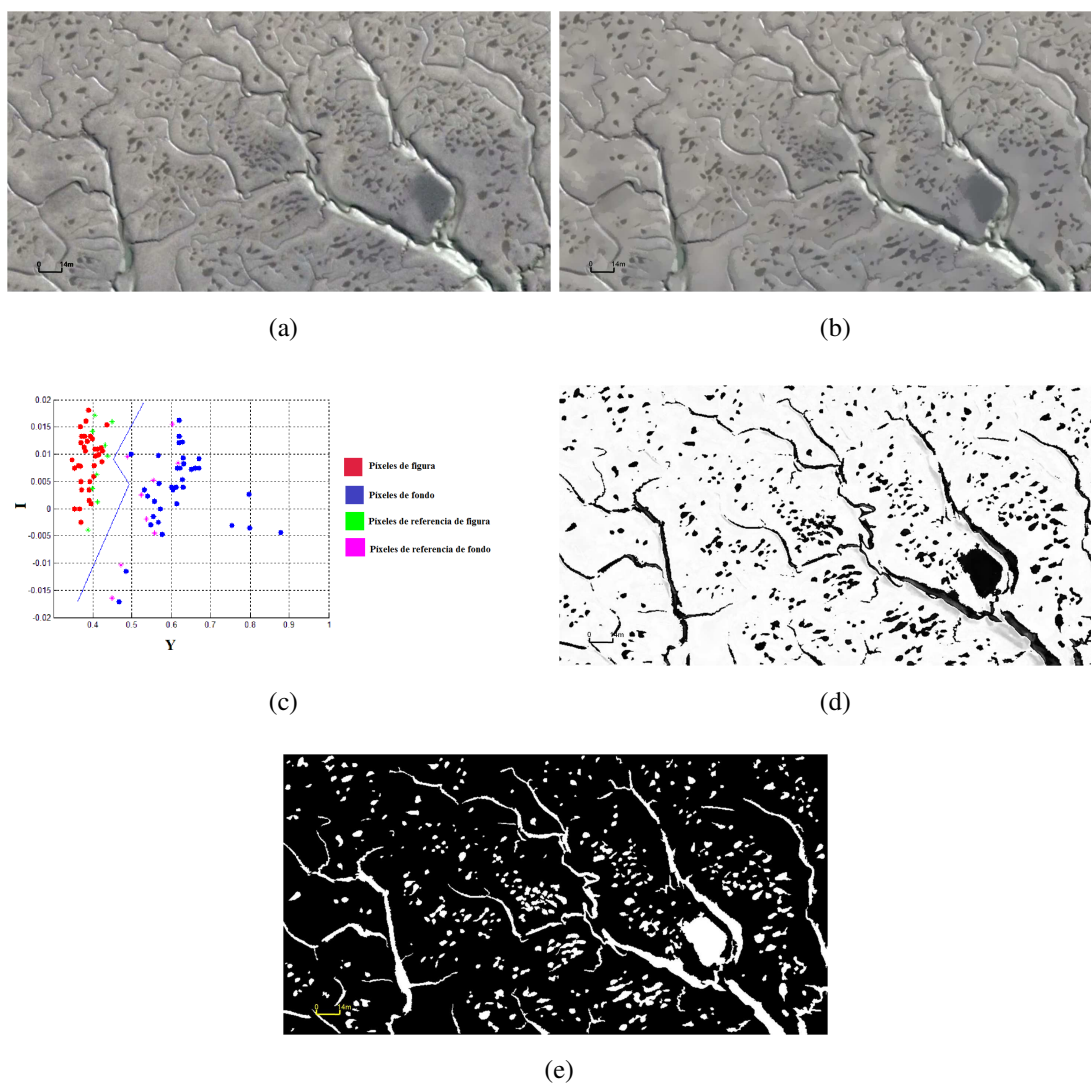


Fig. 5.3. Zona de entrenamiento 8b. (a) Imagen original. (b) Imagen pre-segmentada con el algoritmo Mean Shift. (c) YIQ clustering y píxeles prototipo de figura y fondo en color verde y magenta, respectivamente en el espacio de color Y vs. I. (d) Imagen segmentada con el algoritmo Distancias mínimas a múltiples prototipos. (e) Imagen Binaria.

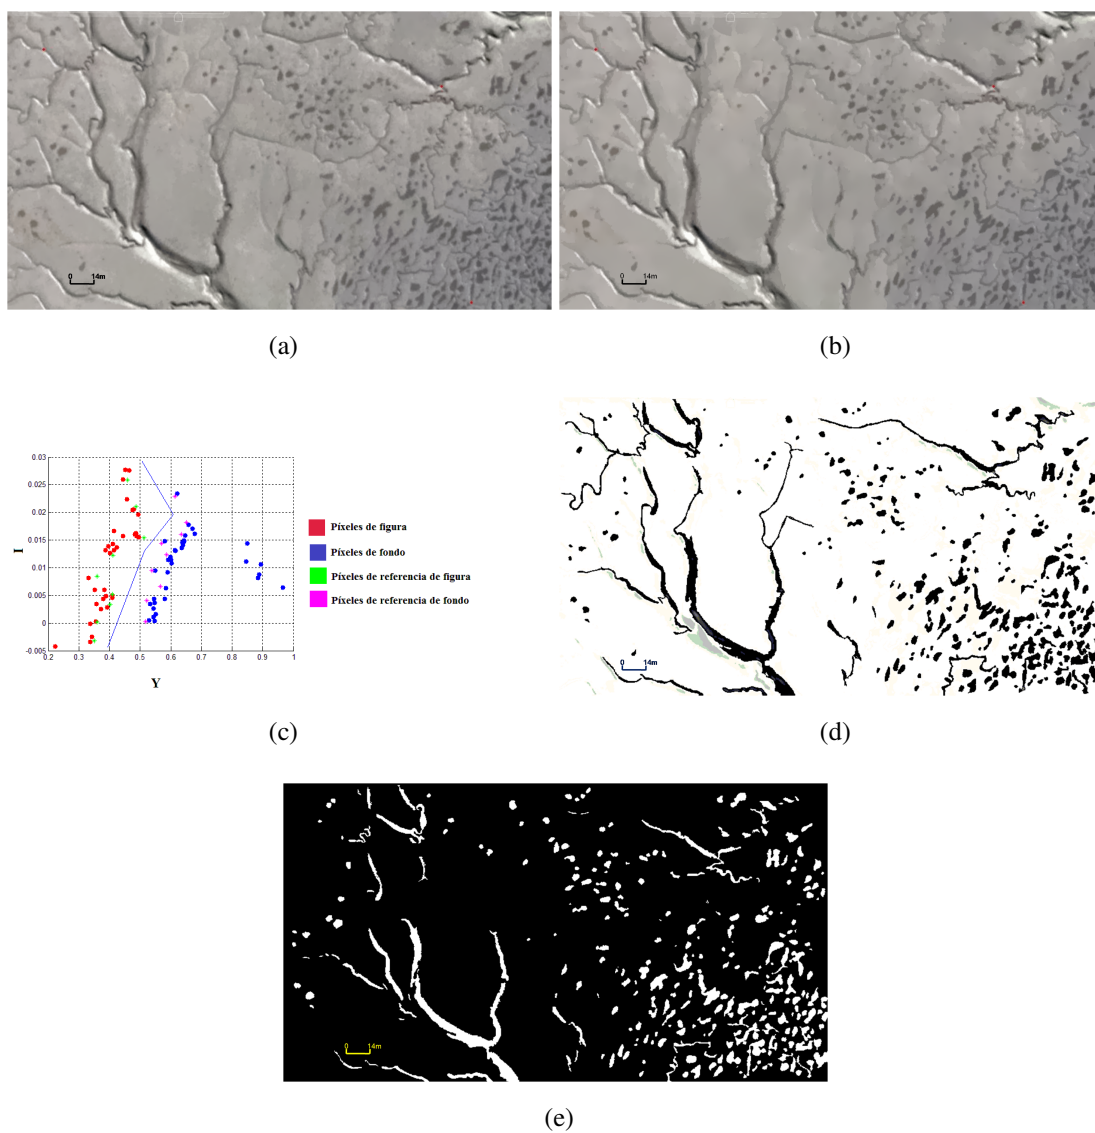


Fig. 5.4. Zona de entrenamiento 9a. (a) Imagen original. (b) Imagen pre-segmentada con el algoritmo Mean Shift. (c) YIQ clustering y píxeles prototipo de figura y fondo en color verde y magenta, respectivamente en el espacio de color Y vs. I. (d) Imagen segmentada con el algoritmo Distancias mínimas a múltiples prototipos. (e) Imagen Binaria.

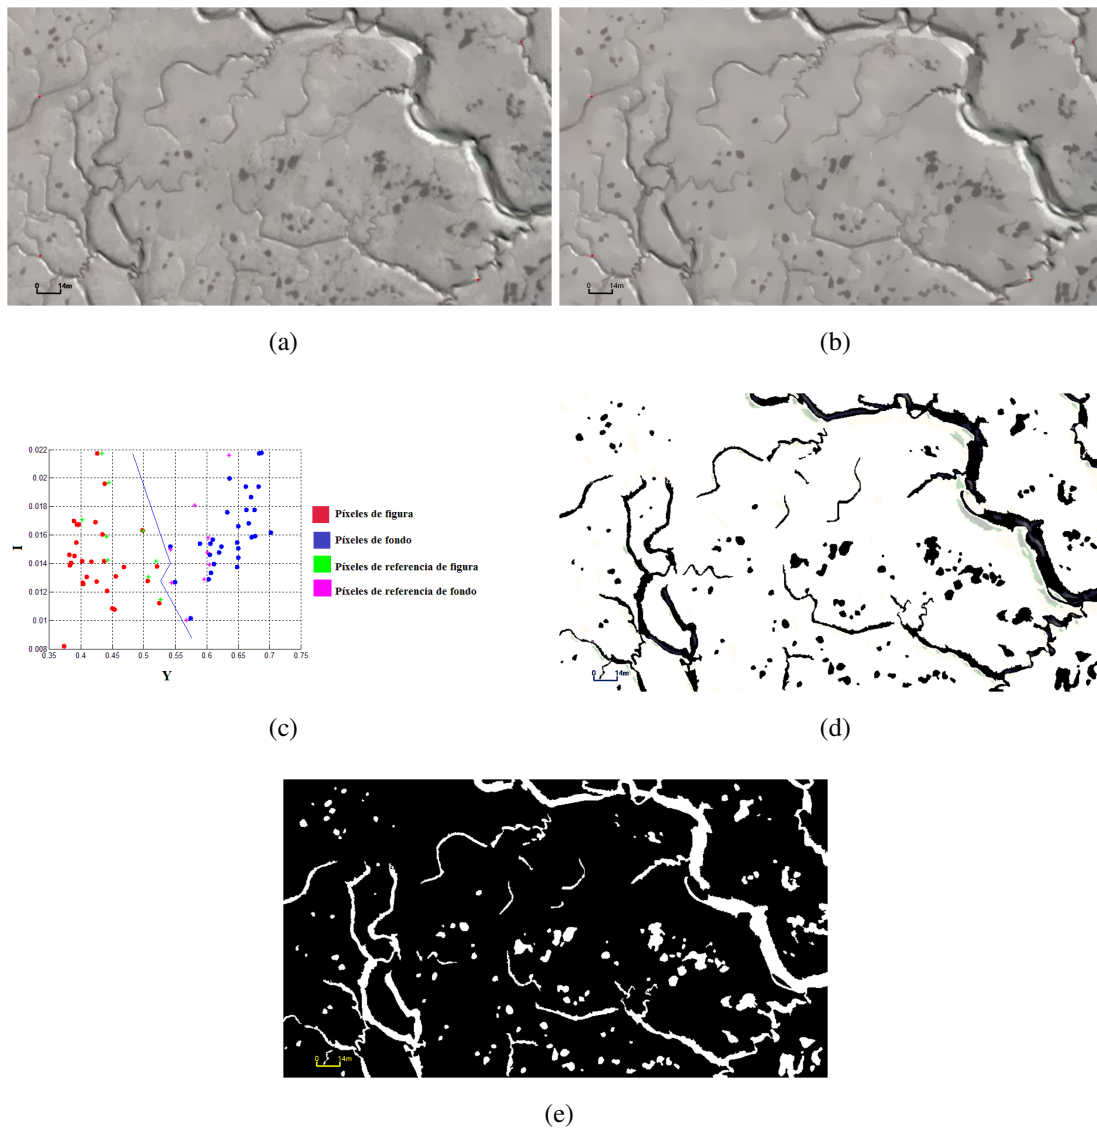


Fig. 5.5. Zona de entrenamiento 9b. (a) Imagen original. (b) Imagen pre-segmentada con el algoritmo Mean Shift. (c) YIQ clustering y píxeles prototipo de figura y fondo en color verde y magenta, respectivamente en el espacio de color Y vs. I. (d) Imagen segmentada con el algoritmo Distancias mínimas a múltiples prototipos. (e) Imagen Binaria.




Fig. 5.6. Zona de Validación 5. (a) y (b): Imágenes originales. (c) y (d): Imágenes Distancias. (e) y (f) : Imágenes binarias.




Fig. 5.7. Zona de Validación 6. (a), (b) y (c): Imágenes originales. (d), (e) y (f): Imágenes Distancias. (g), (h) y (i): Imágenes binarias.




Fig. 5.8. Zona de Validación 10. (a) y (b): Imágenes originales. (c) y (d): Imágenes Distancias . (e) y (f): Imágenes binarias.

5.3. Resultados obtenidos en las zonas de entrenamiento

En la comparación entre la clasificación supervisada vs. automática se observa que en todas las imágenes existe una correspondencia visual entre la clasificación según la apreciación del evaluador experto y la predicha por la exactitud del modelo (Fig. 5.9). Por otro lado, las precisiones globales A_g de la zona 8a y 8b son 99.4 y 96.58 %, respectivamente. Las zonas 9a y 9b tienen un valor A_g de 99.2 y 100 %, respectivamente. Estos valores son

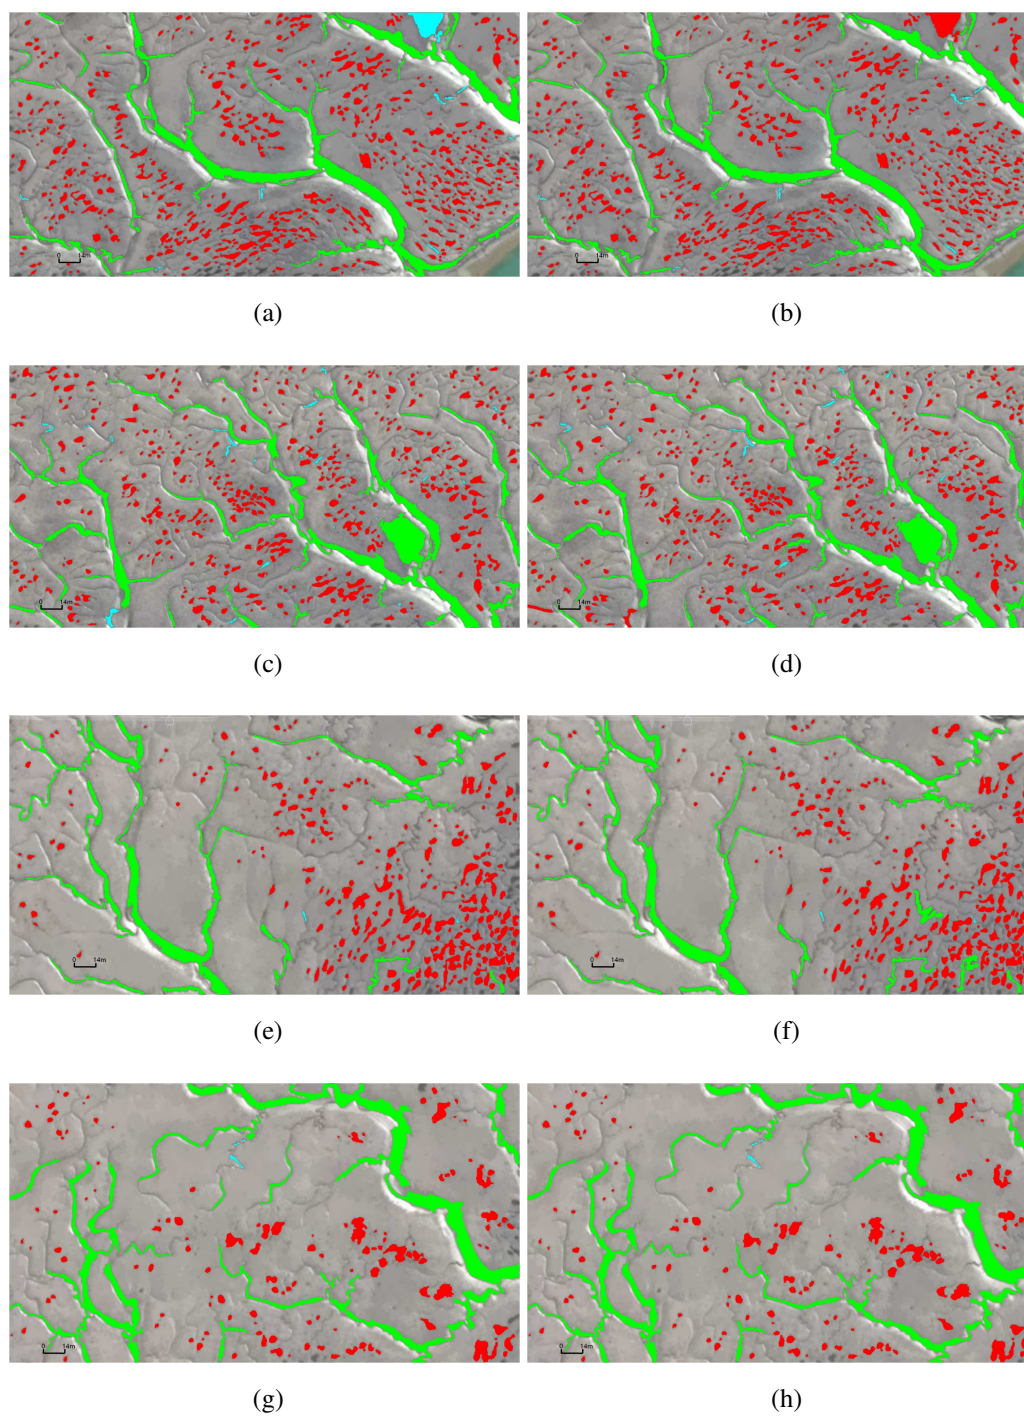


Fig. 5.9. Resultados de la clasificación en las zonas de entrenamiento. Zona 8a y b: (a) y (c): Clasificación supervisada. (b) y (d): Clasificación automática. Zona 9a y b: (e) y (g): Clasificación supervisada. (f) y (h): Clasificación automática. Las clases cuenco (*P*), cursos de marea (*C*) y estructuras espurias (*O*) se visualizan en rojo, verde y cyan, respectivamente.

superiores al 96 % y proporcionan un alto nivel de confianza en la clasificación. Además, los coeficientes κ son de 0.96 y 0.84 en la zona 8a y 8b, respectivamente. Las zonas 9 a y 9b tienen valores de κ de 0.93 y 1.00, respectivamente. Las matrices de confusión y los parámetros de precisión se detallan en la Tabla 5.1 y 5.6.

En general, los valores de precisión R_{Tp} , R_{Tc} y R_{To} en casi todos los casos son superiores a 0.83, asegurando una alta probabilidad de aciertos (Tabla 5.1 y 5.6). A excepción de $R_{To} = 0.59$ en la zona 8 donde se manifiesta un error de asimilación, algunos accidentes de la clase (O) son confundidas con la clase (P) (Fig. 5.10). Este resultado es aceptable debido a que la imagen segmentada no dispone de la información completa de algunos accidentes, especialmente los cursos de marea. Por dicha razón, estas estructuras residuales son clasificadas por el experto como espurias. Inclusive, estas últimas son de forma muy parecida al tipo de cuencos alargados. Sin embargo, la imagen de la zona 10b presenta una perfecta exactitud en la clasificación automática $A_g = 100\%$. Particularmente, a pesar del desbalanceo existente entre las clases, el resultado del índice κ presenta una alta proporción de coincidencias entre ambas clasificaciones (supervisada y automática) y, de acuerdo a Fleiss (1981), los resultados estadísticos obtenidos en las zonas de entrenamiento son calificables como óptimos.

En la Fig. 5.11, se empleó la técnica denominada *mosaic plot* (Hartigan y Kleiner, 1981; Friendly, M., 1994) para visualizar los resultados de las matrices de confusión, representando en superficie la frecuencia de los valores de cada celda. En este sentido, se observa fácilmente la relación entre la proporción de éxito y fracaso de la clasificación automática, diferenciadas en rojo y amarillo, respectivamente. En el gráfico, los valores de magnitud igual a cero se visualizan con líneas de trazos en color negro. En todos los casos se observa que la clase (P) es la predominante. Por el contrario, la presencia de estructuras espurias es escasa por lo que la convierte en la clase minoritaria. La relación entre las superficies de la clase estructuras espurias y cuencos de agua, muestra una tendencia a la confusión entre ambas.

Tabla 5.1. Desempeño de la Zona 8: (a) y (b): Matriz de confusión y Parámetros de precisión de la zona 8a. (c) y (d): Matriz de confusión y Parámetros de precisión de la zona 8b.

					Parámetro	Resultado
					$A_g[\%]$	99.4
					(R_{Tp})	0.99
Predicción					(R_{Tc})	1.00
P C O					(R_{To})	0.83
Actual	P	486	1	0	(R_{Fp})	0.99
	C	0	25	0	(R_{Fc})	0.96
	O	2	0	10	(R_{Fo})	1.00
(a)					$P_r(a)$	0.99
					$P_r(e)$	0.87
					κ	0.96
(b)						
					Parámetro	Resultado
					$A_g[\%]$	96.6
					R_{Tp}	0.99
Predicción					R_{Tc}	0.96
P C O					R_{To}	0.59
Actual	P	381	1	2	R_{Fp}	0.97
	C	1	27	0	R_{Fc}	0.96
	O	11	0	16	R_{Fo}	0.88
(c)					$P_r(a)$	0.96
					$P_r(e)$	0.78
					κ	0.84
(d)						

Tabla 5.2. Desempeño de la Zona 9: (a) y (b) : Matriz de confusión y Parámetros de precisión de la zona 9a. (c) y (d): Matriz de confusión y Parámetros de precisión de la zona 9b.

					Parámetro	Resultado
					$A_g[\%]$	99.2
					R_{Tp}	0.99
					R_{Tc}	1.00
					R_{To}	1.00
Actual	P	225	2	0	R_{Fp}	1.00
	C	0	12	0	R_{Fc}	0.86
	O	0	0	2	R_{Fo}	1.00
(a)					$P_r(a)$	0.99
					$P_r(e)$	0.88
					κ	0.93
(b)						
					Parámetro	Resultado
					$A_g[\%]$	100
					R_{Tp}	1.00
					R_{Tc}	1.00
					R_{To}	1.00
Actual	P	126	0	0	R_{Fp}	1.00
	C	0	15	0	R_{Fc}	1.00
	O	0	0	4	R_{Fo}	1.00
(c)					$P_r(a)$	1.00
					$P_r(e)$	0.77
					κ	1.00
(d)						

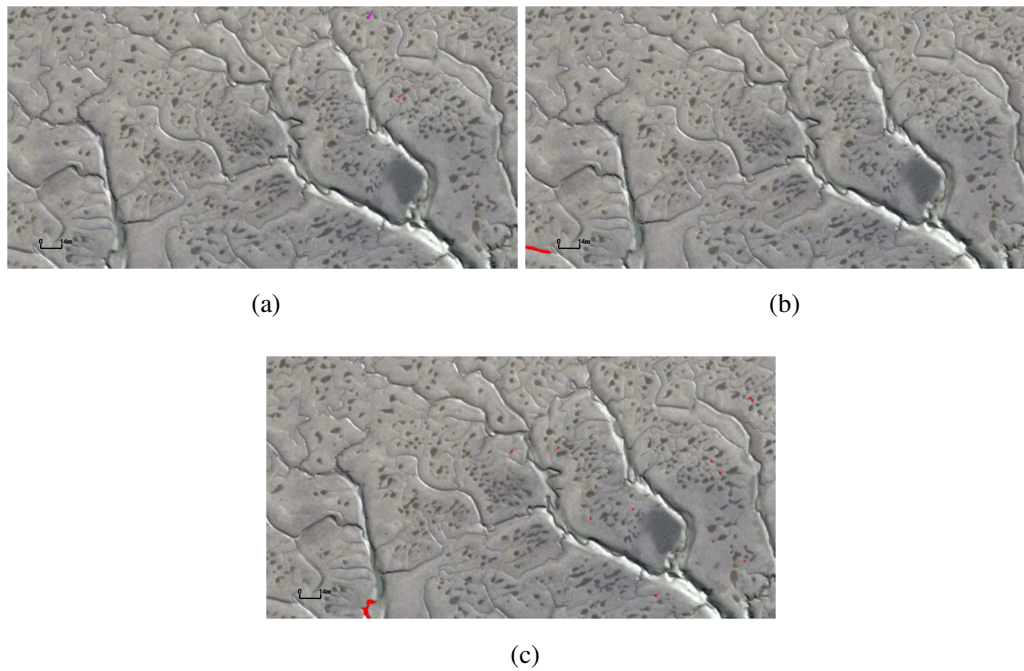


Fig. 5.10. Error de clasificación en la zona 8b. (a) Cuencos de agua clasificados como estructuras espurias. (b) Curso de marea clasificado como cuenco de agua. (c) Estructura espuria clasificada como cuenco de agua.

Este resultado es razonable debido a que la clase (O) contiene las estructuras incompletas por lo que son residuos de algunos accidentes. Por lo tanto, la información no está disponible en su totalidad y los cuencos al tener formas muy variadas tienden a confundirse entre ambas clases. Finalmente, la Fig. 5.12 muestra el error global en la precisión de la clasificación del modelo en cada zona de entrenamiento, donde el error está en el intervalo $[0, 4]$.




Fig. 5.11. Mosaic plot de las matrices de confusión. La proporción de éxitos (rojo) y fracaso (amarillo) se presentan con áreas proporcionales a la cantidad de casos, las líneas de trazos representan los valores de magnitud iguales a cero. Zonas de entrenamiento: (a) y (b): Zonas 8a y b. (c) y (d): Zonas 9a y b.




Fig. 5.12. Porcentajes de clasificación global (rojo) y su error asociado (amarillo) de las zonas de entrenamiento.

5.4. Resultados obtenidos en las zonas de validación

La validación del modelo se realiza sobre un segundo conjunto de imágenes. Particularmente, en esta sección se presentan los resultados correspondientes a las zonas 5, 6 y 10 del área de estudio. El propósito es evaluar la precisión de la clasificación del modelo en un grupo de imágenes de prueba diferentes al del entrenamiento. Cabe destacar que en el apéndice A se detallan los resultados de las restantes zonas que conforman toda el área de estudio.

Las tres zonas de validación seleccionadas en esta sección fueron elegidas por ser representativas de la diversidad de accidentes geográficos presentes en las planicies. En las figuras 5.13, 5.14 y 5.15 se muestran los resultados correspondientes a la clasificación

realizada por el experto y la provista por el modelo (automática).

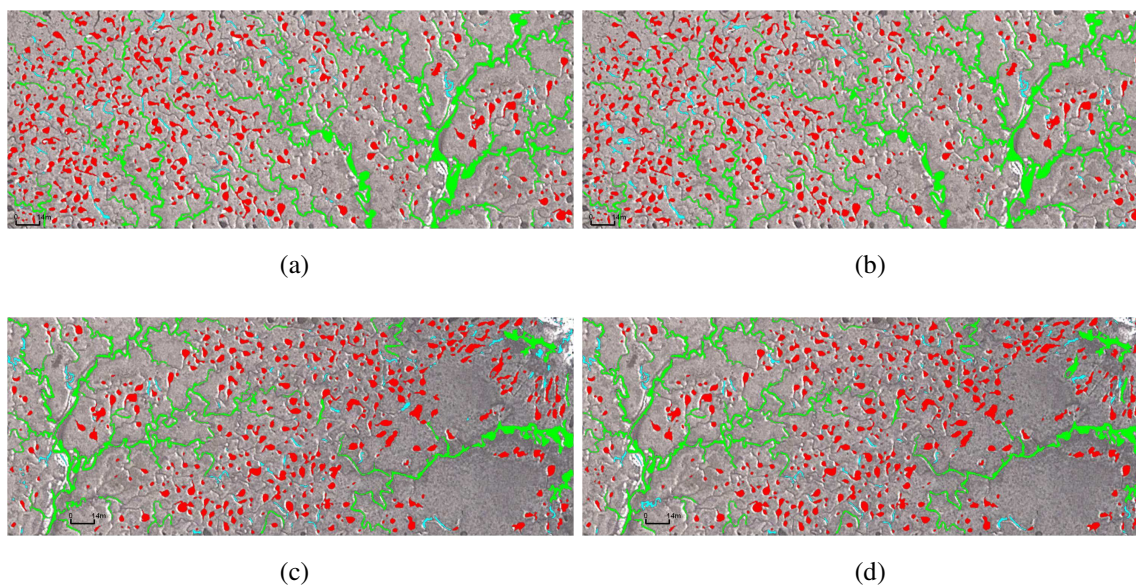


Fig. 5.13. Resultados de la clasificación en la zona de validación 5. (a) y (b): Clasificación supervisada y automática de la zona 5a. (c) y (d): Clasificación supervisada y automática de la zona 5b. Las clases Cuenco (P), Cursos de marea (C) y estructuras espurias (O) se visualizan en rojo, verde y cyan, respectivamente.

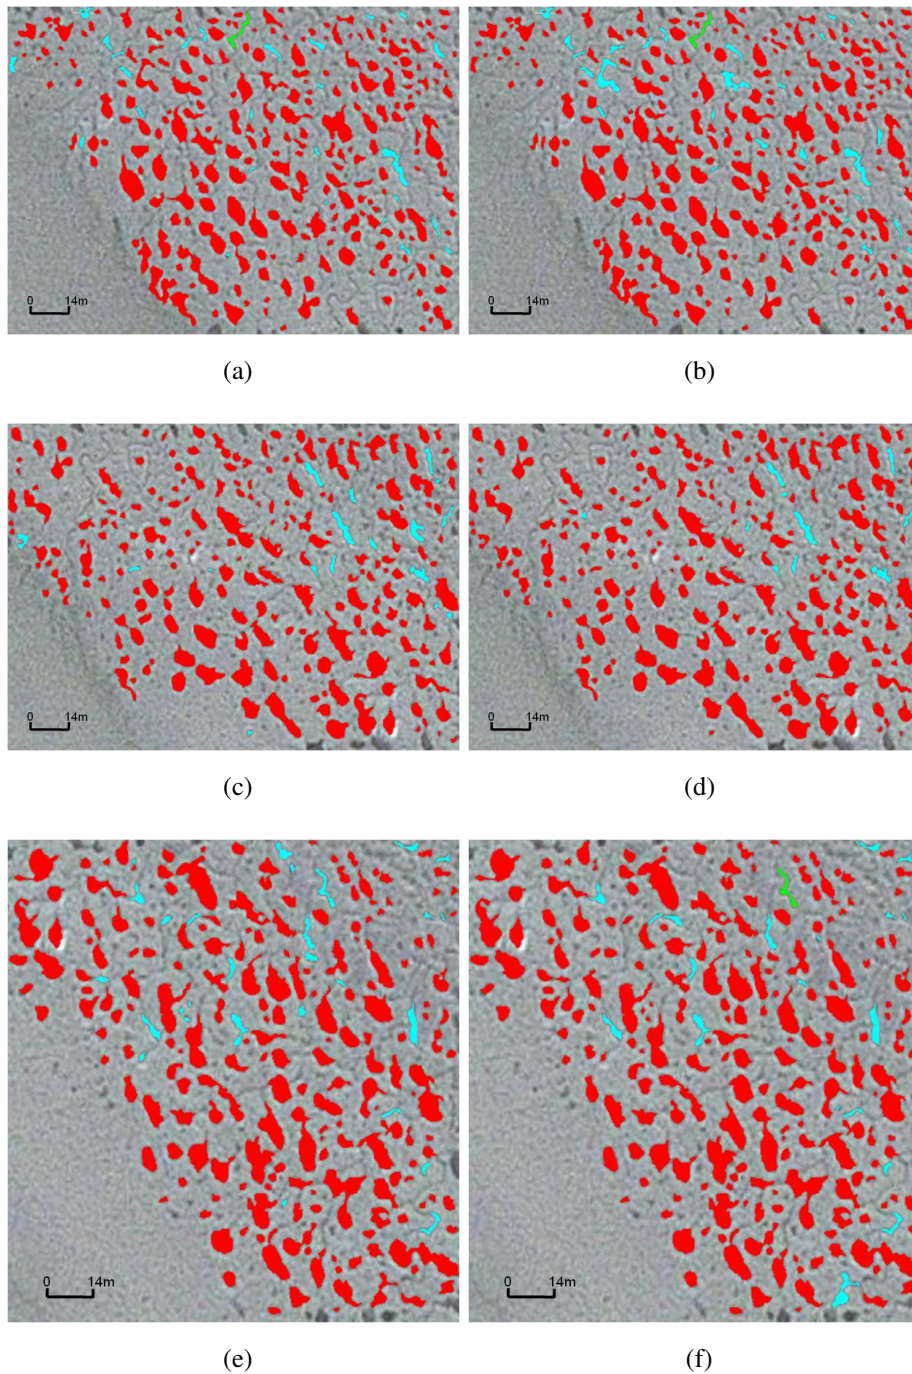


Fig. 5.14. Resultados de la clasificación en las zona de validación 6. (a) y (b): Clasificación supervisada y automática de la zona 6a. (c) y (d): Clasificación supervisada y automática de la zona 6b. (e) y (f): Clasificación supervisada y automática de la zona 6c. Las clases Cuenco (*P*), Cursos de marea (*C*) y estructuras espurias (*O*) se visualizan en rojo, verde y cyan, respectivamente.




Fig. 5.15. Resultados de la clasificación en las zona de validación 10. (a) y (b): Clasificación supervisada y automática de la zona 10a. (c) y (d): Clasificación supervisada y automática de la zona 10b. Las clases Cuenco (P), Cursos de marea (C) y estructuras espurias (O) se visualizan en rojo, verde y cyan, respectivamente.

Visualmente se observa que los resultados de la clasificación automática son muy similares a los supervisados. Por otro lado, en la Tablas 5.3, 5.4, 5.5 y 5.6 se presentan las matrices de confusión y los parámetros de precisión de cada zona.

Las precisiones globales A_g de la zona 5 (a y b) son 92 y 91 %, respectivamente. La zona 6 (a,b y c) presenta valores de A_g de 93.9, 94 y 92.2 % y, la zona 10 (a y b) valores de 96.2 y 94.2 %, respectivamente. En general, en todas las zonas, los valores de A_g son superiores al 90 %. Los coeficientes κ son de 0.77 y 0.76 en la zona 5 (a y b), de 0.7, 0.5 y 0.62 en la zona 6 (a, b y c), y de 0.90 y 0.84 en la zona 10 (a y b). Los valores de las precisiones, R_{Tp} y R_{Tc} son superiores a 0.94 en las tres zonas. En las zonas 5a, 6a y 10a el valor de R_{Tc} es igual a 1, lo que indica que no hay error de asignación en la clase (C).

Tabla 5.3. Desempeño de la Zona 5. (a) y (b): Matriz de confusión y Parámetros de precisión de la zona 5a. (c) y (d): Matriz de confusión y Parámetros de precisión de la zona 5b.

					Parámetro	Resultado
					$A_g[\%]$	92
					R_{Tp}	0.94
Predicción					R_{Tc}	1.00
P C O					R_{To}	0.77
Actual	P	473	0	31	R_{Fp}	0.97
	C	0	38	0	R_{Fc}	0.95
	O	17	2	63	R_{Fo}	0.67
(a)					$P_r(a)$	0.92
					$P_r(e)$	0.66
					κ	0.77
(b)						
					Parámetro	Resultado
					$A_g[\%]$	91
					R_{Tp}	0.97
Predicción					R_{Tc}	0.97
P C O					R_{To}	0.62
Actual	P	378	2	11	R_{Fp}	0.92
	C	0	38	1	R_{Fc}	0.93
	O	31	1	53	R_{Fo}	0.82
(c)					$P_r(a)$	0.91
					$P_r(e)$	0.63
					κ	0.76
(d)						

Tabla 5.4. Desempeño de la Zona 6. (a) y (b): Matriz de confusión y Parámetros de precisión de la zona 7a. (c) y (d) : Matriz de confusión y Parámetros de precisión de la zona 7b.

					Parámetro	Resultado
					$A_g[\%]$	93.9
					R_{Tp}	0.97
					R_{Tc}	1.00
					R_{To}	0.71
					R_{Fp}	0.97
					R_{Fc}	1.00
					R_{Fo}	0.71
(a)					$P_r(a)$	0.94
					$P_r(e)$	0.80
					κ	0.70
(b)						
					Parámetro	Resultado
					$A_g[\%]$	94
					R_{Tp}	0.99
					R_{Tc}	<i>NaN</i>
					R_{To}	0.41
					R_{Fp}	0.95
					R_{Fc}	<i>NaN</i>
					R_{Fo}	0.7
(c)					$P_r(a)$	0.94
					$P_r(e)$	0.88
					κ	0.5
(d)						

Tabla 5.5. Desempeño de la Zona 6c. (a) Matriz de confusión. (b) Parámetros de precisión.

					Parámetro	Resultado
					$A_g[\%]$	92.2
					R_{Tp}	0.98
					R_{Tc}	<i>NaN</i>
					R_{To}	0.55
					R_{Fp}	0.94
					R_{Fc}	0.00
					R_{Fo}	0.8
					$P_r(a)$	0.92
					$P_r(e)$	0.80
					κ	0.62

					(b)	
					$P_r(a)$	0.92
					$P_r(e)$	0.80
					κ	0.62

Tabla 5.6. Desempeño de la Zona 10. (a) y (b) : Matriz de confusión y Parámetros de precisión de la zona 11a. (c) y (d): Matriz de confusión y Parámetros de precisión de la zona 11b.

					Parámetro	Resultado
					$A_g[\%]$	96.2
					R_{Tp}	0.99
					R_{Tc}	1.00
					R_{To}	0.77
					R_{Fp}	0.96
					R_{Fc}	0.94
					R_{Fo}	0.97
(a)					$P_r(a)$	0.96
					$P_r(e)$	0.61
					κ	0.90
(b)						
					Parámetro	Resultado
					$A_g[\%]$	94.2
					R_{Tp}	0.98
					R_{Tc}	0.96
					R_{To}	0.74
					R_{Fp}	0.95
					R_{Fc}	0.96
					R_{Fo}	0.89
(c)					$P_r(a)$	0.94
					$P_r(e)$	0.64
					κ	0.84
(d)						

En particular, los valores de $R_{Tc} = NaN$ en las zonas 6 (b y c) representan la ausencia de accidentes correspondientes a la clase (C) que fueron identificados por el clasificador. Inclusive, el valor de $R_{Fc} = NaN$ de la zona 6b significa que no hay falsos accidentes detectados como clase (C) además de ser esta última una clase ausente en la clasificación. Por otro lado, los valores de R_{To} igual a 0.41 y 0.55 son relativamente bajos porque las estructuras espurias son similares en forma a los cuencos de agua. En la figura 5.16 se visualizan los falsos positivos (estructuras espurias clasificadas como cuencos de agua). En general, a pesar del significativo desbalanceo existente entre las clases, según la categorización de Fleiss (1981), en las zonas 6 (b y c) el resultado de las clasificaciones son buenas y óptimas en las zonas 5 y 10.




Fig. 5.16. Errores de clasificación. Estructuras espurias clasificadas como cuencos de agua. (a) Zona 6b. (b) Zona 6c.

Gráficamente se muestran los resultados de las matrices de confusión (Fig. 5.17). Estas representaciones (en superficie de frecuencias de los valores de cada celda de la matriz) facilitan la interpretación entre las asignaciones predichas y las verdaderas. En los gráficos, los valores de magnitud igual a cero se visualizan con líneas de trazos y la

carencia de valores en la clase (C) no se visualizan.

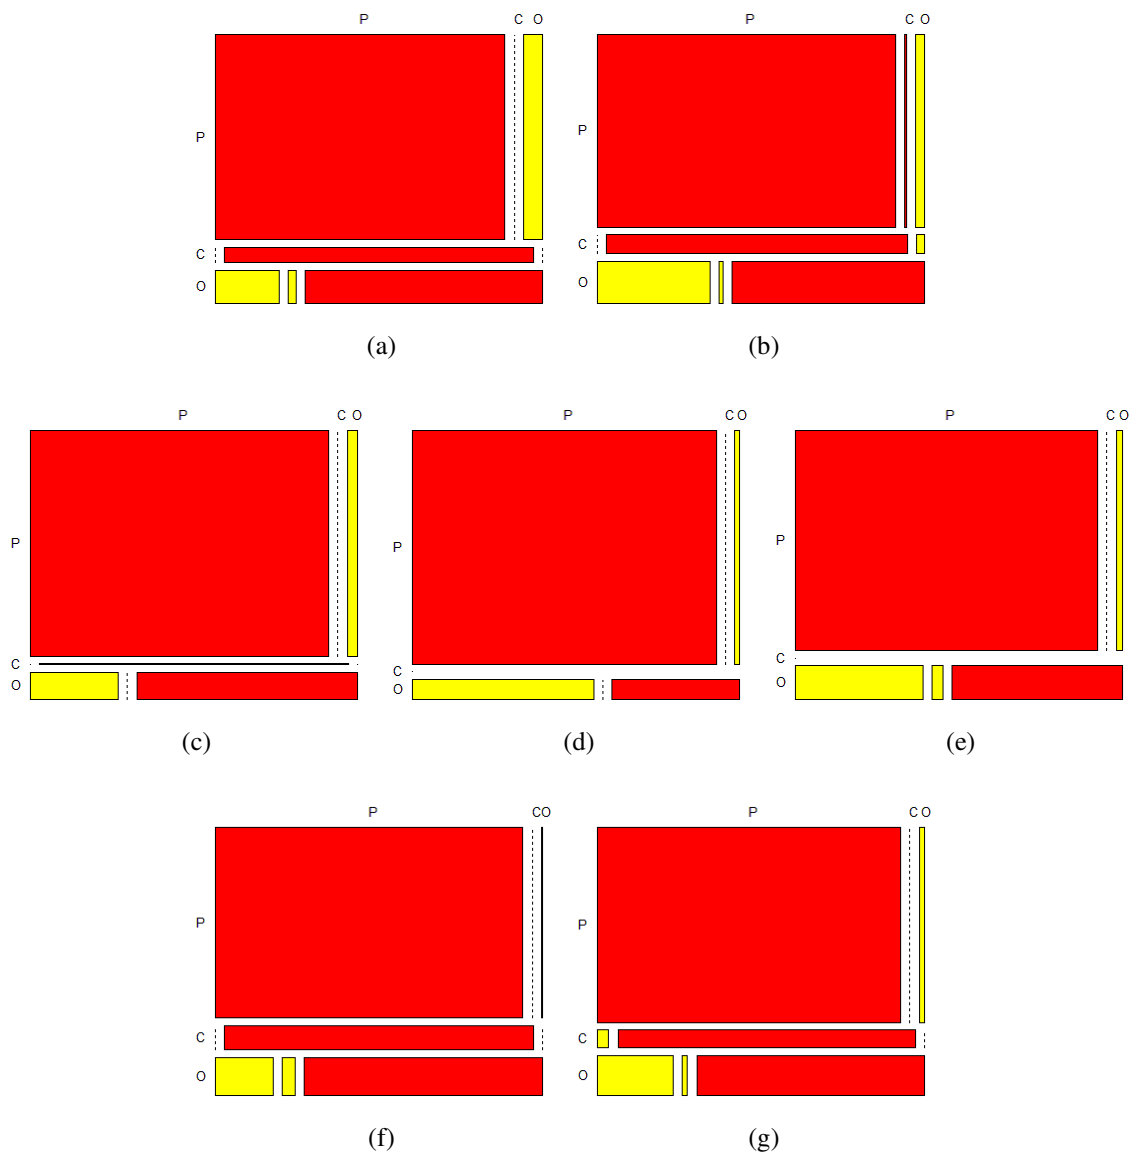



Fig. 5.17. Mosaic plot de las matrices de confusión. La proporción de éxitos (rojo) y fracaso (amarillo) se presentan con áreas proporcionales a la cantidad de casos, las líneas de trazos representan los valores de magnitud iguales a cero. Zonas de validación: (a) y (b): Zonas 5a y b. (c) , (d) y (e): Zonas 6a, b y c. (f) y (g): Zonas 10a y b.


En general, el valor A_g en estas tres zonas de validación es superior al 91 %. En la

figura 5.18a se presenta el porcentaje de error global en cada clasificación automática. En todas las zonas analizadas se observa que los cuencos de agua son los accidentes de mayor frecuencia. Por el contrario, la presencia de estructuras espurias (clase O) es escasa por lo que la convierte en la clase minoritaria.

Globalmente, el valor A_g en toda el área de validación es superior al 86 %. Particularmente, las zonas 12 y 13 presentan precisiones globales de 97 y 96 % respectivamente. En la figura (Fig. 5.18b) se observa los porcentajes de errores globales asociados a cada zona. Por otro lado, el valor del índice κ se encuentra en el intervalo $[0.7, 0.92]$, lo que significa que la concordancia entre la clasificación según la apreciación del experto y la obtenida por el modelo (automática) se considera óptima.



(a)



(b)

Fig. 5.18. Porcentajes de clasificación global (rojo) y su error asociado (amarillo) de las zonas de validación. (a) Zonas 5, 6 y 10. (b) Zonas 1, 2, 3, 4, 7, 11, 12 y 13.

5.5. Observaciones finales

Los resultados de las clasificaciones automáticas frente a las supervisadas visualmente son muy similares y cuantitativamente presentan un alto porcentaje en las precisiones globales (A_g). Los mismos son superiores al 86 % en toda el área de estudio, obteniéndose la máxima exactitud del 100 % en la zona 9b. Las precisiones obtenidas son elevadas y el error es bajo, si se considera que se trata de una clasificación realizada sobre accidentes con una alta variación geomorfológica, además del existente desbalanceo entre sus clases. En este contexto, los datos de la clasificación obtenidos en forma automática de las distintas zonas de estudio son considerados óptimos. La ventaja de disponer de esta información en forma automática hace más sencilla la tarea del experto que analiza los datos. En este sentido se minimizan los tiempos y costos que lleva recopilar toda la información si se utilizan los métodos tradicionales de estudio *in situ*.

Capítulo 6

Conclusiones

Las planicies de marea son ambientes característicos de los estuarios. Las mismas se encuentran expuestas durante la bajamar y presentan importantes cambios geomorfológicos debido a factores ambientales. En particular, el estuario de Bahía Blanca se caracteriza por la presencia de diversos accidentes geográficos, tal como los cuencos de agua y cursos de marea presentes en sus planicies. El estudio de estos accidentes requiere conocer diferentes parámetros relacionados con su morfología, variación geográfica y temporal para poder determinar los procesos dinámicos que ocurren en el humedal costero. Sin embargo, los datos no siempre están disponibles debido a la imposibilidad de un acceso directo *in situ*, lo cual introduce modificaciones en el sistema, alterando el estado natural de los mismos. Además de existir zonas inaccesibles y tener asociados elevados costos de planificación de campañas.

En este contexto, las técnicas de PDI aplicadas a imágenes de sensado remoto en las ciencias naturales conlleva a interrelacionar experiencia y conocimiento de diversas áreas, de una manera creativa y beneficiosa. Bajo este concepto, esta tesis presenta el desarrollo de una aplicación PDI para la identificación, medición, representación y reconocimiento automático de los accidentes geográficos presentes en las planicies del estuario.

Las técnicas desarrolladas para la etapa de segmentación y aplicadas en imágenes de Google Earth permitió distinguir los cuencos de agua y cursos de marea presentes en las

planicies. El algoritmo Mean Shift redujo notablemente la dispersión en la distribución de intensidades de los píxeles de la imagen, posibilitando así, un mejor resultado en la segmentación obtenida al implementar el algoritmo de distancias mínimas a múltiples prototipos. Este algoritmo generó una imagen distancia que posee mayor contraste entre las zonas de figura y fondo. Sin embargo, debido a la complejidad que fueron presentando algunas zonas y la modalidad de las imágenes, la segmentación obtenida introdujo zonas espurias.

En la etapa subsiguiente, la aproximación y medición de contornos de los accidentes geográficos realizada mediante el algoritmo TCC posibilitó el cálculo de distintos descriptores morfológicos. A partir del conjunto de datos obtenidos, se procedió al entrenamiento de un clasificador supervisado para discriminar los accidentes geográficos de nuestro interés. Esta tarea requirió la intervención de expertos humanos para proveer la clasificación a priori de dichos accidentes. Con el nuevo conjunto de datos obtenido se llevó a cabo el diseño de un modelo estadístico que es capaz de clasificar automáticamente en forma masiva los accidentes en grandes volúmenes de imágenes.

Finalmente, para evaluar la exactitud del clasificador se aplicó el modelo en toda el área de estudio. A partir de los resultados obtenidos, se realizó una evaluación cualitativa y cuantitativa. La primera se llevó a cabo basada en el conocimiento de un experto y la cuantitativa mediante la matriz de confusión, el cálculo de parámetros de precisión y el índice κ . Este último es una medida de consenso que evalúa la variabilidad entre los resultados de las clasificaciones, tanto supervisadas como automáticas, sin tener en cuenta el desbalanceo de clases.

Los resultados obtenidos tienen una alta precisión en la clasificación automática de toda el área de estudio. Estos porcentajes están en el intervalo [86, 100] y dada la alta variabilidad de los accidentes bajo estudio, la aplicación PDI desarrollada cumple el objetivo planteado en esta tesis. El principal aporte de este trabajo es el avance importante en el estudio cualitativo y cuantitativo de estos accidentes geográficos presentes en las planicies. En tanto, la intervención humana puede centrarse en la interpretación de los

datos obtenidos, reduciendo costos y tiempos. Además la metodología puede ser aplicada en otra modalidad de imágenes de sensado remoto, inclusive, con imágenes multi e hiper-espectrales se alcanzaría una mayor precisión en los resultados.

Como trabajo futuro, los resultados obtenidos proporcionan varias líneas de investigación: El estudio del comportamiento y evolución de cada accidente geográfico en su propio ambiente. Inclusive se pueden implementar métodos de análisis fractal de las zonas segmentadas para caracterizarlas morfológicamente. Además de mejorar la performance del clasificador implementando técnicas de validación de *cross-fold*. Por otro lado, se puede aplicar en forma masiva la arquitectura PDI desarrollada para segmentar todos los cuencos y cursos de marea del estuario. Resumiendo las acciones nombradas anteriormente, se espera generar un modelo predictivo para la toma de decisiones.

Bibliografía

- Agresti, A. (1996). *An Introduction to Categorical Data Analysis*. Wiley-Interscience, New Jersey, 2nd edition.
- Almeida-Prieto, S., Blanco-Méndez, J., y Otero-Espinar, F. J. (2007). Microscopic image analysis techniques for the morphological characterization of pharmaceutical particles: Influence of the software, and the factor algorithms used in the shape factor estimation. *European Journal of Pharmaceutics and Biopharmaceutics*, 67(3):766–776.
- Aplin, P., Atkinson, P. M. y Curran, P. (1999). Per-field classification of land use using the forthcoming very fine spatial resolution satellite sensors: problems and potential solutions. *Advances in remote sensing and GIS analysis*, pages 219–239.
- Bao, P., Zhang, D., y Wu, X. (2005). Canny edge detection enhancement by scale multiplication. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 27(9):1485–1490.
- Bedoya, J., Branch, J., y Restrepo, A. (2002). Image analysis to characterize tsp in medellín. In *95th Annual Conference and Exhibition The Air & Waste Management Association's 2002 Annual Conference & Exhibition Proceedings, Baltimore, Maryland, USA*.
- Blum, H. et al. (1967). A transformation for extracting new descriptors of shape. *Models for the perception of speech and visual form*, 19(5):362–380.

- Boston, K. G. (1983). The Development of Salt Pans on Tidal Marshes, with Particular Reference to South-Eastern Australia. *Journal of Biogeography*, 10(1):1–10.
- Bovik, A. C. (2009). *The essential guide to image processing*. Academic Press.
- Bow, S. T. (2002). *Pattern recognition and image preprocessing*. CRC Press.
- Campbell, J. (2002). *Introduction to Remote Sensing*. The Guilford Press, New York, second edition.
- Chapman, V. J. V. J. (1960). *Salt marshes and salt deserts of the world / by V. J. Chapman*. London : L. Hill ; New York : Interscience Publishers.
- Chen, C. y Fu, H. (1986). A comparison of decisión rules for seismic recognition. In *Eighth International Conference on Pattern Recognition, Paris, France, October 27-31, 1986: proceedings*, page 386. IEEE Computer Society Press.
- Chen, G. Y., Chen, Y. C., Lin, C. F., Hu, A. C., Wu, C. C., y Chen, Y. C. (2008). Template-based automatic segmentation of drosophila mushroom bodies. *Journal of Information Science and Engineering*, 24(1):99–113.
- Chen, H. y Meer, P. (2005). Robust fusion of uncertain information. *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on*, 35(3):578–586.
- Chen, Q., Luo, J., Heng, P. y Dshen, X. (2007). Fast and Active Texture Segmentation Based on Orientation and Local Variance. *Journal of Visual Communication and Image Representation*, 18(2):119 – 129.
- Cheng, Y. (1995). Mean shift, mode seeking, and clustering. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 17(8):790–799.
- Chung, K. L., Yang, W. J., y Yan, W. M. (2008). Efficient edge-preserving algorithm for color contrast enhancement with application to color image segmentation. *Journal of Visual Communication and Image Representation*, 19(5):299–310.

- Chuvieco, S. (2008). Teledetección ambiental: La observación de la tierra desde el espacio. ed. *Ariel. Barcelona*.
- Cipolletti, M. P., Delrieux, C. A., Perillo, G. M. E. y Piccolo, M. C. (2012). Superresolution Border Segmentation and Measurement in Remote Sensing Images. *Computers & Geosciences*, 40(0):87–96.
- Cohen, J. (1960). A Coefficient of Agreement for Nominal Scales. *Educational and Psychological Measurement*, 20(1):37–46.
- Comaniciu, D. (2003). An algorithm for data-driven bandwidth selection. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 25(2):281–288.
- Comaniciu, D. y Meer, P. (2002). Mean shift: A robust approach toward feature space analysis. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 24(5):603–619.
- Comaniciu, D., Ramesh, V., y Meer, P. (2003). Kernel-based object tracking. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 25(5):564–577.
- Congalton, R. G. y Green, K. (2008). *Assessing the accuracy of remotely sensed data: principles and practices*. CRC press, Boca Raton.
- da Fontoura Costa, L. y Cesar Jr, R. M. (2000). *Shape analysis and classification: theory and practice*. CRC press.
- Debeir, O., Van Ham, P., Kiss, R. y Decaestecker, C. (2005). Tracking of migrating cells under phase-contrast video microscopy with combined mean-shift processes. *Medical Imaging, IEEE Transactions on*, 24(6):697–711.
- Duda, R. O., Hart, P. E. y Stork, D. G. (2001). Pattern classification. *A Wiley-Interscience*, pages 373–378.

- Dunkelberger, K. y Mitchell, O. (1985). Contour Tracing for Precision Measurement. In *Proceedings of the International Conference on Robotics and Automation*, volume 2, pages 22–27, West Lafayette, Indiana. IEEE.
- Duran, B. S. y Odell, P. L. (1974). Cluster analysis: A Surevey. *Lectures Notes in Economics and Mathematical Systems*, 100.
- Estrada, F. J. y Jepson, A. D. (2009). Benchmarking image segmentation algorithms. *International Journal of Computer Vision*, 85(2):167–181.
- Everitt, BS, Landau, S y Leese, M (2001). Cluster analysis. 2001. *Arnold, London*.
- Feret, L. R. (1931).
- Fisher, W. D. (1958). On Grouping for Maximum Homogeneity. *Journal of the American Statistical Association*, 53(284):789–798.
- Fleiss, J. L. (1981). *Statistical methods for rates and proportions*. Wiley & Sons, New York, 2nd edition.
- Foody, G. M. (1996). Approaches for the production and evaluation of fuzzy land cover classifications from remotely-sensed data. *International Journal of Remote Sensing*, 17(7):1317–1340.
- Foody, G. M. (2002). Status of land cover classification accuracy assessment. *Remote sensing of environment*, 80(1):185–201.
- Franklin, S., Peddle, D., Dechka, J. y Stenhouse, G. (2002). Evidential reasoning with Landsat TM, DEM and GIS data for landcover classification in support of grizzly bear habitat mapping. *International Journal of Remote Sensing*, 23(21):4633–4652.
- Freeman, H. (1961). On the Encoding of Arbitrary Geometric Configurations. *IEEE Transactions on Electronic Computers*, 10(2):260–268.

- Freeman, H. (1970). Boundary Encoding and Processing. In *Picture Processing and Psychopictorics*, (Eds. by B. S. Lipkin and A. Rosenfeld), pages 241–263, New York. Symposium on Psychopictorics held at Arlington.
- Frey, R. (1985). Coastal and salt marshes. *Coastal Sedimentary Environments*, pages 187–224.
- Friedman, H. y Rubin, J. (1967). On some invariant criteria for grouping data. *Journal of the American Statistical Association*, 62(320):1159–1178.
- Friendly, M. (1994). Mosaic displays for multi-way contingency tables. *Journal of the American Statistical Association*, 89(425):190–200.
- Fukunaga, K. y Hostetler, L. (1975). The estimation of the gradient of a density function, with applications in pattern recognition. *Information Theory, IEEE Transactions on*, 21(1):32–40.
- Gallego, F. J. (2004). Remote sensing and land cover area estimation. *International Journal of Remote Sensing*, 25(15):3019–3047.
- Gan, G., Ma, C. y Wu, J. (2007). *Data Clustering: Theory, Algorithms, and Applications*. Society for Industrial and Applied Mathematics.
- Garcia Ugarriza, L., Saber, E., Vantaram, S. R., Amuso, V., Shaw, M. y Bhaskar, R. (2009). Automatic image segmentation by dynamic region growth and multiresolution merging. *Image Processing, IEEE Transactions on*, 18(10):2275–2288.
- Girard, C. M. y Girard, M. C. (1999). *Processing of Remote Sensing Data*. Dunod, Paris.
- Gong, P. y Howarth, P. (1992). Frequency-based contextual classification and gray-level vector reduction for land-use identification. *Photogrammetric Engineering and Remote Sensing*, 58(4):423–437.

- González, R. y Woods, R. (1996). *Digital Image Processing*. Addison-Wesley, Wilmington, DE.
- Gordon, A. (1999). Classification. 1999. *Chapman & Hall, CRC, Boca Raton, FL*.
- Goudie, A. (2013). Characterising the distribution and morphology of creeks and pans on salt marshes in England and Wales using Google Earth. *Estuarine, Coastal and Shelf Science*, 129:112–123.
- Hansen, P. y Jaumard, B. (1997). Cluster analysis and mathematical programming. *Mathematical programming*, 79(1–3):191–215.
- Haralick, R. M. y Kelly, G. L. (1969). Pattern recognition with measurement space and spatial clustering for multiple images. *Proceedings of the IEEE*, 57(4):654–665.
- Hartigan, J. A. (1975). Clustering algorithms. *John Willey & Sons*.
- Hartigan, J.A. y Kleiner, B. (1981). Mosaics for Contingency Tables. In Eddy, William F., editor, *Computer Science and Statistics: Proceedings of the 13th Symposium on the Interface*, pages 268–273. Springer US.
- Hosmer, D. W. y Lemeshow, S. (2000). *Applied Logistic Regression*. Wiley & Sons, Inc., New Jersey, second edition.
- Hoy, D. E. (1997). On the use of color imaging in experimental applications. *Experimental Techniques*, 21(4):17–19.
- Hu, M. K. (1962). Visual pattern recognition by moment invariants. *Information Theory, IRE Transactions on*, 8(2):179–187.
- Imre, A. R. (2009). Fractal dimension of time-indexed paths. *Applied Mathematics and Computation*, 20(1):90–94.
- Jain, A., Murty, M. y Flynn, P. (1999). Data Clustering: a Review. *ACM Computing Surveys*, 31(3):264–323.

- Jain, A. K. y Dubes, R. C. (1988). *Algorithms for clustering data*. Prentice-Hall, Inc.
- Jensen, J. R. (2000). *Introductory Digital Image Processing. A Remote Sensing Perspective*. Prentice-Hall Inc., Upper Saddle River, N.J., second edition.
- Kerautret, B. y Lachaud, J. O. (2009). Curvature estimation along noisy digital contours by approximate global optimization. *Pattern Recognition*, 42(10):2265–2278.
- Kesel, R. H. y Smith, J. S. (1978). Tidal creek and pan formation in intertidal salt marshes, Nigg Bay, Scotland. *Scottish Geographical Magazine*, 94(3):159–168.
- Kim, H.-K. y Kim, J.-D. (2000). Region-based shape descriptor invariant to rotation, scale and translation. *Signal Processing: Image Communication*, 16(1):87–93.
- Kim, K. I., Jung, K. y Kim, J. H. (2003). Texture-based approach for text detection in images using support vector machines and continuously adaptive mean shift algorithm. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 25(12):1631–1639.
- Kohavi, R. (1995). The power of decision tables. In *Machine Learning: ECML-95*, pages 174–189. Springer.
- Kontoes, C., Wilkinson, G., Burrill, A., Goffredo, S. y Megier, J. (1993). An experimental system for the integration of GIS data in knowledge-based image analysis for remote sensing of agriculture. *International Journal of Geographical Information Systems*, 7(3):247–262.
- Krinidis, M. y Pitas, I. (2009). Color texture segmentation based on the modal energy of deformable surfaces. *Image Processing, IEEE Transactions on*, 18(7):1613–1622.
- Landgrebe, D. A. (2005). *Signal theory methods in multispectral remote sensing*. John Wiley & Sons.
- Lillesand, T., Kiefer, R. y Chipman, J. (2004). *Remote Sensing and Image Interpretation*. Wiley & Sons, New York, fifth edition.

- Littmann, E. y Ritter, H. (1997). Adaptive color segmentation—a comparison of neural and statistical methods. *Neural Networks, IEEE Transactions on*, 8(1):175–185.
- Liu, H., Latecki, L. J. y Liu, W. (2008). A unified curvature definition for regular, polygonal, and digital planar curves. *International Journal of Computer Vision*, 80(1):104–124.
- Loncaric, S. (1998). A survey of shape analysis techniques. *Pattern recognition*, 31(8):983–1001.
- Lunetta, R. S. y Lyon, J. G. (2004). *Remote sensing and GIS accuracy assessment*. CRC press, Boca Raton.
- Maitra, M. y Chatterjee, A. (2008). A hybrid cooperative–comprehensive learning based PSO algorithm for image segmentation using multilevel thresholding. *Expert Systems with Applications*, 34(2):1341–1350.
- Maitre, M. y Do, M.Ñ. (2010). Depth and depth–color coding using shape-adaptive wavelets. *Journal of Visual Communication and Image Representation*, 21(5):513–522.
- Manay, S., Cremers, D., Hong, B. W., Yezzi, A. J. y Soatto, S. (2006). Integral invariants for shape matching. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 28(10):1602–1618.
- Mather, P. y Tso, B. (2003). *Classification methods for remotely sensed data*. CRC press.
- Melo, W., Perillo, G., Perillo, M., Schilizzi, R. y Piccolo, M. (2013). Late pleistocene–holocene deltas in the southern buenos aires province, argentina. In *Deltas: Landforms, Ecosystems and Human Activities*. IAHS, pages 187–195. Young Perillo Publishers.
- Neal, F. y Russ, J. (2012). *Measuring Shape*. CRC Press, N.W.
- Packham, J. R. y Liddle, M. J. (1970). The Cefni salt marsh, Anglesey, and its recent development. *Field studies*, 3:331–356.

- Pal, M. y Mather, P. M. (2003). An assessment of the effectiveness of decision tree methods for land cover classification. *Remote sensing of environment*, 86(4):554–565.
- Peng, N. S., Yang, J. y Liu, Z. (2005). Mean shift blob tracking with kernel histogram filtering and hypothesis testing. *Pattern Recognition Letters*, 26(5):605–614.
- Perillo, G.M.E. (1995). *Geomorphology and sedimentology of estuaries. Developments in Sedimentology*, volume 53. Access Online via Elsevier, Amsterdam.
- Perillo, G. M., Ripley, M., Piccolo, M. C. y Dyer, K. (1996a). The Formation of Tidal Creeks in a Salt Marsh: New Evidence from the Loyola Bay Salt Marsh, Rio Gallegos Estuary, Argentina. *Mangroves and Salt Marshes*, 1(1):37–46.
- Perillo, G. M. E., García Martínez, M. y Piccolo, M. C. (1996b). Geomorfología de canales de marea: análisis de fractales y espectral. *Actas VI Reunión Argentina de Sedimentología*, pages 155–160.
- Perillo, G. M. E., Piccolo, M. C., Parodi, E. y Freije, R. H. (2001). The Bahia Blanca Estuary, Argentina. In Seeliger, U. and Kjerfve, B., editors, *Coastal Marine Ecosystems of Latin America*, volume 144, pages 205–217. Springer Berlin Heidelberg.
- Perillo, G. M. E. e Iribarne, O. O. (2003). New mechanisms studied for creek formation in tidal flats: From crabs to tidal channels. *Eos, Transactions American Geophysical Union*, 84(1):1–5.
- Perillo, G., Wolanski, E., Cahoon, D. y Brison, M. (2009). *Coastal Wetlands, An Integrated Ecosystem Approach*. Elsevier Science, Netherlands.
- Pestrong, R. (1965). The development of drainage patterns on tidal marshes. *Stanford University publications*, 10(2).
- Pethick, J. S. (1974). The Distribution of Salt Pans on Tidal Salt Marshes. *Journal of Biogeography*, 1(1):57–62.

- Pietikainen, M., Nieminen, S., Marszalec, E. y Ojala, T. (1996). Accurate color discrimination with classification based on feature distributions. In *Pattern Recognition, International Conference on*, volume 3, pages 833–833. IEEE Computer Society.
- Pratt, W. K. (1991). *Digital Image Processing*. Wiley-Interscience, New York.
- Raup, B., Kääh, A., Kargel, J., Bishop, M., Hamilton, G., Lee, E., Paul, F., Rau, F., Soltesz, D., Khalsa, S., Beedle, M. y Helm, C. (2007). Remote sensing and GIS technology in the Global Land Ice Measurements from Space (GLIMS) Project. *Computers & Geosciences*, 33(1):104 – 125.
- Richards, J. A. y Jia, X. (2006). *Remote Sensing Digital Image Analysis: An Introduction*. Springer, Berlin.
- Robinson, G. S. (1977). Color edge detection. *Optical Engineering*, 16(5):165479–165479.
- Russ, J. C. (1993). *Fractal Images*. Plenum Press.
- Russ, J. C. (1999). *The Image Processing Handbook*. CRC Press, Boca Raton, FL, third edition.
- Russ, J. C. (2010). *The image processing handbook*. CRC press.
- Saha, S. y Bandyopadhyay, S. (2010). Application of a Multiseed-Based Clustering Technique for Automatic Satellite Image Segmentation. *IEEE Geoscience and Remote Sensing Letters*, 7(2):306–308.
- San Miguel-Ayanz, J. y Biging, G. (1997). Comparison of single-stage and multi-stage classification approaches for cover type mapping with TM and SPOT data. *Remote Sensing of Environment*, 59(1):92–104.
- Schwarz, H. (1980). Two dimensional feature shape indexes. *Mikroskopie*, 37:64–67.

- Shi, J. y Malik, J. (2000). Normalized cuts and image segmentation. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 22(8):888–905.
- Sridhar, P.Ñ., Surendran, A. y Ramana, I. V. (2008). Auto-extraction technique-based digital classification of saltpans and aquaculture plots using satellite data. *International Journal of Remote Sensing*, 29(2):313–323.
- Steers, J. A. (1964). *The coastline of England and Wales*. Cambridge Univ. Press, Reidel, Dordrecht.
- Stuckens, J., Coppin, P. y Bauer, M. (2000). Integrating contextual information with per-pixel classification for improved land cover classification. *Remote Sensing of Environment*, 71(3):282–296.
- Teh, C.-H. y Chin, R. T. (1989). On the detection of dominant points on digital curves. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 11(8):859–872.
- Tou, J. y Gonzalez, R. (1974). Pattern recognition principles. *Addison-Wesley, Reading Massachusetts*, 10(123):250–361.
- Unnikrishnan, R., Pantofaru, C. y Hebert, M. (2007). Toward objective evaluation of image segmentation algorithms. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 29(6):929–944.
- Wadell, H. (1933). Sphericity and roundness of rock particles. *The Journal of Geology*, pages 310–331.
- Wang, X. Y. y Sun, Y. (2010). A color and texture based image segmentation algorithm. *Machine Graphics and Vision*, 19(1):3–18.
- Wojnar, L. y Kurzydłowski, K. (2000). Practical guide to image analysis. *ASM International*, 157–160.

- Xu, R. y Wunsch, D. C. (2010). Clustering algorithms in biomedical research: a review. *Biomedical Engineering, IEEE Reviews in*, 3:120–154.
- Xu, R. y Wunsch II, D. C. (2011). BARTMAP: A viable structure for biclustering. *Neural Networks*, 24(7):709–716.
- Yang, L., Albregtsen, F., Lønnestad, T. y Grøttum, P. (1994). Methods To Estimate Areas And Perimeters Of Blob-Like Objects: A Comparison. In *In Proc. IAPR Workshop on Machine Vision Applications*, pages 272–276, Kawasaki. MVA.
- Yang, M. S. (1993). A Survey of Fuzzy Clustering. *Mathematical and Computer Modelling*, 18(11):1–16.
- Yang, X. y Liu, J. (2001). Unsupervised texture segmentation with one-step mean shift and boundary markov random fields. *Pattern Recognition Letters*, 22(10):1073–1081.
- Yapp, R. H., Johns, D. y Jones, O. T. (1916). The Salt Marshes of the Dovey Estuary. *Journal of Ecology*, 4(1):27–42.
- Yapp, R. H., Johns, D. y Jones, O. T. (1917). The Salt Marshes of the Dovey Estuary. *Journal of Ecology*, 5(2):65–103.
- Yatabe, S. y Fabbri, A. (1986). The application of remote sensing to canadian petroleum exploration: promising and yet unexploited. *Computers & Geosciences*, 12(4):597 – 609.
- Yuksel, M. y Borlu, M. (2009). Accurate segmentation of dermoscopic images by image thresholding based on type-2 fuzzy logic. *Fuzzy Systems, IEEE Transactions on*, 17(4):976–982.
- Zeng, X. Y., Chen, Y. W., Nakao, Z. y Lu, H. (2004). Texture representation based on pattern map. *Signal Processing*, 84(3):589–599.

Zhang, D. y Lu, G. (2003). A comparative study of curvature scale space and fourier descriptors for shape-based image retrieval. *Journal of Visual Communication and Image Representatio*, 14(1):39–57.

Zhang, T. y Suen, C. Y. (1984). A fast parallel algorithm for thinning digital patterns. *Communications of the ACM*, 27(3):236–239.

Zunic, J. y Rosin, P. L. (2003). Rectilinearity measurements for polygons. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 25(9):1193–1200.

Apéndice A

Zonas de validación

Resultados obtenidos en las zonas de validación

A continuación se presentan los resultados obtenidos en las zonas de validación que conforman el área de estudio. Se detallan los resultados de la etapa de segmentación y clasificación. Asimismo, los valores de las matrices de confusión, parámetros de precisión y los mosaic plot de cada zona.

Zona 1




Fig. A.1. Zona 1. (a): Imagen original. (b): Imagen segmentada con el algoritmo Distancias mínimas a múltiples prototipos. (f): Imagen binaria.




Fig. A.2. Resultados de la clasificación en la zona 1. (a): Clasificación supervisada. (b): Clasificación automática. Las clases Cuenco (P), Cursos de marea (C) y estructuras esporias (O) se visualizan en rojo, verde y cyan, respectivamente.

Tabla A.1. Desempeño de la Zona 1. (a) y (b) : Matriz de confusión y Parámetros de precisión.

					Parámetro	Resultado
					$A_g[\%]$	90.57
					R_{Tp}	0.94
Predicción					R_{Tc}	0.96
P C O					R_{To}	0.68
Actual	P	520	4	31	R_{Fp}	0.95
	C	0	27	1	R_{Fc}	0.84
	O	26	1	58	R_{Fo}	0.64
(a)					$P_r(a)$	0.90
					$P_r(e)$	0.70
					κ	0.69
					(b)	




Fig. A.3. Mosaic plot de la matriz de confusión. La proporción de éxitos (rojo) y fracaso (amarillo) se presentan con áreas proporcionales a la cantidad de casos, las líneas de trazos representan los valores de magnitud iguales a cero. Zona 1.

Zona 2




Fig. A.4. Zona 2. (a): Imagen original. (b): Imagen segmentada con el algoritmo Distancias mínimas a múltiples prototipos. (c): Imagen binaria.




Fig. A.5. Resultados de la clasificación en la zona 2. (a): Clasificación supervisada. (b): Clasificación automática. Las clases Cuenco (P), Cursos de marea (C) y estructuras espurias (O) se visualizan en rojo, verde, y cyan, respectivamente.

Tabla A.2. Desempeño de la Zona 2. (a) y (b) : Matriz de confusión y Parámetros.

					Parámetro	Resultado
					$A_g[\%]$	86.10
					R_{Tp}	0.91
Predicción					R_{Tc}	0.97
P C O					R_{To}	0.64
Actual	P	833	6	78	R_{Fp}	0.92
	C	1	37	0	R_{Fc}	0.75
	O	72	6	140	R_{Fo}	0.64
(a)					$P_r(a)$	0.86
					$P_r(e)$	0.64
					κ	0.61

(b)




Fig. A.6. Mosaic plot de la matriz de confusión. La proporción de éxitos (rojo) y fracaso (amarillo) se presentan con áreas proporcionales a la cantidad de casos, las líneas de trazos representan los valores de magnitud iguales a cero. Zona 2.

Zona 3




Fig. A.7. Zona 3. (a): Imagen original. (b): Imagen segmentada con el algoritmo Distancias mínimas a múltiples prototipos. (c): Imagen binaria.

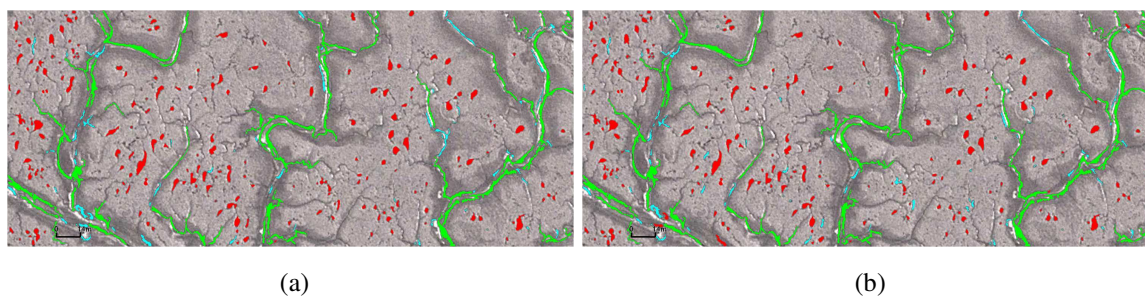


Fig. A.8. Resultados de la clasificación en la zona 3. (a): Clasificación supervisada. (b): Clasificación automática. Las clases Cuenco (P), Cursos de marea (C) y estructuras espurias (O) se visualizan en rojo, verde y cyan, respectivamente.

Tabla A.3. Desempeño de la Zona 3. (a) y (b) : Matriz de confusión y Parámetros de precisión.

				Parámetro	Resultado	
				$A_g[\%]$	89.46	
				R_{Tp}	0.90	
Predicción				R_{Tc}	1.00	
				R_{To}	0.82	
	P	C	O	R_{Fp}	0.94	
Actual	P	183	0	20	R_{Fc}	0.95
	C	0	37	0	R_{Fo}	0.75
	O	11	2	60		
(a)				$P_r(a)$	0.89	
				$P_r(e)$	0.47	
				κ	0.80	

(b)




Fig. A.9. Mosaic plot de la matriz de confusión. La proporción de éxitos (rojo) y fracaso (amarillo) se presentan con áreas proporcionales a la cantidad de casos, las líneas de trazos representan los valores de magnitud iguales a cero. Zona 3.

Zona 4




Fig. A.10. Zona 4. (a) y (b): Imágenes originales. (c) y (d): Imágenes segmentadas con el algoritmo Distancias mínimas a múltiples prototipos. (e) y (f): Imágenes binarias.




Fig. A.11. Resultados de la clasificación en la zona 4. (a) y (b): Clasificación supervisada y automática de la zona 4a. (c) y (d): Clasificación supervisada y automática de la zona 4b. Las clases Cuenco (P), Cursos de marea (C) y estructuras espurias (O) se visualizan en rojo, verde y cyan, respectivamente.

Tabla A.4. Desempeño de la Zona 4. (a) y (b) : Matriz de confusión y Parámetros de precisión de la zona 4a. (c) y (d): Matriz de confusión y Parámetros de precisión de la zona 4b.

					Parámetro	Resultado
					$A_g[\%]$	91.85
					R_{Tp}	0.98
					R_{Tc}	0.90
					R_{To}	0.64
					R_{Fp}	0.94
					R_{Fc}	0.85
					R_{Fo}	0.83
(a)					$P_r(a)$	0.92
					$P_r(e)$	0.59
					κ	0.80
(b)						
					Parámetro	Resultado
					$A_g[\%]$	90.33
					R_{Tp}	0.95
					R_{Tc}	0.95
					R_{To}	0.60
					R_{Fp}	0.93
					R_{Fc}	0.92
					R_{Fo}	0.70
(c)					$P_r(a)$	0.90
					$P_r(e)$	0.57
					κ	0.77
(d)						




Fig. A.12. Mosaic plot de la matriz de confusión. La proporción de éxitos (rojo) y fracaso (amarillo) se presentan con áreas proporcionales a la cantidad de casos, las líneas de trazos representan los valores de magnitud iguales a cero. (a) y (b): Zonas 4a y b, respectivamente.

Zona 7




Fig. A.13. Zona 7. (a): Imagen original. (b): Imagen segmentada con el algoritmo Distancias mínimas a múltiples prototipos. (c): Imagen binaria.




Fig. A.14. Resultados de la clasificación en la zona 7. (a): Clasificación supervisada. (b): Clasificación automática. Las clases Cuenco (P), Cursos de marea (C) y estructuras esporias (O) se visualizan en rojo, verde y cyan, respectivamente.

Tabla A.5. Desempeño de la Zona 7. (a) y (b) : Matriz de confusión y Parámetros de precisión.

				Parámetro	Resultado	
				$A_g[\%]$	95.28	
				R_{Tp}	0.97	
Predicción				R_{Tc}	1.00	
	P	C	O	R_{To}	0.66	
Actual	P	515	1	14	R_{Fp}	0.98
	C	0	7	0	R_{Fc}	0.70
	O	10	2	23	R_{Fo}	0.62
(a)				$P_r(a)$	0.95	
				$P_r(e)$	0.85	
				κ	0.67	

(b)




Fig. A.15. Mosaic plot de la matriz de confusión. La proporción de éxitos (rojo) y fracaso (amarillo) se presentan con áreas proporcionales a la cantidad de casos, las líneas de trazos representan los valores de magnitud iguales a cero. Zona 7.

Zona 11




Fig. A.16. Zona 11. (a): Imagen original. (b): Imagen segmentada con el algoritmo Distancias mínimas a múltiples prototipos. (c): Imagen binaria.




Fig. A.17. Resultados de la clasificación en la zona 11. (a): Clasificación supervisada. (b): Clasificación automática. Las clases Cuenco (P), Cursos de marea (C) y estructuras espurias (O) se visualizan en rojo, verde y cian, respectivamente.

Tabla A.6. Desempeño de la Zona 11. (a) y (b) : Matriz de confusión y Parámetros de precisión.

				Parámetro	Resultado	
				$A_g[\%]$	95.44	
				R_{Tp}	0.99	
Predicción				R_{Tc}	1.00	
				R_{To}	0.70	
	P	C	O	R_{Fp}	0.95	
Actual	P	247	0	2	R_{Fc}	1.00
	C	0	37	0	R_{Fo}	0.94
	O	13	0	30	$P_r(a)$	0.95
(a)				$P_r(e)$	0.62	
				κ	0.88	



Fig. A.18. Mosaic plot de la matriz de confusión. La proporción de éxitos (rojo) y fracaso (amarillo) se presentan con áreas proporcionales a la cantidad de casos, las líneas de trazos representan los valores de magnitud iguales a cero. Zona 11.

Zona 12

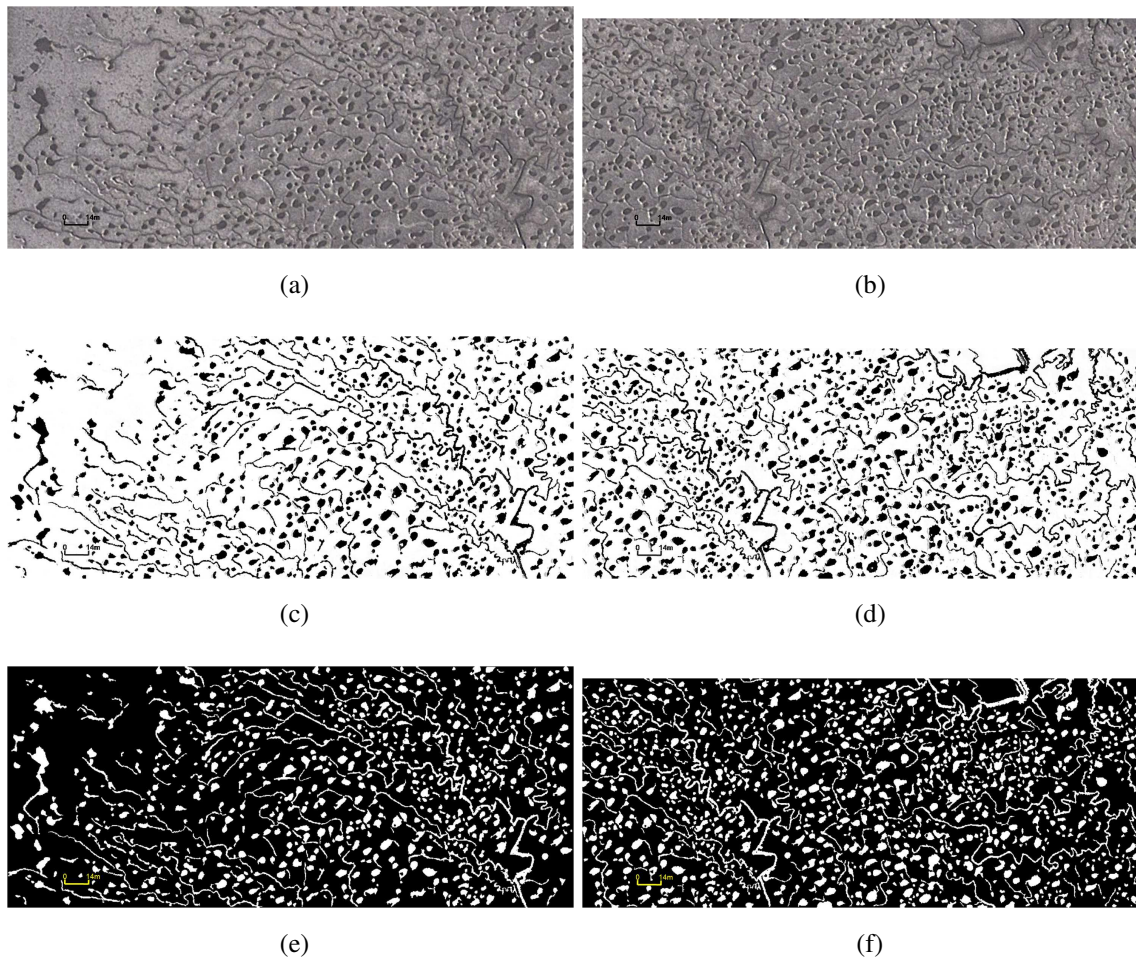


Fig. A.19. Zona 12. (a) y (b): Imágenes originales. (c) y (d): Imágenes segmentadas con el algoritmo Distancias mínimas a múltiples prototipos. (e) y (f): Imágenes binarias.




Fig. A.20. Resultados de la clasificación en la zona 12. (a) y (b): Clasificación supervisada y automática de la zona 12a. (c) y (d): Clasificación supervisada y automática de la zona 12b. Las clases Cuenco (P), Cursos de marea (C) y estructuras espurias (O) se visualizan en rojo, verde y cian, respectivamente.

Tabla A.7. Desempeño de la Zona 12. (a) y (b) : Matriz de confusión y Parámetros de precisión de la zona 12a. (c) y (d): Matriz de confusión y Parámetros de precisión de la zona 12b.

					Parámetro	Resultado
					$A_g[\%]$	97.57
					R_{Tp}	0.98
					R_{Tc}	1.00
					R_{To}	0.91
					R_{Fp}	0.99
					R_{Fc}	0.91
					R_{Fo}	0.91
(a)					$P_r(a)$	0.98
					$P_r(e)$	0.70
					κ	0.92
(b)						
					Parámetro	Resultado
					$A_g[\%]$	97.02
					R_{Tp}	0.98
					R_{Tc}	1.00
					R_{To}	0.87
					R_{Fp}	0.99
					R_{Fc}	0.96
					R_{Fo}	0.72
(c)					$P_r(a)$	0.97
					$P_r(e)$	0.78
					κ	0.86
(d)						




Fig. A.21. Mosaic plot de la matriz de confusión. La proporción de éxitos (rojo) y fracaso (amarillo) se presentan con áreas proporcionales a la cantidad de casos, las líneas de trazos representan los valores de magnitud iguales a cero. (a) y (b): Zonas 12a y b, respectivamente.

Zona 13




Fig. A.22. Zona 13. (a) y (b): Imágenes originales. (c) y (d): Imágenes segmentadas con el algoritmo Distancias mínimas a múltiples prototipos. (e) y (f): Imágenes binarias.




Fig. A.23. Resultados de la clasificación en la zona 13. (a) y (b): Clasificación supervisada y automática de la zona 13a. (c) y (d): Clasificación supervisada y automática de la zona 13b. Las clases Cuenco (*P*), Cursos de marea (*C*) y estructuras espurias (*O*) se visualizan en rojo, verde y cyan, respectivamente.

Tabla A.8. Desempeño de la Zona 13. (a) y (b) : Matriz de confusión y Parámetros de precisión de la zona 13a. (c) y (d): Matriz de confusión y Parámetros de precisión de la zona 13b.

					Parámetro	Resultado
					$A_g[\%]$	96.98
					R_{Tp}	0.97
					R_{Tc}	1.00
					R_{To}	0.94
					R_{Fp}	0.99
					R_{Fc}	0.90
					R_{Fo}	0.88
					$P_r(a)$	0.97
					$P_r(e)$	0.65
					κ	0.91
(b)						
					Parámetro	Resultado
					$A_g[\%]$	96.31
					R_{Tp}	0.99
					R_{Tc}	1.00
					R_{To}	0.70
					R_{Fp}	0.96
					R_{Fc}	0.94
					R_{Fo}	0.96
					$P_r(a)$	0.96
					$P_r(e)$	0.70
					κ	0.88
(d)						

					Predicción							
					P	C	O					
					P	386	5	7				
Actual						C	0	44	0			
						O	3	0	51			
						(a)						

					Predicción							
					P	C	O					
					P	284	2	1				
Actual						C	0	31	0			
						O	10	0	24			
						(c)						




Fig. A.24. Mosaic plot de la matriz de confusión. La proporción de éxitos (rojo) y fracaso (amarillo) se presentan con áreas proporcionales a la cantidad de casos, las líneas de trazos representan los valores de magnitud iguales a cero. (a) y (b): Zonas 13a y b, respectivamente.