



UNIVERSIDAD NACIONAL DEL SUR

TESIS DE DOCTOR EN INGENIERÍA

Metodologías de segmentación y medición
de característicos lineales en imágenes de sensado remoto

Marina P. Cipolletti

BAHÍA BLANCA

ARGENTINA

2012

Prefacio

Esta Tesis es presentada 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 otras. La misma contiene los resultados obtenidos en investigaciones llevadas a cabo en el Instituto Argentino de Oceanografía, durante el período comprendido entre el día 1 de Abril de 2007 y el 30 de Noviembre de 2011, bajo la dirección del Dr. Claudio A. Delrieux, Profesor Titular del Departamento de Ingeniería Eléctrica y de Computadoras y la Dra. M. Cintia Piccolo Investigadora Superior de CONICET del Instituto Argentino de Oceanografía y Profesora Titular del Departamento de Geografía.

Marina P. Cipolletti

`mpcipolletti@gmail.com`

DEPARTAMENTO DE INGENIERÍA ELÉCTRICA Y DE COMPUTADORAS
UNIVERSIDAD NACIONAL DEL SUR
Bahía Blanca, 15/02/2012.



UNIVERSIDAD NACIONAL DEL SUR
Secretaría General de Posgrado y Educación Continua

La presente tesis ha sido aprobada el / / , mereciendo la calificación de(.....)

Agradecimientos

El proceso de realización y escritura de esta Tesis fue posible no sólo gracias al trabajo personal sino al aporte de muchas personas que hicieron del resultado final lo que es hoy y a las cuales estoy profundamente agradecida. En primer lugar quisiera agradecer a mis directores de Tesis, el Dr. Claudio Delrieux y la Dra. Cintia Piccolo por su guía, apoyo y paciencia sobre todo en los momentos más complicados. Así como también un especial agradecimiento al Dr. Gerardo Perillo quien participó activamente de cada una de las tareas. Las innumerables charlas compartidas, sugerencias y correcciones fueron sin duda fundamentales e hicieron de esta tesis lo que es hoy.

A mi familia por ser mi respaldo en todos los momentos de la vida. Soy lo que soy gracias a ustedes. En particular, a mi madre por sufrir cada etapa tanto o más que yo preocupándose por todo. A mi hermano que puso su oreja cuan gran psicólogo todos estos años y a papá por inculcarme que es más importante la búsqueda de la gloria que el dinero. Viejo...ya soy Dra.

A Christian por recorrer el camino a mi lado respetando mis tiempo y ayudando cada vez que lo he necesitado. Y, por último no quiero dejar de acordarme de las personas que aportaron diferentes visiones de la ciencia a mis puntos de vista: Alejandro Vitale, Vanesa Bohn y Natalia Revollo. Vane se lo que sé de geografía gracias a tu paciencia.

Es importante destacar que esta tesis muestra el potencial existente en la conformación de grupos de investigación interdisciplinarios lo cual constituye el mecanismo ideal para el avance del conocimiento y de metodologías novedosas. Así como también, impulsan la transferencia de tecnologías de las ciencias básicas e ingenierías dentro del contexto local y regional en otras áreas de la ciencia.

Resumen

Una cantidad importante de estudios geomorfológicos y oceanográficos se basa en la utilización de modelos físico-matemáticos que requieren un conocimiento preciso de las magnitudes geográficas para ser aplicables. En este trabajo se perfeccionaron y se desarrollaron nuevas técnicas de procesamiento de imágenes satelitales multispectrales para la extracción y medición precisa de dichos característicos cuya importancia es crucial en estudios de Ciencias de la Tierra. Para la segmentación de diversas áreas geográficas, se elaboraron mejoras en el algoritmo de clasificación por distancia mínima a uno y múltiples prototipos. La nueva metodología de selección de pixels de referencia permite la segmentación no supervisada en forma más robusta que las propuestas existentes.

Se desarrolló un nuevo método de medición de característicos lineales (longitud). El algoritmo se basa en la combinación de técnicas que aprovechan la información generada durante la segmentación para la extracción súper-resolución de las coordenadas del contorno. Los resultados se obtienen con mayor precisión en la medición reduciendo la limitación impuesta por la resolución de la imagen. Esta metodología fue rigurosamente testeada en imágenes sintéticas de objetos geométricos de características conocidas, así como también, en imágenes satelitales de accidentes geográficos y parcelas de las cuales se realizaron mediciones directas de campo. En todos los casos, los resultados poseen menor error asociado que los datos obtenidos con los métodos existentes e implementados en los software de Sistema de Información Geográfica más populares.

Finalmente, se propuso un método de estimación de longitud a partir de extrapolación fractal. Se fundamenta en las ideas presentadas por Richardson (1961), sin los problemas de incongruencia de información presentes en otros desarrollos. El algoritmo infiere el valor correspondiente a una medición hipotética realizada con una resolución espacial mejor que la disponible. Este método fue probado con imágenes sintéticas y en áreas geográficas para las cuales fue posible contar con dos tipos de imágenes satelitales, una de baja resolución (Landsat) y otra de alta resolución (Ikonos). La estimación de perímetros utilizando la imagen Landsat predice con gran exactitud la medición en la imagen Ikonos, lo cual valida experimentalmente una metodología que permitiría refinar en casi dos órdenes de magnitud la precisión de trabajo utilizando imágenes de bajo costo.

Abstract

An important amount of geomorphologic and oceanographic studies are based on the use of physical-mathematical models that require a precise knowledge of certain geographic magnitudes in order to be applied. In this work, previous techniques were enhanced and new multispectral satellite image processing techniques were developed, specifically for precise extraction and measurement of geographic features whose importance is crucial in a wide spectrum of Earth science studies. Several enhancements were performed on classification methods by minimum distance to single and multiple prototypes for segmentation of diverse areas. The new methodology for prototype selection allows for non-supervised segmentation in a more robust manner than that of previous methods.

A new method for measurement of linear features (length) was developed. The algorithm is based on the combination of techniques that use the information generated during the segmentation process for the extraction of the contour coordinates by super-resolution. The results obtained achieve greater precision on the measurement, reducing the limitation introduced by the image resolution. This methodology was rigorously tested and validated both with synthetic images of geometric objects with known parameters, as well as satellite images of geographic features and areas from which direct field measurements have been taken. In all cases, the performed measurements show lower associated error compared to the existent algorithms implemented on the most popular Geographic Information System softwares.

Finally, a novel length estimation method based on a fractal extrapolation was proposed. It is based on the ideas originally presented by Richardson(1961) but avoids the information incongruence issues that usually affect other proposals. The algorithm infers the value corresponding to a hypothetical measurement performed with a spatial resolution higher than the available. This method was validated against both synthetic images as well as geographic areas for which two satellite images (a low resolution Landsat image and a high resolution Ikonos) were available. The perimeter estimation of geographic areas using only the Landsat image predicts with great accuracy the measurement in the Ikonos image, which validates experimentally a methodology that would allow to refine in almost two orders of magnitude the precision achievable when working with low cost satellite images.

Índice general

1. Introducción	1
2. Segmentación	8
2.1. Antecedentes	9
2.2. Imágenes satelitales	10
2.3. Espacios de color	12
2.3.1. Matrices de conversión entre los RGB e YIQ	14
2.4. Segmentación mono-distancia	15
2.4.1. Operador de distancia mínima a un pixel prototipo	16
2.5. Segmentación multi-distancia	17
2.5.1. Selección de pixels prototipos	20
2.5.2. Operador distancia a múltiples pixels prototipo	21
2.6. Resumen	25
3. Medición súper resolución de característicos lineales	26
3.1. Antecedentes	27
3.2. Algoritmos de medición estándar	28
3.3. MSI	31
3.3.1. Cálculo de un punto de frontera	33
3.4. Comparación de desempeño	36
3.5. Resumen de desempeño	42
4. Estimación de Longitud de Característicos Lineales con Regresión Fractal	43
4.1. Antecedentes	44
4.2. Dimensión fractal	45

4.2.1.	Definición y características	45
4.2.2.	Gráficos de Richardson	46
4.2.3.	Dimensión de Hausdorff-Besicovitch	48
4.2.4.	Análisis de Korcak	50
4.2.5.	Análisis R/S de Hurst	50
4.3.	Estimación del perímetro	51
4.3.1.	Preparación de la imagen	52
4.3.2.	Regresión Fractal	53
4.4.	Imagen sintética	54
4.4.1.	Análisis de las estimaciones	58
4.5.	Resumen	59
5.	Resultados experimentales	61
5.1.	Imágenes satelitales	62
5.2.	Segmentación de imágenes reales	64
5.2.1.	Segmentación mono-distancia	65
5.2.2.	Segmentación Multi-distancia	71
5.3.	MSI y su comparación con métodos estándar	78
5.3.1.	Espejos de agua en imágenes Landsat	78
5.3.2.	Parcela de campo en imagen Landsat	79
5.3.3.	Linea de costa en fotogramas de video	81
5.4.	Estimación de perímetros con regresión fractal	83
5.4.1.	Validación de resultados con imágenes Landsat	83
5.4.2.	Validación de resultados con imágenes de alta resolución	89
5.5.	Relevamiento de lagunas del Sur de la Provincia de Buenos Aires	93
6.	Conclusiones	97
A.	MSI:	
	Determinaciones matemáticas	100
B.	Campana de medición de campo	109

Índice de figuras

1.1. Extracción de datos de imágenes digitales con técnicas de procesamiento digital de imágenes.	1
2.1. Imágenes satelitales	11
2.2. Estándar CIE	12
2.3. Espacio de color RGB	13
2.4. Espacio de color YIQ	14
2.5. Segmentación a un pixel prototipo	16
2.6. Segmentación de una imagen sintética RGB	18
2.7. Clasificación por umbral U figura/fondo de la figura 2.6c.	19
2.8. Selección de pixels prototipo	21
2.9. Segmentación a múltiples pixels prototipo	23
2.10. Resultado de la segmentación de la figura 2.8a	24
3.1. Ejemplos de algoritmos de cadena.	27
3.2. Bit quad.	29
3.3. Chain code y Marching squares	31
3.4. MSI: Configuraciones	32
3.5. MSI: Cotas	33
3.6. MSI: P_f	34
3.7. Ejemplo de MSI sobre la figura 3.1	36
3.8. Error de medición en objetos curvos. Medición realizada sobre círculos de radio variable de entre 3 y 15 m de diámetro. Resolución de las imágenes es $L = 1$ m.	37
3.9. Error de estimación del método BEP	38
3.10. Error de medición en función del ángulo.	39
3.11. Estudio de simetría	40

3.12. Desempeño en las esquinas	41
4.1. Longitud versus escala.	47
4.2. Dimensión de Hausdorff.	49
4.3. Diagrama de trabajo: Estimación de perímetro.	51
4.4. Submuestreo.	53
4.5. Isla sintética.	55
4.6. Imagen de la isla sintética.	56
4.7. Regresión fractal del perímetro de la figura 4.6.	58
4.8. Análisis del error de estimación	59
5.1. Diagrama de trabajo: Etapas de la metodología desarrollada y posteriormente aplicada sobre imágenes multiespectrales.	61
5.2. Recorte de imagen Landsat 7	62
5.3. Recorte de imagen Ikonos	64
5.4. Sector de la costa.	65
5.5. Segmentación mono-distancia de agua sobre imagen Landsat 7.	66
5.6. Segmentación de lagunas: Comparación con resultados de Envi®.	67
5.7. Segmentación de un campo.	68
5.8. Segmentación de un campo con Envi®.	69
5.9. Segmentación de un recorte de imagen Ikonos.	70
5.10. Diagrama del procesamiento de un segmento de video.	71
5.11. Pre-procesamiento de fotogramas de video.	72
5.12. Segmentación multi-distancia de video.	73
5.13. Segmentación multi-distancia de canales de marea.	74
5.14. Imágenes segmentadas en recortes de imagen Ikonos.	75
5.15. Canales de marea secundarios.	76
5.16. Imagen Landsat: Isla del estuario de Bahía Blanca.	77
5.17. Imagen Ikonos: Isla del estuario de Bahía Blanca.	77
5.18. MSI en lagunas.	79
5.19. Segmentación de campo de una parcela en la Provincia de Buenos Aires.	80
5.20. Medición de campo de una parcela en la Provincia de Buenos Aires.	81
5.21. Línea de costa en imágenes de video. Sector seleccionado dentro de la imagen 5.11b para la medición.	82
5.22. Medición de la línea de costa en imágenes de video.	82

5.23. Escala versus perímetro.	83
5.24. Cambio de escala de medición.	84
5.25. Regresión fractal del perímetro de la figura 5.4.	87
5.26. Conmutación entre segmentación y submuestreo.	88
5.26. Conmutación entre segmentación y submuestreo.	89
5.27. IM de la isla del estuario.	90
5.28. Regresión fractal del perímetro de una isla del estuario.	91
5.29. Superposición de resultados.	92
5.30. Segmentación mono-distancia de agua sobre imagen Landsat 7.	94
5.31. Clasificación según el factor de forma (FF). El pseudo color aplica rojo/verde al valor máximo/mínimo de la información.	96
B.1. Campaña de medición de campo.	110

Índice de cuadros

2.1. Coordenadas de cromaticidad.	14
2.2. Lista completa de los pixels prototipo empleados para segmentar la imagen sintética.	25
3.1. Cómputos asociados a las coordenadas del algoritmo MSI.	35
3.2. Medición de perímetros sobre círculos de radio variable de entre 3 y 15 m de diámetro. La resolución de las imágenes es de $L = 1$ m.	38
4.1. Estimación de la longitud del borde de la isla sintética de la figura 4.6. . .	57
5.1. Imágenes satelitales	63
5.2. Pixels prototipo marcados en la figura 5.13c.	74
5.3. Datos de medición de perímetros de las lagunas en la figura 5.18.	79
5.4. Resultados de medición de campo de una parcela en la Provincia de Buenos Aires. Las mediciones realizadas con cada método se compara con el Valor medido para obtener e	80
5.5. Resultado de las mediciones sobre la linea de costa en imágenes de video. .	81
5.6. Datos de medición de perímetro de la figura 5.24.	85
5.7. Datos de las mediciones de la costa sur de la Provincia de Buenos Aires. .	86
5.8. Resultados de la extrapolación de perímetro de la costa sur de la Provincia de Buenos Aires.	87
5.9. Estimación del perímetro de una isla del estuario de Bahía Blanca.	91
5.10. Resultados de la extrapolación de perímetro de un Islote del estuario de Bahía Blanca.	92
5.11. Base de datos resultante. Los índices corresponden con las identificaciones marcadas en la figura 5.30b	95
B.1. Coordenadas medidas.	109

Capítulo 1

Introducción

Una cantidad importante de estudios geomorfológicos y oceanográficos (transporte de sedimentos, balance de calor, erosión, etc.) se basan en la utilización de modelos físico-matemáticos que requieren un conocimiento preciso de los valores geográficos (áreas, longitudes costeras, etc.) para ser aplicables. Estos valores, sin embargo, no están siempre disponibles, tanto porque las áreas son de difícil acceso, o de gran extensión, o porque la presencia misma de la campaña de medición produce un efecto ambiental negativo. El análisis de las características geomorfológicas a partir de imágenes satelitales surge entonces como alternativa ventajosa para el estudio de accidentes geográficos en regiones vastas o de difícil acceso, sin ejercer influencia desfavorable (Yatabe y Fabbri, 1986; Schowen-gerdt, 1997; Lillesand y Kiefer, 2000). No obstante, su utilización implica el desarrollo de técnicas específicas para la extracción de datos y su precisión se ve altamente influenciada por la resolución espacial de la imagen. Las imágenes satelitales de resolución aceptable para la precisión que se requiere en los modelos mencionados son de un costo prohibitivo, mientras que las imágenes disponibles que aseguran la cobertura temporal y espacial de las regiones de interés no poseen la resolución adecuada. Las técnicas de procesamiento digital de imágenes (PDI) proveen herramientas para la extracción de la información útil del entorno en la que se encuentra inmersa (Figura 1.1).

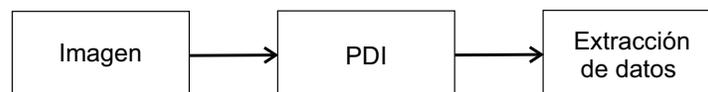


Figura 1.1: Extracción de datos de imágenes digitales con técnicas de procesamiento digital de imágenes.

Conceptualmente, PDI está integrado por diversas etapas que en este trabajo de tesis se simplifican en dos etapas principales: la segmentación y la descripción de características cuantitativas específicas. Luego se continúa con la identificación de estructuras y el reconocimiento de patrones cualitativos. En imágenes de teledetección, tanto aéreas como satelitales (LANDSAT, IKONOS, MODIS, etc.), la segmentación resulta la etapa clave dada la diversidad de información, las diferentes modalidades de formato y la complejidad intrínseca de las áreas geográficas que constituyen el mayor desafío en el desarrollo de los algoritmos. La precisión de las siguientes etapas de procesamiento se encuentra altamente influenciada por los resultados obtenidos durante ésta etapa y, además, los métodos tradicionales (filtrado por convolución, morfología, umbralizado, etc.) no consiguen el objetivo. En la literatura sobre el tema, la elección de un algoritmo específico depende de las condiciones particulares debido a que los algoritmos no son inmunes a los ruidos y perturbaciones presentes en las imágenes satelitales. En consecuencia, no es posible sistematizar los resultados, procesar grupos de imágenes con los mismos parámetros, ni realizar estadísticas robustas. Una solución posible incluiría el mejoramiento de las técnicas estándar y la incorporación de descriptores de alto nivel como por ejemplo el estudio de características fractales en las estructuras.

El objetivo de esta tesis consiste en desarrollar e implementar nuevas tecnologías de segmentación y medición super resolución que apliquen PDI sobre accidentes geográficos. En particular, métodos confiables y de precisión que permitan la aproximación de datos a partir de imágenes de menor resolución, así como también, determinar característicos de zonas particulares, sistematizar los resultados y procesar grupos de imágenes con los mismos parámetros para obtener estadísticas robustas.

La segmentación más adecuada en imágenes de teledetección se basa en algoritmos de agrupamiento o en inglés “*clustering*” (Pratt, 1991). Desde mediados de los años 50, la necesidad de separar grandes cantidades de información en grupos de características similares motiva su estudio (Fisher, 1958; Friedman y Rubin, 1967; Dubes y Jain, 1976; Yang, 1993; Gan et al., 2007). Haralick y Kelly (1969) se encuentran entre los primeros autores en aplicarlo en segmentación de imágenes. Sin embargo, es motivo de nuevas investigaciones hasta la actualidad (Jain et al., 1999; Jain y Law, 2005; Saha y Bandyopadhyay, 2008) e incluso es una técnica ampliamente utilizada en imágenes multispectrales de teledetección (Murthy et al., 1992; Wemmert et al., 2009; Saha y Bandyopadhyay, 2010).

Luego de la segmentación, la medición de áreas y perímetros en imágenes digitalizadas (raster) es el siguiente paso en el estudio morfológico de accidentes geográficos. Sin embar-

go, a diferencia de los algoritmos usuales de medición de áreas, los métodos estándar de medición de características lineales (Freeman, 1970; Kulpa, 1977; Vossepoel y Smeulders, 1982; Dunkelberger y Mitchell, 1985; Schuster y Katsaggelos, 1998) poseen un alto grado de error sistemático asociado (Kulpa, 1983; Yang et al., 1994; Cipolletti et al., 2012). Su uso para mediciones precisas y la ulterior elaboración de modelos geodinámicos y geomorfológicos, como por ejemplo los elaborados en Perillo et al. (1996) y Angeles et al. (2003), es muy limitado y cuestionable. La precisión no mejora con un aumento en la resolución de la imagen debido a diversos factores geométricos como se explica más adelante en esta tesis.

Existen comparativamente pocos trabajos de investigación orientados a la segmentación y medición precisa de características geográficas lineales en imágenes de teledetección. Rocca et al. (2004), por ejemplo, utilizan técnicas de contornos activos y crecimiento de regiones para obtener segmentaciones de accidentes geográficos lineales en imágenes satelitales. Parrinello y Vaughan (2002, 2006) estudian la extracción de características en imágenes satelitales utilizando espectros multifractales. Muchos de estos métodos han sido estudiados en imágenes sintéticas con propiedades estadísticas conocidas, pero no han sido aún aplicados en la segmentación sobre imágenes reales y, menos aún para el reconocimiento del tipo de accidentes geográficos planteados en este trabajo, por lo que resulta particularmente relevante su utilización en imágenes satelitales de zonas geográficas de las que se posea un conocimiento importante provisto por otras fuentes (campanas oceanográficas, mediciones con GPS, etc.). Esto también permitiría ajustar los parámetros de los métodos de segmentación.

Los métodos de medición, específicamente los denominados métodos de cadena o “*chain codes*” fueron desarrollados para codificar y facilitar el envío de información de figuras geométricas en formato digital. Pese a cambios en la metodología de ejecución se trata de los algoritmos usualmente implementados en los programas específicos de PDI. Dichos algoritmos describen una poligonal cuyos segmentos poseen longitud fija, dirección y número para codificar el movimiento. La fórmula de cómputo del perímetro, desarrollada por Freeman (1961), es mejorada en estudios posteriores a partir de la aplicación de diversos factores de corrección determinados por el análisis del error (Kulpa, 1977; Vossepoel y Smeulders, 1982). En todos los casos, la mejora en los resultados depende específicamente de las cualidades de la figura a medir (Kulpa, 1983; Yang et al., 1994). Más tarde, Dunkelberger y Mitchell (1985) presentan el algoritmo Crack Code también denominado Mid Crack, el cual introduce una mejora sustancial a el método de Freeman

con ocho niveles de adyacencia en los algoritmos de cadena. Luego, Pratt (1991) a partir de notas no publicadas de Duda (Pratt, 1991; Yang et al., 1994), presenta las fórmulas del algoritmo Marching Squares. El Marching Squares produce gráficamente los mismos resultados que el Crack Code pero con un cambio en el procesamiento de la información.

Por otra parte, la geometría fractal ofrece el marco teórico ideal para el desarrollo de algoritmos de estimación. Sus conceptos y aplicaciones se extienden a todos los ámbitos de la experiencia humana (Russ, 1993; Falconer, 2003) incluyendo las ciencias naturales (Mandelbrot, 1967, 1983; Siu y Lam, 2002; Lopes y Betrouni, 2009). En PDI la teoría fractal es la base de diversas técnicas para segmentación, reconocimiento de patrones, etc (Zhende y Yuwen, 2003; Lopes y Betrouni, 2009; García et al., 2010). Hoy sus aplicaciones se extienden a todos ámbitos de la experiencia humana incluyendo las ciencias naturales (Mandelbrot, 1983; Siu y Lam, 2002; Lopes y Betrouni, 2009). En el caso particular de su uso en mediciones y caracterización de texturas, se expresan enfoques diferentes priorizando el algoritmo de cálculo (Allen et al., 1995; Soille y Rivest, 1996), las condiciones para validar los resultados (Goodchild, 1980; Shelberg et al., 1982; Wu, 2004; Wu et al., 2006) o simplemente utilizando la técnica para la estimación de características (Håkanson, 1978).

Este trabajo de tesis se compone de seis capítulos divididos entre introducción, metodología implementada, resultados y conclusión. Los tres capítulos de metodología apuntan a las diferentes etapas de procesamiento: segmentación, medición y estimación. En cada una de las mismas se describe el marco teórico en el cual fue desarrollado, las especificaciones técnicas y los resultados sobre imágenes sintéticas con características estadísticas conocidas con el objeto de analizar su desempeño. El capítulo de resultados presenta con detalles el funcionamiento de cada uno de los algoritmos en imágenes reales de diversas modalidades con énfasis en las imágenes satelitales Landsat e Ikonos. De esta manera se corroboran los resultados obtenidos en los capítulos anteriores bajo condiciones especiales.

Durante este trabajo se realizan avances en el desarrollo de métodos de perímetros y su aproximación a resultados obtenidos con mayores resoluciones por medio de estimadores fractales. El método de extracción super-resolución de bordes aprovecha la información que, de otro modo, se pierde al binarizar (Rivest y Soille, 1995) con el objetivo de calcular las coordenadas del contorno con mayor precisión que la que presenta la resolución de la imagen (Revollo et al., 2009; Cipolletti et al., 2012). También, se formula un método de estimación de perímetros a partir de extrapolación fractal basado en las ideas presentadas originalmente por Richardson (1961). El método infiere el valor correspondiente a

una medición hipotética realizada con muy alta precisión. Esta extrapolación resulta ser extremadamente precisa, tanto en imágenes sintéticas (de resolución controlada) como en áreas geográficas para las que se cuenta con imágenes satelitales de diferentes resoluciones (Landsat e Ikonos, por ejemplo (Cipolletti et al., 2009b, 2011b)), sin los problemas de incongruencia de información que se presentan en otros trabajos similares como el de Håkanson (1978). En materia de segmentación, se perfecciona la técnica de selección de referencias para minimizar el tiempo de ejecución y asegurar la convergencia del método basado en distancia mínima el cual fue probado en diversas modalidades de imágenes (Cipolletti et al., 2009a, 2010, 2011a; Revollo et al., 2010a). En el capítulo de conclusiones se sintetizan los aportes presentados, el significado de los resultados obtenidos, y las líneas futuras de investigación que quedan abiertas a partir de este trabajo.

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

Artículo en revista

- *“Border extrapolation using fractal attributes in remote sensing images” (2014).*
Marina P. Cipolletti, Claudio A. Delrieux, Gerardo M.E. Perillo y M. Cintia Piccolo.
“Computers & Geosciences”. 62: 25–34. ISSN 0098-3004.
Doi = “10.1016/j.cageo.2013.09.006.”

- *“Super-resolution Border Segmentation and Measurement in Remote Sensing Images” (2012).*
Marina P. Cipolletti, Claudio A. Delrieux, Gerardo M.E. Perillo y M. Cintia Piccolo.
“Computers & Geosciences”. 40: 87–96. ISSN = 0098–3004.
Doi: “10.1016/j.cageo.2011.07.015”.

Capítulo de libro

- *“Coastal Monitoring and Feature Estimation with Small Format Cameras: Application to the Shoreline of Monte Hermoso, Argentina”.*
Natalia Revollo, Claudio A. Delrieux, Gerardo M.E. Perillo y Marina P. Cipolletti.
ISBN: 978-950-34-0684-7. Título del libro: “Computer Science & Technology Series.”

XV Argentine Congress of Computer Science Selected Papers”. Ed: edulp. Editores: G. Simari, P. Pesado y J. Paganini. 2010(165–174).

Artículos en conferencias

- *“Estimación de características lineales en imágenes de sensado remoto”*
Marina P. Cipolletti, Claudio Delrieux, Gerardo M.E. Perillo y M.Cintia Piccolo. La Plata. Cacic 2011 - Workshop Computación Gráfica, Imágenes y Visualización (WCGIV). ISBN: 978-950-34-0756-1.
- *“Segmentación no supervisada de accidentes geográficos en imágenes satelitales”*
Marina P. Cipolletti, Claudio Delrieux, Gerardo M.E. Perillo y M.Cintia Piccolo. Buenos Aires. ECIImag 2011 - 4ta Escuela y Workshop de Ciencias de las Imágenes.
- *“Segmentación y Medición de las Zonas que conforman la Playa en Secuencias de Videos”.*
Natalia Revollo, Marina P. Cipolletti, Claudio A. Delrieux, Gerardo M.E. Perillo y M. Cintia Piccolo”. ISBN: 978-950-34-0652-6. El Calafate, Santa Cruz. WICC 2010 (288–292).
- *“Segmentación Supervisada y No Supervisada de Zonas Costeras en Secuencias de Videos”.*
Marina P. Cipolletti, Natalia V. Revollo Sarmiento, Claudio A. Delrieux, Gerardo M.E. Perillo y M.Cintia Piccolo. ISSN: 1850-2806. Ciudad Autónoma de Buenos Aires. 39 JAIIO 2010 - 11° Argentine Symposium on Technology.
- *“Coastal Monitoring and Feature Estimation with Small Format Cameras: Application to the Shoreline of Monte Hermoso, Argentina”.*
Natalia Revollo, Claudio A. Delrieux, Gerardo M.E. Perillo y Marina P. Cipolletti. ISBN: 978-897-24068-4-1. Jujuy, Argentina. CACiC 2009(615–624).
- *“Predicción de la Longitud de la línea de Costa del Sur de la Provincia de Buenos Aires por medio de Fractales”*
Marina P. Cipolletti, Claudio A. Delrieux, Gerardo M.E. Perillo y M. Cintia Piccolo. “Libro de resúmenes”, ISBN: 978–987–25479–0–4. VII Jornadas Nacionales de Ciencias del Mar 2009, Instituto Argentino de Oceanografía (IADO-CONICET). Bahía Blanca, Argentina(10).

- *“Segmentación y Medición de Fronteras en Imágenes de Sensado Remoto”*
Marina P. Cipolletti, Claudio A. Delrieux y Gerardo M.E. Perillo. Tandil. ECImag
2009 - 2da Escuela y Workshop de Ciencias de las Imágenes.

Capítulo 2

Segmentación

La segmentación es el primer paso para la adquisición de datos en imágenes digitales. Las diversas modalidades disponibles, en particular, la gran variedad de imágenes multi-espectrales provenientes de misiones satelitales estimulan el desarrollo y la implementación de técnicas confiables para la extracción de la información contenida. Su utilización en accidentes geográficos, permite monitorear, analizar e incluso alcanzar regiones de difícil acceso sin interferir en las condiciones del medio.

En este capítulo se detallan las características generales de las imágenes de teledetección empleadas como fuente de información, las especificaciones técnicas los espacios cromáticos utilizados, un algoritmo de selección inteligente de pixels de referencia y se implementan dos métodos de segmentación. El comportamiento de cada procedimiento se analiza sobre imágenes sintéticas y, posteriormente, en el capítulo de resultados se aplican a diferentes tipos de imágenes en diversos espacios cromáticos.

Los algoritmos de segmentación implementados se basan en el concepto de distancia mínima a uno o múltiples prototipos (Girard y Girard, 1999; Richards y Jia, 2006). Estos algoritmos permiten la construcción de imágenes en escala de gris mejorando la utilización de la información disponible y favoreciendo la precisión de etapas posteriores de procesamiento (Rivest y Soille, 1995; Cipolletti et al., 2012). Por otra parte, los algoritmos usuales de selección de pixels de referencia en los casos analizados son inadecuados o aumentan en forma exagerada el tiempo de procesamiento. Por lo tanto, se desarrolla un método supervisado de selección de pixels prototipo que minimiza el número referencias y, en consecuencia, el tiempo de cómputo.

2.1. Antecedentes

El problema de discriminar la información útil del entorno que la rodea se repite constantemente en todos los ámbitos de la ciencia (Fisher, 1958; Tolbert et al., 1980; Pham et al., 2000) y, en el procesamiento digital de imágenes (PDI), la segmentación es el primer paso para la extracción de datos. Los algoritmos de segmentación separan en zonas homogéneas objetos que poseen cualidades semejantes respecto de algún atributo como, por ejemplo, la textura (Chen et al., 2007; Ilea y Whelan, 2011), el color (Cheng et al., 2001; Navon et al., 2005), etc. La configuración cromática se simplifica a partir de *etiquetas* para facilitar su interpretación. Haralick y Shapiro (1985) dividen las diferentes técnicas en seis grupos mayoritarios: métodos basados en el estudio del histograma, crecimiento de regiones simple, crecimiento de regiones híbrido, algoritmos de agrupamiento, detección de bordes y particionamiento gráfico (split and merge). La calidad obtenida influye directamente en la precisión de instancias posteriores de desarrollo en alto nivel (reconocimiento, identificación, clasificación, medición, seguimiento, etc).

En este capítulo, se describen las dos técnicas de segmentación empleadas las cuales se basan en algoritmos de agrupamiento o en inglés “*clustering*” (Pratt, 1991). Desde mediados de los años 50, la necesidad de separar grandes cantidades de información en grupos de características similares motiva su estudio (Fisher, 1958; Friedman y Rubin, 1967; Dubes y Jain, 1976; Yang, 1993; Gan et al., 2007). Haralick y Kelly (1969) se encuentran entre los primeros autores en aplicarlo en segmentación de imágenes. Sin embargo, es motivo de nuevas investigaciones hasta la actualidad (Jain et al., 1999; Jain y Law, 2005; Saha y Bandyopadhyay, 2008) e incluso es una técnica ampliamente utilizada en imágenes multiespectrales de teledetección (Murthy et al., 1992; Wemmert et al., 2009; Saha y Bandyopadhyay, 2010).

Los métodos de *clustering* agrupan la información en diversos conjuntos auto-excluyentes a partir de la elección de referencias y reglas de decisión. Las primeras publicaciones empleaban una única variable (Cox, 1957; Fisher, 1958) para determinar la inclusión de cada dato en la clase correspondiente pero se multiplicaron a partir de estudios posteriores (Ward, 1963). Si bien, se sugiere la existencia de categorías naturales en la búsqueda de los grupos (Friedman y Rubin, 1967), Good (1964) describe minuciosamente el problema y caracteriza los objetos en estudio con un conjunto de mediciones. Gower (1966), por su parte, determina el resultado de la clasificación analizando diversos factores mediante el uso de *funciones distancia*.

2.2. Imágenes satelitales

Las imágenes obtenidas por los satélites de teledetección ofrecen una perspectiva única de la Tierra, sus recursos y el impacto que sobre ella ejercen diversos factores. Así como también, han demostrado ser una fuente indispensable de información para numerosas aplicaciones como planificación urbana, vigilancia del medio ambiente, gestión de cultivos, entre muchas otras.

La teledetección o sensado remoto es la adquisición de información a pequeña o gran escala de un objeto o fenómeno usando instrumentos que no están en contacto directo con el mismo (satélites, barcos, radares, etc). Esto hace posible recoger información de regiones peligrosas e incluso inaccesibles. Principalmente existen dos modalidades diferentes de teledetección: pasiva y activa. Los teledetectores pasivos detectan la radiación natural emitida o reflejada por un objeto o superficie que está siendo observada, mientras que los teledetectores activos emiten energía para rastrear objetos y áreas midiendo la radiación reflejada por el objetivo.

Un satélite se dedica a captar imágenes de un tipo específico. En su estructura posee sensores electro-ópticos que miden la radiación electromagnética, es decir, la energía del sol reflejada por la superficie de la Tierra y los objetos que se hayan en ella¹. Dependiendo de la sensibilidad para la que han sido concebidos, cada tipo de sensor registra un intervalo distinto de longitud de onda del espectro (λ , figura 2.1a), promedia la reflectancia medida en un área determinada y almacena los datos divididos en canales espectrales (figura 2.1b). Dichos datos se transmiten de nuevo a la Tierra donde una computadora los convierte en colores o matices de gris para construir una imagen.

Una imagen satelital se define entonces como la representación visual de la información capturada y almacenada en un satélite artificial. Debido a la naturaleza del proceso digital, dichas imágenes son del tipo ráster y se clasifican como pancromáticas o multiespectrales según presentan uno o más canales de información. La energía captada por cada sensor se determina con exactitud a lo largo de un área terrestre, usualmente cuadrada. Tal superficie posee una dimensión definida, denominada distancia de muestreo de tierra o GSD de su acrónimo en inglés (*ground sample distance*) y se corresponde con la resolución espacial o, lo que es lo mismo, la dimensión del pixel. Sin embargo, las imágenes muestran algo más que simple información espacial, también exponen su relación con la información espectral la cual proporciona la comprensión del estado de las características visibles.

¹Los sensores de radiación térmica infrarroja son la única excepción ya que miden las fuentes generadoras de calor tales como centrales eléctricas y no el reflejo de la energía del sol.

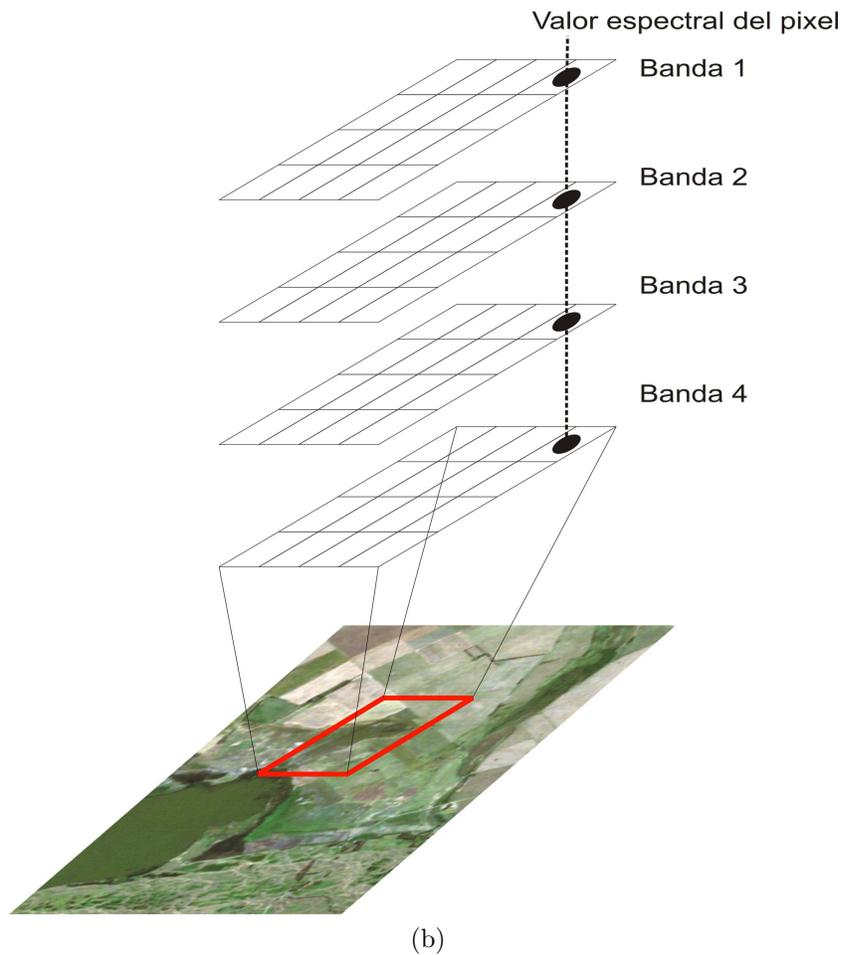
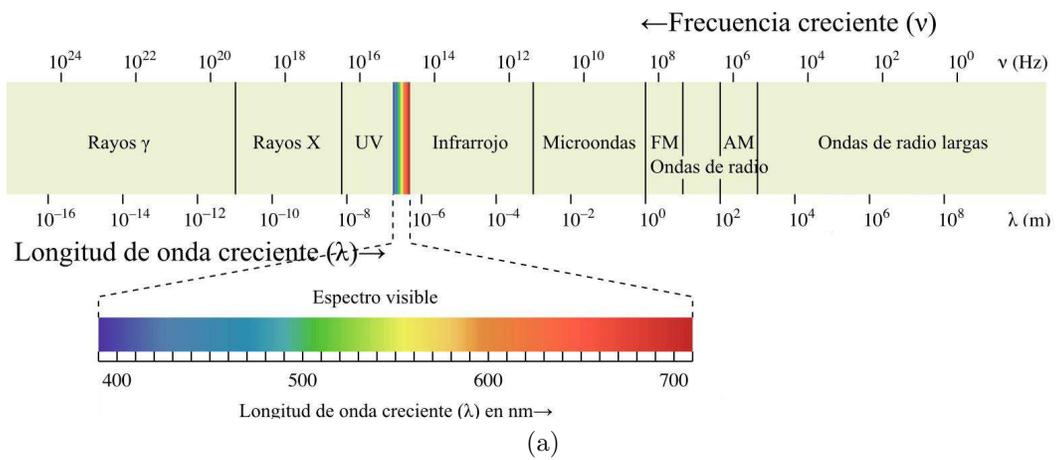


Figura 2.1: (a) Espectro electromagnético. (b) Representación de una imagen satelital multispectral.

2.3. Espacios de color

Un modelo de color es una representación matemática abstracta que describe la forma en la que los colores se definen como vectores de números. Normalmente las tuplas² se componen de tres o cuatro valores y permite su reproducción en formato digital. Dicho modelo se asocia mediante una función de mapeo a un espacio de color y para definirlo se emplea una referencia estándar.

La Comisión Internacional de L'Éclairage o CIE, basados en los experimentos realizados a finales de los años 20, definen con precisión en 1931 la referencia estándar habitual: el espacio de color CIE (Russ, 1993). El mismo está diseñado para abarcar todos los colores que el ser humano puede ver (figura 2.2a³) a partir de la suma de radiaciones de luz o, síntesis aditiva de color. Diversos espacios de color se establecen siguiendo este estándar o modelo RGB donde los tres colores primarios están determinados por el Rojo (R), el Verde (G) y el Azul (B) (figura 2.2b⁴).

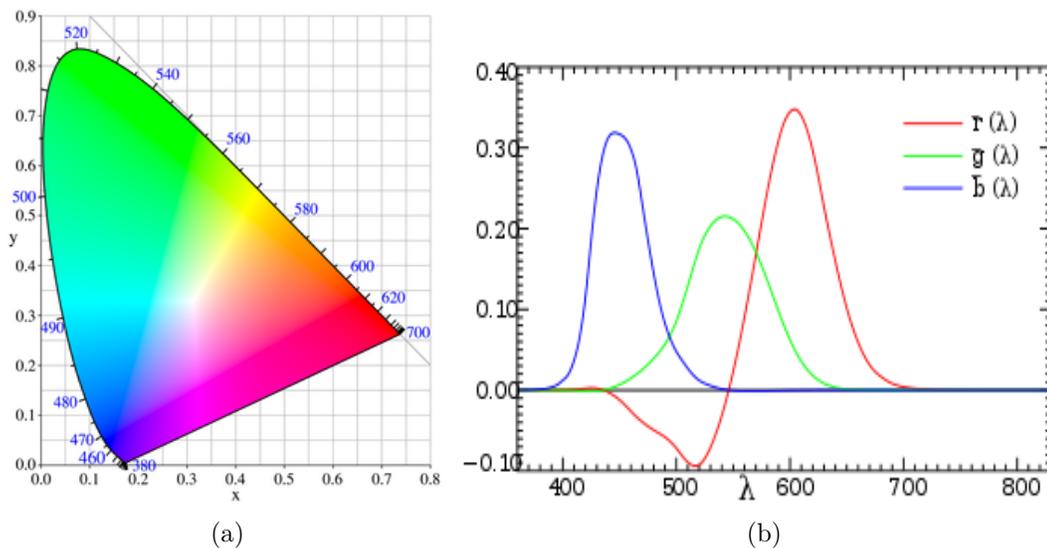


Figura 2.2: Estándar CIE. (a) Diagrama de cromaticidad. (b) Percepción de los conos de la retina humana en respuesta a la luz. Funciones espectrales en función de la longitud de onda, λ . $X(\lambda)$ en línea roja, $Y(\lambda)$ en verde y $Z(\lambda)$ para $10X$ en azul.

²Una tupla, es una secuencia ordenada de objetos, en este caso números, cuya estructura se puede describir a partir de un número finito de componentes.

³Gráficos extraídos de: http://en.wikipedia.org/wiki/CIE_1931_color_space

⁴Gráficos extraídos de: http://en.wikipedia.org/wiki/CIE_1931_color_space

En el espacio RGB, las coordenadas cromáticas xy y el punto blanco, D65 (cuerpo negro a 6500K) se especifican dentro de la figura 2.3⁵. Su implementación adquiere diferentes formatos siendo el más utilizado el de 24 bits, con 8 bits por canal (256 niveles de color discretos). Cualquier espacio de color basado en ese modelo RGB de 24 bits está limitado a un rango de $256 * 256 * 256 \approx 16,7$ millones de colores. Algunas implementaciones usan 16 bits por componente para un total de 48 bits, resultando en la misma gama con mayor número de colores. El mismo principio se aplica en cualquier espacio de color basado en el mismo modelo, pero implementado con distinta profundidad de color. Sin embargo, el espacio RGB presenta una alta correlación de información entre bandas que dificulta la segmentación de la información útil del entorno.

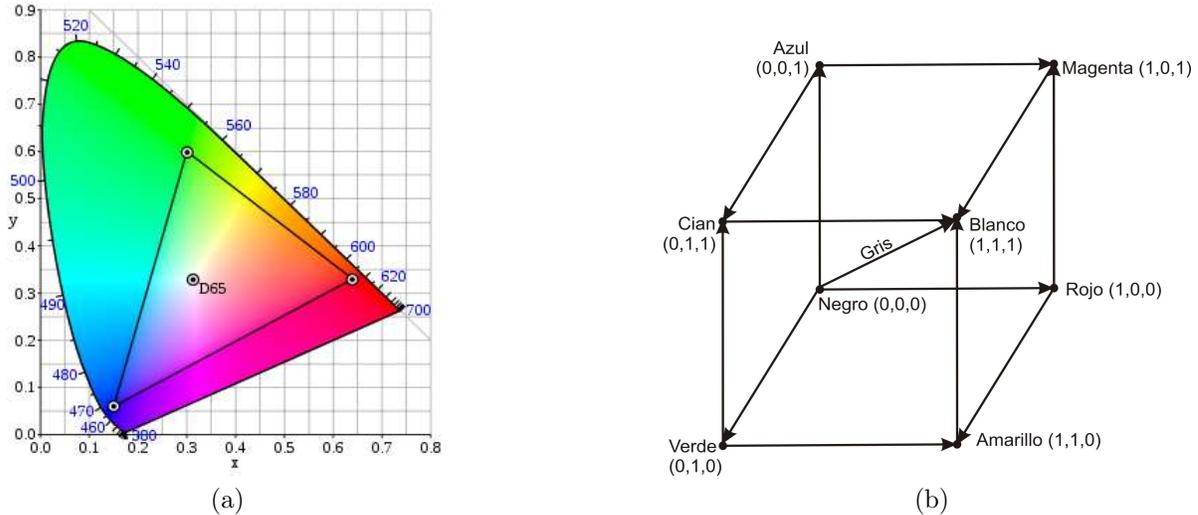


Figura 2.3: Espacio de color RGB. (a) Gráfico de cromaticidad de los primarios rojo, verde y azul, y del blanco D65 (cuerpo negro a 6500K). (b) Cubo de colores en el espacio RGB.

Surge como alternativa el espacio de color YIQ establecido por el estándar de televisión NTSC. Este modelo representa la información de luminancia con un único coeficiente, “Y” desacoplado de la cromaticidad (figura 2.4a), mientras que la información de color se almacena en “I” y “Q” (figura 2.4). La componente “I” significa en fase (en inglés, *in-phase*) mientras que “Q” en cuadratura (*quadrature*). Este sistema tiene la ventaja de utilizar las características de la respuesta humana al color. El ojo es mucho más sensible a los cambios de luminancia que a cambios en la cromaticidad y dentro de la cromaticidad, es más sensible a cambios en el rango naranja-azul (I) que en el rango púrpura-verde (Q). Por

⁵Gráficos extraídos de: http://es.wikipedia.org/wiki/Espacio_de_color_sRGB

Cromaticidad	Rojo	Verde	Azul	D65
x	0,6400	0,3000	0,1500	0,3127
y	0,3300	0,6000	0,0600	0,3290
z	0,0300	0,1000	0,7900	0,3583

Tabla 2.1: Espacio de color RGB. Coordenadas de la cromaticidad, (x, y, z) , en el diagrama para la componente del rojo, del verde, del azul y un valor blanco de referencia (6500 K).

lo tanto, se requiere menos ancho de banda para Q que para I (figura 2.4b). La conversión entre ambos espacios de color, RGB e YIQ, se obtiene mediante una transformación lineal entre sus componentes (González y Woods, 1996; Russ, 1993).

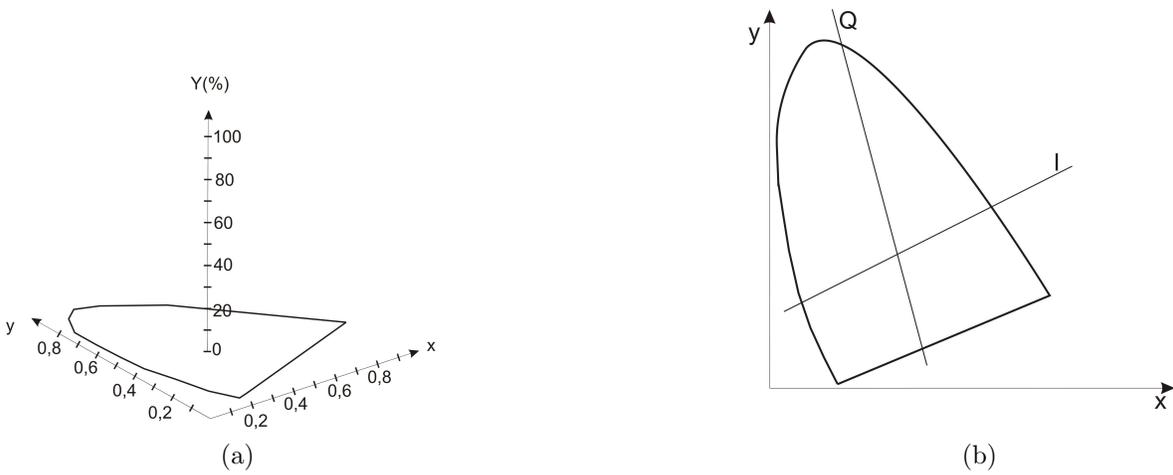


Figura 2.4: Espacio de color YIQ. (a) Componente Y en el estándar CEI. (b) Componentes I y Q en el estándar CEI.

2.3.1. Matrices de conversión entre los RGB e YIQ

La matriz de cambio de $RGB \rightarrow YIQ$ se encuentra dada por

$$[H] \begin{bmatrix} Y \\ I \\ Q \end{bmatrix} = \begin{bmatrix} 0,299 & 0,587 & 0,114 \\ 0,59572 & -0,27445 & -0,32126 \\ 0,21146 & -0,52259 & 0,31113 \end{bmatrix} * \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.1)$$

donde las coordenadas R , G y B están normalizadas y pertenecen al entorno $[0; 1]$. Mientras que la matriz de transformación de $YIQ \rightarrow RGB$ se define como

$$[H] \begin{bmatrix} R \\ G \\ B \end{bmatrix} = \begin{bmatrix} 1 & 0,95629 & 0,62102 \\ 1 & -0,27212 & -0,64738 \\ 1 & -1,10699 & 1,70461 \end{bmatrix} * \begin{bmatrix} Y \\ I \\ Q \end{bmatrix} \quad (2.2)$$

donde las coordenadas normalizadas de Y , I y Q pertenecen a los entornos $[0; 1]$, $[-0,59572; 0,59572]$ y $[-0,52259; 0,52259]$, respectivamente.

2.4. Segmentación mono-distancia

En esta sección se presenta uno de los métodos utilizados para segmentar, el cual se basa en el concepto de distancia mínima (Girard y Girard, 1999; Richards y Jia, 2006) a un pixel prototipo. Un pixel prototipo, patrón o referencia (\vec{r}) representa en su composición en bandas las características típicas del objeto que se desea segmentar. Luego de la selección del pixel patrón, se determina una función escalar que relaciona los datos de todas las bandas de información de la imagen con un único coeficiente (figura 2.5a).

El algoritmo establece el descriptor escalar por pixel que calcula la distancia entre el pixel prototipo y todos los pixels de la imagen en un espacio cromático específico. A partir de dicho coeficiente y una escala de gris, se construye una *imagen distancia* (ID) la cual agrupa sus niveles en dos modos dominantes. A su vez, se analizan los coeficientes obtenidos en ID y se los clasifica mediante un valor de umbral U permitiendo dividir la imagen en regiones de figura o fondo⁶. A la ID binarizada se la denomina *máscara* (IM) (figura 2.5b). El umbral óptimo U se establece de acuerdo a diversos criterios como por ejemplo un clasificador Bayesiano (Rish, 2001), el método de Otsu (Otsu, 1979), análisis de histograma, etc.

⁶A lo largo de todo el trabajo de tesis se utilizan de manera análoga los términos figura/fondo, blanco/negro y predido/apagado. Un pixel de figura, blanco o prendido hace referencia a un pixel perteneciente al objeto segmentado mientras que un pixel de fondo, negro o apagado representa un pixel del entorno en el cual se encuentra inmerso.

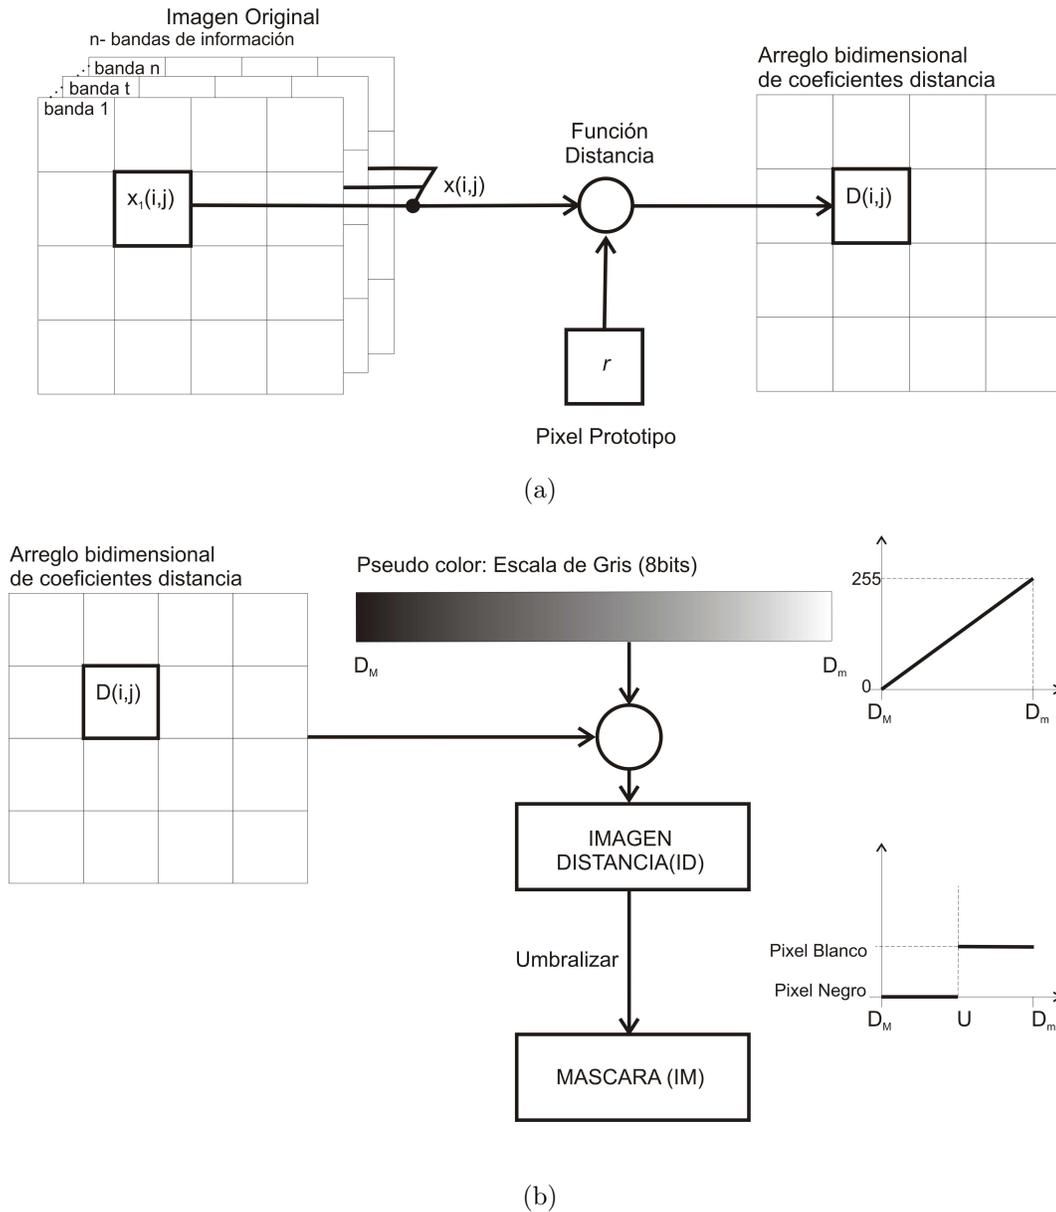


Figura 2.5: Segmentación a un pixel prototipo a partir de una imagen multispectral. (a) Cálculo de los coeficientes $D(i, j)$ de la matriz distancia. (b) Construcción de ID e IM empleando la escala de grises de 8-bits y un valor de umbral $= U$.

2.4.1. Operador de distancia mínima a un pixel prototipo

El operador de distancia mínima evalúa el “camino cromático más corto” entre dos pixels en un espacio de color dado. En este caso, entre cada uno de los pixels de la imagen

y el pixel de referencia. El resultado asocia a cada punto de la imagen una etiqueta o, magnitud escalar D , la cual se emplea para comparar con un valor de umbral y segmentar.

El operador distancia

$$D(i, j) = \sqrt[k]{\sum_{t=1}^n a_t (x_t(i, j) - r_t)^{k_t}} \quad (2.3)$$

generaliza la norma, sin por ello dejar de ser una métrica, por ser más flexible. Éste operador pondera cada banda de la imagen de manera diferente o simplemente determina la distancia Euclidiana en el espacio n -dimensional, donde n es la cantidad de bandas o canales de información que componen la imagen.

El $\vec{x}(i, j)$ es el pixel de la columna i y la fila j y \vec{r} contiene la información espectral del pixel prototipo. La referencia no es necesariamente un pixel dentro de la imagen, es posible que se trate del promedio en el espacio cromático de varios pixel característicos de figura o, incluso, provenir de un modelo. El subíndice t , identifica la t -ésima banda de información y varía entre $1 \leq t \leq n$. El peso final de cada banda en el resultado de distancia, se controla a partir de la aplicación de la potencia aplicada k_t y el factor de multiplicación a_t en ambos casos ≥ 0 . Finalmente se aplica la raíz K -ésima sobre la sumatoria. La usual norma 2 o Distancia Euclidiana entre los vectores \vec{x} y \vec{r} , se obtiene asignando 1 a todos los factores a_t y 2 a los coeficientes k_t y K .

Del resultado de aplicar el operador se desprende que a menor distancia mayor probabilidad de tratarse de un pixel figura y, a mayor distancia, mayor probabilidad de tratarse de un pixel del fondo. A partir del análisis del histograma es posible determinar un valor óptimo de distancia D como umbral, U , siguiendo algún criterio tal que la información se divida en dos grupos: figura o fondo.

2.5. Segmentación multi-distancia

La utilización de imágenes de teledetección de alta resolución obliga a la especialización del método de segmentación. Un único pixel prototipo no alcanza para separar del fondo las formas geométricas dentro de una escena debido a la amplia dispersión cromática (figura 2.6). Dado que las dos clases no son linealmente separables, la metodología anterior es inadecuada. El análisis de su histograma, figura 2.6d, no denota modas y resulta perfectamente visible en las imágenes de la figura 2.7 los errores de clasificación incluso

con el cambio de valor de umbral. Por dicha razón, se emplean múltiples pixels de referencia con el fin de caracterizar de mejor manera cada zona. La nueva metodología divide la información mediante distancia mínima a múltiples pixels de referencia consiguiendo segmentar valores heterogéneos y minimizando la aparición de falsos positivos y falsos negativos.

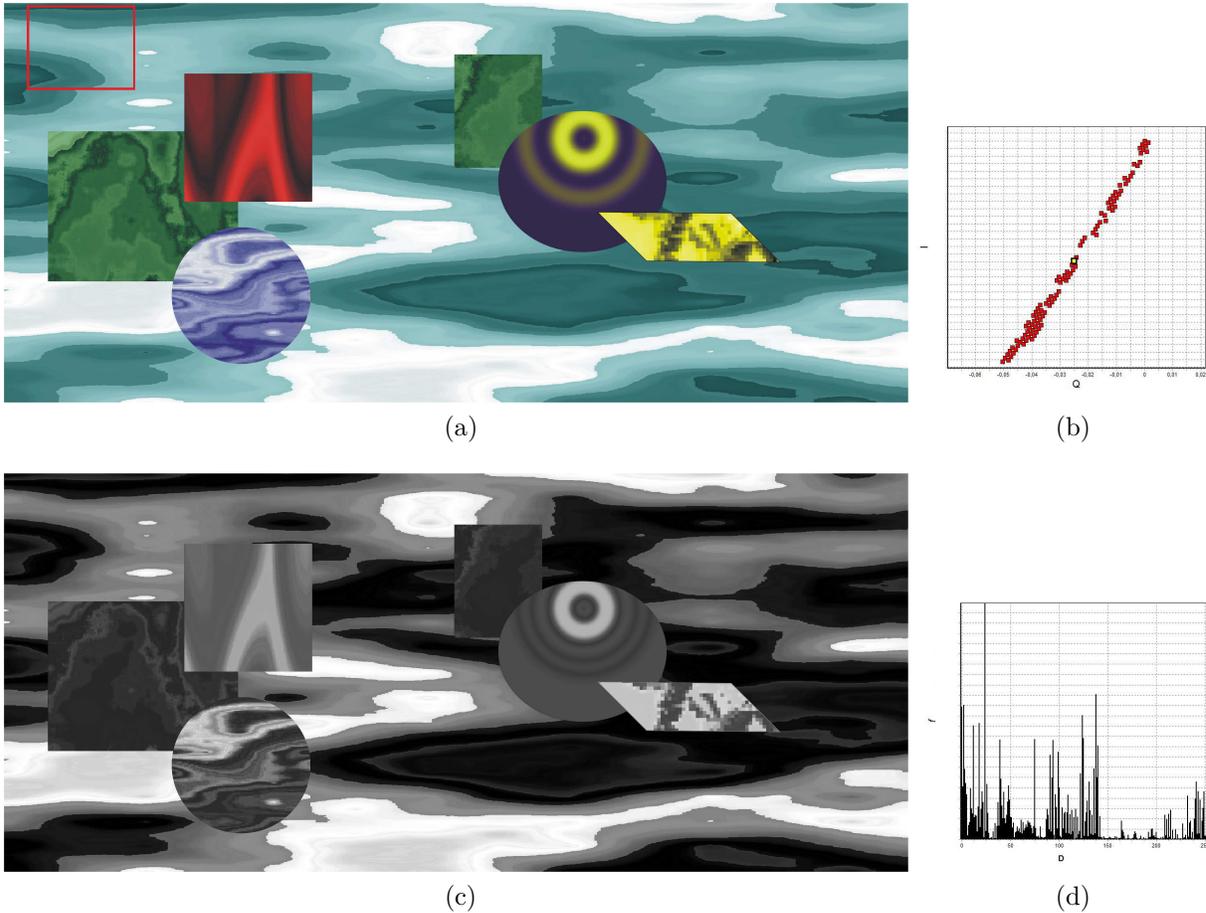


Figura 2.6: Segmentación de una imagen sintética RGB donde el objetivo es separar las formas geométricas del entorno. (a) Imagen original con la región seleccionada para determinar el pixel prototipo. (b) Dispersión de los pixels de figura seleccionados previamente. Como prototipo se elige el pixel central el cual se destaca en color amarillo. (c) Imagen Distancia resultante(ID). (d) Histograma de ID.

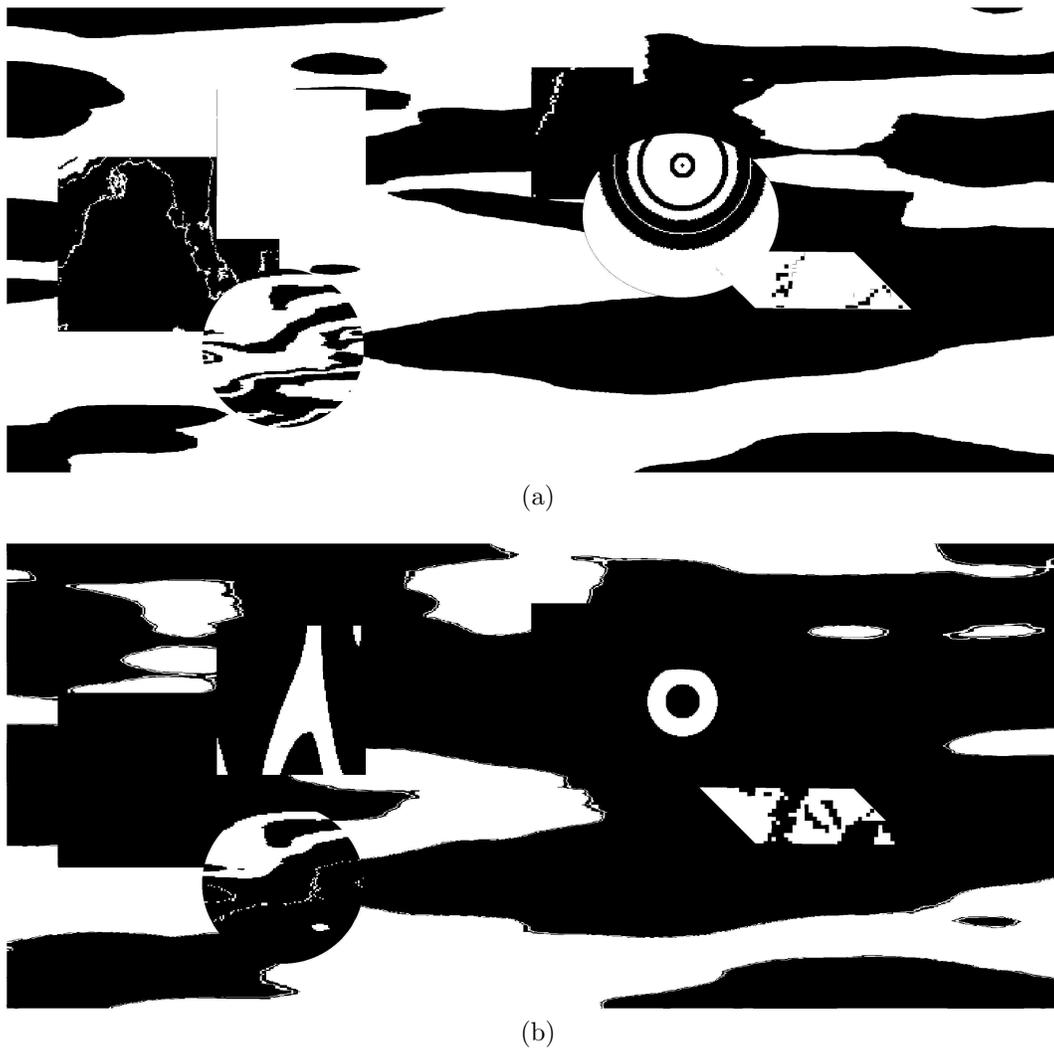


Figura 2.7: Clasificación por umbral U figura/fondo de la figura 2.6c. Umbral empleado: (a) $U = 70$ y (b) $U = 127$.

El algoritmo realiza un análisis en función del cómputo de distancia entre todos los pixels patrones con cada uno de los pixels de la imagen y determina un único coeficiente D . La imagen distancia de salida traduce el valor de cada coeficiente en información cromática en función de la escala utilizada. El resultado se controla a partir de la selección de pixels de referencia divididos en dos grupos: figura y fondo. Al igual que en el caso anterior, se construye a partir de D y una escala de gris la *imagen distancia* (ID) y se obtiene la máscara (IM) clasificando por valor de umbral U .

2.5.1. Selección de pixels prototipos

La determinación de los pixels prototipo es crucial para obtener un buen descriptor. La primer propuesta implicaba determinar dos secciones de la imagen, una de la zona de figura y otra de la región de fondo y utilizar varios puntos de cada una de esas regiones como pixels prototipo. El operador resultante

$$\left. \begin{aligned} D^f &= \min_{1 \leq f \leq F} (d^f) \\ D^b &= \min_{1 \leq b \leq B} (d^b) \end{aligned} \right\} D(i, j) = \min(D^f, D^b) \quad (2.4)$$

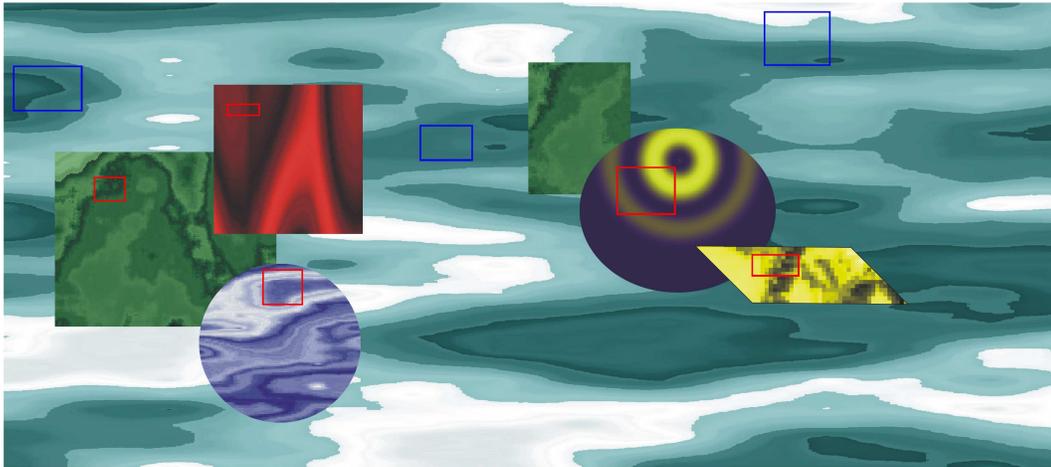
determina el coeficiente D como la mínima distancia entre todos los pixels prototipo distinguiendo entre mínima distancia a pixel de figura o fondo. Este procedimiento se descartó debido a la inclusión de información redundante, el bajo contraste de las imágenes distancia y el excesivo costo computacional.

También se utilizó otro método usual de selección el cual consiste en elegir un sector de la imagen que se corresponda con la zona a desacoplar y utilizar el valor medio o centroide de la firma espectral de los pixels de dicho sector como pixel de referencia (Friedman y Rubin, 1967; Haralick y Kelly, 1969; Saha y Bandyopadhyay, 2010). Sin embargo, esta metodología no produce resultados satisfactorios en imágenes con alta dispersión cromática y, por lo tanto, para estos casos se desarrolla una nueva teoría de selección de los múltiples prototipos de figura y fondo.

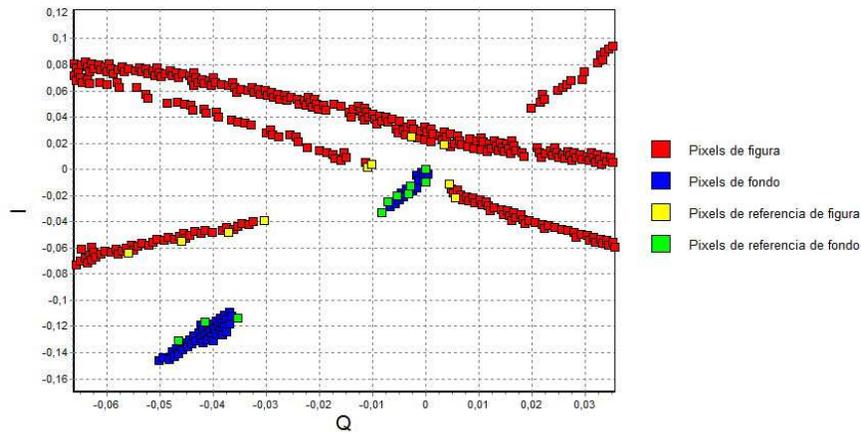
Definida las regiones de interés que se desean segmentar se eligen secciones que correspondan a porciones de figura y fondo (figura 2.8a). La distribución de los pixels distinguiendo si se tratan de pixels de figura o fondo determina la localización óptima de las referencias. Cada pixel patrón se selecciona de la frontera entre dos zonas continuas de clases diferentes y el número total de muestras depende de la distribución de las “islas” de puntos dentro del diagrama de dispersión.

El procedimiento se ilustra con la figura 2.8a con la cual previamente no se obtuvieron resultados satisfactorios. Además, en lugar de estudiar la distribución de los pixels en el espacio de color RGB, se analiza la distribución en el plano I vs Q para evitar la fuerte correlación de información. Se ilustran dos grupos de pixels, los pixels de figura indicados en rectángulos rojos y los de fondo indicados en rectángulos azules (figura 2.8a). La figura 2.8b muestra la variación en el plano previamente indicado de las regiones de pixels seleccionados donde se observa la dispersión de firmas espectrales. Los prototipos de figura

y fondo, resaltados en color amarillo y verde, respectivamente, se eligen de los bordes entre regiones vecinas de diferente clase. El clasificador distancia, entonces, determina el grupo al que pertenece cada pixel, en función de cual de estos prototipos es el más cercano.



(a)



(b)

Figura 2.8: Selección de pixels prototipo. (a) Imagen sintética con las regiones delimitadas. (b) Gráfico de dispersión de I vs Q de las regiones seleccionadas en (a).

2.5.2. Operador distancia a múltiples pixels prototipo

A partir de la elección de un objeto figura dentro de la imagen el cual se desea separar del fondo, se seleccionan dos grupos representativos de pixels de referencia pertenecientes uno a cada zona: \vec{r}^f y \vec{r}^b figura y fondo, respectivamente siguiendo la metodología descrita

en la sección anterior. El superíndice f/b corresponde al f/b -ésimo pixel de referencia de figura/fondo el cual varía entre $1 \leq f \leq F / 1 \leq b \leq B$ donde F/B es la cantidad total de prototipos de cada clase. Dada la ecuación 2.3 con sus parámetros definidos, se calcula la distancia (d^f / d^b) de cada uno de los pixel de la imagen con todos los pixels patrón y se conservan las mínimas distancias correspondientes obtenidas (D^f / D^b). El coeficiente D final de un pixel en la imagen se determina relacionando ambas distancias mínimas de figura y fondo. Es decir, se calcula como la relación entre D^f y D^b si $D^f \leq D^b$ o viceversa si $D^f > D^b$ (figura 2.9a).

El operador distancia resultante es

$$\begin{aligned}
 d^f(i, j) &= \sqrt[k]{\sum_{t=1}^n a_t(x_t(i, j) - r_t^f)^{k_t}} , \\
 D^f(i, j) &= \min_{1 \leq f \leq F} (d^f) \\
 d^b(i, j) &= \sqrt[k]{\sum_{t=1}^n a_t(x_t(i, j) - r_t^b)^{k_t}} , \\
 D^b(i, j) &= \min_{1 \leq b \leq B} (d^b)
 \end{aligned}
 \Rightarrow D(i, j) = \begin{cases} -\frac{D^f(i, j)}{D^b(i, j)} & \text{si } D^f(i, j) \leq D^b(i, j) \\ \frac{D^b(i, j)}{D^f(i, j)} & \text{si } D^f(i, j) > D^b(i, j) \end{cases}
 \tag{2.5}$$

donde todos los coeficientes $D(i, j)$ de la matriz distancia se encuentran dentro del entorno $[D_m, D_M]$ cuyo subíndice M/m corresponde al valor máximo/mínimo calculado.

Del resultado de aplicar el operador, se desprende que a menor distancia a un pixel patrón de figura/fondo mayor probabilidad de tratarse de un pixel de figura/fondo. Por lo tanto, es posible determinar el valor de distancia óptimo como umbral en $U = |D_M^b|$ para clasificar la información en dos grupos. La *imagen distancia* se construye a partir del arreglo bidimensional de coeficientes $D(i, j)$ y utilizando un pseudocolor en escala de gris que asigna blanco a la menor distancia a un pixel patrón figura (D_m^f) y negro a la menor distancia a un pixel patrón de fondo (D_m^b) (figura 2.9b).

Sobre la imagen sintética se aplica el proceso de segmentación con la intención de separar las figuras geométricas del resto de la información de la imagen. Los 20 puntos de referencia detallados en la tabla 2.5.2, 10 de ellos pertenecen al fondo y los otros 10 a zonas de figura, se eligen según el proceso descrito en la sección 2.5.1 de las fronteras de conjuntos de pixels de diferente clase. Cabe destacar que todos los pixels patrón siguiendo esta metodología pertenecen a la imagen. En la figura 2.10 se muestran las imágenes resultantes ID e IM y el valor de umbral aplicado en la obtención de la máscara es $U = 110$.

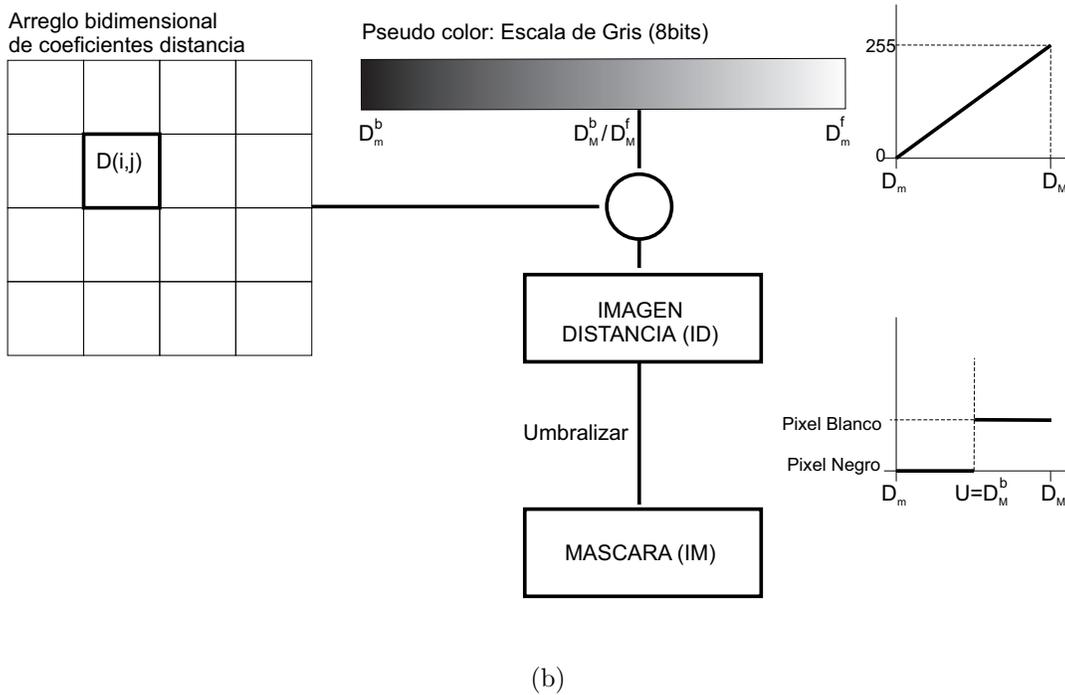
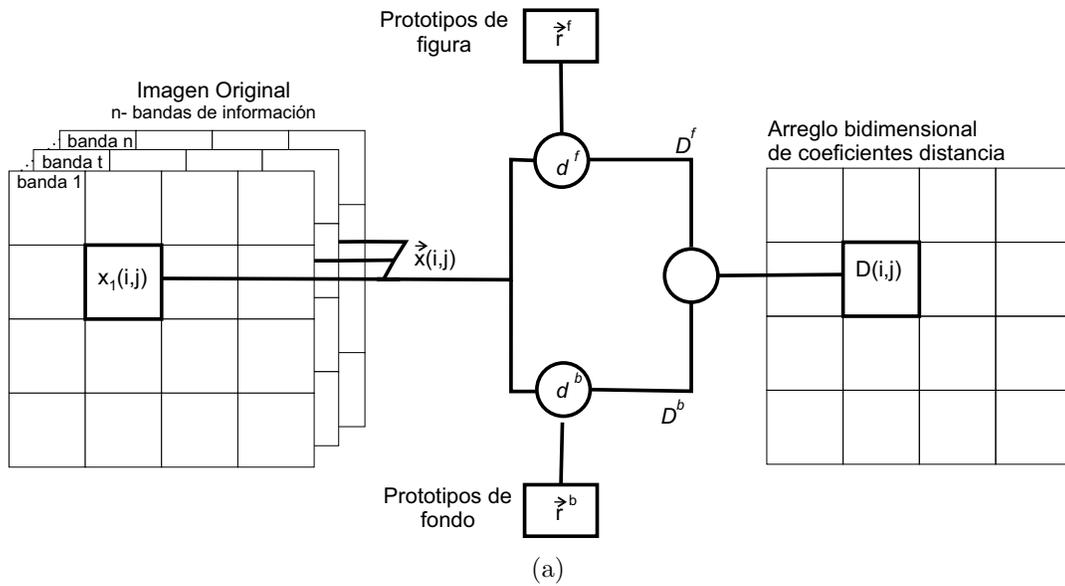
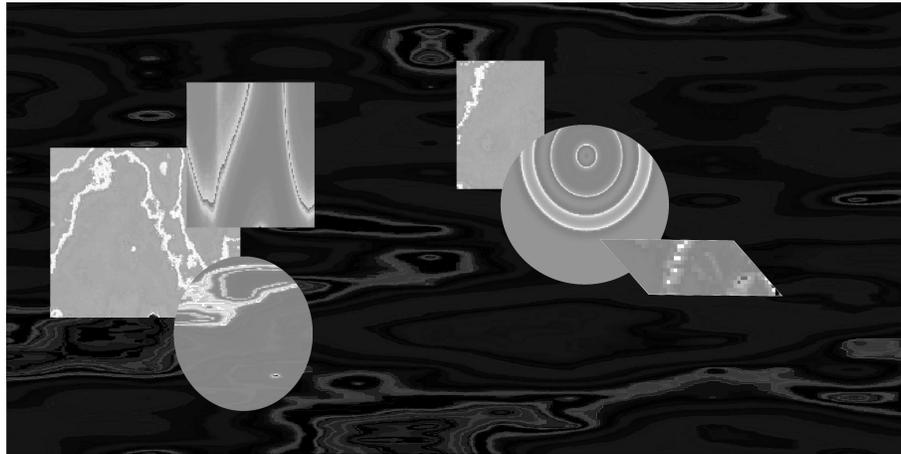
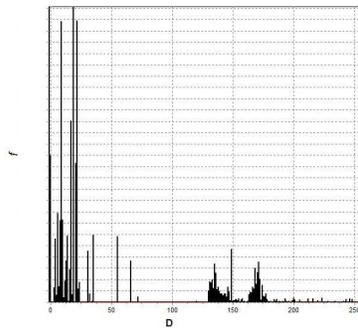


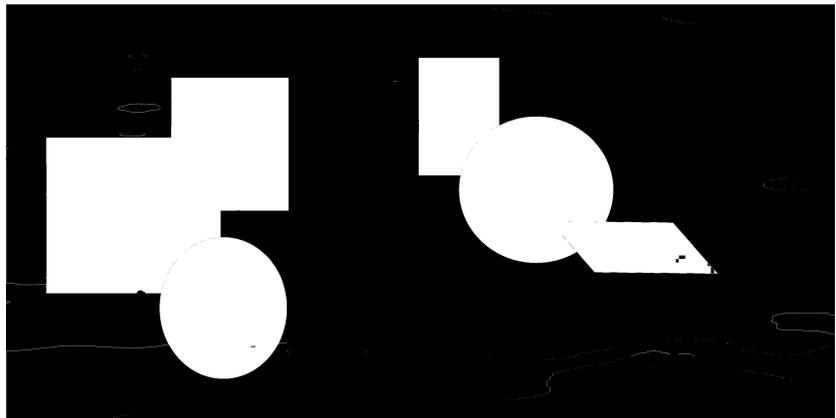
Figura 2.9: Segmentación a múltiples pixels prototipo a partir de una imagen multiespectral. (a) Cálculo de los coeficientes $D(i, j)$ de la matriz distancia. (b) Construcción de ID e IM empleando la escala de grises de 8-bits y un valor de umbral $= U$.



(a)



(b)



(c)

Figura 2.10: Resultado de la segmentación de la figura 2.8a. (a) Imagen Distancia. (b) Histograma de la imagen Distancia. (c) Máscara de la la imagen Distancia.

Claramente el resultado final disminuye en forma drástica la aparición de falsos positivos y falsos negativos permitiendo su utilización para etapas posteriores de procesamiento.

Pixel		Región (Z/F)	I-Q		Pixel		Región (Z/F)	I-Q	
i	j		I	Q	i	j		I	Q
2623	32	F	0	0	1958	546	Z	0,025172	-0,00271
2573	52	F	-0,00952	0	2027	550	Z	0,018878	0,003380
2573	53	F	-0,01887	-0,00338	873	859	Z	-0,01096	0,004435
2602	46	F	-0,03290	-0,00836	878	868	Z	-0,02175	0,005599
2564	68	F	-0,02463	-0,00709	2503	803	Z	0,004137	-0,01020
2603	45	F	-0,01294	-0,00293	2490	803	Z	0,001799	-0,01103
2465	76	F	-0,01995	-0,00543	366	557	Z	-0,03883	-0,03048
2423	84	F	-0,11362	-0,03541	339	570	Z	-0,04800	-0,03708
151	246	F	-0,11686	-0,04156	343	604	Z	-0,05465	-0,04611
96	308	F	-0,13088	-0,04655	296	600	Z	-0,06363	-0,05598

Tabla 2.2: Lista completa de los pixels prototipo empleados para segmentar la imagen sintética.

2.6. Resumen

- Se proponen y estudian técnicas para segmentar objetos que luego permitirá aislar accidentes geográficos en imágenes satelitales.
- Las segmentaciones propuestas son semi-asistidas, y superan en performance y resultados a las obtenibles en sistemas comerciales lo cual se demostrará en el capítulo de resultados.
- Dependiendo de la complejidad del problema (lo confusas que sean en apariencia las áreas a segmentar) el método multidistancia requiere que el usuario determine cantidades crecientes de prototipos.
- El aumento del número total de pixels de referencia implica el incremento del costo computacional.
- Existen casos donde esta separación es imposible, en las conclusiones de la tesis se propondrá una manera de abordar el problema.

Capítulo 3

Medición súper resolución de característicos lineales

La medición de característicos lineales en imágenes de teledetección remota es el primer paso en el estudio morfológico de accidentes geográficos. Sin embargo, a diferencia de los algoritmos de medición de áreas, los métodos estándar de medición de perímetros en imágenes digitales poseen un alto grado de error sistemático asociado. La precisión no mejora con un aumento en la resolución de la imagen debido a diversos factores geométricos.

En este capítulo se presenta la implementación de un método de cálculo de características lineales. El mismo se basa en el algoritmo *marching squares* mejorado a partir de interpolación lineal. Dicha técnica permite obtener mayor precisión en los resultados que los métodos tradicionales de medición con imágenes de igual resolución. El algoritmo se estudia sobre imágenes sintéticas para analizar su comportamiento y se valida sobre imágenes de teledetección con mediciones de campo. Los errores producidos por la orientación, el tamaño y la forma del objeto a medir se minimizan sensiblemente.

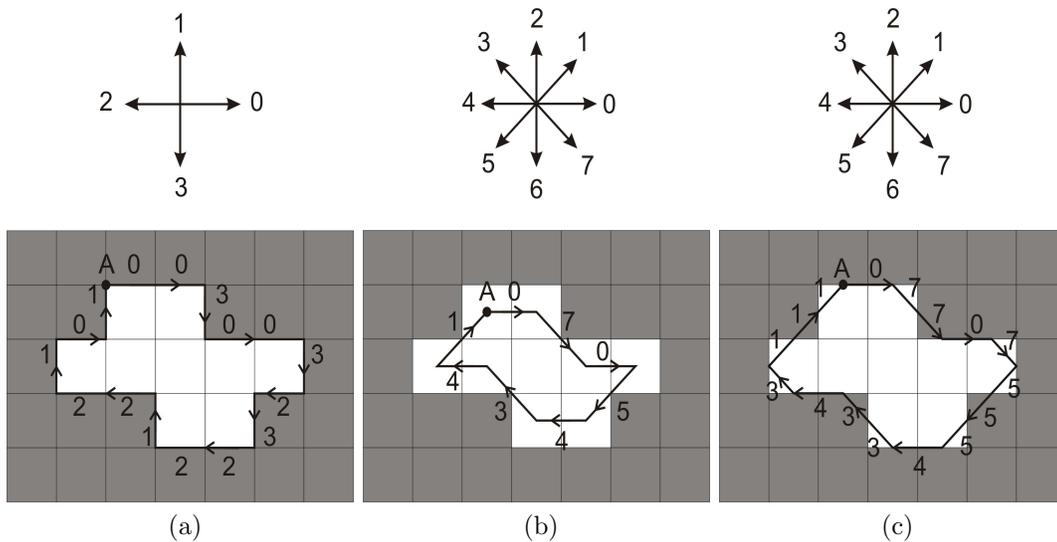


Figura 3.1: Ejemplos de algoritmos de cadena. Código numérico generado en sentido horario a partir del punto A. (a) Bordes exteriores de los pixel, secuencia: 0030032322122101. (b) Chain code, secuencia: 07054341. (c) Mid-crack, secuencia: 0770755543343111.

3.1. Antecedentes

La diversidad de imágenes disponibles, en especial, imágenes multiespectrales de baja resolución provenientes de misiones satelitales como las misiones Landsat 5 o Landsat 7, aseguran una gran cobertura espacial a un costo razonable. Sin embargo, es posible observar que los algoritmos de segmentación y medición de características lineales utilizados por los sistemas de información geográficos (SIG) más difundidos cometen errores sistemáticos. Su uso para estimaciones geográficas precisas, como pueden ser las características lineales de accidentes geográficos, es muy limitado. Los métodos de cadena o “chain codes” (Freeman, 1961, 1970; González y Woods, 1996) fueron desarrollados por Freeman en 1961 para codificar y facilitar el análisis de figuras geométricas en forma digital. Dichos algoritmos describen una poligonal cuyos segmentos poseen longitud fija, dirección y número para codificar el movimiento (figura 3.1).

A partir de la localización dentro de una imagen binaria de un pixel de frontera, se genera una cadena que rodea al objeto desplazándose de un pixel de frontera al siguiente. Dicho método analiza dos casos particulares teniendo en cuenta si contempla 4 u 8 niveles de adyacencia o, lo que es equivalente, según la cantidad de direcciones que pueden tomar los movimientos. Para diferenciarlos, se denominará Bordes Exteriores de los

Pixels(figura 3.1a) al algoritmo de Freeman con 4 niveles de adyacencia y Chain Code al método con 8 niveles de adyacencia (figura 3.1b). Ambos fueron creados para recorrer el objeto a medir vinculando un paso con el otro y formar el código de la cadena que rodea el objeto. Sin embargo, dependiendo de su implementación, es posible alcanzar el mismo resultado sin cumplir con esta condición. La fórmula de cálculo del perímetro fue desarrollada por Freeman y mejorada en estudios posteriores (Kulpa, 1977; Vossepoel y Smeulders, 1982) a partir de la aplicación de diversos factores de corrección determinados por el análisis del error. En ambos casos, la mejora en los resultados dependía específicamente de las cualidades de la figura a medir (Kulpa, 1983; Yang et al., 1994).

El Crack Code (Dunkelberger y Mitchell, 1985) también denominado Mid Crack, introduce una mejora sustancial al método de Fremman con ocho niveles de adyacencia en los algoritmos de cadena (figura 3.1c). Luego, Pratt (1991) a partir de notas no publicadas de Duda (Pratt, 1991; Yang et al., 1994), presenta las fórmulas del algoritmo Marching Squares. El Marching Squares produce gráficamente los mismos resultados que el Crack Code pero con un cambio en la metodología de ejecución.

Lorensen y Cline (1987) presentan su técnica para generar una superficie a partir de datos volumétricos la cual se puede *renderizar* (*derivado de “render” en inglés*) por medio de bibliotecas gráficas. Está basado en una generalización del método MS y la denominan Marching Cubes (MC). El algoritmo determina las poligonales mediante el cálculo de interpolación lineal entre las aristas de voxels contiguos. El vóxel (del inglés “volumetric pixel”) es la unidad cúbica que compone un objeto tridimensional. Constituye la unidad mínima procesable de una matriz tridimensional y es, por tanto, el equivalente del pixel en un objeto 3D. El MC posee severas inconsistencias resueltas por Nielson y Hamann (1991) a partir de interpolación bilineal entre las superficies de voxels vecinos y más tarde, interpolación trilineal en el interior de los voxels para determinar iso-superficies y eliminar las ambigüedades originales del método (Nielson, 2003).

3.2. Algoritmos de medición estándar

Consideraciones preliminares

Una imagen digital se puede representar como un arreglo bidimensional dentro de una grilla cartesiana de pixels con superficie cuadrada denominados *rasters*. Cada pixel posee información de color separada en n -bandas, tiene asociado un valor de resolución (L) correspondiente a la longitud del lado del pixel y coordenadas que determinan su

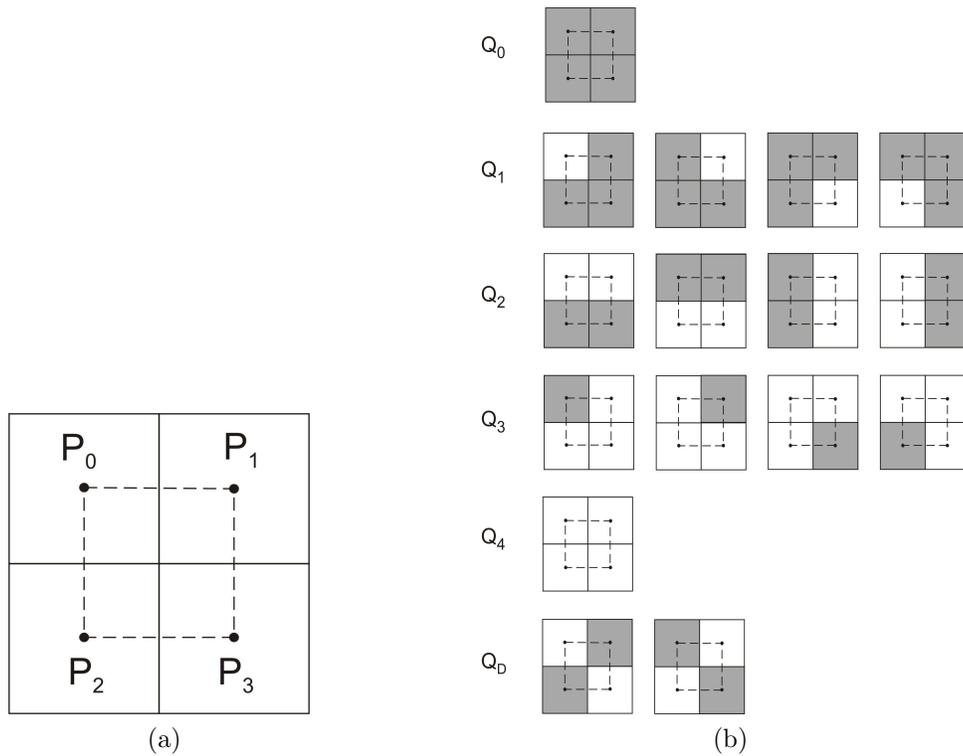


Figura 3.2: (a) Definición de un Bit quad: ventana de 2x2 pixels. (b) Configuraciones posibles: combinaciones de pixels blancos y negros.

ubicación dentro de la grilla. A su vez, una imagen binaria está compuesta por pixel blancos y negros, en donde los pixels blancos o píxeles figura corresponden al objeto a medir y los negros corresponden a los pixel del fondo. En particular, dentro de una imagen binaria se denomina *pixel frontera* a un pixel blanco/negro adyacente en al menos una arista con un pixel negro/blanco.

Un *Bit Quad*, figura 3.2a, es una ventana de 2x2 pixels cuyos patrones de pixels prendidos (blancos) o apagados (negros), fueron clasificados por Gray (1971) a partir del número de Euler. En la figura 3.2b se presentan las 16 configuraciones posibles de las cuales Q_1 , Q_2 , Q_3 y Q_D corresponden a zonas de borde mientras que las configuraciones Q_0 y Q_4 pertenecen a zonas de fondo y figura, respectivamente. Posteriormente, el análisis de todos los Bit Quad de la imagen permitirá la reconstrucción de la frontera.

Bordes exteriores de los pixels

El algoritmo Chain Code con 4-niveles de adyacencia o *Bordes exteriores de los pixels* (BEP) es el método de cómputo más sencillo y se aplica sobre una imagen binaria. La poligonal del borde se construye a partir de segmentos de longitud fija L . Las líneas unen los extremos de cada pixel frontera desplazándose de un punto a otro de la arista del raster en ángulos rectos hasta rodear el objeto (figura 3.1a). El perímetro total es la sumatoria de los bordes exteriores de los pixel frontera.

Chain Code

El algoritmo Chain Code con 8-niveles de adyacencia o simplemente *Chain Code* (CC) se aplica sobre una imagen binaria. La poligonal del borde envuelve internamente al objeto desplazándose del centro de un pixel frontera al otro (figura 3.1b). Los segmentos son de longitudes fijas L o $+\sqrt{2}L$ según la dirección del movimiento la cual se determina en función de las características del Bit Quad que contiene el raster en grilla corrida (figura 3.3a). La fórmula para calcular el perímetro desarrollada por Freeman es

$$P = c_p + \sqrt{2}c_i$$

donde c_p y c_i es la suma de segmentos con números pares e impares, respectivamente.

Marching Squares

El algoritmo *Marching Squares* (MS) posee 8 niveles de adyacencia y se aplica sobre una imagen binaria. La poligonal del borde rodea externamente el objeto suavizando las esquinas (figura 3.1c). La longitud y la dirección de cada segmento depende de la configuración de Bit Quad que contiene el raster en grilla corrida (figura 3.3b). El perímetro se calcula como la sumatoria de las longitudes de cada desplazamiento.

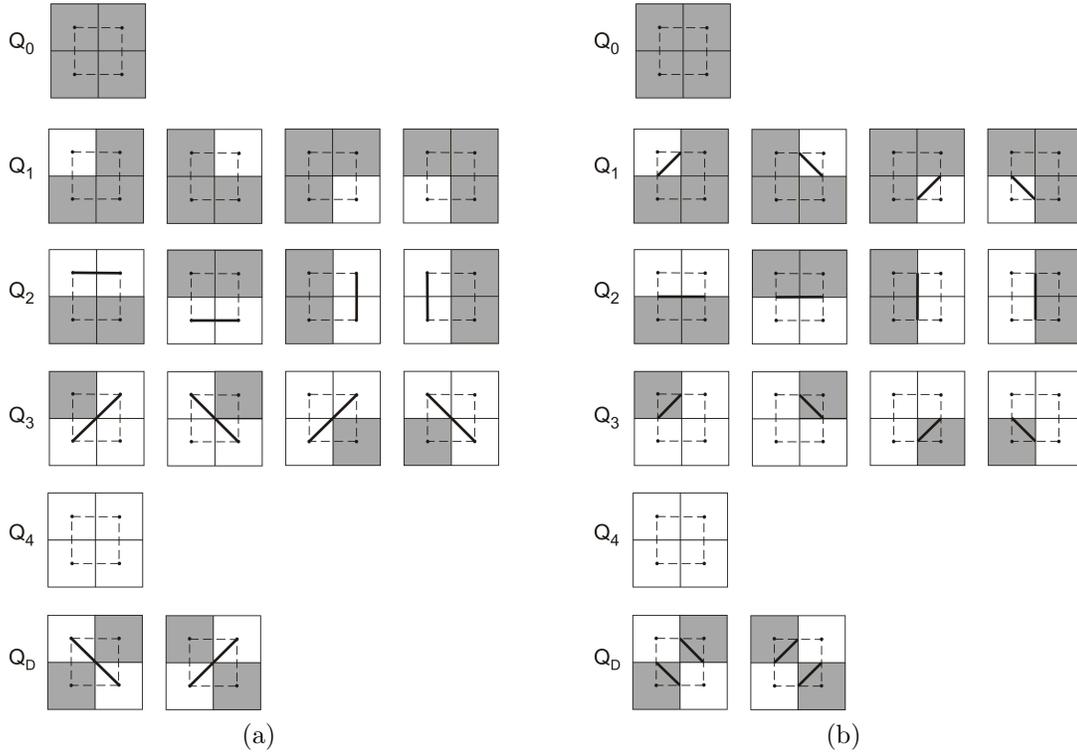


Figura 3.3: Definición de los segmentos de borde de cada configuración de Bit Quad según el método utilizado. (a) Chain code. (b) Marching squares.

3.3. Marching squares con interpolación lineal

En esta sección se presenta un nuevo método de medición de características lineales súper resolución al cual denominamos Marching Squares con Interpolación (MSI; figura 3.4). Se utiliza en forma conjunta la técnica de MS descrita en la sección 3.2 mejorada a partir de interpolación lineal y el método de segmentación por distancia mínima a uno o múltiples pixels prototipo introducido en el capítulo 2. En un primer paso se construye una imagen distancia y su respectiva imagen máscara siguiendo los lineamientos establecidos previamente. La selección de los pixels prototipo \vec{r} , los parámetros \vec{a} , K y \vec{k} del operador distancia y el valor de umbral U se realizan de manera supervisada.

Hasta este momento todos los algoritmos de medición propuestos se aplicaban sobre imágenes binarias desaprovechando el grado extra de información que proporciona la segmentación (Rivest y Soille, 1995) y que se pierde al umbralizar. El método MSI (Cipolletti et al., 2012) es la adaptación bidimensional del método MS que incluye la información de

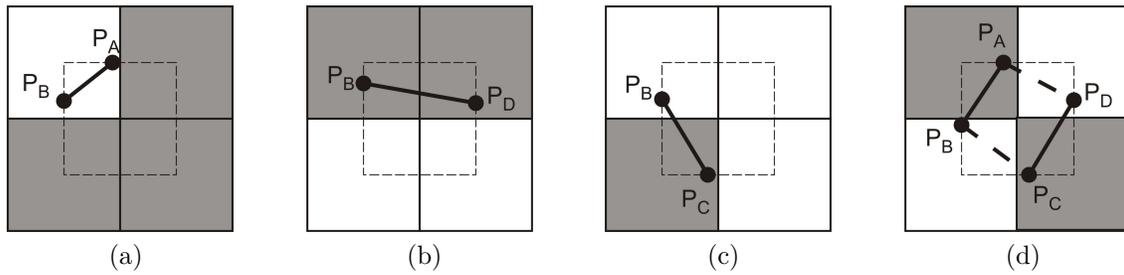


Figura 3.4: Bit Quads correspondientes a zonas de borde. A modo de ejemplo se presentan los segmentos de borde en las distintas configuraciones. (a) Q_1 . (b) Q_2 . (c) Q_3 . (d) Caso ambiguo: Q_D . Un juego de segmentos posible se dibuja con líneas recta y el otro con líneas de puntos.

distancia. Se obtiene un contorno súper resolución utilizando la imagen en escala de grises ID y su binarización IM construida a partir del umbral U . El método recorre IM y analiza las propiedades locales de cada Bit Quads (figura 3.2b) en busca de configuraciones de borde.

Las configuraciones de frontera Q_1 , Q_2 y Q_3 poseen un solo par de coordenadas asociadas al fragmento de borde el cual queda unívocamente determinado (figura 3.4). Sin embargo, las configuraciones del tipo Q_D , usualmente denominadas casos ambiguos, poseen dos pares de coordenadas ligadas a dos juegos de segmentos. Si bien se produce una indeterminación la elección de unos u otros no introduce errores significativos en el cómputo final del perímetro. En la figura 3.4d cada par se diferencia con tramos en línea recta y punteada respectivamente. Dado cualquier segmento, cada coordenada del mismo se sitúa en la línea que une los puntos medios de los pixels que lo contiene (figura 3.5) y su posición dentro del mismo se determina relacionando la información proveniente de ID y el valor de umbral U .

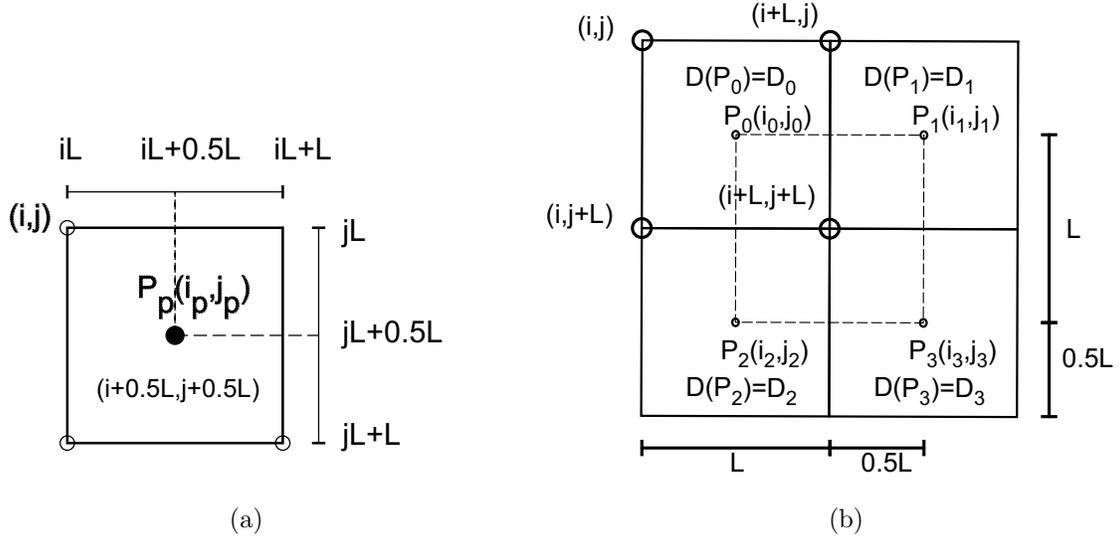


Figura 3.5: (a) Cotas de un pixel. (b) Coordenadas de un pixel. Parámetros dentro de un Bit Quad.

3.3.1. Cálculo de un punto de frontera

Dados dos puntos vecinos dentro de la ventana, P_0 perteneciente al objeto y P_1 fuera del mismo, con valores de intensidad que se desprenden del nivel de gris en ID correspondientes al valor de distancia D_0 y D_1 respectivamente, se calcula el coeficiente de interpolación lineal convexo α entre ambos como:

$$\alpha = \frac{U - D_1}{D_0 - D_1} \quad (3.1)$$

donde $0 \leq \alpha \leq 1$.

Las coordenadas del punto de frontera P_f , teniendo en cuenta la resolución de la imagen L , se encuentran dadas por la interpolación lineal convexa entre P_0 y P_1 .

$$\begin{aligned} P_f[i_f, j_f] &= \alpha P_0[i_0, j_0] + (1 - \alpha) P_1[i_1, j_1] \\ P_f[i_f, j_f] &= \alpha P_0\left[i + \frac{L}{2}, j + \frac{L}{2}\right] + (1 - \alpha) P_1\left[i + L + \frac{L}{2}, j + L + \frac{L}{2}\right] \end{aligned} \quad (3.2)$$

Sustituyendo i_0 , i_1 , j_0 y j_1 por sus equivalencias con el punto (i, j) donde (i, j) son las coordenadas del vértice izquierdo superior del pixel P_0 (figura 3.6). Finalmente se tiene

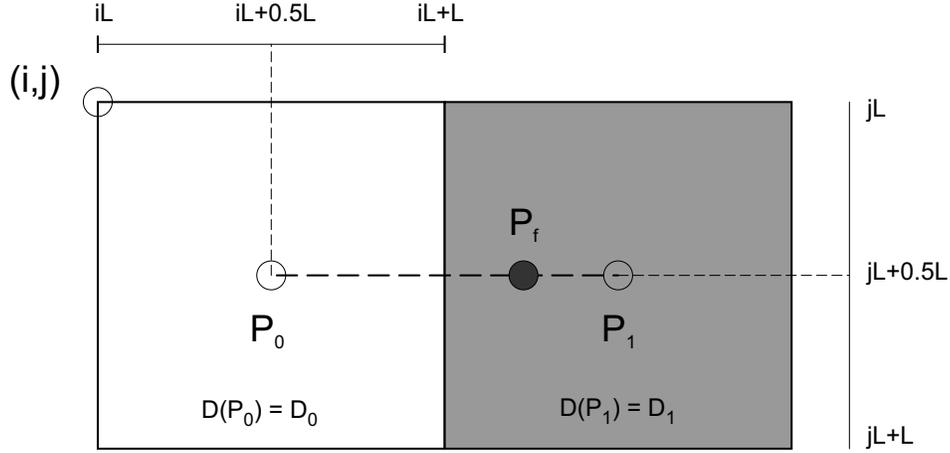


Figura 3.6: Coordenadas del píxel P_f .

que las coordenadas de P_f son:

$$\begin{aligned}
 i_f &= \alpha i_0 + (1 - \alpha) i_1 \\
 &= \alpha \left(iL + \frac{1}{2}L \right) + (1 - \alpha) \left(iL + L + \frac{1}{2}L \right) \\
 &= \cancel{\alpha iL} + \alpha \frac{1}{2}L + iL + \frac{3}{2}L - \cancel{\alpha iL} - \alpha \frac{3}{2}L \\
 &= iL + \frac{3}{2}L - \alpha L \\
 \\
 j_f &= \alpha j_0 + (1 - \alpha) j_1 \\
 &= \alpha \left(jL + \frac{1}{2}L \right) + (1 - \alpha) \left(jL + \frac{1}{2}L \right) \\
 &= \cancel{\alpha \left(jL + \frac{1}{2}L \right)} + jL + \frac{1}{2}L - \cancel{\alpha \left(jL + \frac{1}{2}L \right)} \\
 &= jL + \frac{1}{2}L
 \end{aligned}$$

$$P_f[i_f, j_f] = P_f \left[L \left(i + \frac{3}{2} - \alpha \right), L \left(j + \frac{1}{2} \right) \right] \quad (3.3)$$

P_f está afectado por el factor de escala L , correspondiente a la resolución de la imagen (ecuación 3.3). Determinados dos puntos consecutivos del contorno a partir del análisis de configuración, se calculan los segmentos de frontera mediante distancia Euclidiana entre ambos. La figura 3.4 muestra los cuatro ejemplos de borde para cada configuración de Bit

Quad. El cálculo se determina con $L = 1$ y se escala el resultado final en los casos que la resolución sea diferente. Los desarrollos matemáticos pertinentes a cada caso del algoritmo se desarrollan en el apéndice A y los resultados finales se concentran en la tabla 3.3.1. La suma de todos los segmentos de recta calculados constituye el perímetro total.

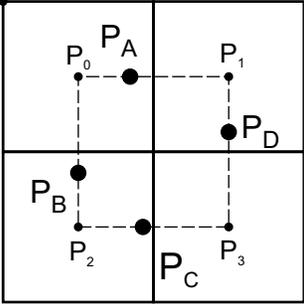
(i,j)	$P_A[i_A, j_A] = \alpha_A P_0[i_0, j_0] + (1 - \alpha_A) P_1[i_1, j_1]$		
	$\alpha_A(P_0, P_1) = \frac{U-D_1}{D_0-D_1} \quad i_A = L(i + \frac{3}{2} - \alpha_A) \quad j_A = L(j + \frac{1}{2})$		
	$P_A[i_A, j_A] = \alpha_A P_1[i_1, j_1] + (1 - \alpha_A) P_0[i_0, j_0]$		
$\alpha_A(P_1, P_0) = \frac{U-D_0}{D_1-D_0} \quad i_A = L(i + \frac{1}{2} + \alpha_A) \quad j_A = L(j + \frac{1}{2})$			
$P_B[i_B, j_B] = \alpha_B P_0[i_0, j_0] + (1 - \alpha_B) P_2[i_2, j_2]$			
$\alpha_B(P_0, P_2) = \frac{U-D_2}{D_0-D_2} \quad i_B = L(i + \frac{1}{2}) \quad j_B = L(j + \frac{3}{2} - \alpha_B)$			
$P_B[i_B, j_B] = \alpha_B P_2[i_2, j_2] + (1 - \alpha_B) P_0[i_0, j_0]$			
$\alpha_B(P_2, P_0) = \frac{U-D_0}{D_2-D_0} \quad i_B = L(i + \frac{1}{2}) \quad j_B = L(j + \frac{1}{2} + \alpha_B)$			
$P_C[i_C, j_C] = \alpha_C P_2[i_2, j_2] + (1 - \alpha_C) P_3[i_3, j_3]$			
$\alpha_C(P_2, P_3) = \frac{U-D_3}{D_2-D_3} \quad i_C = L(i + \frac{3}{2} - \alpha_C) \quad j_C = L(j + \frac{3}{2})$			
$P_C[i_C, j_C] = \alpha_C P_3[i_3, j_3] + (1 - \alpha_C) P_2[i_2, j_2]$			
$\alpha_C(P_3, P_2) = \frac{U-D_2}{D_3-D_2} \quad i_C = L(i + \frac{1}{2} + \alpha_C) \quad j_C = L(j + \frac{3}{2})$			
$P_D[i_D, j_D] = \alpha_D P_3[i_3, j_3] + (1 - \alpha_D) P_1[i_1, j_1]$			
$\alpha_D(P_3, P_1) = \frac{U-D_1}{D_3-D_1} \quad i_D = L(i + \frac{3}{2}) \quad j_D = L(j + \frac{1}{2} + \alpha_D)$			
$P_D[i_D, j_D] = \alpha_D P_1[i_1, j_1] + (1 - \alpha_D) P_3[i_3, j_3]$			
$\alpha_D(P_1, P_3) = \frac{U-D_3}{D_1-D_3} \quad i_D = L(i + \frac{3}{2}) \quad j_D = L(j + \frac{3}{2} - \alpha_D)$			

Tabla 3.1: Cómputos asociados a las coordenadas del algoritmo MSI.

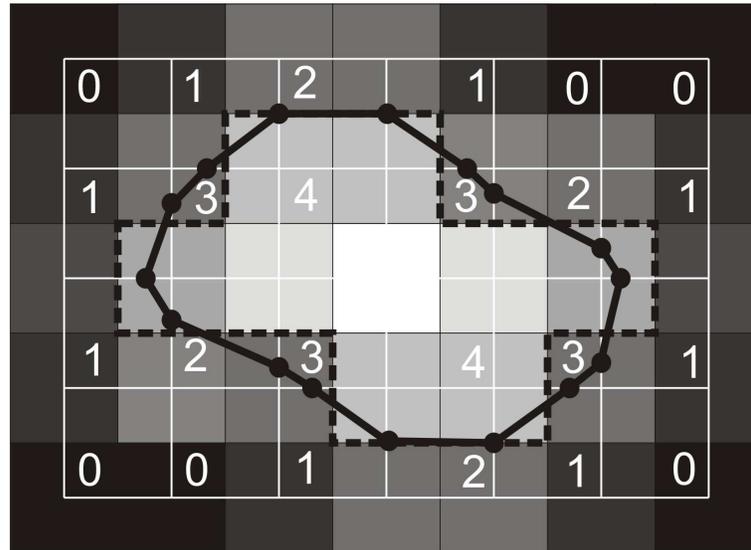


Figura 3.7: Ejemplo de la ejecución del algoritmo MSI aplicado sobre la figura 3.1c dibujado con trazo negro donde los puntos representan la posición calculada de las coordenadas de frontera. La línea de puntos negra corresponde al límite $U = 127$ y coincide con el borde determinado por método BEP (sección 3.2). Los bordes y los números de cada Bit Quad se destacan en color blanco.

En la figura 3.7 se presenta el mismo ejemplo de la figura 3.1 con el contorno dibujado con el algoritmo MSI. La imagen en niveles de gris asociada es el resultado de aplicar un filtro Gaussiano pasabajos (Gaussian blur también conocido como Gaussian smoothing) a la imagen binaria. Comparando los resultados entre ambas imágenes, figuras 3.1c y 3.7, es posible observar que las coordenadas del borde se mueven hacia afuera o hacia adentro del objeto a medir en función del color (nivel de gris) presente en el pixel.

3.4. Comparación de desempeño

En esta sección se compara el desempeño del método Marching Squares con interpolación lineal (MSI) introducido en este capítulo con Bordes Exteriores de los Pixels (BEP) y Chain Code (CC) en condiciones especiales. Los algoritmos de Freeman se eligen por ser las rutinas de medición usualmente implementadas en los software de GIS más comunes (al menos Envi[®] y ArcInfo[®] se comportan como si ambos implementaran BEP y CC). La forma de analizar la eficiencia del método desarrollado aquí es compararlo con los otros métodos existentes aplicando cambios en la resolución, la rotación, la simetría

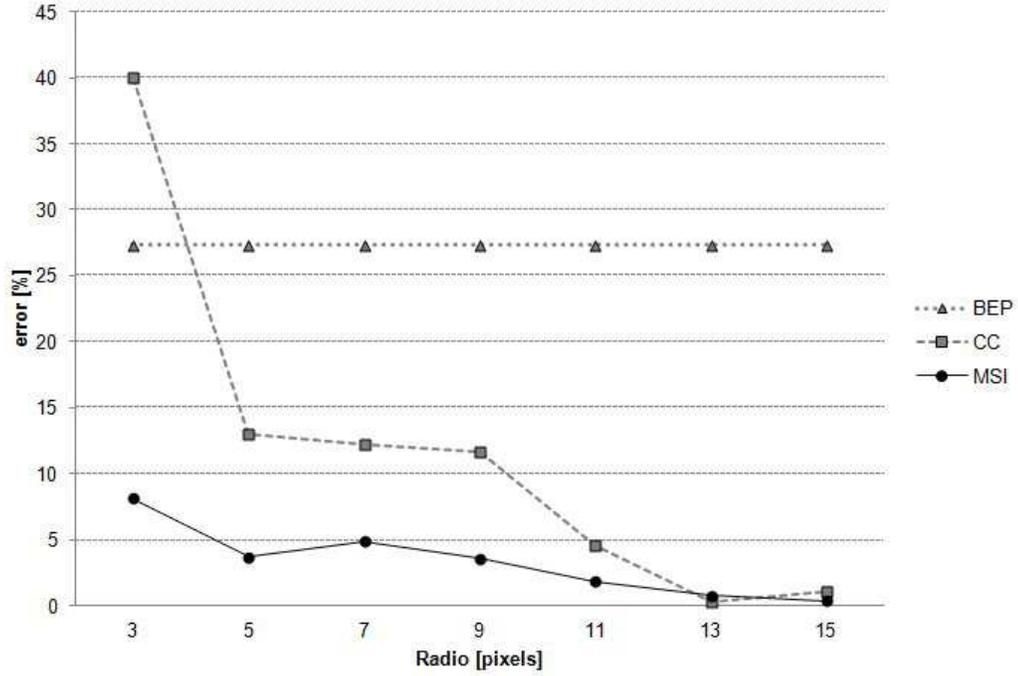


Figura 3.8: Error de medición en objetos curvos. Medición realizada sobre círculos de radio variable de entre 3 y 15 m de diámetro. Resolución de las imágenes es $L = 1$ m.

y en el seguimiento de las esquinas en imágenes sintéticas con propiedades geométricas conocidas.

Para ello se mide el perímetro en imágenes con círculos de diámetros entre 3 y 15 pixels las cuales proveen información específica sobre el desempeño de los algoritmos en presencia de bordes curvos. La Figura 3.8 muestra que el error correspondiente a BEP es sistemático y no disminuye al aumentar la resolución espacial de la imagen. El error relativo en el cálculo para BEP es (figura 3.9a):

$$e_r = \frac{Perimetro_{Cuadrado}}{Perimetro_{circulo}} = \frac{4L}{2R\pi} = 4/\pi = 1,2732.$$

CC produce errores relativos mayores al 10 % para círculos de diámetro menor a 11 pixels. La mayor parte de las veces este error es una sub-estimación que es inherente al método (tabla 3.2). MSI supera el rendimiento de BEP y CC con errores relativos menores al 8 % incluso en el peor caso.

Diámetro [m]	Perímetro						
	Valor Real	BEP	e_{BEP} %	CC	e_{CC} %	MSI	e_{MSI} %
3	9,425	12	27,32	5,66	39,98	8,66	8,16
5	15,708	20	27,32	13,66	13,08	15,13	3,71
7	21,991	28	27,32	19,31	12,18	20,92	4,89
9	28,274	36	27,32	24,97	11,68	27,26	3,60
11	34,558	44	27,32	32,97	4,594	33,93	1,82
13	40,841	52	27,32	40,97	0,32	41,16	0,78
15	47,124	60	27,32	46,63	1,05	46,95	0,37

Tabla 3.2: Medición de perímetros sobre círculos de radio variable de entre 3 y 15 m de diámetro. La resolución de las imágenes es de $L = 1$ m.

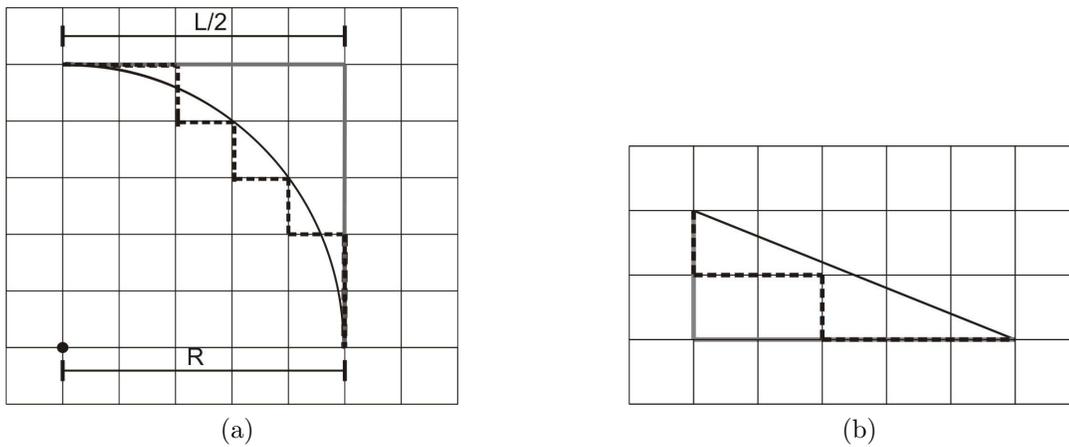


Figura 3.9: Error de estimación del método BEP. (a) En presencia de curvas. (b) En presencia de líneas oblicuas.

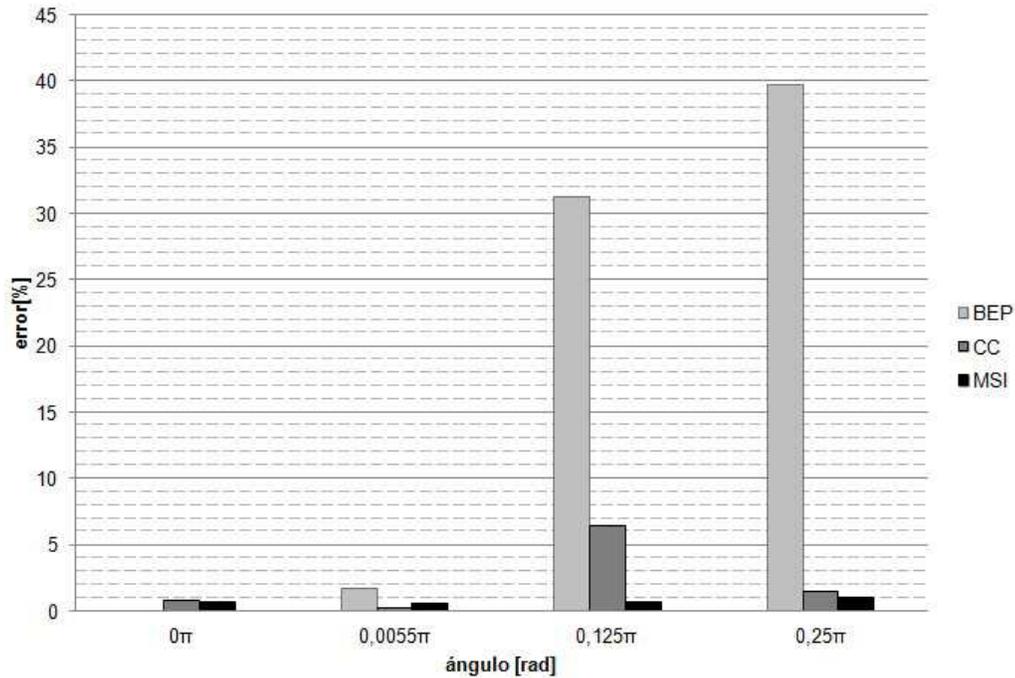


Figura 3.10: Error de medición en función del ángulo.

La segunda serie de ejemplos utiliza un rectángulo de dimensiones conocidas con distinto ángulo de rotación: $0,0055\pi$, $1/8\pi$ y $1/4\pi$, para determinar su influencia en el cálculo. BEP muestra gran dependencia en el valor final, acercándose a su error máximo con un ángulo de $1/4\pi$. El máximo error teórico por sobre-estimación esperado en este método es $\sqrt{2} \approx 41,42\%$ (figura 3.9b teorema de Pitágoras). Si bien es menos acentuado, CC presenta el mismo problema respecto de la rotación que BEP. El pico de error aparece para un ángulo de $1/8\pi$ con un error mayor al 8%. Mientras tanto, MSI es prácticamente independiente de la rotación, con un error por debajo del 1% en todos los casos (figura 3.10).

El tercer caso estudia la simetría respecto de figura y fondo. A partir de esta prueba es posible establecer si las rutinas son propensas a errores sistemáticos cuando la misma forma está presente ya sea en la figura como en el fondo. En la figura 3.11 es evidente que los bordes producidos por los algoritmos BEP y MSI coinciden si se los superponen mientras que el CC produce dos curvas diferentes si se modifica la referencia (figuras 3.11b y 3.11e). Es decir, BEP y MSI son métodos simétricos mientras que CC no.

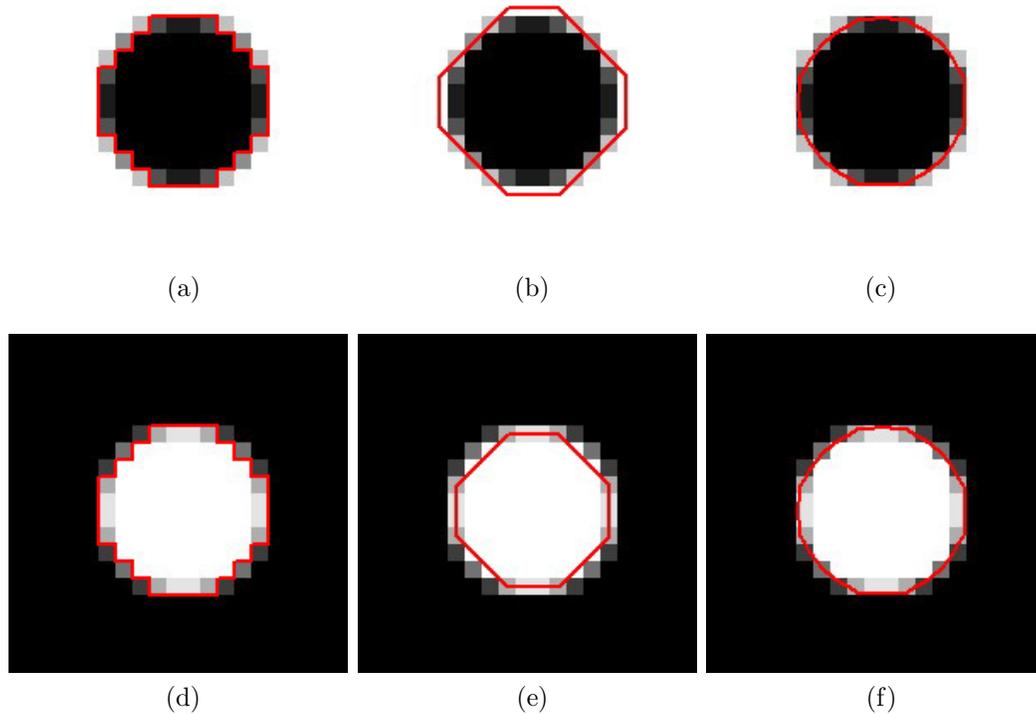
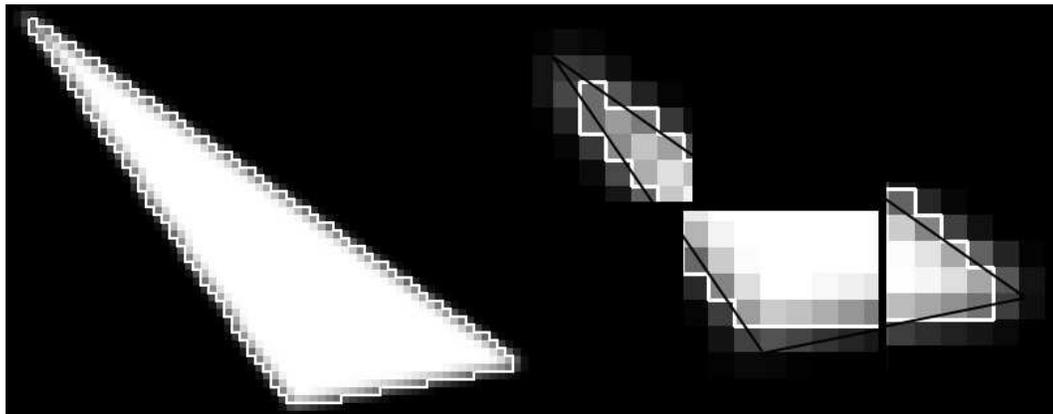
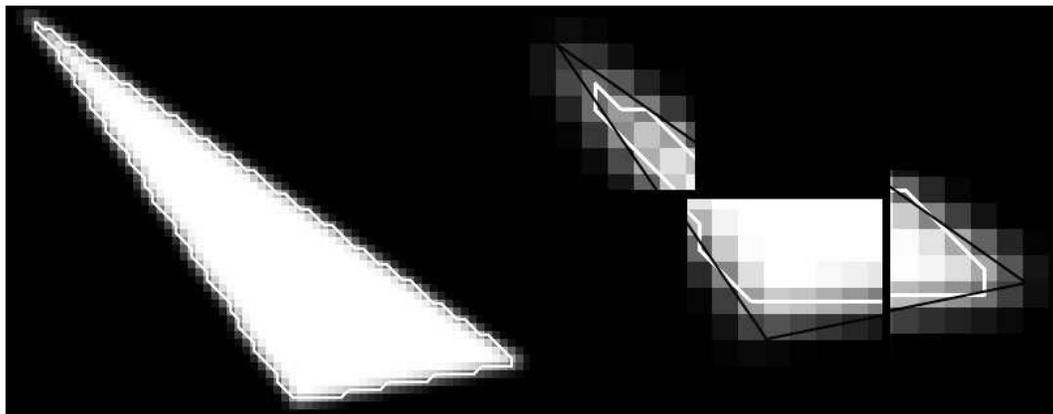


Figura 3.11: Estudio de simetría. Curvas sobre objetos de figura obtenidas con el algoritmo (a) BEP, (b) CC y (c) MSI. Curvas calculadas sobre objetos del fondo con igual forma y tamaño construidas con el algoritmo (d) BEP, (e) CC y (f) MSI.

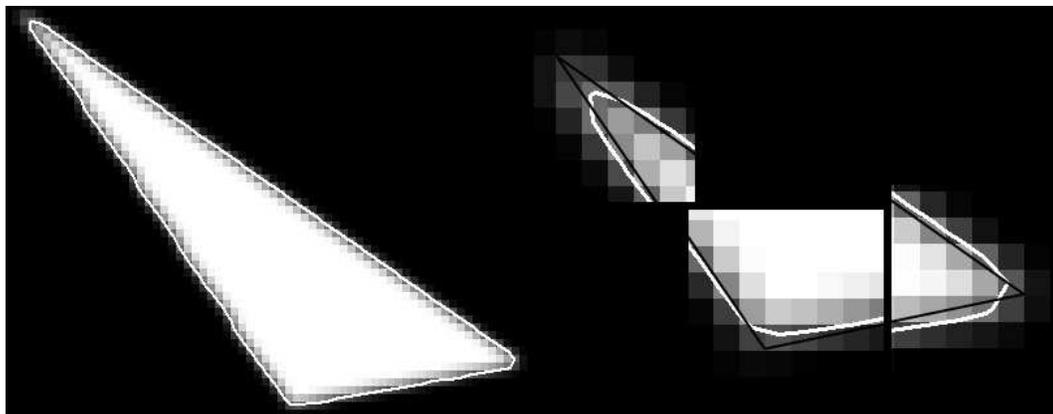
El cuarto ejemplo analiza el comportamiento de los métodos en presencia de esquinas. Para ese fin, se realizan pruebas sobre la imagen de un triángulo escaleno con un ángulo mayor a $1/4\pi$ (figura 3.12). Los tres algoritmos producen errores de interpolación en los vértices, los cuales son mayores cuanto menor es el ángulo (ver el vértice superior en los triángulos de la figura 3.12). Sin embargo, el MSI sigue la forma real de los vértices de manera más natural, con errores únicamente en el último píxel de cada uno, i.e., sólo tres píxels en todo el triángulo son considerados de manera incorrecta. Por lo tanto, se muestra que el error en polígonos irregulares siempre estará acotado y disminuirá con una resolución espacial más fina.



(a)



(b)



(c)

Figura 3.12: Desempeño en las esquinas. El borde obtenido en cada caso se muestra a la izquierda mientras que a la derecha se amplían las tres zonas de las esquinas. (a) BEP. (b) CC. (c) MSI.

3.5. Resumen de desempeño

Luego de dichos estudios, se destacan los siguientes aspectos:

Bordes exteriores de los Pixels Es el algoritmo más veloz, utilizado en los sistemas GIS y programas de procesamiento de imágenes más populares (Envi[®] y ArcInfo[®]). La precisión en el cálculo de perímetros se ve afectada fuertemente por diferentes factores. Específicamente la rotación, es el peor caso en presencia de aristas lineales con un ángulo $1/4\pi$. Para formas circulares, el error constante de 27 %, es independiente del radio de curvatura. Es simétrico con respecto a figura/fondo. Los resultados siempre poseen sobre-estimación y son independientes de la resolución espacial de la imagen (tabla 3.2).

Chain Code Su desempeño es superior al de BEP a un mayor costo computacional. El error obtenido en los cálculos aumenta en función de la orientación, siendo el ángulo $1/8\pi$ su peor condición y no mejora al aumentar la resolución espacial de la imagen. El método no presenta simetría entre figura y fondo. La medición es siempre una sub-estimación de los perímetros reales, y el error relativo aumenta para objetos de pequeñas dimensiones (tabla 3.2).

Marching Squares con Interpolación Lineal tiene un costo computacional mayor que los métodos precedentes. El error de cálculo es menor en casi todos los casos y su precisión es menos sensible ante factores de cambio como orientación, forma y tamaño de los objetos a medir. A su vez es un algoritmo simétrico con respecto a figura/fondo.

Capítulo 4

Estimación de Longitud de Característicos Lineales con Regresión Fractal

Diversos estudios en Ciencias de la Tierra se basan en modelos que demandan un conocimiento minucioso de la información geográfica para implementarlos (transporte de sedimentos, balance de calor, erosión, etc.). Por otra parte, la extracción de datos de imágenes satelitales ve limitada su precisión no sólo a los algoritmos destinados para obtenerlos, sino también, a la resolución empleada en el proceso. Las imágenes disponibles no poseen la resolución apropiada, mientras que, el uso de imágenes de alta resolución implica incrementar considerablemente el costo si se pretende abarcar extensas regiones.

En este capítulo se formula un método de estimación de perímetro a partir de una imagen de baja resolución y análisis fractal fundamentado en la teoría original expuesta por Richardson. El algoritmo segmenta la imagen y sub-muestreos de la misma y, en cada caso, determina la longitud de la poligonal aplicando el algoritmo MSI presentado previamente. Finalmente, calcula la regresión fractal de la dependencia de la longitud de las poligonales en función de la escala, permitiendo extrapolar en forma robusta el perímetro en una resolución mayor.

4.1. Antecedentes

En Ciencias de la Tierra, determinados estudios exigen la mayor precisión posible en los datos y la utilización de imágenes de teledetección remota de baja resolución espacial (por ejemplo Landsat) es limitada. A su vez, incluso con la tecnología de adquisición adecuada, la cobertura de vastas regiones con imágenes de alta resolución implicaría un costo excesivo. Dicha situación motiva el desarrollo de técnicas confiables de aproximación de datos a partir de imágenes de menor resolución. La geometría fractal ofrece el marco teórico ideal que permite el planteo de rutinas de estimación. Sus conceptos y sus aplicaciones se extienden a todos los campos de la experiencia humana (Mandelbrot, 1983; Russ, 1993), en particular su utilización en PDI alcanza diversas actividades como segmentación, medición, caracterización de texturas, etc (Zhende y Yuwen, 2003; Lopes y Betrouni, 2009; García et al., 2010).

El método estándar de análisis fractal es el postulado por Richardson (Richardson, 1961; Mandelbrot, 1967; Dutch, 1993) el cual calcula la invariancia a la escala D en el plano $\log(\textit{Longitud}) - \log(\textit{Escala})$. Sin embargo, diferentes autores presentan en sus trabajos algoritmos de medición de DF y analizan su desempeño (Allen et al., 1995; Soille y Rivest, 1996; Schlueter et al., 1997; Dillon et al., 2001; Lopes y Betrouni, 2009). Entre ellos, Korčák (1938), describe el complejo patrón de la distribución de áreas de las islas del mar Egeo y encuentra una relación empírica de naturaleza fractal con constantes C y B para determinar el número de islas en una ubicación cualquiera en función de su superficie. En su ensayo asigna un valor fijo a B y Mandelbrot (1983) observa que varía según la región geográfica a la que pertenece (Russ, 1993; Imre et al., 2011). Hurst et al. (1965), por su parte, utiliza análisis fractal en series temporales y desarrolla su método estadístico (*rescaled range analysis*) que da origen al parámetro fractal H o coeficiente de autosimilitud.

Determinar una longitud es un tema recurrente en muchas disciplinas. En particular, en PDI el cómputo del perímetro depende del algoritmo (Vossepoel y Smeulders, 1982; Kulpa, 1983; Yang et al., 1994; Cipolletti et al., 2012) y, por lo tanto, su utilización para determinar la constante D se ve altamente influenciada (Håkanson, 1978). Más aún si se relaciona con el área (Imre, 2006). En investigaciones posteriores, se reconoce la dependencia existente entre D y la densidad de muestreo y se establece que los gráficos de Richardson son lineales a trozos (Goodchild, 1980; Shelberg et al., 1982; Lam y Quattrochi, 1992).

Håkanson (1978) calcula el perímetro de doce lagos de Suecia utilizando la técnica desarrollada por Richardson. En su trabajo, enuncia que no es posible precisar el resultado de una medición sin especificar el método empleado y establece las pautas para elegir una escala apropiada según el tipo de mensura. También desarrolla una expresión empírica de la variación de la longitud en función de la escala la cual permite la comparación de los datos obtenidos. Sin embargo, algunos autores desestiman su trabajo debido a la incongruencia de información que posee el cálculo con el uso de cartografía heterogénea (Mark y Aronson, 1984; Lam y Quattrochi, 1992).

4.2. Dimensión fractal

4.2.1. Definición y características

La dimensión fractal es un número real que generaliza el concepto de la dimensión topológica para objetos que no admiten espacio tangente. Desde el punto de vista geométrico, un objeto fractal posee una estructura básica fragmentada e irregular. Además tiene la capacidad de ser *auto-similar*, es decir, a cualquier escala se vuelve a repetir la misma estructura y, por lo tanto, poseen infinitos niveles de detalle. En esta definición se distingue entre un objeto fractal geométrico y un conjunto fractal estudiado desde el punto de vista topológico (Falconer, 2003). Sólo los fractales matemáticos poseen auto-similitud exacta. El término fue propuesto por el matemático Benoît Mandelbrot en 1975 y deriva del Latín *fractus*, que significa quebrado o fracturado.

Un objeto geométrico fractal normalmente posee las siguientes características (no siempre deben encontrarse todas presentes en el mismo fractal):

- Su estructura compleja e irregular no puede ser descrita por la geometría tradicional.
- El nivel de detalle es independiente de la escala.
- Es auto-similar (exacta, aproximada o estadísticamente).
- Su dimensión de Hausdorff-Besicovitch es estrictamente mayor que su dimensión topológica.
- Se define mediante un algoritmo recursivo.

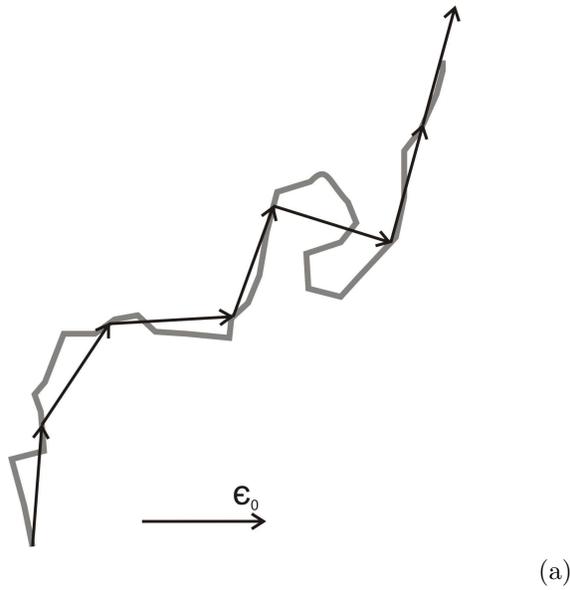
Un *fractal natural* es un elemento de la naturaleza cuyos patrones de rugosidad, grietas o fracturas puede ser descrito mediante la geometría fractal. Las nubes, las montañas, el sistema circulatorio, las líneas costeras o los copos de nieve son algunos ejemplos. Su representación es aproximada ya que no posee detalle infinito. En estos casos, en cuya génesis intervienen fenómenos estocásticos, la capacidad del formalismo fractal para modelarlos es adecuada solo hasta cierto nivel de detalle lo cual se denomina *auto-similitud estadística*.

4.2.2. Gráficos de Richardson

Lewis F. Richardson dedica parte de su vida a analizar matemáticamente la guerra. Entre sus hipótesis de la predisposición a un conflicto bélico entre estados, se encuentra la longitud de la frontera común entre ambos territorios. En sus mediciones de la frontera de varios países, observa que la distancia medida dependía de la precisión utilizada al calcular y el resultado final aumentaba si aumentaba el nivel de detalle. La medición de una curva la realiza mediante su aproximación a partir de un camino poligonal de lados con longitud ϵ . Si $\epsilon \rightarrow 0$, se espera que la estimación de la poligonal se aproxime a un límite. En el caso de líneas costeras, curvas continuas pero no derivables, aumentar la resolución implica la aparición de más salientes y entrantes de manera tal que la longitud total a estimar parece aumentar sin límites $L(\epsilon) \rightarrow \infty$ (figura 4.1). Richardson (1961) descubre que existen constantes F y D características de cada frontera tal que

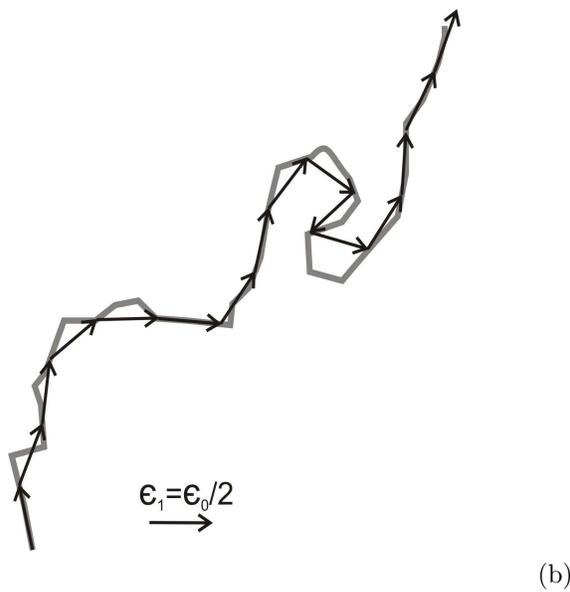
$$L(\epsilon) = F\epsilon^{1-D}.$$

Mandelbrot (1967) a partir de los estudios de Richardson propone utilizar el valor del exponente D como *dimensión natural* la cual coincide con la dimensión de Hausdorff-Besicovitch que se introduce en la siguiente sección.



Longitud l de la curva:

$$l(\epsilon_0) = 6,6 * \epsilon_0$$



Longitud L de la curva:

$$l(\epsilon_1) = 15,8 * \epsilon_1$$

$$l(\epsilon_1) = 15,8 * \frac{\epsilon_0}{2}$$

$$l(\epsilon_1) = 7,9 * \epsilon_0$$

Figura 4.1: Según la teoría de Richardson, la longitud medida de un fragmento de costa depende exclusivamente de la escala empleada para la medición. En este ejemplo se puede visualizar un tramo esquemático de costa medido con dos escalas diferentes. (a) Escala = ϵ_0 . (b) Escala = $\epsilon_1 = \epsilon_0/2$.

4.2.3. Dimensión de Hausdorff-Besicovitch

Al igual que con diversas teorías matemáticas los fractales surgen como respuesta para estudiar conjuntos de datos que poseían medida de Lebesgue¹ nula pero que además tenían características geométricas, aritméticas o analíticas muy especiales. Hausdorff desarrolla una teoría matemática que permite estudiar estos conjuntos y que actualmente se conoce como dimensión de Hausdorff.

La *dimensión de Hausdorff-Besicovitch* es una generalización del concepto de dimensión y de la medida de Lebesgue. Fue introducida por Felix Hausdorff en 1918 y estudiada extensivamente por Abram Besicovitch a quien se le deben la mayoría de los resultados teóricos y teoremas concernientes tanto a la medida de Hausdorff como a la dimensión fractal. Si denominamos d_t a la dimensión topológica y d_H a la dimensión de Hausdorff entonces $d_t \leq d_H$.

Medida de Hausdorff: Sea $U \subset \mathbb{R}^n$ un conjunto no vacío, el diámetro de U se define como:

$$|U| = \sup\{|x - y| : x, y \in U\}$$

Sea I un conjunto arbitrario de índices, la colección de $\{U_i\}_{i \in I}$ se denomina δ - cubrimiento de F si

- $F \subset \cup_{i \in I} U_i$; y
- $0 < |U_i| \leq \delta$, para cada $i \in I$.

Sea $F \subset \mathbb{R}^n$ y s un número no negativo. Para cualquier $\delta > 0$ se define la dimensión de Hausdorff como:

$$\mathcal{H}_\delta^s(F) = \inf \left\{ \sum_{i=1}^{\infty} |U_i|^s \right\}$$

en donde el ínfimo se toma sobre todos los δ - cubrimientos numerables de F y es posible verificar que \mathcal{H}_δ^s es de hecho una medida exterior en \mathbb{R}^n .

La medida exterior s -dimensional de Hausdorff del conjunto F se define como el valor:

$$\mathcal{H}^s(F) = \lim_{\delta \rightarrow 0} \mathcal{H}_\delta^s(F)$$

¹La medida de Lebesgue representa la forma estándar de asignar una longitud, área, o volumen a los subconjuntos del espacio euclídeo. Se usa en el análisis real para los conjuntos a los que se les puede asignar un tamaño también denominados Lebesgue-medibles, o medibles a secas si no hay ambigüedad sobre la medida (Fava y Zó (2013), http://es.wikipedia.org/wiki/Medida_de_Lebesgue).

Existe un valor de s crítico, $s_o \leq n$, denominado dimensión de Hausdorff en F ($dim_H F$) tal que

$$\mathcal{H}^s(F) = \begin{cases} \infty & \text{para } s < s_o \\ 0 & \text{para } s > s_o \end{cases}$$

Si $s = dim_H F$ entonces $\mathcal{H}^s(F)$ puede tomar el valor 0 o ∞ , o se cumple que (figura 4.2):

$$0 < \mathcal{H}^s(F) < \infty$$

A partir de la teoría de Hausdorff, cuando se trabaja con datos reales, la experiencia requiere técnicas más simples, basadas en el concepto de medida de Hausdorff pero fácilmente computables. Dado un conjunto de dimensión fractal D , es posible descomponerlo en N réplicas de sí mismo reducidas en un factor de escala r obteniendo que $Nr^D = C$ donde C es una constante. Aplicando logaritmo y resolviendo

$$D = \frac{\log(N)}{\log(\frac{1}{r})} = \lim_{\epsilon \rightarrow 0} -\frac{\log(N)}{\log(r)}$$

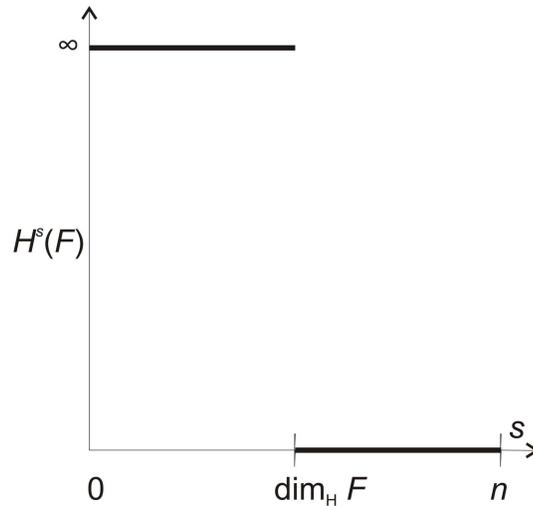


Figura 4.2: Dimensión de Hausdorff.

4.2.4. Análisis de Korcak

Su análisis describe el patrón de la distribución de áreas de las islas del mar Egeo y determina la relación empírica para calcular el número de islas en una región geográfica cualquiera, con una superficie superior a r como:

$$n(a) = Ca^{-B}$$

donde B y C son constantes y $n(a)$ es el número de islas con superficie mayor que a . Korcak supone que $B = 1/2$, pero Mandelbrot (1983) observa que el valor de B varía dependiendo de la región y además se cumple siempre que $B > 1/2$.

Dada el área de un grupo de objetos (islas, bosques, etc) se contabiliza el número de elementos cuya superficie sea mayor que un valor fijo a . De la relación entre la frecuencia y el área en el plano $\log - \log$ se obtiene una línea recta cuya pendiente es B . Por lo tanto la constante B es característica del grupo de objetos y está relacionada con la dimensión fractal de la distribución de las mismas.

4.2.5. Análisis R/S de Hurst

R/S deriva del inglés *rescaled range* y es una medida estadística de la variabilidad en las series de tiempo. A partir del diseño de la presa de Assuan, Hurst estudia las series temporales relacionadas con el caudal del río Nilo y los problemas de almacenamiento de agua, a partir de lo cual define su método (Hurst et al., 1965).

En sus ensayos con fenómenos naturales, utiliza una relación adimensional R/S , donde R indica un rango de variación de algún dato a lo largo del período de estudio y S es la desviación típica de los valores observados. Hurst observa que la relación R/S está bien descrita, para un número considerable de fenómenos, por una ecuación de la forma

$$R/S = (\tau/2)^H$$

donde H o exponente de Hurst, también se lo denomina *coeficiente de autocorrelación*. Si el exponente de Hurst se encuentra dentro del rango $0,5 < H < 1$ corresponde a series temporales que muestran persistencia, un período de crecimiento es seguido de otro análogo. Si $H = 0,5$, la serie de tiempo es indistinguible del ruido Browniano (acumulación de eventos aleatorios independientes). En cambio, si los valores incluidos pertenecen al

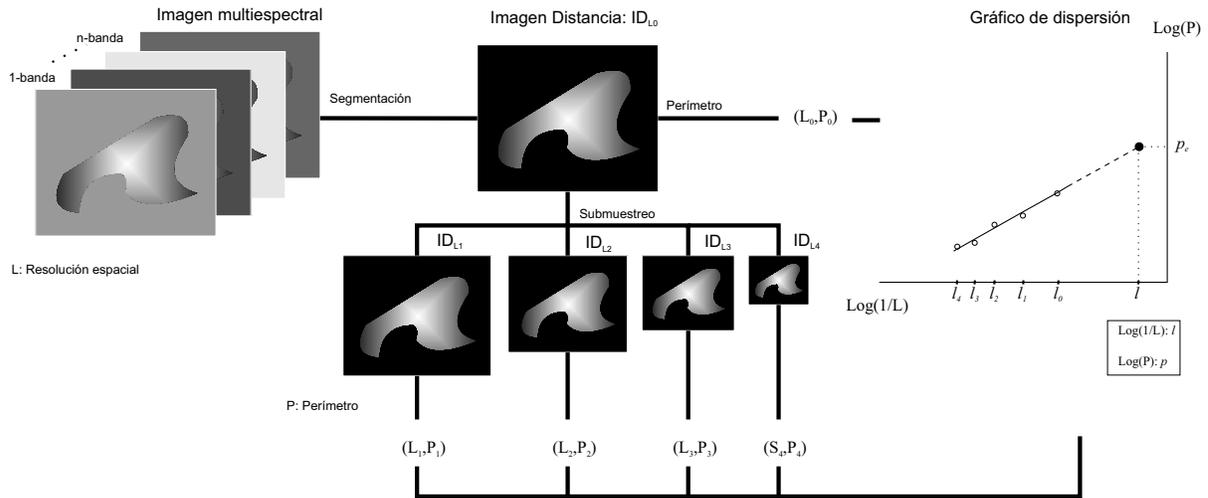


Figura 4.3: Diagrama de trabajo: Estimación de perímetro.

entorno $0 < H < 0,5$ corresponden a un comportamiento antipersistente, un período de crecimiento es seguido de otro de decrecimiento.

4.3. Estimación del perímetro

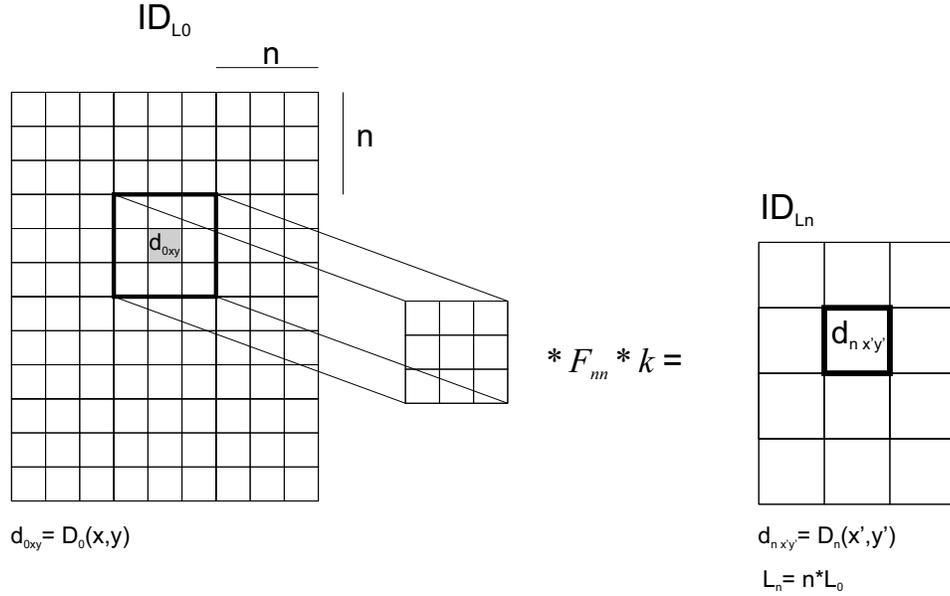
Siguiendo el diagrama de la figura 4.3, se parte de una imagen de resolución espacial baja y se segmenta. El objetivo es obtener una imagen en escala de gris denominada imagen distancia (ID). La ID se submuestra a diferentes escalas. Finalmente para cada submuestreo se calcula la longitud de la poligonal utilizando un algoritmo de medición. El proceso de submuestreo y medición produce tantos pares de datos como sean necesarios para que la estimación sea confiable. Dado un conjunto de pares se utiliza la técnica de estimación numérica de mínimos cuadrados para encontrar la función que mejor se aproxime a los datos, de acuerdo con el criterio de menor error cuadrático. La pendiente en el diagrama log – log que ajuste a dichos pares de puntos es por definición la dimensión fractal del objeto. Con la dimensión fractal obtenida, es posible utilizar la ecuación 4.7 para determinar el perímetro a una escala arbitraria. Esta extrapolación, basada en las mediciones, permite predecir el valor de una medición realizada a una escala mucho más detallada que la originalmente disponible.

4.3.1. Preparación de la imagen

Segmentación: se realiza a partir de alguno de los algoritmos de segmentación presentados en el capítulo 2 basados en el concepto de distancia mínima a uno o múltiples prototipos. A partir de la elección de los pixels prototipos, se determina una función escalar distancia que relaciona los datos de todas las bandas de información de la imagen con un único coeficiente. Dependiendo de la variedad de imagen de teledetección empleada, la información de cada banda varía (NASA, 2001; GeoEye, 2006). Cada pixel de referencia representa en su composición en bandas las características del objeto que se desea segmentar. A la imagen en escala de gris generada o *imagen distancia* se puede clasificar en fondo/figura definiendo el valor de umbral U .

Submuestreo: sobre la imagen segmentada se aplica un filtro lineal basado en *kernels* o *máscaras de convolución*. El kernel es una matriz de coeficientes f de tamaño y forma variable elegido por el usuario; sin embargo, comúnmente se trata de una matriz cuadrada de $n * n$. En el dominio del espacio se realiza una convolución del kernel sobre la imagen de partida. Cada pixel de la imagen resultante $D_{L0*n}(x', y')$ se obtiene mediante la sumatoria de la multiplicación del kernel por los pixels contiguos a $D_{L0}(x, y)$ normalizado mediante una constante k (figura 4.4). Existen diversos filtros de submuestreo; Gaussiano, media aritmética, media ponderada, etc. Sin embargo, en esta aplicación, el filtro que aplica la media aritmética a los pixels del kernel es el más apropiado debido a que simula adecuadamente el proceso de muestreo geoespacial de la tecnología presente en los satélites. Los sensores de medición promedian la radiación emitida por una superficie durante un período de tiempo. El proceso de submuestreo y medición produce tantos pares de datos como sean necesarios para que la estimación sea confiable lo cual depende de la resolución de la imagen y las dimensiones del objeto en estudio.

Perímetro: se calcula la longitud del perímetro de todas las imágenes utilizando el algoritmo *Marching Squares con Interpolación Lineal* (MSI) (Cipolletti et al., 2012) presentado en el capítulo 3. El MSI, se basa en el Crack Code o Marching Squares original (Dunkelberger y Mitchell, 1985) y permite obtener resultados super resolución sobre *imágenes distancia*. El algoritmo recorre la imagen distancia en grilla corrida y analiza la configuración cromática de los extremos de cada Bit Quad (Gray, 1971) determinando los puntos del segmento de frontera a partir de interpolación lineal convexa.



$$F_{nn} = \begin{pmatrix} f_{11} & \cdots & f_{1n} \\ \vdots & \ddots & \vdots \\ f_{n1} & \cdots & f_{nn} \end{pmatrix}$$

$$k = \frac{1}{\sum_{i=1}^n \sum_{j=1}^n f_{ij}}$$

$$D_{L_0 * n}(x',y') = \left(\sum_{i=1}^n \sum_{j=1}^n f_{ij} D_0(x,y) \right) * k$$

Figura 4.4: Submuestreo.

4.3.2. Regresión Fractal

Durante el procedimiento de submuestreo y medición se producen tantos pares de datos como imágenes se generan. Los puntos se grafican en un diagrama de dispersión en el plano $\log(P)$ vs $\log(1/L)$. Un procedimiento objetivo para ajustar un conjunto de este tipo se conoce como el *método de los mínimos cuadrados* (Gibbs, 2011). Es el ejemplo más simple para aproximar los datos $((l_1, p_1), \dots, (l_i, p_i), \dots, (l_n, p_n))$ mediante una línea recta. Para simplificar la nomenclatura se denomina $l_i = \log(1/L_i)$ y $p_i = \log(P_i)$. La recta resultante es de la forma $p = c + bl + E$, donde c , b y E son los coeficientes que representan la intersección con el eje de las abscisas, la pendiente y el error o residuo entre las observaciones respectivamente.

La recta de aproximación es:

$$\sum_{i=1}^n p_i = nc + b \sum_{i=1}^n l_i \quad (4.1)$$

$$\sum_{i=1}^n p_i l_i = c \sum_{i=1}^n l_i + b \sum_{i=1}^n l_i^2 \quad (4.2)$$

Despejando se obtiene:

$$b = \frac{n \sum p_i l_i - \sum l_i \sum p_i}{n \sum l_i^2 - (\sum l_i)^2} \quad (4.3)$$

$$c = \frac{\sum l_i^2 \sum p_i - \sum l_i \sum p_i l_i}{n \sum l_i^2 - (\sum l_i)^2} \quad (4.4)$$

donde c y b son el término independiente y la pendiente respectivamente.

Perímetro estimado: P_e

Finalmente y continuando las ecuaciones de la sección 4.3.2, P_e es el perímetro estimado para una resolución L deseada.

$$p_e = bl + c \quad (4.5)$$

$$\log(P_e) = b \log(1/L) + c \quad (4.6)$$

$$P_e = 10^{b \log(1/L) + c} \quad (4.7)$$

4.4. Imagen sintética

Para validar el método, se procede a evaluarlo en una imagen sintética cuyos valores a medir se pueden calcular matemáticamente. Se genera una imagen binaria de una “isla” con propiedades geométricas conocidas. La resolución inicial es $L_0 = 1m$ y a la imagen se la denomina IB001. Los perímetros se calculan con los tres métodos analizados en el capítulo 3, MSI, BEP y CC, para determinar la dependencia existente con el algoritmo de medición.

Siguiendo el esquema de la figura 4.5, el lateral superior e inferior de la “isla” está compuesto por u semi-círculos de diámetros entre H_1 y H_u donde $H_i = H_1/i$. El borde izquierdo y derecho son líneas rectas que unen tangencialmente el círculo superior con el

inferior. IB001 se submuestra en la imagen IB030 de resolución $L_{30} = 30 m$, quien a su vez se submuestra en las imágenes IB060, IB090, IB120 y IB150 cuya resolución en cada caso es $L_{60} = 60 m$, $L_{90} = 90 m$, $L_{120} = 120 m$ y $L_{150} = 150 m$. La elección de los valores de L elegidos coincide con la resolución espacial de las imágenes Ikonos y Landsat con el fin de emular su condición de partida.

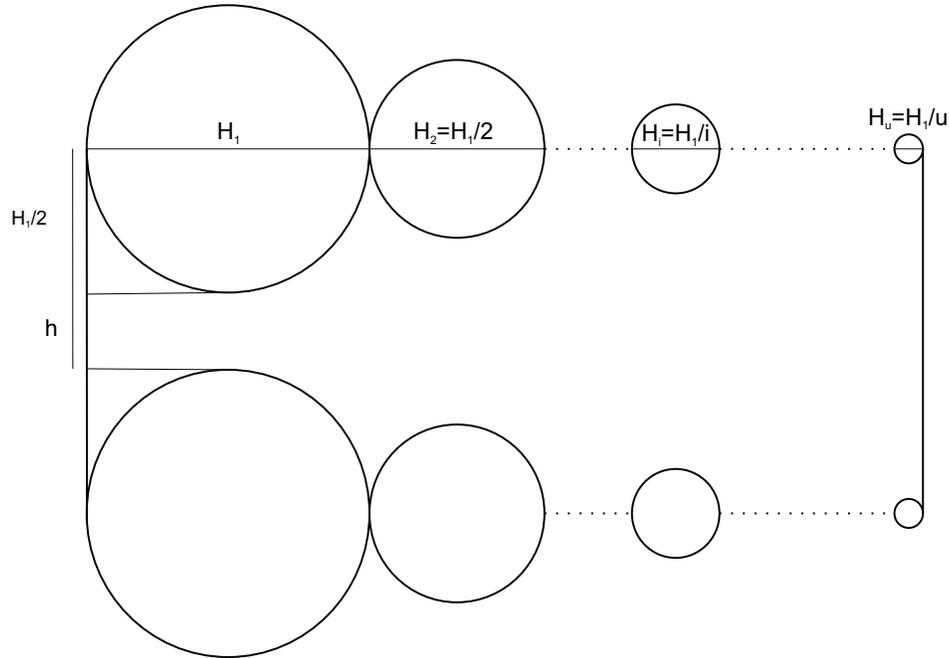


Figura 4.5: Esquema utilizado para la construcción de la isla sintética. En cada caso se especifican las cotas y la relación de diámetros respecto de H_1

Perímetro real calculado: P_r

IB001, figura 4.6, posee $u = 100$ círculos por lado, el diámetro mayor $H_1 = 2000 m$ y el margen $h = 100 m$. Los subíndices m , e y r corresponden al valor medido, estimado y real de un punto, respectivamente. El perímetro total es:

$$\begin{aligned}
 P_r &= \pi * \sum_{t=1}^u \frac{H_1}{t} + 2 * (H_1 + h) \\
 P_r &= \pi * \sum_{t=1}^{100} \frac{2000}{t} + 2 * (2000 + 100) \\
 P_r &= 36793,254 m
 \end{aligned}$$

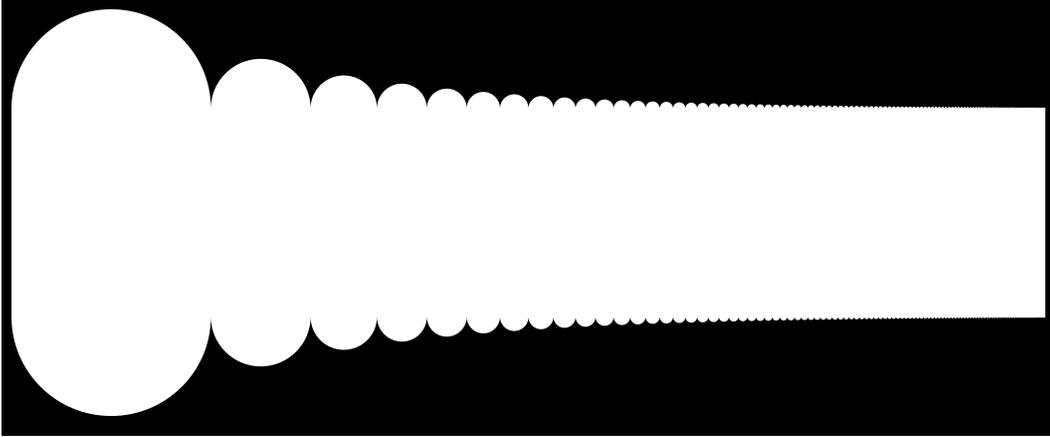


Figura 4.6: Isla sintética: Imagen construida: IB01.

Análisis del error: e

La eficiencia del método se contrasta con el perímetro medido (P_{m1}) en IB001. El error se calcula como:

$$e = |100 * (\frac{P_{m1} - P_{e1}}{P_{m1}})| \quad (4.8)$$

donde P_{e1} es el valor estimado a partir de la regresión fractal para $L = 1 \text{ m}$.

La información medida en la imagen IB001 se utiliza para contrastar la estimación realizada con submuestras de la misma a partir de una resolución de $L_{30} = 30 \text{ m}$. En la figura 4.7 se presentan en forma gráfica los datos de la regresión fractal y los puntos importantes detallados en la tabla 4.1. En la imagen de prueba (IB01, figura 4.6), si bien el nivel de rugosidad es bajo (la DF varía en el intervalo $[1,057; 1,100]$), la presencia de alta frecuencia existe en forma controlada por los círculos de diámetros cada vez más pequeños.

Medición con MSI				
$L[m]$	P_m	$\log(L)$	$p = \log(P_m)$	P_e
1	37047	0	4,568753045	36439,46
30	30139,52	1,477121255	4,479136331	30056,96
60	28752,44	1,77815125	4,458674706	28900,29
90	28257,24	1,954242509	4,45112974	28244,43
120	27794,78	2,079181246	4,443963241	27788,14
150	27485,81	2,176091259	4,43910854	27439,29
DF: 1,056614828		$e = 1,64$		$r^2 = 0,9929$
Medición con BEP				
$L[m]$	P_m	$\log(L)$	$p = \log(P_m)$	P_e
1	36793	0	4,5657652	51615,28
30	36960	1,477121255	4,567731963	36720,68
60	33960	1,778151250	4,530967682	34259,11
90	32760	1,954242509	4,515343893	32896,41
120	31920	2,079181246	4,504062883	31962,55
150	31500	2,176091259	4,498310554	31256,49
DF: 1,100105219		$e = 16,92$		$r^2 = 0,9879$
Medición con CC				
$L[m]$	P_m	$\log(L)$	$p = \log(P_m)$	P_e
1	37044	0	4,568717876	40429,26
30	31357,04	1,477121255	4,49633506	31246,94
60	29537,48	1,77815125	4,470373441	29648,67
90	28656,82	1,954242509	4,457227996	28751,91
120	28065,87	2,079181246	4,448178509	28132,15
150	27824,62	2,176091259	4,444429242	27660,64
DF: 1,0757476		$e = 9,14$		$r^2 = 0,9916$

Tabla 4.1: Estimación de la longitud del borde de la isla sintética de la figura 4.6.

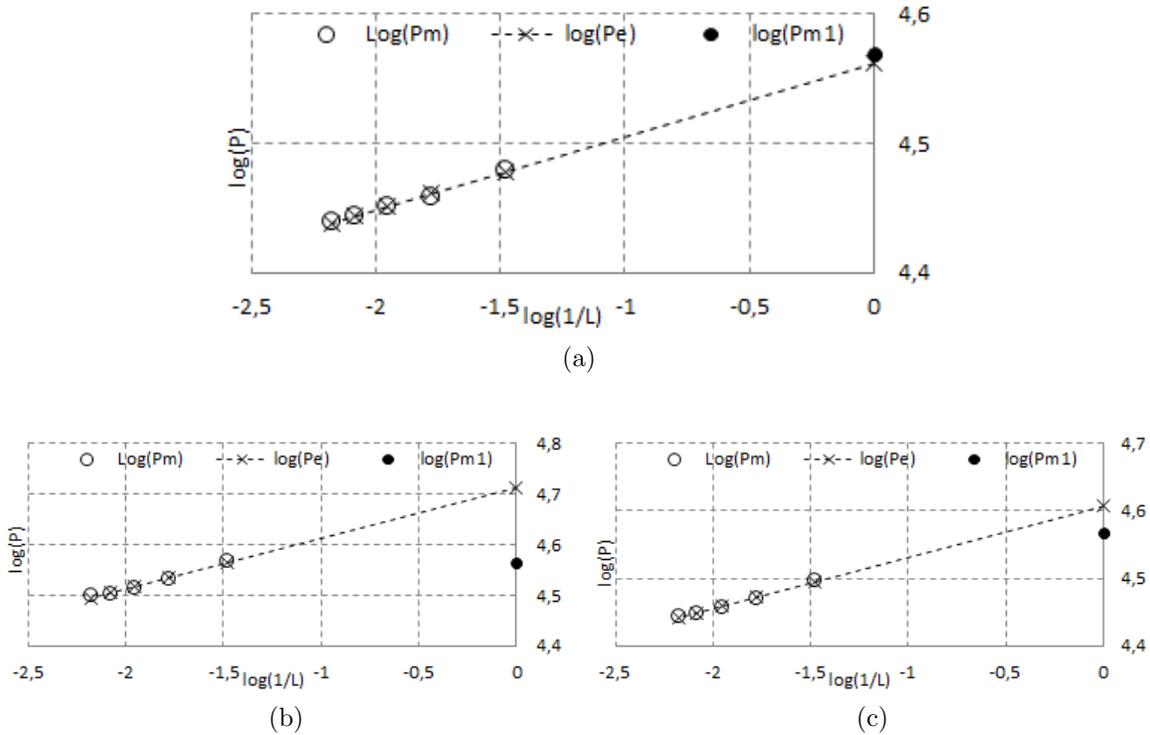


Figura 4.7: Regresión fractal del perímetro de la figura 4.6. Procedimiento realizado con el método de medición (a) MSI, (b) BEP y (c) CC.

4.4.1. Análisis de las estimaciones

Para los tres algoritmos de medición, el error porcentual entre el perímetro medido (P_m) sobre IB001 y el estimado (P_e) es inferior al 17% permitiendo suponer que el método de estimación se independiza de la rutina de cómputo de perímetro. A su vez, el coeficiente de determinación en todos los casos es $r^2 \approx 1$ lo que asegura una alta correlación entre los datos y la estimación. El algoritmo de Freeman de cuatro niveles de adyacencia, BEP, presenta el peor error asociado.

Los resultados se corresponden con el comportamiento analizado en la sección 3.4 en presencia de bordes curvos. El error obtenido para algoritmo MSI es menor al 2%, superando el desempeño de las rutinas de medición BEP y CC (figura 4.8). Este comportamiento fue observado en imágenes sintéticas similares, lo cual permite concluir que el método de aproximación de perímetros propuesto es confiable dentro de los niveles de error encontrados.

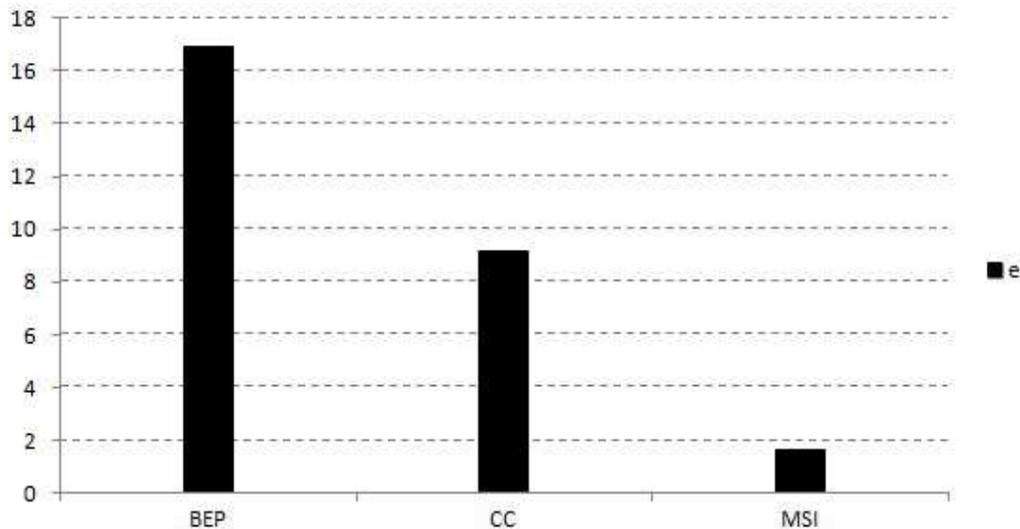


Figura 4.8: Análisis del error de estimación respecto del valor medido en la imagen IB001.

4.5. Resumen

El error asociado es bajo y no se incrementa en presencia de alta frecuencia. Es decir, no baja su eficiencia frente a estimaciones en fronteras muy rugosas. El método ha sido testeado en diferentes modalidades de imágenes y, en todos los casos, el error asociado es menor al 5 %, mejorando el desempeño de los algoritmos clásicos de medición en condiciones de medición directa. En cada caso, el coeficiente de determinación $r^2 \approx 1$ demostrando una alta correlación entre los datos.

En contraste con el método presentado por Håkanson (1978), la estimación de longitud con DF a partir de procesamiento digital de imágenes utiliza información homogénea y establece una condición inicial en la imagen de resolución disponible. Una vez que el proceso de segmentación y la selección del umbral se completaron, los pixels de figura y fondo quedan unívocamente determinados. La imagen distancia se mantiene constante y se emplea para construir las imágenes distancia de resolución espacial gruesa.

Dado que la segmentación de la imagen se ejecuta una única vez, el costo computacional se reduce considerablemente. Esto fue factible debido a que las mediciones de perímetro mostraban diferencias despreciables desarrollando primero el submuestreo y luego la segmentación. Incluso la presencia de pixels espurios en la ID se minimizan durante el proceso de submuestreo, ya que cada pixel de resolución espacial gruesa es una composición de si mismo con los pixels vecinos.

Si bien el algoritmo ha sido testeado sobre fragmentos de costa, su aplicación es posible sobre cualquier contorno topográfico con patrones de auto similitud (lineas de costa, canales de marea, cursos de río, etc). Por ejemplo, Rodriguez-Iturbe y Rinaldo (1997) asegura que las lineas del contorno de los cursos de río dentro de los mapas topográficos son análogos a las costas estudiadas.

Capítulo 5

Resultados experimentales

En este capítulo se presentan los resultados obtenidos con las técnicas desarrolladas en el marco de esta tesis (capítulos 2, 3 y 4) las cuales se aplican a diversas modalidades de imágenes. El desempeño de los métodos se analiza en diferentes accidentes geográficos, principalmente sobre imágenes satelitales multiespectrales Landsat e Ikonos. El objetivo es respaldar con información real las pruebas realizadas sobre imágenes sintéticas.

La primera sección introduce en forma concisa los conceptos esenciales y características principales que encierran la teledección y, en particular, las imágenes satelitales empleadas. Las secciones posteriores apuntan a las diferentes etapas de procesamiento: segmentación, medición y estimación, respectivamente, donde se describen los parámetros utilizados y los resultados conseguidos. Cabe destacar que cada una de dichas etapas emplea la información proveniente de la fase previa para continuar los estudios (figura 5.1).

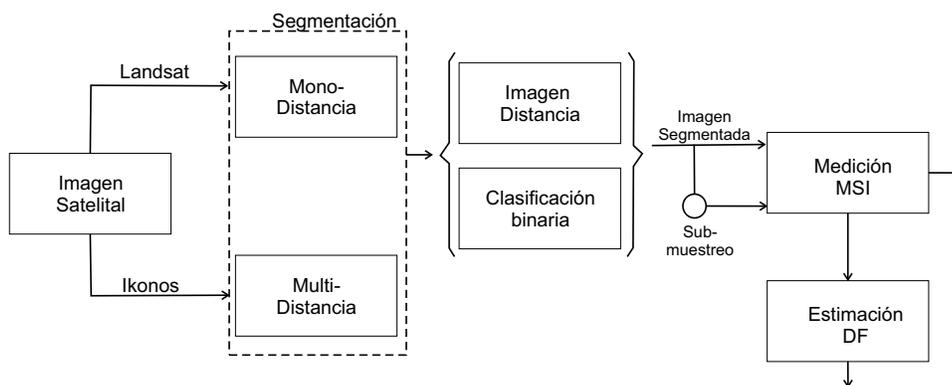


Figura 5.1: Diagrama de trabajo: Etapas de la metodología desarrollada y posteriormente aplicada sobre imágenes multiespectrales.

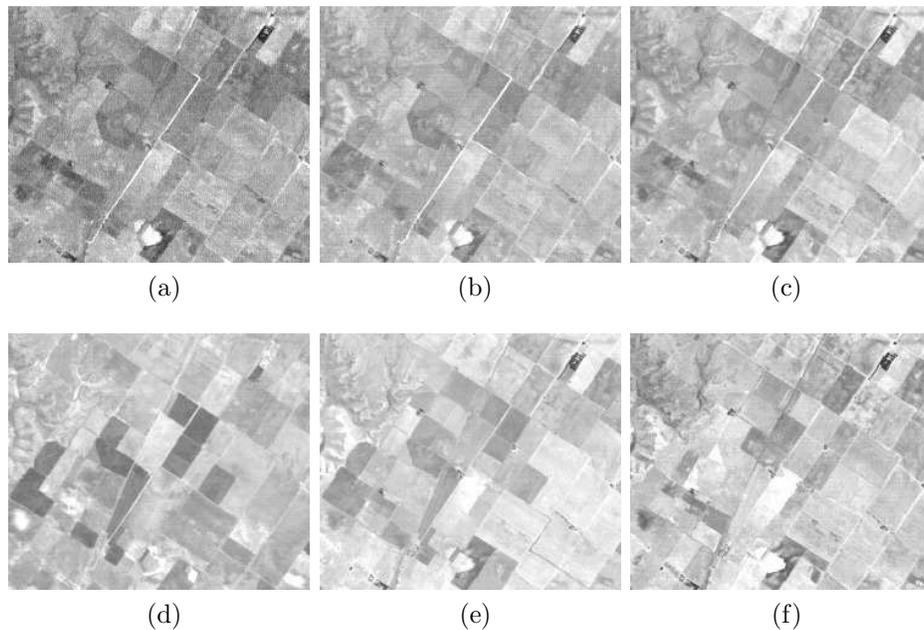


Figura 5.2: Recorte de imagen Landsat 7 de campos en la Provincia de Buenos Aires. Las referencias geográficas se detallan con precisión en el Apéndice B. Bandas de resolución $L = 30 m$. (a) Banda 1. (b) Banda 2. (c) Banda 3. (d) Banda 4. (e) Banda 5. (f) Banda 7.

5.1. Imágenes satelitales

En esta tesis mayormente se utilizan dos tipos de imágenes satelitales multiespectrales de teledetección pasiva. Por un lado, las imágenes Landsat 5 y Landsat 7 que poseen baja resolución espacial (NASA, 2001) y están compuestas por 7 canales de información. Sin embargo, debido a que presenta diferencias de resolución entre sus bandas solo se trabaja con aquellas de 30 m (bandas 1 a 5 y 7 respectivamente, figura 5.2) evitando las bandas térmicas. Por otra parte, se emplean imágenes multiespectrales Ikonos de resolución espacial fina (GeoEye, 2006). Las imágenes Ikonos poseen 4 canales de información, de los cuales solo se emplean las bandas R, G y B de 1 metro de resolución (figura 5.3). La información relevante de cada una se presenta concentrada en dos tablas (tabla 5.1) y, en cada caso a modo de ejemplo, un recorte de un sector (figuras 5.2 y 5.3).

Satélite	Landsat 5		Landsat 7	
Inicio	1-03-1984		15-04-1999	
Sensor	TM		ETM+	
f (días)	16		16	
Imagen	AB [μm]	L [m]	AB [μm]	L [m]
1 EV	0,45 – 0,52	30	0,45 – 0,52	30
2 EV	0,52 – 0,60	30	0,52 – 0,60	30
3 EV	0,63 – 0,69	30	0,63 – 0,69	30
4 IR cercano	0,76 – 0,90	30	0,76 – 0,90	30
5 IR cercano	1,55 – 1,75	30	1,55 – 1,75	30
6 Térmica	10,40 – 12,50	120	10,40 – 12,50	60
7 IR medio	2,08 – 2,35	30	2,08 – 2,35	30
8 Pancromático	–		0,52 – 0,90	15

(a)

Satélite	Ikonos
Inicio	24-11-1999
L	1 m
f (días)	3
Imagen	AB [μm]
1 Azul (EV)	0,445 – 0,516
2 Verde (EV)	0,506 – 0,595
3 Rojo (EV)	0,632 – 0,698
4 IR cercano	0,757 – 0,853

(b)

Inicio: Comienzo de la misión
 f : Demora entre capturas.
 TM: Thematic Mapper
 ETM+: Enhanced Thematic Mapper Plus
 AB: Ancho de banda
 L: Resolución
 EV: Espectro visible
 IF: Infrarojo

Tabla 5.1: Información relevante de las imágenes satelitales empleadas. (a) Landsat. (b) Ikonos.



Figura 5.3: Recorte de imagen Ikonos. Bandas R, G y B de resolución $L = 1 m$. El islote se ubica en el estuario de Bahía Blanca (Coordenadas aproximadas del centro: Latitud $38^{\circ}50'47,86'' S$ - Longitud $62^{\circ}11'48,89'' O$).

5.2. Segmentación de imágenes reales

Diversos tipos de imágenes multiespectrales se manipulan para realzar y extraer la información útil contenida. Para conseguirlo, el primer paso dentro del procesamiento es la segmentación y en esta tesis se emplean con dicho fin los métodos desarrollados en el capítulo 2. Los operadores de distancia mínima a uno o múltiples prototipos descriptos actúan sobre las componentes de radiación de todas las bandas directamente. Sin embargo, en el caso particular de las imágenes Ikonos se procede utilizando dichas técnicas pero modificando el espacio cromático a la hora de implementarlos (ver sección 2.3).

En cada caso, se escogen los parámetros \vec{a} , \vec{k} y K correspondientes a los coeficientes de la ecuación distancia. En consecuencia, quedan definidas las bandas a procesar y aquellas que deben ser descartadas. Una banda elegida posee la particularidad de que la radiación electromagnética se encuentra acotada en un intervalo y éste se repite de manera similar para todos los objetos a segmentar. Aquellos canales de información que no cumplan con dicho patrón se eliminan del cómputo ajustando el coeficiente $a_t = 0$ de la ecuación 2.3.

A partir de la matriz de los coeficientes de distancia D calculados se construye una imagen en escala de gris denominada imagen distancia o su acrónimo ID. Sus binarizaciones

o máscaras, abreviadas como IM, se utilizan en instancias posteriores del procesamiento. En general, los esfuerzos se concentran sobre diversos accidentes geográficos de la región del estuario de Bahía Blanca y el sudoeste de la provincia de Buenos Aires (figura 5.4). Sin embargo, es posible su generalización con un cambio apropiado en los parámetros de ajuste.

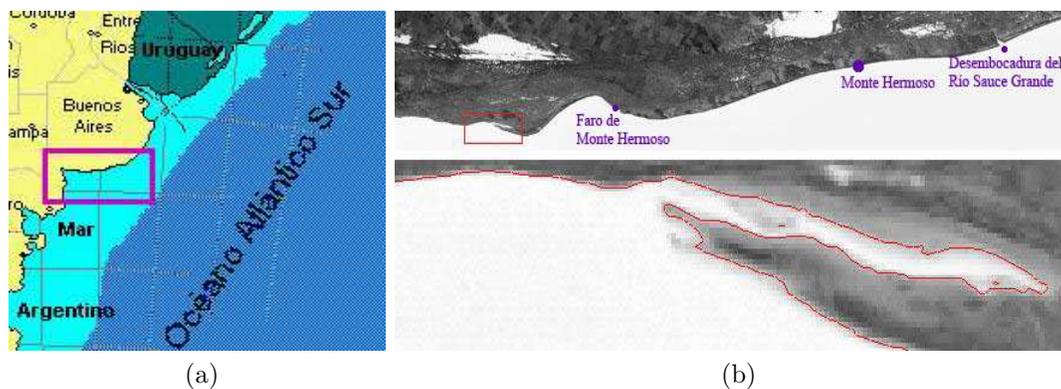


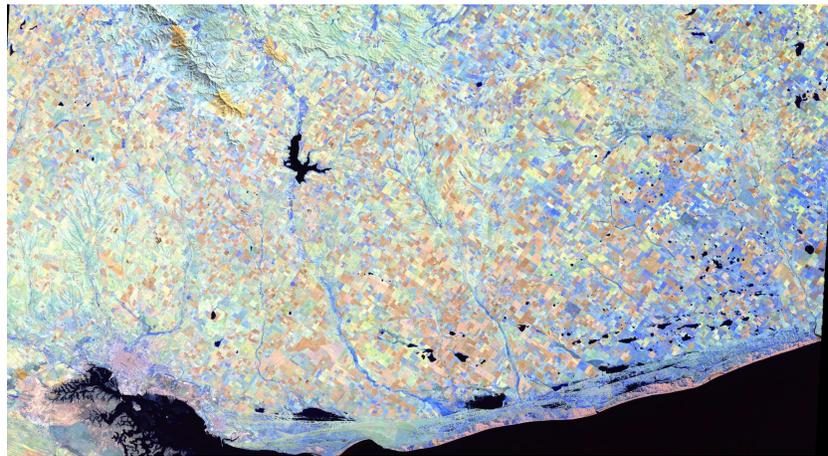
Figura 5.4: Sector de la costa sur de la Provincia de Buenos Aires. (a) Sector seleccionado en el mapa de la República Argentina. (b) Arriba: Recorte de imagen Landsat del sector marcado en (a) (violeta). Abajo: Acercamiento de la región marcada en rojo con el perímetro superpuesto.

5.2.1. Segmentación mono-distancia

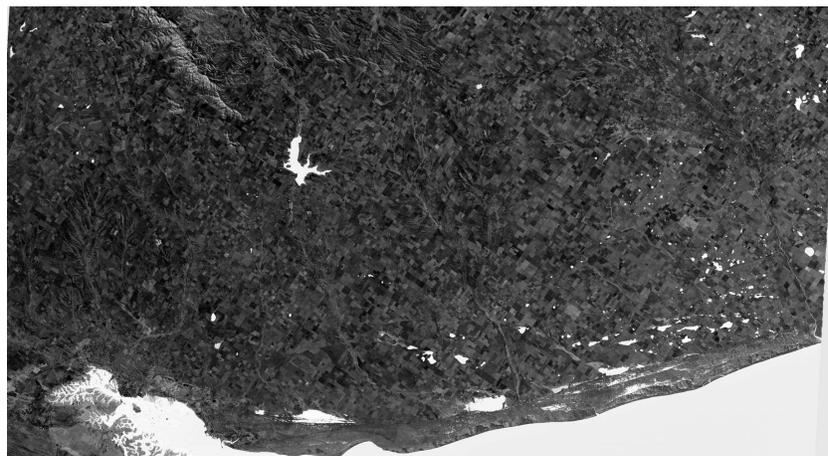
En esta sección se aplica el método de segmentación a un pixel de referencia (sección 2.4). El algoritmo se utiliza principalmente para extraer información de objetos en imágenes de teledetección de baja resolución Landsat. Las primeras pruebas se realizan sobre coberturas de agua y luego se extienden a la clasificación de parcelas según el tipo de cultivo. También se exponen las deficiencias en segmentación sobre imágenes de alta resolución con amplia dispersión cromática.

Presencia de agua en imágenes Landsat

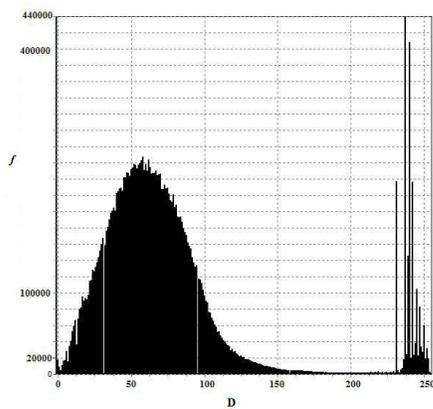
A partir de una imagen Landsat 7, se construye una imagen pseudo coloreada con las bandas 7, 5 y 4 en las componentes de color Rojo, Verde y Azul, respectivamente (figura 5.5a). El objetivo es discriminar los espejos de agua del resto de la imagen. Dicha composición resalta las zonas de interés y permite la selección del pixel prototipo. El pixel



(a)



(b)



(c)



(d)

Figura 5.5: Segmentación mono-distancia de agua sobre imagen Landsat 7. (a) Pseudo-Color construido con las bandas 7, 5 y 4. (b) ID. (c) Histograma de ID. (d) IM.

de referencia se calcula como la media de un grupo de pixels de una región de profundidad media.

La ecuación 2.3 utiliza para calcular la distancia mediante las bandas 4, 5 y 7 entre cada pixel de la imagen y la referencia. Las componentes de radiación de las bandas 1, 2 y 3 poseen un rango de variación que produce errores en la segmentación y, por lo tanto, se anulan para mejorar el resultado final. En consecuencia, las componentes a_t del \vec{a} quedan como: $(0, 0, 0, 1, 1, 1)$ y los parámetros k_t y K se fijan en 2 o norma Euclidiana, es decir, $\vec{k} = (2, 2, 2, 2, 2, 2)$ y $K = 2$.

Siguiendo el diagrama de la figura 2.5b se genera ID (figura 5.5b) donde 0 refleja la distancia máxima y 255 la distancia mínima al pixel prototipo de agua. El análisis visual del histograma de los coeficientes D (figura 5.5c) refleja claramente dos grupos de datos separados por el entorno $[180, 210]$ y, por lo tanto, el valor de umbral se fija en $U = 190$ perteneciente a dicho grupo. ID se binariza con el fin de obtener IM, figura 5.5d, donde resulta visible la división de las zonas con presencia de agua del resto de la información.

Luego, los datos de segmentación de lagunas se comparan con la clasificación realizada por el software Envi[®]¹. Dada la misma imagen Landsat 7 se ejecutan las herramientas proporcionadas por dicho programa y se obtienen dos posibles soluciones al problema. Para éste caso, zonas con presencia de agua, el objetivo se alcanza parcialmente. Si bien se trata de un año particularmente húmedo, es evidente que incurre en errores confundiendo parcelas con lagunas y ríos (figura 5.6).

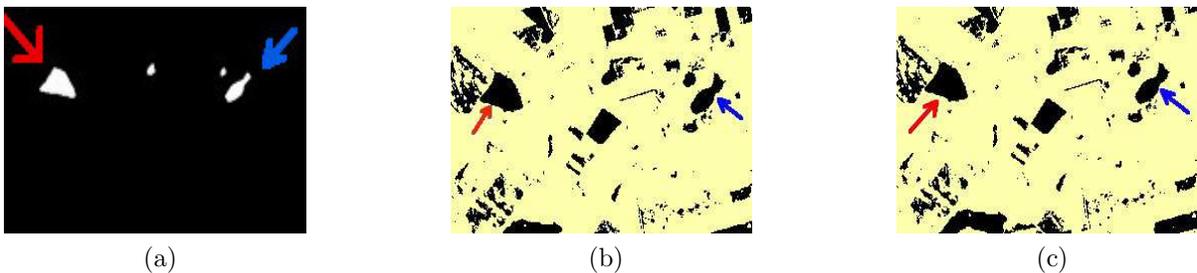


Figura 5.6: Segmentación de lagunas: Comparación con resultados de Envi[®].. (a) De la imagen máscara se eligen dos lagunas. (b) Primer clasificación. (c) Segunda clasificación.

¹Envi[®] es el software de procesamiento digital de imágenes que más se impuso en geografía y actividades afines para la extracción de datos de imágenes satelitales.

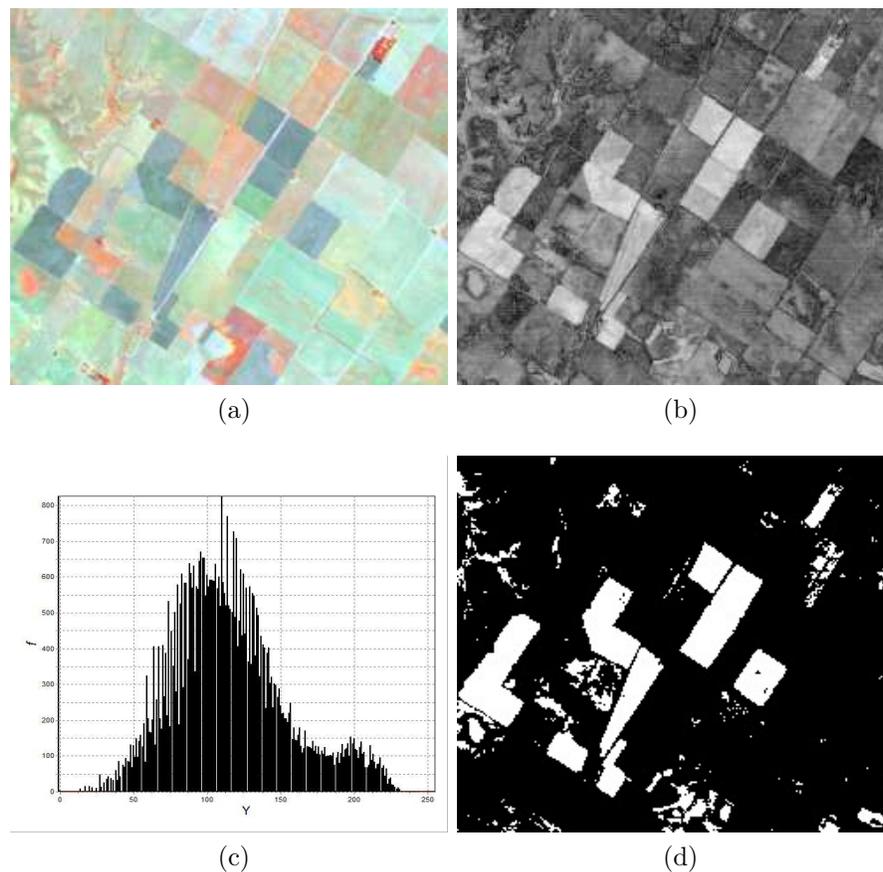


Figura 5.7: Segmentación de un campo en el recorte de imagen Landsat de la figura 5.2. (a) Pseudo-color construido con las bandas 4, 5 y 3. (b) ID. (c) Histograma de ID. (d) IM.

Parcelas de campo en imágenes Landsat

Una parcela de campo de la Provincia de Buenos Aires se segmenta a partir de una imagen Landsat 7 (figura 5.2). Nuevamente se construye un pseudocolor combinando las bandas 4, 5 y 3 en los canales Rojo, Verde y Azul, respectivamente (figura 5.7a). Con ésta configuración se destacan las regiones con presencia del cultivo seleccionado.

En la ecuación distancia (ecuación 2.3), el pixel prototipo se determina calculando el promedio de pixels pertenecientes a una región del campo $\vec{r} = (161, 196, 183, 227, 204, 188)$. Las componentes de las bandas 1, 2 y 7 se anulan ($\vec{a} = (0, 0, 1, 1, 1, 0)$) mientras que los coeficientes k_t y K se fijan en 2 determinando la distancia Euclídea entre las componentes activas y asegurar la convergencia del resultado. En las figuras 5.7 se presentan todas las

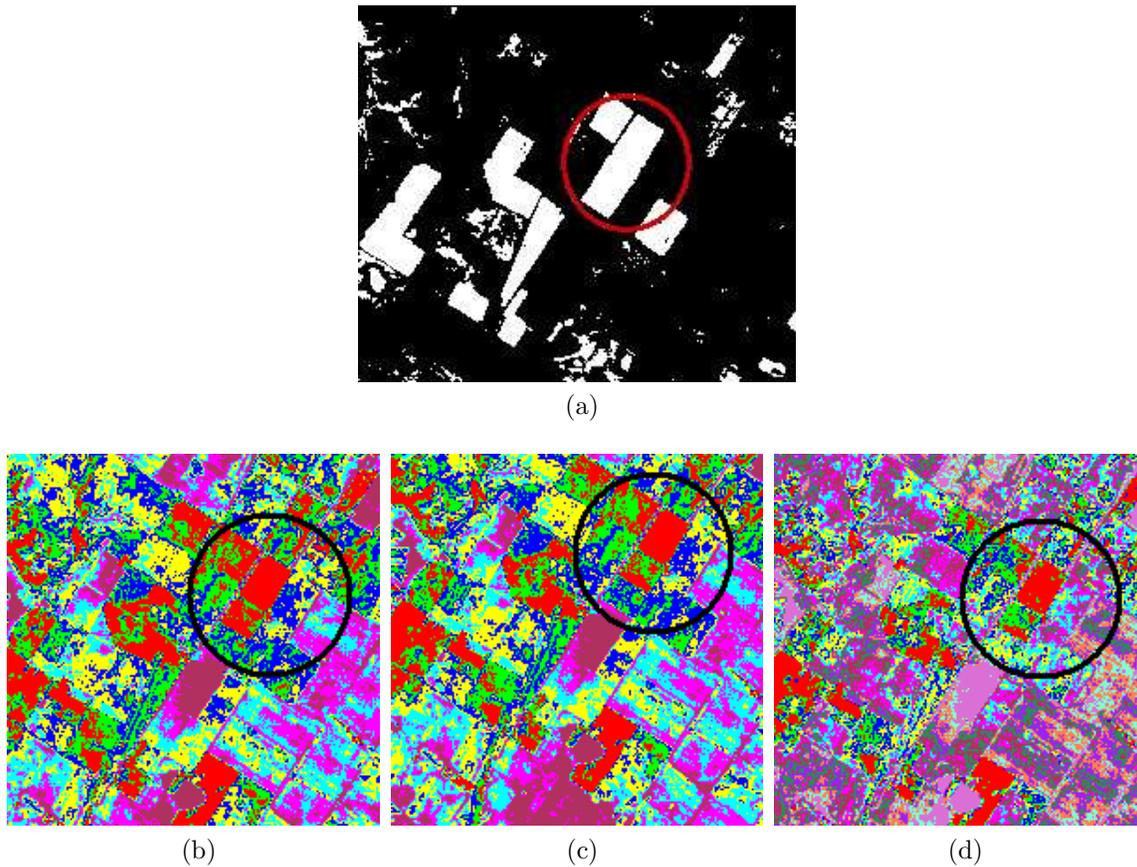


Figura 5.8: Segmentación de un campo en el recorte de imagen Landsat de la figura 5.2 con el software Envi[®]. (a) Campo de interés señalado. Primera clasificación de Envi[®] (b), segunda (c) y tercera (d).

imágenes con los resultados de la segmentación incluyendo a ID e IM. Dado que de un análisis rápido del histograma, figura 5.7c, no se desprende un valor natural de umbral, el mismo se fija de manera empírica en $U = 155$.

Al igual que se hizo con la segmentación de lagunas, se procesa la misma escena de Landsat con software Envi[®]. Sin embargo, los intentos de separar la parcela del entorno no arrojan resultados satisfactorios pese a los diversos intentos realizados (figura 5.8). Los diferentes colores presentes dentro del sector de la parcela denota la ineficacia del programa para procesar la tarea.

Imágenes Ikonos

Sobre un recorte de imagen Ikonos se pretende segmentar la superficie ocupada por los canales de marea empleando la técnica de segmentación mono-distancia. El proceso no se aplica directamente sobre las bandas sino que se modifica el espacio de color RGB original por el espacio de color YIQ para poder desacoplar la luminancia de la ecuación 2.3. Los coeficientes de la matriz Distancia se obtienen calculando la distancia Euclídea entre las bandas de crominancia del pixel prototipo y todos los pixels de la imagen. El pixel patrón (\vec{r}) es el resultado de computar componente a componente el promedio de intensidad de un sector del canal.

$$D(i, j) = \sqrt[2]{0 * (x_Y(i, j) - r_Y)^2 + (x_I(i, j) - r_I)^2 + (x_Q(i, j) - r_Q)^2}$$

Todos los resultados obtenidos sobre imágenes de alta resolución empleando esta técnica poseen características similares y un alto porcentaje de error asociado. A modo de ejemplo se presenta la figura 5.9 donde claramente se notan las deficiencias del métodos para casos con alta dispersión cromática. La segmentación del canal se ve fragmentada y posee una textura irregular con ausencia de pixels dentro de la estructura principal del mismo debido a la presencia de olas. IM exhibe múltiples zonas espúrias que no es posible eliminar con filtros morfológicos básicos sin distorsionar aún más los bordes en la imagen (figura 5.9c). Por lo tanto, su uso resulta inadecuado para las etapas posteriores de procesamiento.

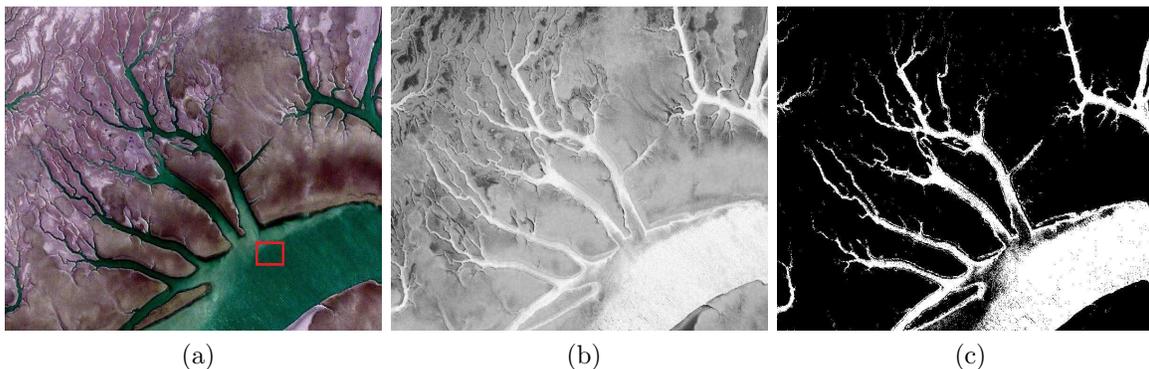


Figura 5.9: Segmentación mono-distancia de un recorte de imagen Ikonos. (a) Recorte de imagen Ikonos. El pixel prototipo es el promedio de los pixels pertenecientes a la zona delimitada del canal principal. (b) ID. (c) IM.

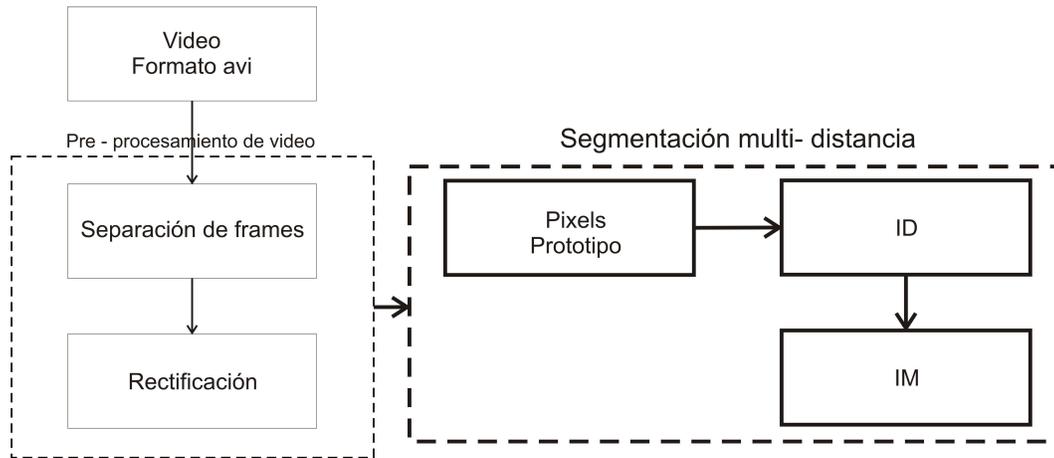


Figura 5.10: Diagrama del procesamiento de un segmento de video.

5.2.2. Segmentación Multi-distancia

La técnica de segmentación multi-distancia fue evolucionando a medida que las imágenes lo requerían. En un principio las referencias se determinan seleccionando zonas dentro de la imagen de figura y fondo y utilizando los pixels en su interior como prototipos. Sin embargo, esta práctica involucra una cantidad excesiva de pixels patrón que en su mayoría poseen una composición espectral o cromática similar.

Segmentación multi-distancia en imágenes de video

La técnica de segmentación multi-distancia también se aplica a secuencias de video para determinar la dinámica de la longitud de la línea costera con respecto a la marea (Revollo et al., 2010b) siguiendo el esquema de la figura 5.10. La cámara, instalada a 30 m de altura en el techo de un edificio, se encuentra ubicada en la zona del Balneario de Monte Hermoso, Provincia de Buenos Aires. Es un dispositivo de bajo costo, formato digital RGB y resolución aproximada de 1,5 Mp (1293 x 1142).

El tratamiento previo implica dos etapas (figura 5.11): la separación del video en los múltiples fotogramas que lo componen y la rectificación de cada uno de ellos. Cada fotograma o imagen oblicua posee una vista panorámica de la playa. La perspectiva dificulta la medición de variables geométricas presentes en la misma debido a que la escala varía en función de la posición y, por lo tanto, la rectificación resulta indispensable ya que produce resolución espacial constante.



Figura 5.11: Pre-procesamiento de fotogramas de video. (a) Fotograma de video o imagen oblicua. (b) Imagen rectificada y rotada 90° en sentido horario. El rectángulo azul representa los pixels de referencia de playa mientras que el rectángulo rojo caracteriza el sector del mar.

La segmentación aplica la metodología detallada en la sección 2.5 siguiendo el diagrama 2.9. Los pixels prototipos se determinan en forma supervisada seleccionando dos regiones rectangulares de zonas homogéneas contiguas. La figura 5.11b muestra en forma exagerada ambos sectores ya que la superficie real tomada como referencia no se visualizaría correctamente. En un paso posterior de procesamiento, el objetivo es calcular la longitud de la línea de costa y, para ello, es necesario segmentar la región de la playa de la superficie del mar. En consecuencia, los pixels de referencia del fondo caracterizan la franja de arena mientras que los de figura se ubican dentro del sector de la imagen ocupado por agua. A partir de los coeficientes de distancia Euclidiana D calculados con las bandas de color RGB se construye ID e IM cuyo umbral utilizado es $U = 125$ (figura 5.12).

Selección de pixels prototipo en imágenes Ikonos sobre canales de marea

Sobre recortes de una imagen Ikonos se aplica el proceso de segmentación multidistancia con la intención de separar las zonas de canales de marea del resto de la información de la imagen. La selección de pixels prototipo se perfecciona para disminuir el tiempo de procesamiento y mejorar el resultado final debido a que la dispersión cromática presente en la imagen impide el uso de la técnica como se utiliza en el caso anterior.

En imágenes Ikonos la selección de prototipos se obtiene en el espacio de color “YIQ”, más precisamente estudiando las componentes de cromaticidad I y Q . La eliminación de la

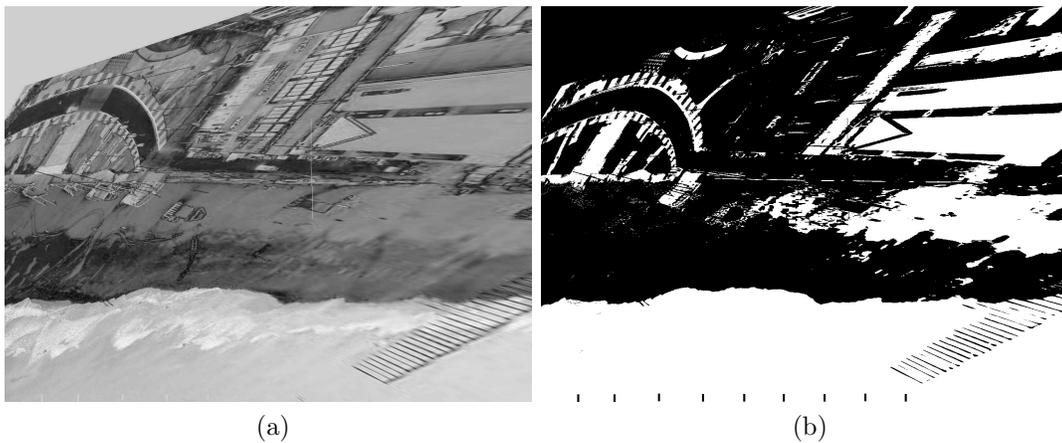


Figura 5.12: Segmentación multi-distancia de costa versus playa de fotogramas de video. (a) Imagen Distancia. (b) Máscara de la imagen distancia.

luminancia (Y) en la función escalar distancia d (ecuaciones 2.5.2) minimiza la aparición de falsos positivos y falsos negativos. El operador calcula la distancia Euclidiana de sus elementos entre los pixels de la imagen y las referencias. Los parámetros quedan definidos como $\vec{a} = (0, 1, 1)$, $\vec{k} = (2, 2, 2)$ y $K = 2$.

Los puntos de referencia se determinan siguiendo el procedimiento de la sección 2.5.1 (Cipolletti et al., 2011a). Los pixels de diversos sectores de la imagen se grafican en el plano $I - Q$ distinguiendo entre regiones de figura y fondo los cuales se marcan en rojo y azul, respectivamente. Cada pixel de referencia se elige en forma supervisada de los bordes de grupos contiguos de distinta clase.

El primer ejemplo, presenta un sector del canal principal con una cantidad moderada de ramificaciones. Los pixels marcados en la figura 5.13a ² se grafican en el diagrama de dispersión (figura 5.13c) donde se evidencia que ambas clases se agrupan en dos sectores bien definidos sin intersectarse. Se seleccionan 23 prototipos, 14 pertenecientes al fondo y 9 a zonas de canal de marea. En la tabla 5.2 se detallan las coordenadas $(i; j)$ dentro de la imagen y las componentes I y Q de cada referencia.

²Los extremos de los canales se evitan tanto en regiones de fondo como de figura. Al final de la sección se explica en detalle el motivo.

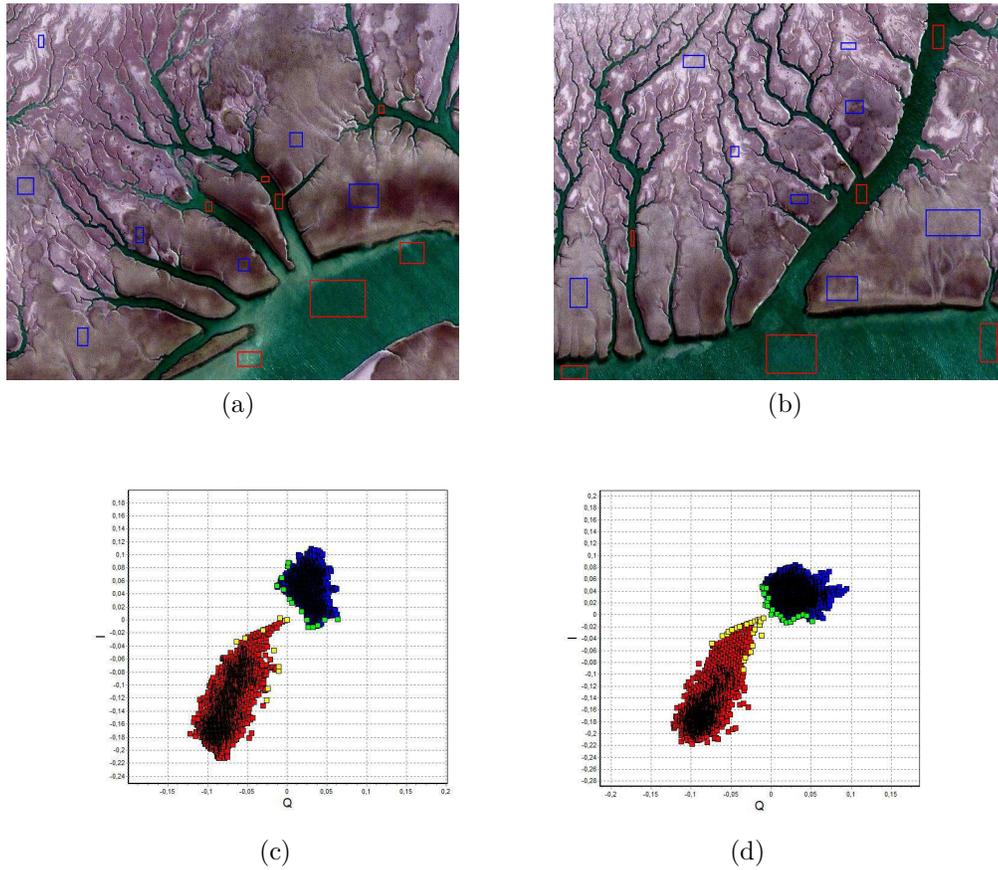


Figura 5.13: Las zonas marcadas de la figura/fondo de la imagen original con rectángulos de color rojo/azul se grafican en el plano I vs. Q . En particular, los pixels prototipo se resaltan en otro color. Ejemplo 1: (a) Delimitación de zonas. (c) Gráfico de dispersión. Ejemplo 2: (b) Delimitación de zonas. (d) Gráfico de dispersión.

Zona				Fondo			
i	j	I	Q	i	j	I	Q
683	429	-4.125	-7.844	372	540	15.682	-8.878
689	430	-11.414	-7.887	364	541	11.050	-7.548
363	318	-8.847	-10.375	375	555	8.666	-2.869
364	329	-12.835	-15.194	85	513	8.114	1.610
648	444	-22.601	-8.890	552	193	3.209	2.417
665	436	-28.562	-11.010	425	5	-1.054	2.601
460	492	-19.802	-21.075	424	5	-1.697	3.223
664	435	-36.905	-13.977	40	293	0.181	7.717
664	436	-45.250	-16.945	40	291	0.365	9.909
				423	13	-0.140	13.555
				420	11	-1.470	15.633
				420	13	-1.654	18.969
				364	549	12.746	-5.244
				365	549	12.975	-3.888

Tabla 5.2: Pixels prototipo marcados en la figura 5.13c.

El segundo ejemplo (figura 5.13b) presenta un sector del canal principal con mayor cantidad de ramificaciones mientras que las condiciones de color se mantienen similares en ambos casos. Los pixels marcados se grafican en el diagrama de dispersión y nuevamente se agrupan en dos sectores bien definidos sin intersectarse (figura 5.13d). El número de prototipos aumenta prácticamente al doble (43 puntos de referencia) lo que implica mayor costo computacional en tiempo de procesamiento.

En las figuras 5.14a y d se ve claramente el alto contraste entre las zonas de canales y el fondo. Los resultados son similares y se puede asegurar que no es necesario un gran número de prototipos. Los coeficientes de D representados en escala de gris en ID se hallan agrupados en los extremos del histograma y, por lo tanto, determinar un valor de umbral no requiere mayor esfuerzo (figuras 5.14b y e). Los dos ejemplos demuestran la convergencia del método en imágenes con amplia dispersión cromática.

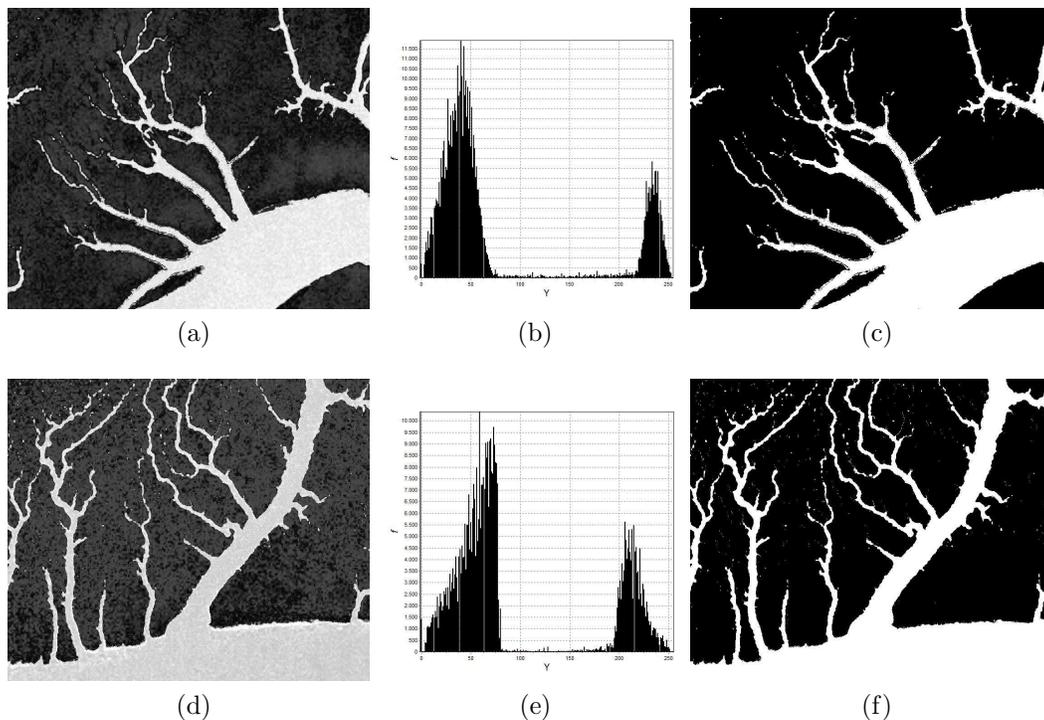


Figura 5.14: Ejemplo 1: (a) ID. (b) Histograma de ID. (c) IM. Ejemplo 2: (d) ID. (e) Histograma de ID. (f) IM.

La metodología de segmentación proporciona resultados satisfactorios con un alto grado de detalles de las áreas de cobertura de agua e información precisa de bordes en la

región de los canales principales. Sin embargo, en ambos casos, las porciones correspondientes a canales de marea secundarios se unifican con el fondo. En la figura 5.15 se ve claramente que las componentes de cromaticidad de estas regiones en el espacio de color I vs. Q, se ubican en el mismo sector del plano y no es posible distinguir entre figura y fondo. Segmentarlos exigiría la implementación conjunta de filtros que incluyan la componente de luminancia y el estudio de la estructura morfológica de la zona.

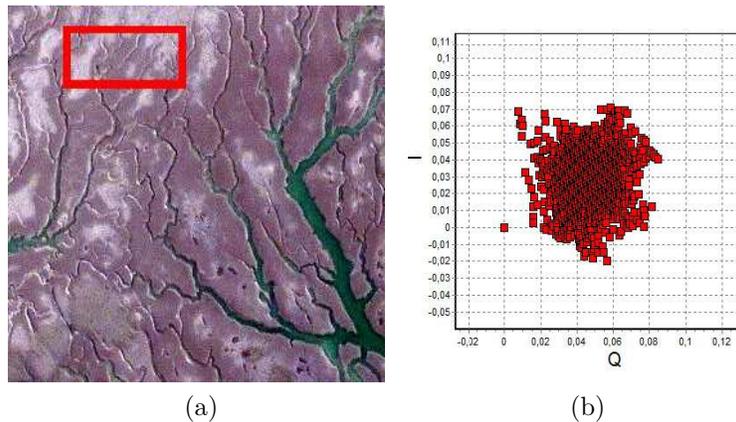


Figura 5.15: Canales de marea secundarios. (a) Zona de canales secundarios de marea. (b) Gráfico de dispersión de los puntos seleccionados en (a).

Segmentación de una isla del estuario de Bahía Blanca

Dentro del estuario de Bahía Blanca se eligió un islote el cual se segmentó en una imagen Landsat y en una imagen Ikonos. El interés por segmentar la isla radica en su utilización posterior para contrastar información de estimación realizada con mediciones extraídas de imágenes de baja resolución.

La isla se segmenta de la imagen Landsat empleando multi-distancia. La superficie que la rodea posee una cobertura heterogénea que impide utilizar un único prototipo. El operador distancia d calcula la distancia Euclídea entre todas sus bandas cuya resolución corresponde a 30 m. Los pixels prototipos se eligieron de forma supervisada de ambas zonas de interés: figura y fondo y el valor de umbral se establece en forma empírica en $U = 90$ (figura 5.16).

Los intentos de segmentar la isla dentro de la imagen Ikonos siguiendo el procedimiento usual, mostraron deficiencias en el espacio de color YIQ. A diferencia de las zonas con



Figura 5.16: Segmentación de una isla del estuario de Bahía Blanca en imagen Landsat. De izquierda a derecha: ID, ID binarizada e IM.

canales de marea, las componentes cromáticas entre la isla de sedimentos y la región circundante se superponen (figura 5.17b).

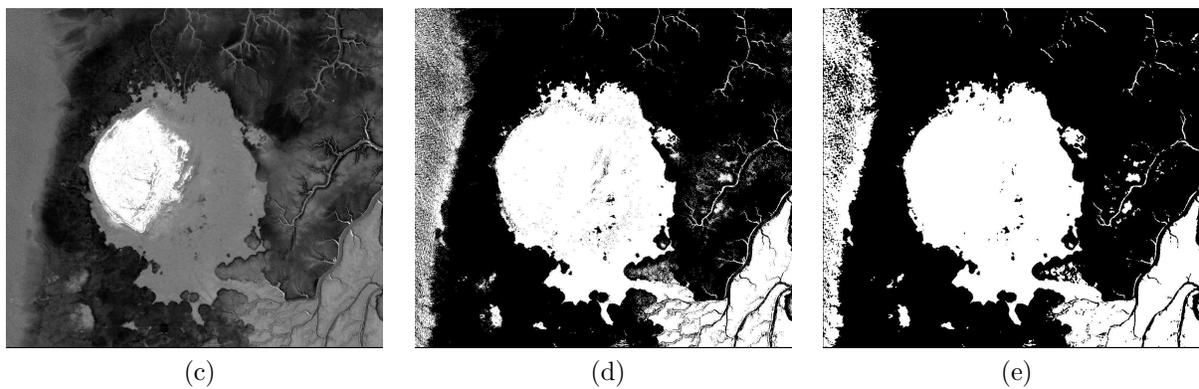
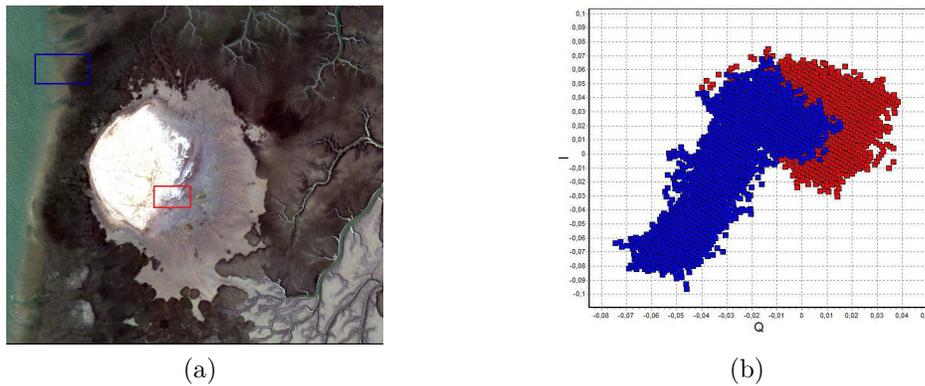


Figura 5.17: Isla del estuario de Bahía Blanca en imagen Ikonos. (a) Recorte sobre imagen Ikonos. (b) Gráfico de dispersión Ivs.Q de las regiones marcadas en (a). (c) ID. (d) ID binarizada. (e) Imagen binaria post procesada con filtros morfológicos.

El mejor resultado, figura 5.17c, se obtiene en el espacio de color RGB (las zonas de pixels prototipos se marcaron en la figura 5.17a). Sin embargo, su binarización sigue

siendo inadecuada para los cálculos posteriores, incluso después de ser procesada con filtros morfológicos para eliminar las zonas espurias (figuras 5.17d y e). La correlación entre los colores sigue siendo fuerte y la figura 5.17e cumple parcialmente con el objetivo de separar la isla del fondo. La segmentación final que posteriormente permite las mediciones correspondientes se realiza en forma supervisada.

5.3. MSI y su comparación con métodos estándar

En esta sección se estima el perímetro de un par de accidentes geográficos segmentados de imágenes Landsat. Los tres métodos empleados para medir son los dos algoritmos desarrollados por Freeman (secciones 3.2 y 3.2) y el MSI presentado en el marco de esta tesis (Cipolletti et al., 2012). En los casos donde el software Envi[®] obtiene resultados satisfactorios en la segmentación también se calcula el perímetro con la función que provee y se comparan los resultados obtenidos.

5.3.1. Espejos de agua en imágenes Landsat

En la figura 5.5 se segmentan los espejos de agua pertenecientes al centro de la Provincia de Buenos Aires. Si bien no es accesible la zona ³ para realizar una medición de campo con la cual comparar, la inspección visual de la figura 5.18 muestra que la segmentación de bordes del MSI es más verosímil que las de BEP y CC en los dos ejemplos. Los bordes resultantes (figuras 5.18a y d) producidos por el MSI forman una poligonal suave delimitando la laguna, en contraste con el contorno escalonado que se obtiene con los métodos BEP (figuras 5.18b y e) y CC (figuras 5.18c y f).

³Las lagunas de la región se encuentran en propiedad privada con acceso restringido a sus dueños. Por otra parte, poseen una superficie que varía según la temporada en la que se realiza la adquisición de la imagen e incluso en algunos casos, se trata de lagunas estacionales. Este fenómeno se minimiza en aquellas lagunas de gran superficie, pero se incrementa la dificultad de transitar con el transporte adecuado para rodearla con un equipo de medición.

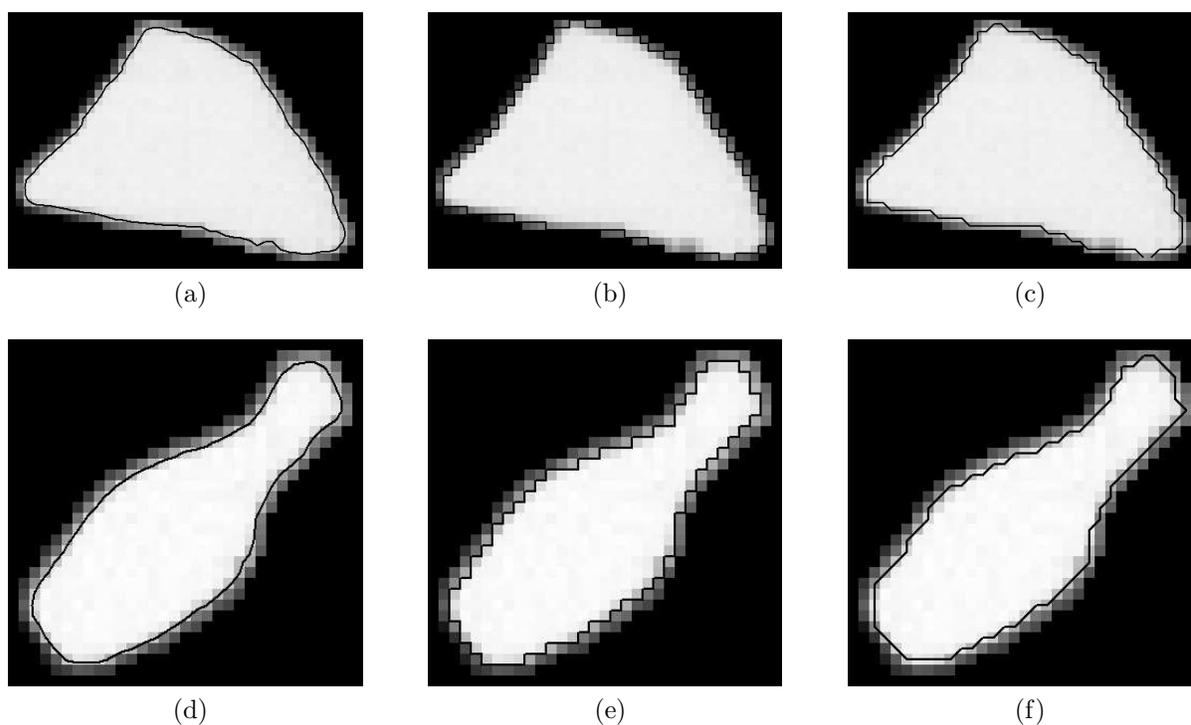


Figura 5.18: Definición de contorno en lagunas segmentadas sobre imágenes Landsat. (a) y (d) Método MSI. (b) y (e) Método BEP. (c) y (f) Método CC.

Los resultados provistos por el Envi[®] son muy similares en magnitud a los datos conseguidos con el BEP (tabla 5.3). Las pequeñas diferencias en la medición se deben a la segmentación exponiendo el método de cálculo utilizado por el software cuyas deficiencias ya han sido establecidas en la sección 3.4.

	Perímetros	
Envi [®]	4500,00 m	3600,00 m
MSI	3342,06 m (fig. 5.18a)	2546,70 m (fig. 5.18d)
BEP	4320,00 m (fig. 5.18b)	3420,00 m (fig. 5.18e)
CC	3484,50 m (fig. 5.18c)	2614,50 m (fig. 5.18f)

Tabla 5.3: Datos de medición de perímetros de las lagunas en la figura 5.18.

5.3.2. Parcela de campo en imagen Landsat

En la figura 5.7, sección 5.2.1, se presentan los resultados de segmentación de parcelas de un cultivo determinado en la Provincia de Buenos Aires a partir de una imagen Land-

sat 7. El objetivo es determinar la precisión del método MSI y los algoritmos de Freeman comparando los datos con la medición de campo realizada con un equipo de GPS-RTK Sokkia de alta precisión (1 cm en el plano horizontal). Todos los detalles de la campaña se exponen en el apéndice B. Elegida la parcela, figura 5.19, se calcula la longitud del borde con los tres métodos estudiados en el capítulo 3.



Figura 5.19: Segmentación de campo de una parcela en la Provincia de Buenos Aires. Zoom de un sector segmentado en la figura 5.7.

En la tabla 5.4 se presentan los datos medidos y el cálculo del error relativo correspondiente a cada caso (la segmentación entregada por el Envi[®] no permite medición alguna y, por lo tanto, no se incluyen sus resultados). La rotación cercana a 60° y la forma rectangular de la parcela permiten suponer a priori el rango de error producido en cada caso (figura 3.10). Los resultados obtenidos se corresponden con el estudio de comportamiento realizado en la sección 3.4 favoreciendo al algoritmo de Freeman de 8 niveles de adyacencia y exhibiendo el peor aspecto del método BEP. El MSI posee un error significativamente bajo, menor al 1 %, siendo el más preciso de los algoritmos empleados.

Valor Medido: 4821,74 m		
Método	Perímetros	e %
BEP	6600 m	36,88
CC	4961 m	2,89
MSI	4854 m	0,67

Tabla 5.4: Resultados de medición de campo de una parcela en la Provincia de Buenos Aires. Las mediciones realizadas con cada método se compara con el Valor medido para obtener e .

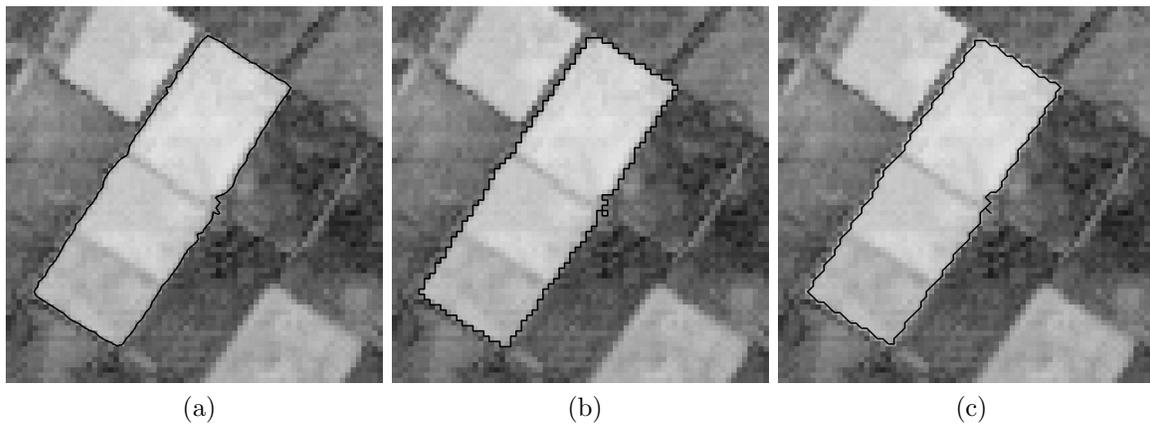


Figura 5.20: Medición de campo de una parcela en la Provincia de Buenos Aires. Algoritmo de borde correspondiente a: (a) MSI, (b) BEP y (c) CC.

5.3.3. Línea de costa en fotogramas de video

Los fotogramas de video procesados y segmentados en la sección 5.2.2 permiten la identificación y la medición de parámetros topográficos de la playa. La línea de playa se encuentra entre ellos y en esta sección se determina su ubicación y se mide su longitud (figura 5.21). Además de los algoritmos de prueba y el MSI, se calcula en forma supervisada el perímetro empleando un software SIG. Dicho resultado se emplea como valor de referencia V_r para comparar las demás medidas.

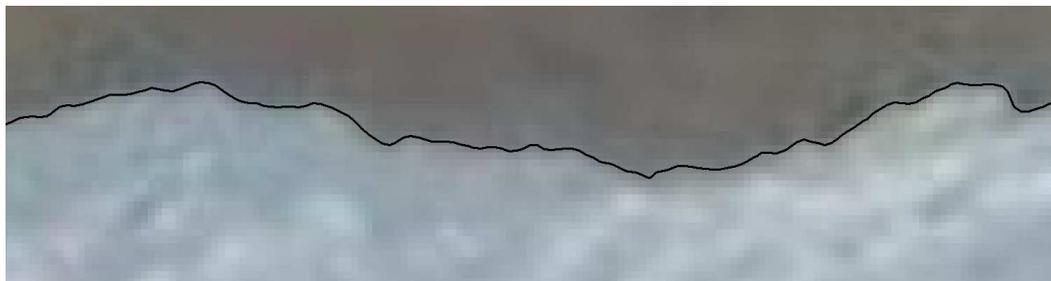
BEP y CC cometen error en exceso que supera el 30% en el peor caso. En contraste, MSI calcula la poligonal con una diferencia menor al 3% respecto de la muestra. Esto se puede atribuir a la tendencia del usuario a despreciar pequeños detalles e incluso es esperable que la longitud real se encuentre ligeramente por encima del valor obtenido bajo supervisión (tabla 5.5). El comportamiento de los tres algoritmos se aprecia en detalle en las figuras 5.22a, 5.22b y 5.22c donde se superpone la frontera sobre la imagen rectificadas que contiene el sector de la costa.

$V_r = 1193 \text{ m}$		
Método	Perímetros	$e \%$
BEP	1558 m	30,59
CC	1322 m	10,81
MSI	1225 m	2,68

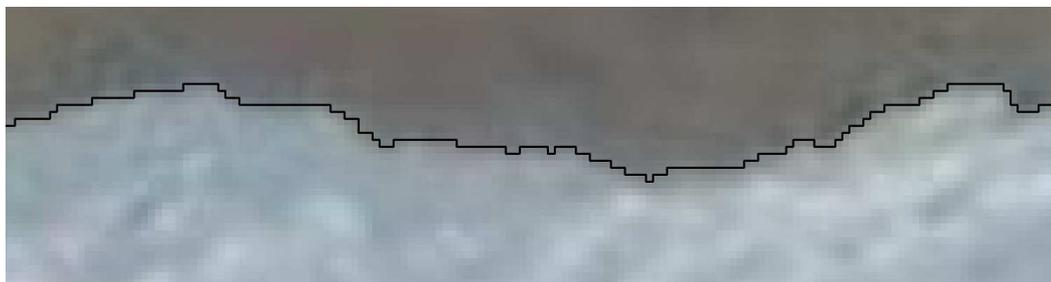
Tabla 5.5: Resultado de las mediciones sobre la línea de costa en imágenes de video.



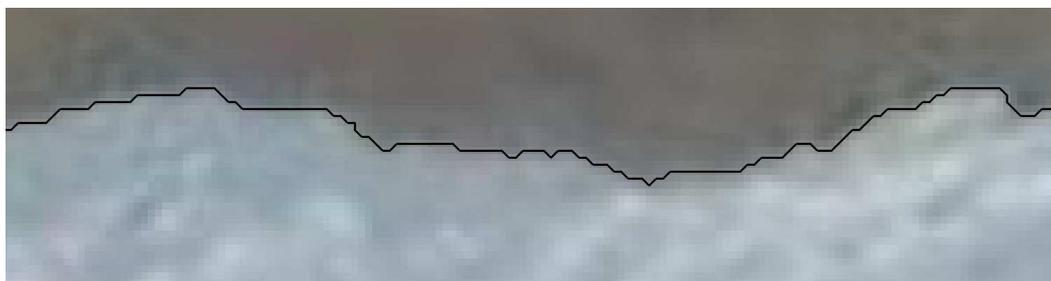
Figura 5.21: Línea de costa en imágenes de video. Sector seleccionado dentro de la imagen 5.11b para la medición.



(a)



(b)



(c)

Figura 5.22: Línea de costa en imágenes de video del sector marcado en la figura 5.21. (a) Método MSI. (b) Método BEP. (c) Método CC.

5.4. Estimación de perímetros con regresión fractal

5.4.1. Validación de resultados con imágenes Landsat

A partir de un recorte de imagen Landsat, se segmenta una porción de la costa (figura 5.5, sección 5.2.1). Los accidentes geográficos que denotan presencia de agua: lagunas, ríos, el dique, etc; se eliminan de la imagen distancia en forma supervisada. La imagen final utilizada en las mediciones presenta la silueta de la costa Sur de la Provincia de Buenos Aires. El objetivo es medir y comprobar la dependencia de la resolución en el valor final de la medición.

La escala se modifica en el entorno $[30\text{ m}, 210\text{ m}]$ con un cambio de paso de 60 m entre sí y se emplea para realizar el cálculo el algoritmo MSI(sección 3.3). En la figura 5.23 se presenta el diagrama de dispersión correspondiente a las mediciones realizadas (tabla 5.6). La diferencia de perímetros entre resoluciones contiguas ronda el 3%, aproximadamente, en todos los casos. Es decir, un aumento en la escala reduce el nivel de detalle y longitud de la poligonal es menor. La curva va adquiriendo una forma rudimentaria y, por lo tanto, queda demostrado que el resultado de la medición está directamente asociado a la resolución de la imagen utilizada en la misma (figura 5.24).

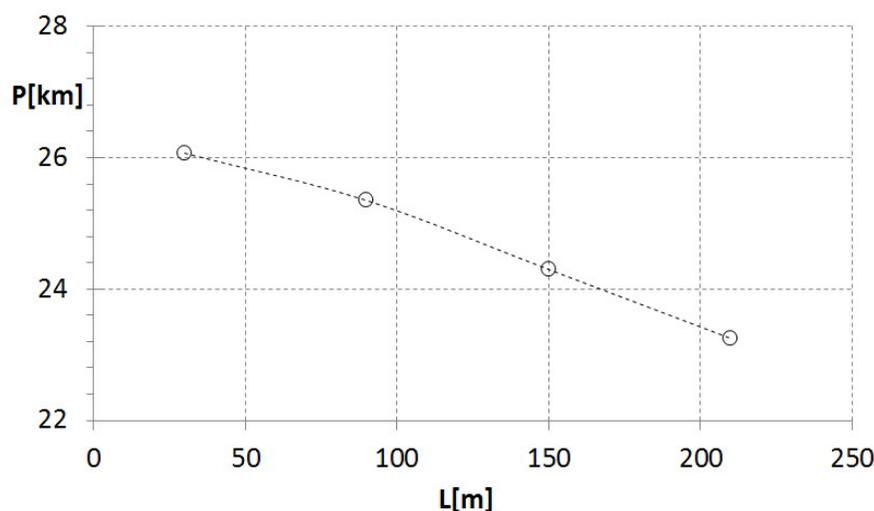
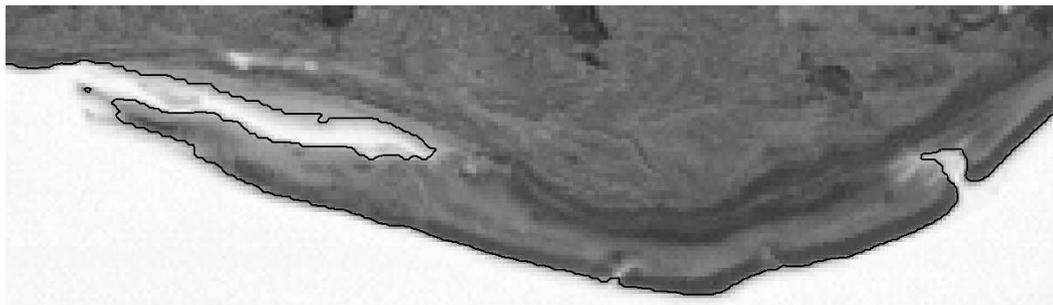
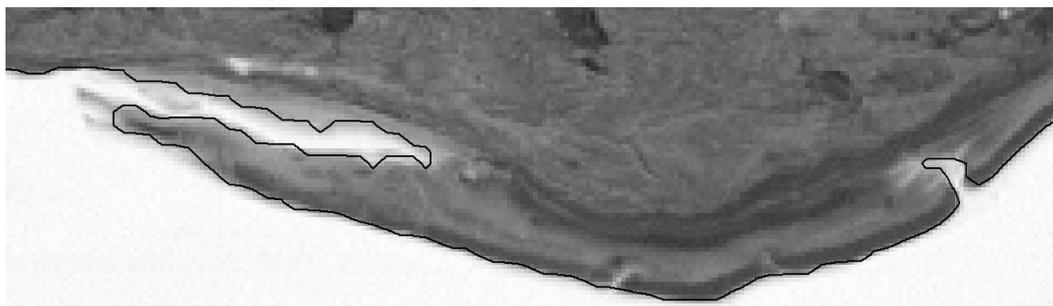


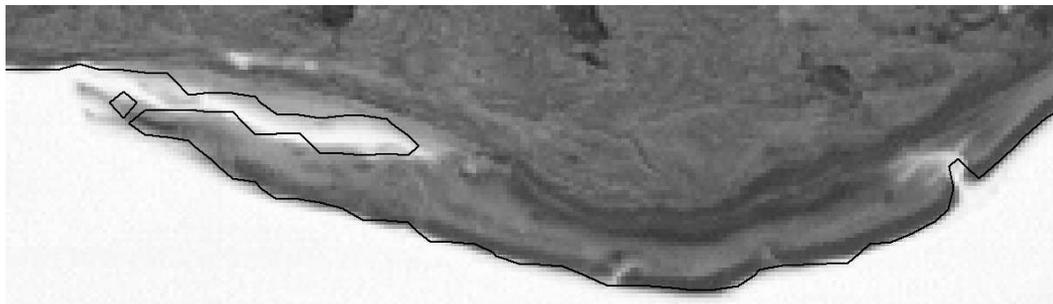
Figura 5.23: Escala versus perímetro: longitud medida en función de la resolución empleada.



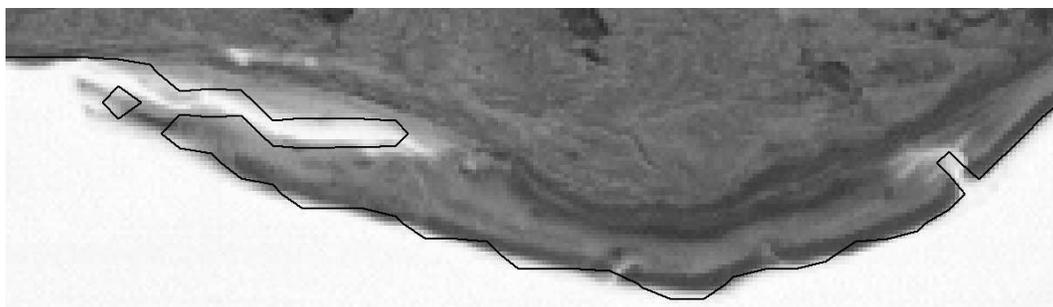
(a)



(b)



(c)



(d)

Figura 5.24: Cambio de escala de medición. (a) Resolución $L = 30 m$. (b) Resolución $L = 90 m$. (c) Resolución $L = 150 m$. (d) Resolución $L = 210 m$.

Resolución [m]	Perímetros [m]	$100 - (100 * P_{L_i}/P_{L_{30}})[\%]$
30	26070	0
90	25350	2,76
150	24300	6,79
210	23250	10,81

Tabla 5.6: Datos de medición de perímetro de la figura 5.24.

Para validar la metodología de estimación por regresión fractal (capítulo 4.3), se procede a evaluarlo con la porción de costa (figura 5.4) segmentada en imagen Landsat. La resolución utilizada para la medición directa es de $L = 30 m$ (resolución original) y se generan submuestras de la misma con resolución final variando L entre $150 m$ y $270 m$. El valor del perímetro con escala $L = 30 m$ medido se compara con el resultado estimado con las ecuaciones de la sección 4.3 y los datos medidos sobre las imágenes sub-muestreadas.

El análisis se realiza en paralelo con los tres métodos de medición de perímetros estudiados en el capítulo 3; MSI, BEP y CC. El objetivo es determinar la dependencia existente entre la rutina y el algoritmo de medición. Los subíndices m y e corresponden a los valores medidos y estimados (tabla 5.7).

En los tres casos, el error porcentual entre el perímetro medido (P_m) y el estimado (P_e) es inferior al 3% permitiendo suponer que el método se independiza del algoritmo de medición. A su vez, el coeficiente de determinación r^2 para MSI, BEP y CC es $r^2 = 0,980$, $r^2 = 0,855$ y $r^2 = 0,965$ respectivamente, asegurando una correlación elevada, es decir $r^2 > 0,8$. En la figura 5.25 se presentan en forma gráfica los datos de la regresión fractal y los puntos importantes detallados en la tabla 5.7.

Resolución	$\text{Log}(L)$	$\text{Log}(P)$	$\text{Log}(1/L)$	P estimado
30	1,477121255	5,178379865	-1,477121255	5,18965968
150	2,176091259	5,144557209	-2,176091259	5,143766372
180	2,255272505	5,137659732	-2,255272505	5,138567452
210	2,322219295	5,134264398	-2,322219295	5,134171828
240	2,380211242	5,129344845	-2,380211242	5,130364165
270	2,431363764	5,128049201	-2,431363764	5,127005568

(a)

Resolución	$\text{Log}(L)$	$\text{Log}(P)$	$\text{Log}(1/L)$	P estimado
30	1,477121255	5,267195203	-1,477121255	5,278556432
150	2,176091259	5,226471015	-2,176091259	5,229274426
180	2,255272505	5,225619381	-2,255272505	5,223691624
210	2,322219295	5,223132362	-2,322219295	5,218971433
240	2,380211242	5,213358354	-2,380211242	5,214882617
270	2,431363764	5,209515015	-2,431363764	5,211276026

(b)

Resolución	$\text{Log}(L)$	$\text{Log}(P)$	$\text{Log}(1/L)$	P estimado
30	1,477121255	5,203498783	-1,477121255	5,212718048
150	2,176091259	5,165202623	-2,176091259	5,166186438
180	2,255272505	5,16250707	-2,255272505	5,160915209
210	2,322219295	5,155631816	-2,322219295	5,156458449
240	2,380211242	5,153791326	-2,380211242	5,152597827

(c)

Tabla 5.7: Datos de las mediciones de la costa sur de la Provincia de Buenos Aires. Medidos con el algoritmo: (a) MSI, (b) BEP y (c) CC.

Sin embargo, también es importante destacar que la estimación en principio se contrasta con el resultado medido en la resolución original y, por lo tanto, el error de estimación posee asociado al procedimiento el error inherente de cada método. Como se demuestra en el capítulo 3 podemos suponer que el algoritmo MSI produce los resultados más precisos en condiciones de medición directa. En la Tabla 5.8 se comparan los perímetros de cada método en particular ($e_{\%}$) y con la medición realizada con el algoritmo MSI ($e_{MSI\%}$).

	DF	$e\%$	$e_{MSI\%}$	r^2
MSI	1,06565848	2,56	2,56	0,980
BEP	1,070506612	2,14	22,94	0,855
CC	1,066571683	2,65	8,23	0,965

Tabla 5.8: Resultados de la extrapolación de perímetro de la costa sur de la Provincia de Buenos Aires comparado con la medición directa de cada método en particular ($e\%$) y con la medición realizada con el algoritmo MSI ($e_{MSI\%}$).

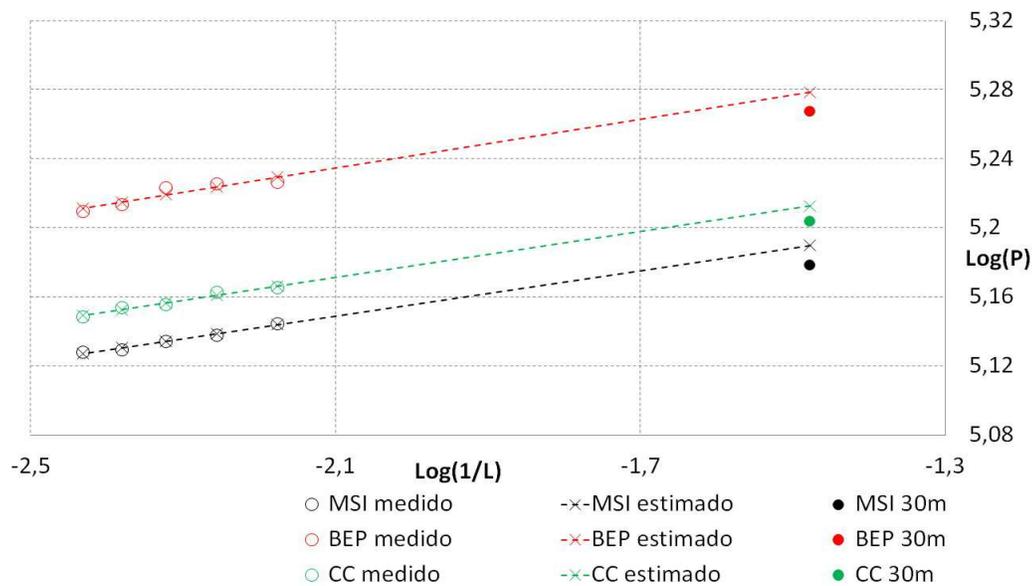


Figura 5.25: Regresión fractal del perímetro de la figura 5.4. El método de medición detallado en color negro es el MSI, en color rojo el BEP y en verde el CC.

Orden entre el submuestreo y la segmentación

El procedimiento de estimación comienza segmentando la imagen original y, posteriormente, submuestra la ID para obtener las imágenes de resolución gruesa. Sin embargo, la intuición establece que el orden correcto implica submuestrear todas las bandas de información para luego segmentar. Ésta práctica aumenta considerablemente el costo computacional y supone realizar la segmentación individualmente para cada resolución por separado.

La segmentación es la tarea con mayor caudal de toma de decisiones provenientes de un operario experto. Eso significa que hay que definir todos sus coeficientes (\vec{a} , \vec{r} , \vec{k} y

K) de manera individual y, por lo tanto, multiplicar instancias de segmentación supone multiplicar la tarea de definición de parámetros. El resto de las operaciones es posible realizarlas de manera automática sin intervención alguna entre sus instancias.

Para determinar las ventajas o desventajas entre aplicar primero una operación u otra se analizan los resultados con $L = 150$ y $L = 240$. Cada banda de la imagen original Landsat se submuestra y luego se segmenta con el objetivo de medir la diferencia de perímetros medidos en cada caso. Las bandas empleadas de la imagen y los parámetros de segmentación son los mismos que los empleados en el proceso inverso (ver sección 5.2.1).

En el primer caso, $L = 150$ m la imagen presenta un 0,4% de diferencia en la medición de perímetro y, en el segundo caso, la diferencia es menor al 0,1%. La Figura 5.26 muestra los resultados de superponer las IM conseguidas en ambos casos y las poligonales de los bordes en $L = 150$ m. Este mismo proceso se realiza en todas las resoluciones empleadas pero se incluyen solo los datos con mayor y menor error asociado. Estos resultados demuestran que es indistinto invertir ambos procesos y aumentar innecesariamente el costo computacional. Además la cantidad de pixels espurios disminuye con las sucesivas etapas de submuestreo.

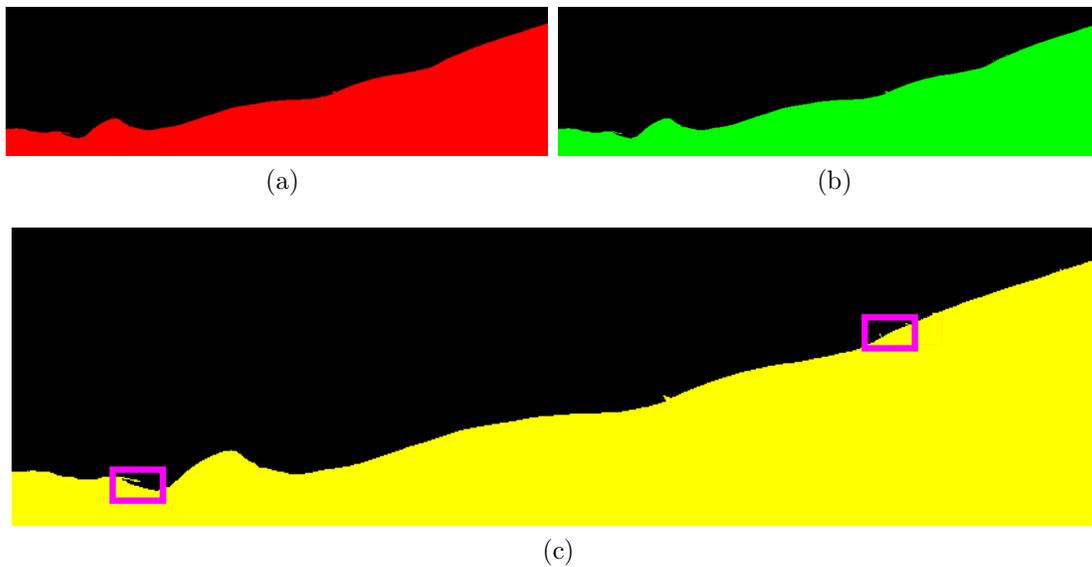


Figura 5.26: Conmutación entre segmentación y submuestreo. (a) IM: Segmentación + Submuestreo. (b) IM: Submuestrea + Segmentación. (c) IM superposición: Fig. 5.26a + Fig. 5.26b. Continúa...

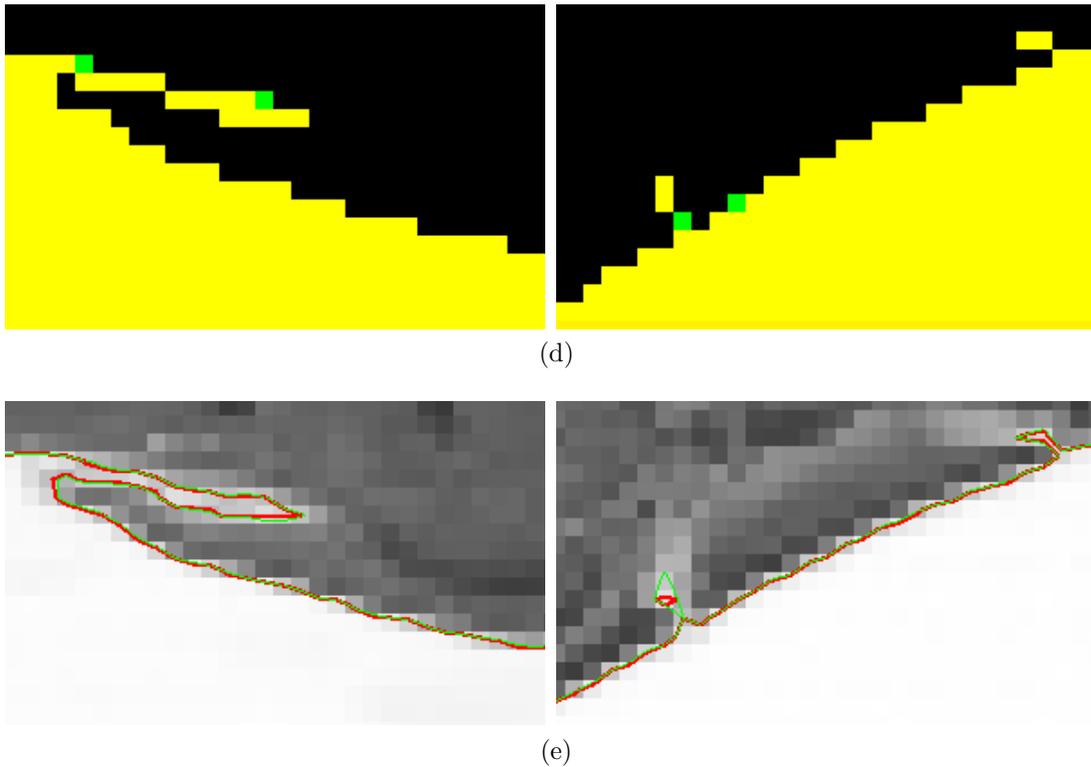


Figura 5.26: Conmutación entre segmentación y submuestreo. Continuación: (d) Zoom de la imagen previa. (e) Superposición de la línea de costa (en rojo/verde se muestran las coordenadas obtenidas por el algoritmo MSI en la imagen $ID_{(a)}$ / $ID_{(b)}$).

5.4.2. Validación de resultados con imágenes de alta resolución

En el segundo caso se verifican los resultados con mediciones realizadas en imágenes de resolución fina. Se elige un islote dentro del estuario de Bahía Blanca y se segmenta en dos tipos distintos de imágenes (sección 5.2.2). Como se destaca durante el proceso de segmentación (figuras 5.17d y 5.17e), el resultado es inadecuado para su medición y, por lo tanto, requiere supervisión externa para extraer completamente la isla del contexto en el que se encuentra (figura 5.27g).

Por un lado, se utiliza el recorte de imagen Landsat y se le aplica el método de estimación fractal presentado y, por el otro, el recorte de imagen Ikonos de alta resolución cuyo perímetro medido se emplea para contrastar el resultado. La resolución utilizada para la medición directa es de $L = 1 \text{ m}$ (imagen Ikonos) y se generan submuestreos de la imagen Landsat cuya resolución varía entre $L = [30 \text{ m}, 90 \text{ m}]$. El valor del perímetro

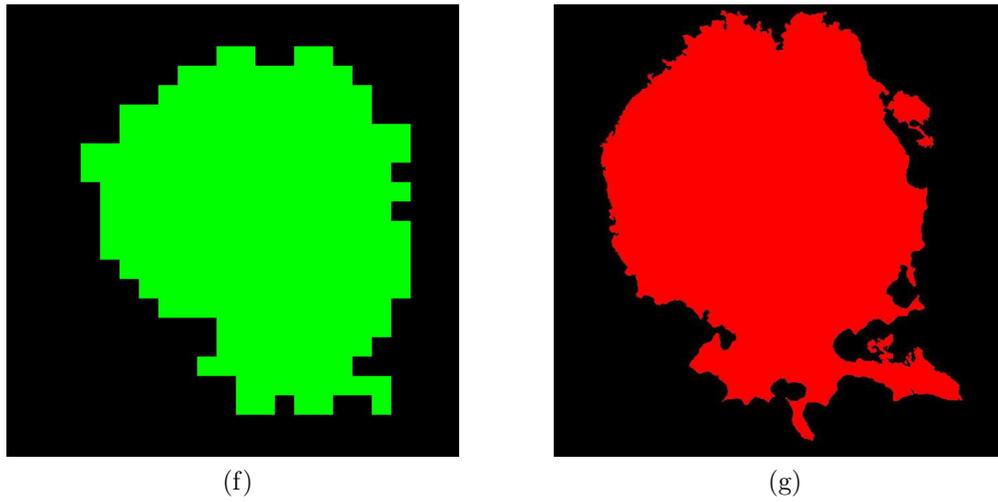


Figura 5.27: IM de la isla del estuario. (f) Imagen Landsat. (g) Imagen Ikonos.

con escala $L = 1 \text{ m}$ medido se compara con el resultado estimado con las ecuaciones de la sección 4.3 y los datos medidos sobre las imágenes sub-muestreadas. El análisis se realiza en paralelo con los tres métodos de medición de perímetros estudiados en el capítulo 3; MSI, BEP y CC.

En los tres casos, el error porcentual entre el perímetro medido (P_m) y el estimado (P_e) es aceptable para una estimación (inferior al 25 %) siendo el CC el algoritmo que peor estima. BEP y MSI no superan el 2% de error donde BEP infiere el resultado más preciso. El coeficiente de determinación para es $r^2 \approx 1$ asegurando una correlación muy elevada en todos los casos.

En este ejemplo, es importante destacar que si bien el error de estimación es bajo no se contempla el error inherente de cada método. La forma cuasi-circular de la isla hace suponer que el algoritmo BEP incurre en errores sistemáticos mayores al 25 % (figuras 3.8 y 3.9) ya que las circunstancias no brindan el marco ideal para un buen desempeño.

En la figura 5.28 se presentan en forma gráfica los datos de la regresión fractal y los puntos importantes detallados en la tabla 5.9. El error calculado en la estimación es de 1,39%, superando el desempeño de métodos estándar de medición como los algoritmos de Freeman de cuatro y ocho niveles de adyacencia. En la Tabla 5.10 los datos de extrapolación se comparan con los resultados de medición directa y el MSI.

Resolución	Perímetro	$Log(P)$	$Log(1/L)$	P estimado
1	4451,42	3,648498573		3,642437745
30	2086,03	3,31932055	-1,477121255	3,316553686
60	1748,41	3,242643282	-1,77815125	3,250140129
90	1644,45	3,216020673	-1,954242509	3,211290689

(a)

Resolución	Perímetro	$Log(P)$	$Log(1/L)$	P estimado
1	5466	3,737669627	0	3,734923993
30	2700	3,431363764	-1,477121255	3,428408502
60	2280	3,357934847	-1,77815125	3,365942163
90	2160	3,334453751	-1,954242509	3,329401697

(b)

Resolución	Perímetro	$Log(P)$	$Log(1/L)$	P estimado
1	4419,45	3,645368225	0	3,532627352
30	2140,66	3,330547694	-1,477121255	3,329490158
60	1928,53	3,285226399	-1,77815125	3,288091804
90	1843,67	3,265683189	-1,954242509	3,26387532

(c)

Tabla 5.9: Estimación del perímetro de una isla del estuario de Bahía Blanca. Método: (a) MSI, (b) BEP y (c) CC.

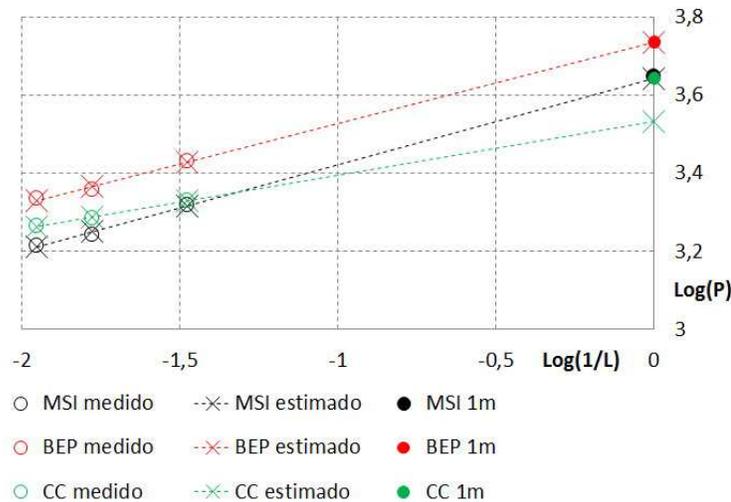


Figura 5.28: Regresión fractal del perímetro de una isla del estuario. El método de medición detallado en color negro es el MSI, en color rojo el BEP y en verde el CC.

	DF	$e_{\%}$	$e_{MSI_{\%}}$	r^2
MSI	1,2206	1,39	1,39	≈ 1
BEP	1,2075	0,63	22,02	≈ 1
CC	1,1375	22,86	23,42	≈ 1

Tabla 5.10: Resultados de la extrapolación de perímetro de un Islote del estuario de Bahía Blanca comparado con la medición directa de cada método en particular ($e_{\%}$) y con la medición realizada con el algoritmo MSI ($e_{MSI_{\%}}$).

En la figura 5.29 se presentan los resultados de superponer las imágenes binarias y las poligonales del perímetro obtenido en cada caso con el cambio apropiado en la escala. En ambas imágenes se observa que si bien la imagen Landsat no posee los detalles de alta frecuencia presentes en la imagen Ikonos es evidente su correspondencia.

En ambos ejemplos los resultados de estimación son aceptables y se puede inferir que el método es robusto frente a cambios en el algoritmo de medición. Si bien en el primer caso, estimación de la longitud de la costa, el nivel de rugosidad es bajo ($DF = 1,065$), para la isla de sedimentos la DF obtenida es de 1,22 ya no tan pequeña teniendo en cuenta que la costa de Gran Bretaña presenta el mismo valor y es una de las costas más fragmentadas del planeta.

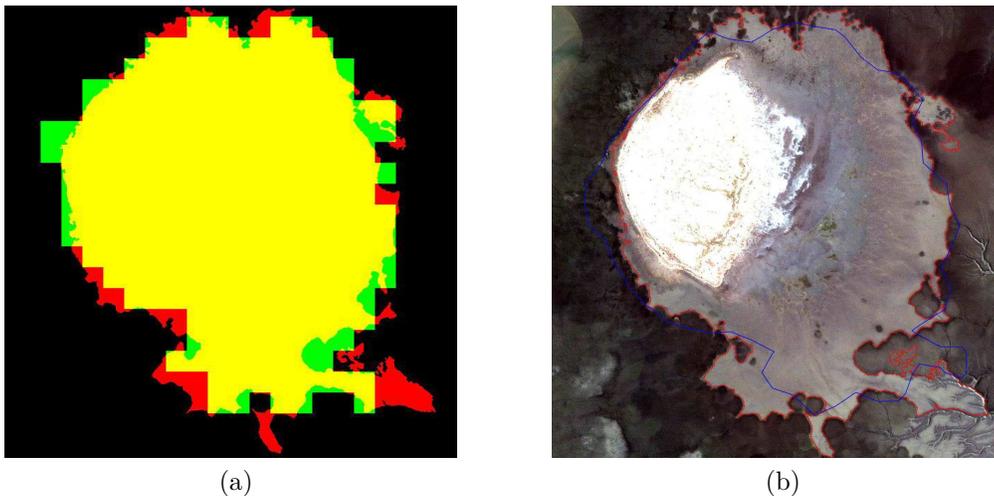


Figura 5.29: Superposición de resultados. (a) Superposición de las imágenes binarias de la figura 5.27. (b) Superposición de línea de costa (en rojo/azul coordenadas obtenidas a partir de MSI en la imagen Ikonos/Landsat).

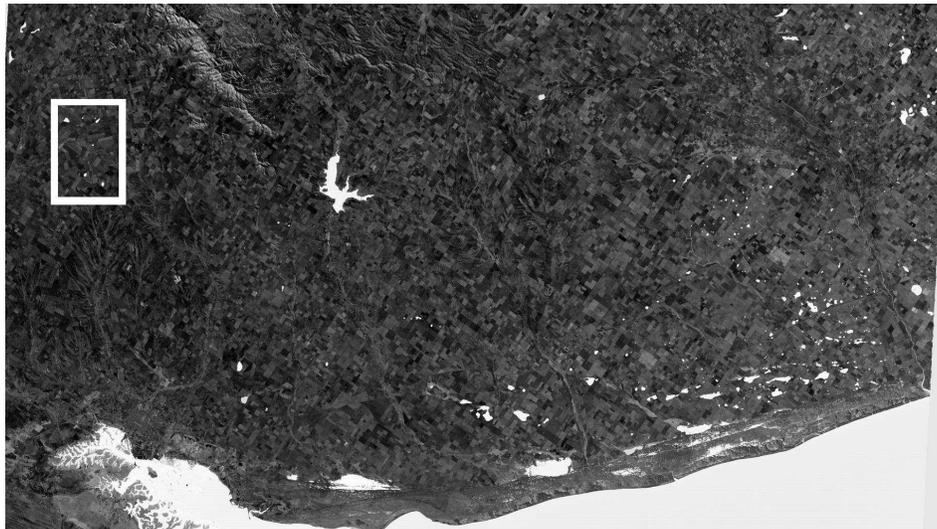
5.5. Relevamiento de lagunas del Sur de la Provincia de Buenos Aires

Dada la imagen Landsat segmentada (figura 5.5) se realiza un relevamiento de lagunas del Sur de la Provincia de Buenos Aires. A modo de ejemplo, se utiliza una pequeña porción de la imagen mencionada (figura 5.30a). En la misma se enumeran las entidades y se extraen los datos de coordenadas de los márgenes máximos, mínimos y puntos medios, los cuales se traducen fácilmente en coordenadas geográficas⁴.

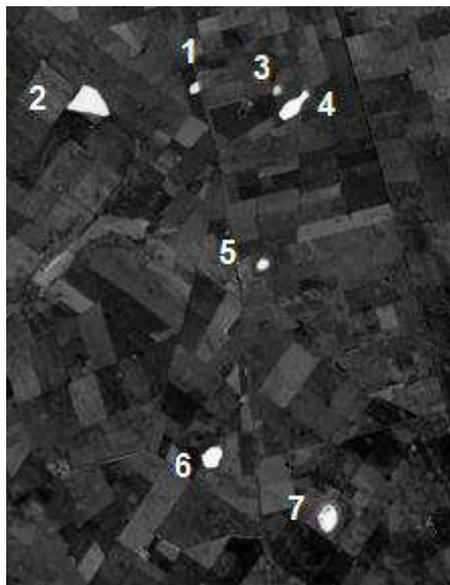
Luego se utilizan las herramientas de medición de contornos e interiores súper resolución que apuntan a la descripción morfológica: áreas (A) y perímetros (P). El MSI fue descrito en el capítulo 3 y su implementación para el cómputo de área calcula la superficie interna de los Bit Quads en grilla corrida teniendo en cuenta la posición de las coordenadas en cada configuración (figura 3.4). Además de los descriptores usuales, perímetro y área, se calcula el factor de forma, $FF = \frac{4\pi A}{P^2}$, coeficiente derivado de las variables anteriores. Es importante destacar que ambas magnitudes poseen errores bajos y comparables y, por lo tanto, el coeficiente no pierde sentido desde el punto de vista morfológico debido a la distorsión de uno de los parámetros. También se determinan la dimensión fractal box del área del blanco sobre negro (DF) y de negro sobre blanco (CoDF). Estas dos últimas técnicas permiten una clasificación más rica en términos cualitativos de los accidentes geográficos. Es importante resaltar que la exactitud ya no se ve limitada a la dimensión de la celda que en este caso es de 30 m.

Los datos se presentan en la tabla 5.11:

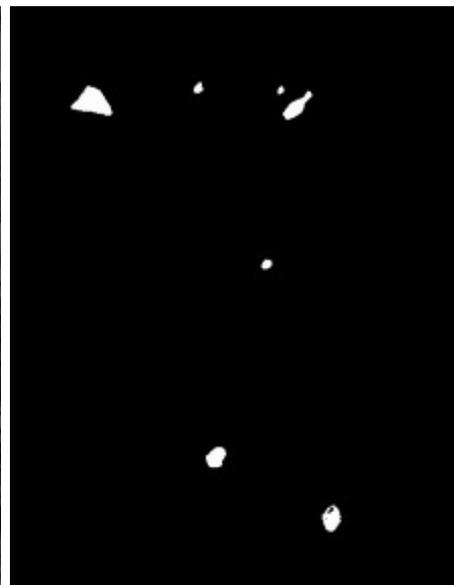
⁴Los archivos de texto con referencias a coordenadas geográficas resultan beneficiosos por la facilidad con la que pueden ser incorporados a bases de datos en SIG.



(a)



(b)



(c)

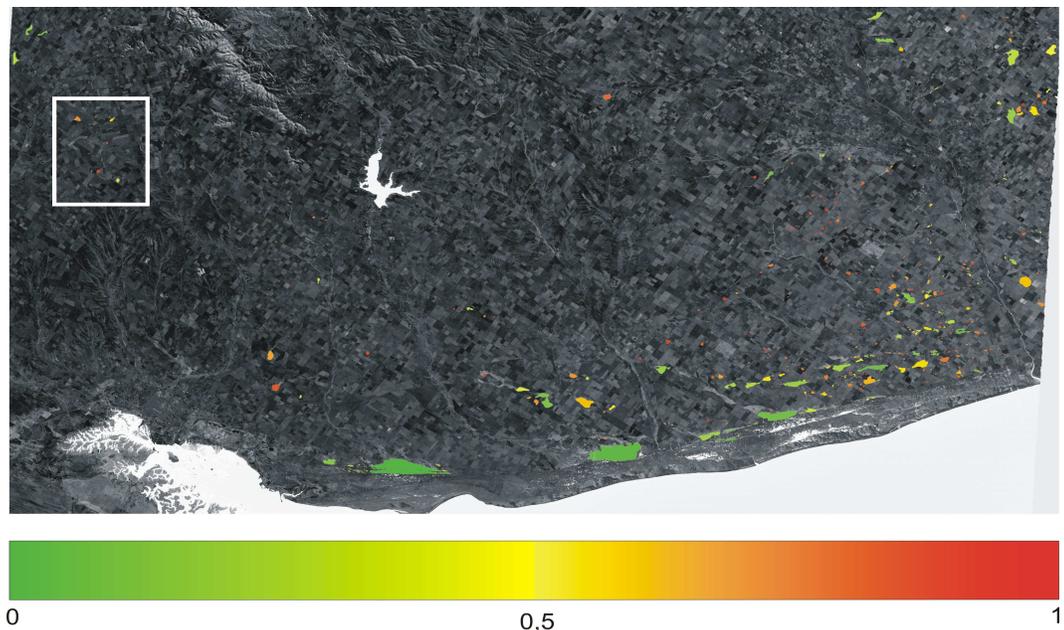
Figura 5.30: Segmentación mono-distancia de agua sobre imagen Landsat 7. (a) Zona incluida en la tabla 5.11. (b) ID. (c) IM.

Índice	Xmin	Ymin	Xmax	Ymax	Xmedio	Ymedio
1	181	75	189	85	1900	81
2	60	79	100	107	81	94
3	264	79	269	86	2700	83
4	269	84	297	111	2800	99
5	248	249	257	258	2500	2500
6	193	434	212	453	200	4400
7	308	491	325	516	3200	500

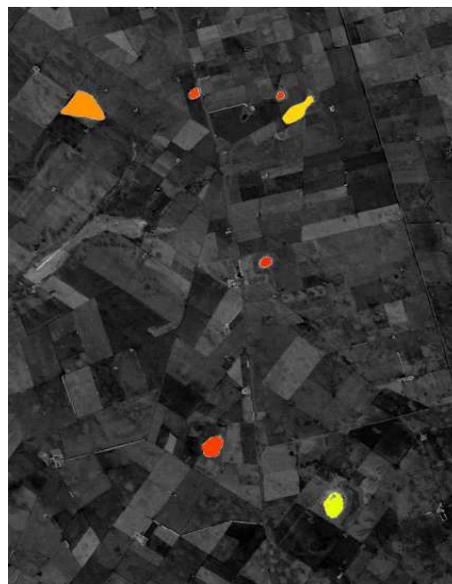
Índice	P	A	FF	DF	CoDF
1	926,8	59230000	0,866395	1,406	1,669
2	3297	616300000	0,712653	1,555	1,639
3	645,3	29350000	0,885814	1,336	1,501
4	2540	296900000	0,578622	1,365	1,633
5	957,5	66530000	0,911937	1,41	1,655
6	1918	257300000	0,879266	1,543	1,601
7	2782	2800000	0,454688	1,583	1,648

Tabla 5.11: Base de datos resultante. Los índices corresponden con las identificaciones marcadas en la figura 5.30b

Una de las formas de clasificación, una vez obtenidas las mediciones, es en forma gráfica. A modo de ejemplo en la figura 5.31 se muestran las lagunas coloreadas a partir de una escala de color teniendo en cuenta su factor de forma. Dicha característica permite hacer conjeturas acerca de la relación entre la forma y el origen geológico.



(a)



(b)

Figura 5.31: Clasificación según el factor de forma (FF). El pseudo color aplica rojo/verde al valor máximo/mínimo de la información.

Capítulo 6

Conclusiones

El procesamiento inteligente de imágenes está ganando aplicaciones en las ciencias, debido a la creciente sofisticación y disponibilidad de los dispositivos de teledetección y el incremento generalizado del poder de las computadoras y su programación. En este sentido, la conformación de grupos multidisciplinarios e interdisciplinarios, como el grupo dentro del cual se desarrolló este trabajo, constituye el mecanismo ideal para el avance del conocimiento y de metodologías novedosas que impulsen la transferencia de tecnologías de las ciencias básicas e ingenierías dentro del contexto local y regional. Desarrollar técnicas que apliquen procesamiento digital de imágenes en las ciencias naturales implica vincular conocimiento y experiencia de diversas áreas previamente disjuntas, de una manera útil y creativa. Las diversas modalidades de imágenes disponibles, en particular, la gran variedad de imágenes multi-espectrales provenientes de misiones satelitales estimulan el desarrollo y la implementación de técnicas confiables para la extracción de la información contenida.

Una cantidad importante de estudios geomorfológicos y oceanográficos (transporte de sedimentos, balance de calor, erosión, etc.) se basa en la utilización de modelos físico-matemáticos que requieren un conocimiento preciso de los valores geográficos (áreas, longitudes costeras, etc.) para ser aplicables y éstos valores no siempre se encuentran disponibles. El procesamiento en este trabajo estuvo orientado a la determinación precisa de características geográficas en imágenes de sensado remoto e integrado por las dos etapas conceptualmente críticas planteadas en el comienzo: la segmentación y descripción de características cuantitativas específicas.

La técnica de segmentación fue evolucionando durante el proceso debido a la complejidad que fueron presentando las regiones a las cuales se les aplicó y la modalidad de

imagen. Los métodos empleados se basaron en la técnica de distancia mínima a uno o varios prototipos y la metodología de selección fue perfeccionada. Incluso el tiempo de ejecución se redujo gracias a la disminución de la cantidad de referencias. Las imágenes distancias construidas con los coeficientes resultantes poseen mayor contraste entre las regiones de figura y fondo. Sobre imágenes satelitales de alta resolución proporcionó un alto grado de detalles, áreas de cobertura e información detallada de bordes en la región de los canales de marea. También permitió la segmentación de zonas costeras en imágenes de video y el relevamiento de lagunas del sur de la provincia de Buenos Aires, coberturas de suelo, entre otros. Ya se está desarrollando en procedimientos complementarios un nuevo método que involucra la componente de luminancia y cálculo de dimensión fractal box en busca de técnicas combinadas para la extracción de detalles cuya información cromática no es suficiente. Esta técnica permitirá la segmentación de objetos analizando su estructura morfológica que, entre otras cosas, esperamos permita segmentar la red de canales de marea del estuario de Bahía Blanca en su totalidad.

En este trabajo también se realizaron importantes avances en el desarrollo de métodos de medición de contornos e interiores. El algoritmo de determinación de frontera, *marching squares* con interpolación lineal (MSI), se basó en la combinación de técnicas que agregaron un grado más de información en el cómputo. Ésto permitió la extracción súper-resolución de coordenadas y mayor precisión en la medición del perímetro. En forma conjunta se utilizaron los resultados de segmentación por distancia mínima aprovechando información que de otro modo se pierde al binarizar, con una adaptación del algoritmo *marching squares* mejorado. Esto permitió establecer con gran eficiencia la ubicación del borde con una poligonal que acompaña la curva con resolución superior a la de la grilla de pixel original, mejorando el desempeño de los métodos tradicionales usualmente implementados en sistemas SIG. El algoritmo comete menor error asociado que sus contrapartes y demuestra robustez frente a todos los factores de cambio presentes en la imagen: rotación, tamaño e incluso en puntas y zonas curvas.

Finalmente, se propuso un método de estimación de perímetros a partir de una extrapolación fractal, el cual se basó en las ideas originalmente presentadas por Richardson. El algoritmo establece la regresión fractal de la relación entre mediciones realizadas con diferentes resoluciones, para extrapolar el valor correspondiente a una medición hipotética realizada con muy alta precisión. Esta extrapolación resultó ser extremadamente precisa, tanto en imágenes sintéticas (de resolución controlada) como en áreas geográficas para las que se contaba con imágenes satelitales de diferentes resoluciones (Landsat e Ikonos),

sin los problemas de incongruencia de información que se presentaban hasta el momento. Incluso su precisión en la estimación es independiente del método de medición utilizado. Las primeras pruebas se realizaron sobre sectores de la costa de la provincia de Buenos Aires y se continuaron con el estudio de un islote del estuario de Bahía Blanca.

En función de los resultados preliminares obtenidos se espera aplicar esta técnica de extrapolación en áreas geográficas más vastas, como por ejemplo el litoral marítimo argentino en su totalidad. Diez (2008) demostró que empleando teoría fractal, la costa de la Argentina era al menos un 10% más extensa que la establecida oficialmente por el Instituto Geográfico Militar o el Servicio de Hidrografía Naval. En base a los estudios previos realizados, se considera que la nueva metodología a aplicar, podría demostrar que esa extensión es aún mayor.

Resumiendo, en esta tesis se presentaron algoritmos innovadores como el MSI y la estimación de longitud con DF (ambos publicados en “Computer & Geosciences”). También se desarrollaron mejoras sustanciales en la técnica de selección de pixels prototipos la cual minimiza el tiempo de ejecución y aumenta el contraste de la ID resultante. En todos los casos, los métodos usuales fueron puestos a prueba y se introdujeron mejoras y nuevas soluciones en los casos que no cumplían con los estándares. En general, las líneas de trabajo buscaron alcanzar el objetivo principal de toda la tesis que pretendía extraer datos de alta resolución de las imágenes multiespectrales de resolución gruesa disponible.

Apéndice A

MSI:

Determinaciones matemáticas

Cálculos del segmento $\overline{P_B P_A}$

El factor de interpolación convexo α_A de P_A combina el valor de umbral U junto a los valores de distancia de los pixels P_0 y P_1 (figura 3.4a): $\alpha_A(P_0, P_1) = \frac{U-D_1}{D_0-D_1}$. Dado α_A , la coordenada de borde P_A suponiendo $L = 1 m$ es:

$$P_A[i_A, j_A] = \alpha_A P_0[i_0, j_0] + (1 - \alpha_A) P_1[i_1, j_1]$$

$$i_A = \alpha_A i_0 + (1 - \alpha_A) i_1$$

$$i_A = \alpha_A \left(i + \frac{1}{2}\right) + (1 - \alpha_A) \left(i + \frac{3}{2}\right)$$

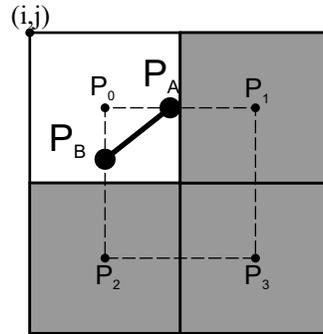
$$i_A = i + \frac{3}{2} - \alpha_A$$

$$j_A = \alpha_A j_0 + (1 - \alpha_A) j_1$$

$$j_A = \alpha_A \left(j + \frac{1}{2}\right) + (1 - \alpha_A) \left(j + \frac{1}{2}\right)$$

$$j_A = j + \frac{1}{2}$$

$$P_A[i_A, j_A] = P_A\left[i + \frac{3}{2} - \alpha_A, j + \frac{1}{2}\right]$$



El factor de interpolación convexo α_B de P_B combina el valor de umbral U junto a los valores de distancia de los pixels P_0 y P_2 (figura 3.4a): $\alpha_B = \frac{U-D_2}{D_0-D_2}$. Dado α_B , la coordenada de borde P_B suponiendo $L = 1 m$ es:

$$P_B[i_B, j_B] = \alpha_B P_0[i_0, j_0] + (1 - \alpha_B) P_2[i_2, j_2]$$

$$i_B = \alpha_B i_0 + (1 - \alpha_B) i_2$$

$$i_B = \alpha_B \left(i + \frac{1}{2}\right) + (1 - \alpha_B) \left(i + \frac{1}{2}\right)$$

$$i_B = i + \frac{1}{2}$$

$$j_B = \alpha_B j_0 + (1 - \alpha_B) j_2$$

$$j_B = \alpha_B \left(j + \frac{1}{2}\right) + (1 - \alpha_B) \left(j + \frac{3}{2}\right)$$

$$j_B = j + \frac{3}{2} - \alpha_B$$

$$P_B[i_B, j_B] = P_B\left[i + \frac{1}{2}, j + \frac{3}{2} - \alpha_B\right]$$

La longitud del segmento de frontera $\overline{P_B P_A}$ es:

$$\overline{P_B P_A} = \sqrt{(i_B - i_A)^2 + (j_B - j_A)^2}$$

$$\overline{P_B P_A} = \sqrt{\left(i + \frac{1}{2} - i - \frac{3}{2} + \alpha_A\right)^2 + \left(j + \frac{3}{2} - \alpha_B - j - \frac{1}{2}\right)^2}$$

$$\overline{P_B P_A} = \sqrt{(\alpha_A - 1)^2 + (1 - \alpha_B)^2}$$

Si $L \neq 1m$:

$$P_A[i_A, j_A] = P_A\left[L\left(i + \frac{3}{2} - \alpha_A\right), L\left(j + \frac{1}{2}\right)\right],$$

$$P_B[i_B, j_B] = P_B\left[L\left(i + \frac{1}{2}\right), L\left(j + \frac{3}{2} - \alpha_B\right)\right]$$

y finalmente

$$\overline{P_B P_A} = L\sqrt{(\alpha_A - 1)^2 + (1 - \alpha_B)^2}.$$

Cálculos del segmento $\overline{P_D P_B}$

El factor de interpolación convexo α_B de P_B combina el valor de umbral U junto a los valores de distancia de los pixels P_2 y P_0 (figura 3.4b): $\alpha_B = \frac{U - D_0}{D_2 - D_0}$.

Dado α_B , la coordenada de borde P_B suponiendo $L = 1 m$ es:

$$P_B[i_B, j_B] = \alpha_B P_2[i_2, j_2] + (1 - \alpha_B) P_0[i_0, j_0]$$

$$i_B = \alpha_B i_2 + (1 - \alpha_B) i_0$$

$$i_B = \alpha_B \left(i + \frac{1}{2}\right) + (1 - \alpha_B) \left(i + \frac{1}{2}\right)$$

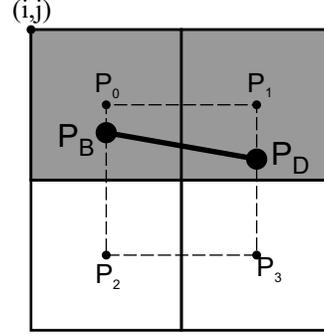
$$i_B = i + \frac{1}{2}$$

$$j_B = \alpha_B j_2 + (1 - \alpha_B) j_0$$

$$j_B = \alpha_B \left(j + \frac{3}{2}\right) + (1 - \alpha_B) \left(j + \frac{1}{2}\right)$$

$$j_B = j + \frac{1}{2} + \alpha_B$$

$$P_B[i_B, j_B] = P_B\left[i + \frac{1}{2}, j + \frac{1}{2} + \alpha_B\right]$$



El factor de interpolación convexo α_D de P_D combina el valor de umbral U junto a los valores de distancia de los píxeles P_3 y P_1 (figura 3.4b): $\alpha_D = \frac{U-D_1}{D_3-D_1}$.

Dado α_D , la coordenada de borde P_D suponiendo $L = 1 m$ es:

$$P_D[i_D, j_D] = \alpha_D P_3[i_3, j_3] + (1 - \alpha_D) P_1[i_1, j_1]$$

$$i_D = \alpha_D i_3 + (1 - \alpha_D) i_1$$

$$i_D = \alpha_D \left(i + \frac{3}{2}\right) + (1 - \alpha_D) \left(i + \frac{3}{2}\right)$$

$$i_D = i + \frac{3}{2}$$

$$j_D = \alpha_D j_3 + (1 - \alpha_D) j_1$$

$$j_D = \alpha_D \left(j + \frac{3}{2}\right) + (1 - \alpha_D) \left(j + \frac{1}{2}\right)$$

$$j_D = j + \frac{1}{2} + \alpha_D$$

$$P_D[i_D, j_D] = P_D\left[i + \frac{3}{2}, j + \frac{1}{2} + \alpha_D\right]$$

La longitud del segmento de frontera $\overline{P_D P_B}$ es:

$$\overline{P_D P_B} = \sqrt{(i_D - i_B)^2 + (j_D - j_B)^2}$$

$$\overline{P_D P_B} = \sqrt{\left(i + \frac{3}{2} - i - \frac{1}{2}\right)^2 + \left(j + \frac{1}{2} + \alpha_D - j - \frac{1}{2} - \alpha_B\right)^2}$$

$$\overline{P_D P_B} = \sqrt{1 + (\alpha_D - \alpha_B)^2}$$

Si $L \neq 1m$:

$$P_B[i_B, j_B] = P_B[L(i + \frac{1}{2}), L(j + \frac{1}{2} + \alpha_B)],$$

$$P_D[i_D, j_D] = P_D[L(i + \frac{3}{2}), L(j + \frac{1}{2} + \alpha_D)]$$

y finalmente

$$\overline{P_D P_B} = L\sqrt{1 + (\alpha_D - \alpha_B)^2}.$$

Cálculos del segmento $\overline{P_C P_B}$

El factor de interpolación convexo α_B de P_B combina el valor de umbral U junto a los valores de distancia de los pixels P_0 y P_2 (figura 3.4b): $\alpha_B = \frac{U-D_2}{D_0-D_2}$.

Dado α_B , la coordenada de borde P_B suponiendo $L = 1 m$ es:

$$P_B[i_B, j_B] = \alpha_B P_0[i_0, j_0] + (1 - \alpha_B) P_2[i_2, j_2]$$

$$i_B = \alpha_B i_0 + (1 - \alpha_B) i_2$$

$$i_B = \alpha_B (i + \frac{1}{2}) + (1 - \alpha_B) (i + \frac{1}{2})$$

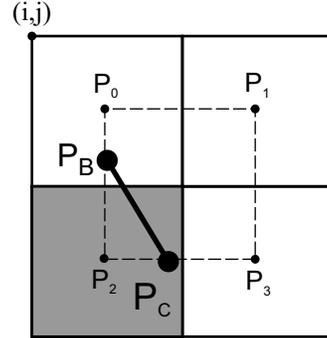
$$i_B = i + \frac{1}{2}$$

$$j_B = \alpha_B j_0 + (1 - \alpha_B) j_2$$

$$j_B = \alpha_B (j + \frac{1}{2}) + (1 - \alpha_B) (j + \frac{3}{2})$$

$$j_B = j + \frac{3}{2} - \alpha_B$$

$$P_B[i_B, j_B] = P_B[i + \frac{1}{2}, j + \frac{3}{2} - \alpha_B]$$



El factor de interpolación convexo α_C de P_C combina el valor de umbral U junto a los valores de distancia de los pixels P_3 y P_2 (figura 3.4b): $\alpha_C = \frac{U-D_2}{D_3-D_2}$.

Dado α_C , la coordenada de borde P_C suponiendo $L = 1 m$ es:

$$P_C[i_C, j_C] = \alpha_C P_3[i_3, j_3] + (1 - \alpha_C) P_2[i_2, j_2]$$

$$i_C = \alpha_C i_3 + (1 - \alpha_C) i_2$$

$$i_C = \alpha_C \left(i + \frac{3}{2}\right) + (1 - \alpha_C) \left(i + \frac{1}{2}\right)$$

$$i_C = i + \frac{1}{2} + \alpha_C$$

$$j_C = \alpha_C j_3 + (1 - \alpha_C) j_2$$

$$j_C = \alpha_C \left(j + \frac{3}{2}\right) + (1 - \alpha_C) \left(j + \frac{3}{2}\right)$$

$$j_C = j + \frac{3}{2}$$

$$P_C[i_C, j_C] = P_C\left[i + \frac{1}{2} + \alpha_C, j + \frac{3}{2}\right]$$

La longitud del segmento de frontera $\overline{P_C P_B}$ es:

$$\overline{P_C P_B} = \sqrt{(i_C - i_B)^2 + (j_C - j_B)^2}$$

$$\overline{P_C P_B} = \sqrt{\left(i + \frac{1}{2} + \alpha_C - i - \frac{1}{2}\right)^2 + \left(j + \frac{3}{2} - j - \frac{3}{2} + \alpha_B\right)^2}$$

$$\overline{P_C P_B} = \sqrt{\alpha_C^2 + \alpha_B^2}$$

Si $L \neq 1m$:

$$P_B[i_B, j_B] = P_B\left[L\left(i + \frac{1}{2}\right), L\left(j + \frac{3}{2} - \alpha_B\right)\right],$$

$$P_C[i_C, j_C] = P_C\left[L\left(i + \frac{1}{2} + \alpha_C\right), L\left(j + \frac{3}{2}\right)\right]$$

y finalmente

$$\overline{P_C P_B} = L\sqrt{\alpha_C^2 + \alpha_B^2}.$$

Segmentos de un Bit Quad ambiguo

El factor de interpolación convexo α_A de P_A combina el valor de umbral U junto a los valores de distancia de los pixels P_1 y P_0 (figura 3.4d): $\alpha_A(P_1, P_0) = \frac{U - D_0}{D_1 - D_0}$.

Dado α_A , la coordenada de borde P_A suponiendo $L = 1 m$ es:

$$P_A[i_A, j_A] = \alpha_A P_1[i_1, j_1] + (1 - \alpha_A) P_0[i_0, j_0]$$

$$i_A = \alpha_A i_1 + (1 - \alpha_A) i_0$$

$$i_A = \alpha_A \left(i + \frac{3}{2}\right) + (1 - \alpha_A) \left(i + \frac{1}{2}\right)$$

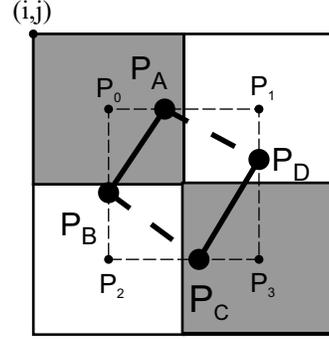
$$i_A = i + \frac{1}{2} + \alpha_A$$

$$j_A = \alpha_A j_1 + (1 - \alpha_A) j_0$$

$$j_A = \alpha_A \left(j + \frac{1}{2}\right) + (1 - \alpha_A) \left(j + \frac{1}{2}\right)$$

$$j_A = j + \frac{1}{2}$$

$$P_A[i_A, j_A] = P_A\left[i + \frac{1}{2} + \alpha_A, j + \frac{1}{2}\right]$$



El factor de interpolación convexo α_B de P_B combina el valor de umbral U junto a los valores de distancia de los pixels P_2 y P_0 (figura 3.4b): $\alpha_B = \frac{U-D_0}{D_2-D_0}$.

Dado α_B , la coordenada de borde P_B suponiendo $L = 1 m$ es:

$$P_B[i_B, j_B] = \alpha_B P_2[i_2, j_2] + (1 - \alpha_B) P_0[i_0, j_0]$$

$$i_B = \alpha_B i_2 + (1 - \alpha_B) i_0$$

$$i_B = \alpha_B \left(i + \frac{1}{2}\right) + (1 - \alpha_B) \left(i + \frac{1}{2}\right)$$

$$i_B = i + \frac{1}{2}$$

$$j_B = \alpha_B j_2 + (1 - \alpha_B) j_0$$

$$j_B = \alpha_B \left(j + \frac{3}{2}\right) + (1 - \alpha_B) \left(j + \frac{1}{2}\right)$$

$$j_B = j + \frac{1}{2} + \alpha_B$$

$$P_B[i_B, j_B] = P_B\left[i + \frac{1}{2}, j + \frac{1}{2} + \alpha_B\right]$$

El factor de interpolación convexo α_C de P_C combina el valor de umbral U junto a los valores de distancia de los pixels P_2 y P_3 (figura 3.4d): $\alpha_C(P_2, P_3) = \frac{U-D_3}{D_2-D_3}$.

Dado α_C , la coordenada de borde P_C suponiendo $L = 1 m$ es:

$$\begin{aligned}
P_C[i_C, j_C] &= \alpha_C P_2[i_2, j_2] + (1 - \alpha_C) P_3[i_3, j_3] \\
i_C &= \alpha_C i_2 + (1 - \alpha_C) i_3 \\
i_C &= \alpha_C \left(i + \frac{1}{2}\right) + (1 - \alpha_C) \left(i + \frac{3}{2}\right) \\
i_C &= i + \frac{3}{2} - \alpha_C \\
j_C &= \alpha_C j_2 + (1 - \alpha_C) j_3 \\
j_C &= \alpha_C \left(j + \frac{3}{2}\right) + (1 - \alpha_C) \left(j + \frac{3}{2}\right) \\
j_C &= j + \frac{3}{2} \\
P_C[i_C, j_C] &= P_C\left[i + \frac{3}{2} - \alpha_C, j + \frac{3}{2}\right]
\end{aligned}$$

El factor de interpolación convexo α_D de P_D combina el valor de umbral U junto a los valores de distancia de los pixels P_1 y P_3 (figura 3.4b): $\alpha_D = \frac{U-D_3}{D_1-D_3}$. Dado α_D , la coordenada de borde P_D suponiendo $L = 1$ m es:

$$\begin{aligned}
P_D[i_D, j_D] &= \alpha_D P_1[i_1, j_1] + (1 - \alpha_D) P_3[i_3, j_3] \\
i_D &= \alpha_D i_1 + (1 - \alpha_D) i_3 \\
i_D &= \alpha_D \left(i + \frac{3}{2}\right) + (1 - \alpha_D) \left(i + \frac{3}{2}\right) \\
i_D &= i + \frac{3}{2} \\
j_D &= \alpha_D j_1 + (1 - \alpha_D) j_3 \\
j_D &= \alpha_D \left(j + \frac{1}{2}\right) + (1 - \alpha_D) \left(j + \frac{3}{2}\right) \\
j_D &= j + \frac{3}{2} - \alpha_D \\
P_D[i_D, j_D] &= P_D\left[i + \frac{3}{2}, j + \frac{3}{2} - \alpha_D\right]
\end{aligned}$$

Caso uno

La longitud del segmento de frontera $\overline{P_B P_A}$ es:

$$\begin{aligned}
\overline{P_B P_A} &= \sqrt{(i_B - i_A)^2 + (j_B - j_A)^2} \\
\overline{P_B P_A} &= \sqrt{\left(i + \frac{1}{2} - i - \frac{1}{2} - \alpha_A\right)^2 + \left(j + \frac{1}{2} + \alpha_B - j - \frac{1}{2}\right)^2}
\end{aligned}$$

$$\overline{P_B P_A} = \sqrt{(-\alpha_A)^2 + \alpha_B^2}$$

Si $L \neq 1m$:

$$P_A[i_A, j_A] = P_A[L(i + \frac{1}{2} + \alpha_A), L(j + \frac{1}{2})],$$

$$P_B[i_B, j_B] = P_B[L(i + \frac{1}{2}), L(j + \frac{1}{2} + \alpha_B)]$$

y finalmente

$$\boxed{\overline{P_B P_A} = L\sqrt{(-\alpha_A)^2 + \alpha_B^2}.}$$

La longitud del segmento de frontera $\overline{P_D P_C}$ es:

$$\overline{P_D P_C} = \sqrt{(i_D - i_C)^2 + (j_D - j_C)^2}$$

$$\overline{P_D P_C} = \sqrt{(i + \frac{3}{2} - i - \frac{3}{2}\alpha_C)^2 + (j + \frac{3}{2} + \alpha_D - j - \frac{3}{2})^2}$$

$$\overline{P_D P_C} = \sqrt{\alpha_C^2 + \alpha_D^2}$$

Si $L \neq 1m$:

$$P_C[i_C, j_C] = P_C[L(i + \frac{3}{2} - \alpha_C), L(j + \frac{3}{2})],$$

$$P_D[i_D, j_D] = P_D[L(i + \frac{3}{2}), L(j + \frac{3}{2} - \alpha_D)]$$

y finalmente

$$\boxed{\overline{P_D P_C} = L\sqrt{\alpha_C^2 + \alpha_D^2}.}$$

Caso dos

La longitud del segmento de frontera $\overline{P_D P_A}$ es:

$$\overline{P_D P_A} = \sqrt{(i_D - i_A)^2 + (j_D - j_A)^2}$$

$$\overline{P_D P_A} = \sqrt{(i + \frac{3}{2} - i - \frac{1}{2} - \alpha_A)^2 + (j + \frac{3}{2} + \alpha_D - j - \frac{1}{2})^2}$$

$$\overline{P_D P_A} = \sqrt{(1 - \alpha_A)^2 + (1 - \alpha_D)^2}$$

Y finalmente si $L \neq 1m$:

$$\overline{P_D P_A} = L\sqrt{(1 - \alpha_A)^2 + (1 - \alpha_D)^2}.$$

La longitud del segmento de frontera $\overline{P_B P_C}$ es:

$$\begin{aligned}\overline{P_B P_C} &= \sqrt{(i_B - i_C)^2 + (j_B - j_C)^2} \\ \overline{P_B P_C} &= \sqrt{\left(i + \frac{1}{2} - i - \frac{3}{2}\alpha_C\right)^2 + \left(j + \frac{1}{2} + \alpha_B - j - \frac{3}{2}\right)^2} \\ \overline{P_B P_C} &= \sqrt{(\alpha_C - 1)^2 + (\alpha_B - 1)^2}\end{aligned}$$

Y finalmente si $L \neq 1m$:

$$\overline{P_B P_C} = L\sqrt{(\alpha_C - 1)^2 + (\alpha_B - 1)^2}.$$

Apéndice B

Campaña de medición de campo

Detalles de la campaña

La medición se realizó gracias a la colaboración de los dueños del campo “La Falcón”, la gentileza de los propietarios del campo lindero y fue financiada por el proyecto de investigación PICT 1202 de la Agencia Nacional de Promoción Científica y Tecnológica. Ambos campos se encuentran ubicados en el sur de la Provincia de Buenos Aires, aproximadamente a 55 km de Bahía Blanca ($38^{\circ}35'20,31467''$ S; $61^{\circ}40'55,46507''$). Las mediciones se realizaron a partir de las 10:15 AM el día 23 de diciembre de 2008.

El equipo de GPS-RTK¹ diferencial Sokkia posee una precisión de 1 *cm* en el plano horizontal y está compuesto de dos unidades: la estación base y una estación móvil. La estación base se instaló en el interior del campo “La Falcón” (punto de referencia: Base) y medía con 6 o 7 satélites (tres leds encendidos) a una altura de 1,34*m*.

Identificación	Puntos		
	Latitud S	Longitud O	Cota [m]
Base	$38^{\circ}35'20,3147''$	$61^{\circ}40'55,4651''$	139
A	$38^{\circ}35'17,6764''$	$61^{\circ}40'43,6660''$	157
B	$38^{\circ}35'31,6077''$	$61^{\circ}40'25,7090''$	159
C	$38^{\circ}34'55,0013''$	$61^{\circ}40'15,5830''$	165
D	$38^{\circ}34'35,5745''$	$61^{\circ}39'51,5155''$	172
E	$38^{\circ}34'48,7737''$	$61^{\circ}39'34,2369''$	172

Tabla B.1: Coordenadas medidas.

¹RTK (del inglés Real Time Kinematic) o navegación cinética satelital en tiempo real

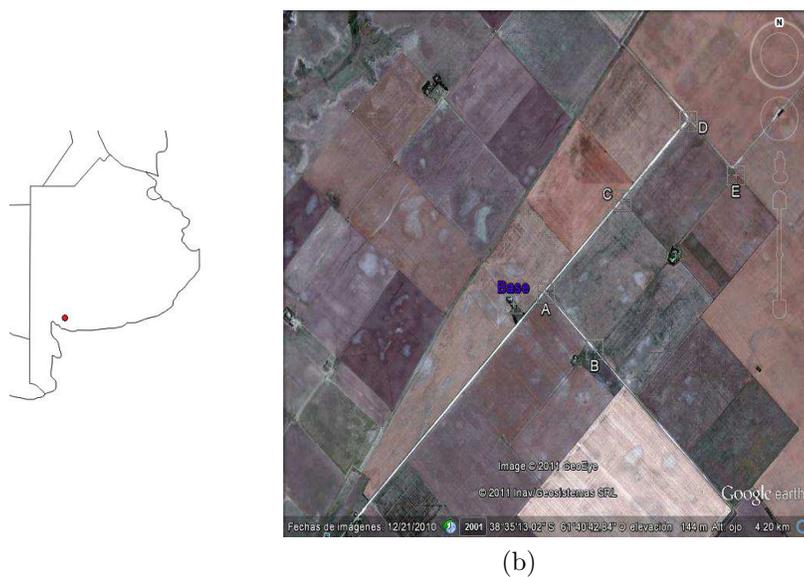
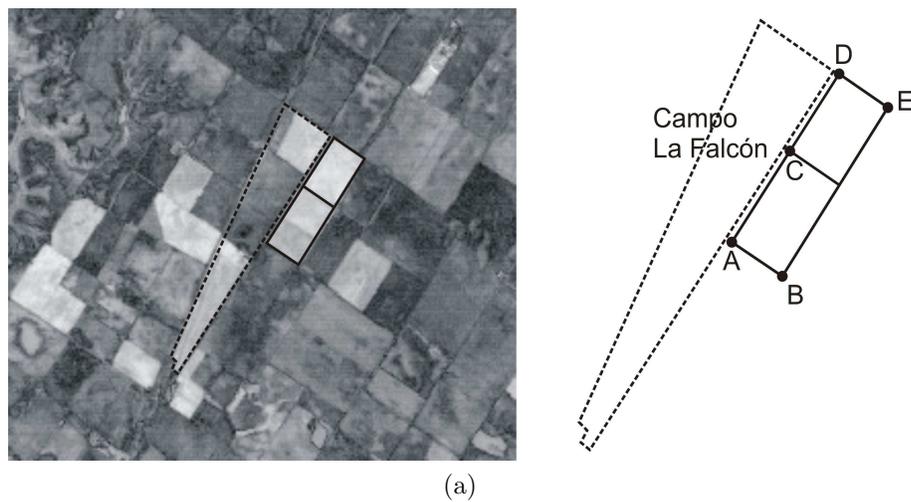


Figura B.1: Campaña de medición de campo. (a) ID (figura 5.7b) con los campos resaltados. (b) Imagen descargada del Google Earth con las coordenadas marcadas.

Bibliografía

- Allen, M., Brown, G., and Miles, N. (1995). Measurement of boundary fractal dimensions: review of current techniques. *Powder Technology*, 84(1):1–14.
- Angeles, G., Perillo, G.M.E., y Piccolo, M.C. (2003). Características físicas y circulación en un meandro de un canal de marea Estuario de Bahía Blanca - Argentina. *Geoacta*, (28):59–69.
- Chen, Q., Luo, J., Heng, P., y De-shen, 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, H., Jiang, X., y Wang, J. (2001). Color Image Segmentation: Advances and Prospects. *Pattern Recognition*, 34:2259–2281.
- Cipolletti, M.P., Delrieux, C., y Perillo, G.M.E. (2009a). Segmentación y Medición de Fronteras en Imágenes de Sensado Remoto. Facultad de Ciencias Exactas. Universidad Nacional del Centro. Tandil, Argentina. ECIImag 2009 - 2da Escuela y Workshop de Ciencias de las Imágenes.
- Cipolletti, M.P., Delrieux, C., Perillo, G.M.E., y Piccolo, M.C. (2009b). Predicción de la Longitud de la línea de Costa del Sur de la Provincia de Buenos Aires por medio de Fractales. In *Libro de resúmenes*, page 10, Instituto Argentino de Oceanografía (IADO-CONICET). Bahía Blanca, Argentina. VII Jornadas Nacionales de Ciencias del Mar. ISBN: 978-987-25479-0-4.
- Cipolletti, M.P., Delrieux, C., Perillo, G.M.E., y Piccolo, M.C. (2011a). Segmentación no supervisada de accidentes geográficos en imágenes satelitales. ITBA. Buenos Aires. ECIImag 2011 - 4ta Escuela y Workshop de Ciencias de las Imágenes.

- Cipolletti, M.P., Delrieux, C., Perillo, G.M.E., y Piccolo, M.C. (2011b). Estimación de Perímetros en Imágenes de Sensado Remoto. La Plata, Argentina. XVII Congreso Argentino de Cs. de la Computación. ISBN 978-950-34-0756-1.
- 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. *In Press*.
- Cipolletti, M.P., Sarmiento, N. V.R., Delrieux, C., Perillo, G.M.E., y Piccolo, M.C. (2010). Segmentación Supervisada y No Supervisada de Zonas Costeras en Secuencias de Videos. UADE, Ciudad Autónoma de Buenos Aires. Argentina. 39 JAIIO - 11° Argentine Symposium on Technology. ISSN 1850-2806.
- Cox, D. (1957). Note on grouping. *Journal of the American Statistical Association*, 52(280):543-547.
- Diez, P. (2008). *Tipología de la costa Argentina*. PhD thesis, Universidad Nacional del Sur, Departamento de Geografía y Turismo. (inérita).
- Dillon, C., Carey, P., y Worden, R. (2001). Fractscript: A macro for calculating the fractal dimension of object perimeters in images of multiple objects. *Computers & Geosciences*, 27:787-794.
- Dubes, R. y Jain, A. (1976). Clustering techniques: The User's Dilemma. *Pattern Recognition*, 8(4):247 - 260.
- 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.
- Dutch, S. (1993). Linear Richardson Plots from non-Fractal Data Sets. *Mathematical Geology*, 725(6):737-751.
- Falconer, K. (2003). *Fractal Geometry: Mathematical Foundations and Applications*. Wiley, England.
- Fava, N y Zó F. (2013). *Medida e Integral de Lebesgue*. Facultad de Ciencias Exactas y Naturales de la Universidad de Buenos Aires.

- Fisher, W. D. (1958). On Grouping for Maximum Homogeneity. *Journal of the American Statistical Association*, 53(284):789–798.
- 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.
- Friedman, H. y Rubin, J. (1967). On some invariant criteria for grouping data. *Journal of the American Statistical Association*, 62(320):1159–1178.
- Gan, G., Ma, C., and Wu, J. (2007). *Data Clustering: Theory, Algorithms, and Applications*. Society for Industrial and Applied Mathematics.
- García, J. V., Oleschko, K., noz Villalobos, J. M., Velásquez-Valle, M., Menes, M. M., Parrot, J., Korvin, G., y Cerca, M. (2010). Land cover monitoring by fractal analysis of digital images. *Complexity and Nonlinearity in Soils*, 160:83–92.
- GeoEye (2006). IKONOS Imagery Products.
- Gibbs, B. (2011). *Advanced Kalman Filtering, Least-Squares and Modeling*. John Wiley & Sons, New Jersey.
- Girard, C. M. y Girard, M. C. (1999). *Processing of Remote Sensing Data*. Dunod, Paris.
- González, R. y Woods, R. (1996). *Digital Image Processing*. Addison-Wesley, Wilmington, DE.
- Good, I. (1964). Categorization of Classification. pages 115–128, Oxford, London. Proc. of a Conference on Mathematics and Computer Science in Biology and Medicine at Balliol College.
- Goodchild, M. F. (1980). Fractals and the accuracy of geographical measures. *Mathematical Geology*, 12(2):85–98.
- Gower, J. (1966). Some Distance Properties of Latent Root and Vector Methods Used in Multivariate Analysis. *Biometrika*, 53:325–338.

- Gray, S. B. (1971). Local Properties of Binary Images in Two Dimensions. *IEEE Transactions on Computers*, 20(5):551–561.
- Håkanson, L. (1978). The length of closed geomorphic lines. *Mathematical Geology*, 10(2):141–167.
- Haralick, R. y Kelly, G. (1969). *Pattern Recognition with Measurement Space and Spatial Clustering for Multiple Images*, volume 57, pages 654–665. IEEE.
- Haralick, R. y Shapiro, L. (1985). Image Segmentation Techniques. *Computer Vision Graphics and Image Processing*, 29(1):100–132.
- Hurst, H., Black, R., y Simaika, Y. (1965). *Long-term Storage: an Experimental Study*. Constable, London.
- Ilea, D. y Whelan, P. (2011). Image Segmentation Based on the Integration of Color-Texture Description - A Review. *Pattern Recognition*, 44:2479–2501.
- Imre, A. (2006). Artificial fractal dimension obtained by using perimeter-area relationship on digitalized images. *Applied Mathematics and Computation*, 173:443–449.
- Imre, A., Cseh, D., Neteler, M., and Rocchini, D. (2011). Korcak Dimension as a Novel Indicator of Landscape Fragmentation and re-Forestation. *Ecological Indicators*, 11(5):1134 – 1138.
- Jain, A. y Law, M. (2005). Data Clustering: A User´s Dilemma. In Pal, S., Bandyopadhyay, S., y Biswas, S., editors, *Pattern Recognition and Machine Intelligence*, volume 3776, pages 1–10. Springer Berlin / Heidelberg. isbn: 978-3-540-30506-4.
- Jain, A., Murty, M., y Flynn, P. (1999). Data Clustering: a Review. *ACM Computing Surveys*, 31(3):264–323.
- Korčák, J. (1938). *Deux types fondamentaux de distribution statistique*. XXIVe session de l'Institut international de statistique. Comité d'organisation.
- Kulpa, Z. (1977). Area and Perimeter Measurement of Blobs in Discrete Binary Pictures. *Computer Graphics and Image Processing*, 6(5):434–451.
- Kulpa, Z. (1983). More about Areas and Perimeters of Quantized Objects. *Computer Vision, Graphics and Image Processing*, 22(2):268–276.

- Lam, N.Ñ. y Quattrochi, D. (1992). On the Issues of Scale, Resolution, and Fractal Analysis in the Mapping Sciences. *Professional Geographer*, 44(1):88–98.
- Lillesand, T. y Kiefer, R. (2000). *Remote Sensing and Image Interpretation (4th. ed.)*. Willey & Sons, New York.
- Lopes, R. y Betrouni, N. (2009). Fractal and multifractal analysis: A review. *Medical Image Analysis*, 13:634–649.
- Lorensen, W. y Cline, H. (1987). Marching Cubes: A High Resolution 3D Surface Construction Algorithm. *ACM Computer Graphics*, 21(4):163–169.
- Mandelbrot, B. (1967). How long is the coast of Britain? Statistical self-similarity and fractional dimension. *Science*, 156(3775):636–638.
- Mandelbrot, B. (1983). *The Fractal Geometry of Nature*. W. H. Freeman, New York.
- Mark, D. M. y Aronson, P. B. (1984). Scale-dependent fractal dimensions of topographic surfaces: An empirical investigation, with applications in geomorphology and computer mapping. *Mathematical Geology*, 16(7):671–683.
- Murthy, C. A., Chatterjee, N., Uma Shankar, B., y Dutta Majumder, D. (1992). IRS Image Segmentation: Minimum Distance Classifier Approach. pages 781–784.
- NASA (2001). Landsat 7 Science Data Users Handbook. National Aeronautics and Space Administration.
- Navon, E., Miller, O., y Averbuch, A. (2005). Color Image Segmentation Based on Adaptive Local Thresholds. *Image and Vision Computing*, 23:69–85.
- Nielson, G. (2003). On Marching Cubes . *IEEE Transactions on Visualization and Computer Graphics*, 9(3):283–297.
- Nielson, G. y Hamann, B. (1991). The Asymptotic Decider: Resolving the Ambiguity in Marching Cubes. In *Proceedings of the IEEE '91 Visualization Conference*, pages 83–91. IEEE.
- Otsu, N. (1979). A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man and Cybernetics*, 9(1):62–66.

- Parrinello, T. y Vaughan, R. (2002). Multifractal Analysis and Feature Extraction in Satellite Imagery. *Int. J. Remote Sensing*, 23(9).
- Parrinello, T. y Vaughan, R. (2006). On comparing multifractal and classical features in minimum distance classification of AVHRR imagery. *Int. J. Remote Sensing*, 27(12).
- Perillo, G.M.E., Martínez, M. G., y Piccolo, M.C. (1996). Geomorfología de canales de marea: análisis de fractales y espectral. pages 155–160. Actas VI Reunión Argentina de Sedimentología.
- Pham, D., Xu, C., y Prince, J. (2000). Current methods in medical image segmentation. *Annual Review of Biomedical Engineering*, 2:315–337.
- Pratt, W. K. (1991). *Digital Image Processing*. Wiley-Interscience, New York.
- Revollo, N., Cipolletti, M.P., Delrieux, C.A., Perillo, G.M.E., y Piccolo, M.C. (2010a). Segmentación y Medición de las Zonas que conforman la Playa en Secuencias de Videos. pages 288–292, El Calafate, Santa Cruz. WICC. ISBN: 978-950-34-0652-6.
- Revollo, N., Delrieux, C., Perillo, G.M.E., y Cipolletti, M.P. (2009). Coastal Monitoring and Feature Estimation with Small Format Cameras: Application to the Shoreline of Monte Hermoso, Argentina. pages 615–624, Jujuy, Argentina. CACiC. ISBN: 978-897-24068-4-1.
- Revollo, N., Delrieux, C., Perillo, G., y Cipolletti, M. (2010b). *Coastal Monitoring and Feature Estimation with Small Format Cameras: Application to the Shoreline of Monte Hermoso, Argentina*, pages 165–174. edulp edition. ISBN: 978-950-34-0684-7.
- Richards, J. A. y Jia, X. (2006). *Remote Sensing Digital Image Analysis: An Introduction*. Springer, Berlin.
- Richardson, L. (1961). The problem of contiguity: an appendix of statistics of deadly quarrels. *General Systems Yearbook of the International Society for Science*, 6:139–187.
- Rish, I. (2001). An Empirical Study of the Naive Bayes Classifier. Technical report, IBM Research Division.
- Rivest, J.-F. y Soille, P. (1995). Physical significance of image measurements. *IEEE Transactions on Instrumentation and Measurement*, 44(3):751–754.

- Rodriguez-Iturbe, I. and Rinaldo, A. (1997). *Fractal River Basins*. Cambridge University Press, United Kingdom.
- Rocca, M. R. D., Fiani, M., Fortunato, A., y P.Pistillo (2004). Active contour model to detect linear features in satellite images. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 34.
- Russ, J. C. (1993). *Fractal Images*. Plenum Press.
- Saha, S. y Bandyopadhyay, S. (2008). Application of a New Symmetry-Based Cluster Validity Index for Satellite Image Segmentation. *Geoscience and Remote Sensing Letters, IEEE*, 5(2):166–170.
- 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.
- Schlueter, E., Zimmerman, R., Witherspoon, P., y Cook, N. (1997). The fractal dimension of pores in sedimentary rocks and its influence on permeability. *Engineering Geology*, 48:199–215.
- Schowengerdt, R. (1997). *Remote Sensing Models and Methods for Image Processing (2th. ed.)*. Academic Press, San Diego.
- Schuster, G. y Katsaggelos, A. (1998). An optimal polygonal boundary encoding scheme in the rate distortion sense. *IEEE Trans. Image Processing*, 7:13–26.
- Shelberg, M., Moellering, H., y Lam, N. (1982). Measuring the Fractal Dimensions of Empirical Cartographic Curves. In *Proceedings of the International Symposium on Computer Cartography*, pages 481–490.
- Siu, N. y Lam, N. (2002). *Fractals in Geography*. The BlackBurn Press, U.S.A. ISBN: 1-930665-69-5.
- Soille, P. y Rivest, J.-F. (1996). On the validity of fractal dimension measurements in image analysis. *J. Visual Communication and Image Representation*, 7(3):217–229.
- Tolbert, C., Horan, P., y Beck, E. (1980). The Structure of Economic Segmentation: A Dual Economy Approach. *American Journal of Sociology*, 85(5):1095–1116.

- Vossepoel, A. y Smeulders, A. (1982). Vector code probability and metrication error in the representation of straight lines of finite length. *Computer Graphics and Image Processing*, 20(4):347–364.
- Ward, J. (1963). Hierarchical Grouping to Optimize an Objective Function. *Journal of the American Statistical Association*, 58(301):236–244.
- Wemmert, C., Puissant, A., Forestier, G., y Gancarski, P. (2009). Multiresolution Remote Sensing Image Clustering. *IEEE Geoscience and Remote Sensing Letters*, 6(3):533–537.
- Wu, J. (2004). Effects of changing scale on landscape pattern analysis: scaling relations. *Landscape Ecology*, 19:125–138. 10.1023/B:LAND.0000021711.40074.ae.
- Wu, J., Li, H., Jones, K., y Loucks, O. (2006). Scaling with Known Uncertainty: A Synthesis. In Wu, J., Jones, K., Li, H., and Loucks, O., editors, *Scaling and Uncertainty Analysis in Ecology*, pages 329–346. Springer Netherlands. 10.1007/1-4020-4663-4 18.
- Yang, L., Albrechtsen, 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.
- 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.
- Zhende, H. y Yuwen, Q. (2003). The study of fractal correlation method in the displacement measurement and its application. *Optics and Lasers in Engineering*, 39:465–472.