

Universidad de Guadalajara

Centro Universitario de los Valles



División de Estudios Científicos y Tecnológicos
Departamento de Ciencias Naturales y Exactas

Un Algoritmo Supervisado para el Estudio de Cultivos a través de Firmas Espectrales en Imágenes de Satélite

Que para obtener el título de:

*Doctor en Ciencias Físico-Matemáticas, con Orientación al Procesamiento
Digital de Señales*

Presenta:

Francisco Eduardo Oliva Ibarra

Director: Dra. Teresa Efigenia Alarcón Martínez

Co-Director: Dr. Oscar Susano Dalmau Cedeño



UNIVERSIDAD DE GUADALAJARA

CENTRO UNIVERSITARIO DE LOS VALLES

DEPARTAMENTO DE CIENCIAS NATURALES Y EXACTAS

COORDINACION DE DOCTORADO EN CIENCIAS FISICO MATEMATICAS

Oficio DCFM/019/2016

Dr. Víctor Manuel Castillo Girón
Secretario Académico
CUVALLES

At'n Mtro. Abraham Vega Tapia

PRESENTE

Por este medio me permito hacer constar que el **Mtro. Francisco Eduardo Oliva Ibarra** con código **210800366**, ha concluido su tesis para optar por el grado de Doctor en Ciencias Físico Matemáticas, con la orientación al procesamiento digital de señales con el tema titulado **“Un Algoritmo Supervisado para el Estudio de Cultivos a través de Firmas Espectrales en Imágenes de Satélite”**.

La tesis ha sido revisada por los integrantes de la Junta Académica y los lectores asignados de este posgrado y habiendo informado que **CUMPLE** con los requerimientos exigidos por el programa para su realización, considera apta para su presentación para examen de grado. La junta académica ha asignado una calificación de 100 al trabajo de tesis. Así mismo, le informo que el estudiante ya ha cubierto la totalidad de los demás créditos correspondientes al plan de estudios del programa.

- Dra. Teresa Efigenia Alarcón Martínez (Presidente)
- Dr. Oscar Susano Dalmau Cedeño (Secretario)
- Dr. Iván Estebán Villalón Turrubiates (Vocal)
- Dr. Miguel Ángel de la Torre Gómora (Vocal)
- Dr. Salvador Cervantes Alvarez (Vocal)

Sin otro particular, aprovecho la oportunidad para reiterarle mi atenta y distinguida consideración.

ATENTAMENTE
“PIENSA Y TRABAJA”

Ameca Jalisco a 9 de Diciembre de 2016


Dr. Víctor Manuel Rentería Tapia
Coordinador de Doctorado en
Ciencias Físico Matemáticas



UNIVERSIDAD DE GUADALAJARA
C. UNIVERSITARIO
DE LOS VALLES
Coordinación de Doctorado
en Ciencias Físico Matemáticas

c.c.p. Dra. Ana Gabriela Ramírez Flores
c.c.p. Archivo

Dedicatoria

Quisiera dedicar este trabajo de tesis a mi familia:

A mi madre, Angelina Ibarra Flores, quien siempre estuvo animándome y estuvo a mi lado en los buenos y malos momentos.

A mis hermanos, quienes siempre me apoyaron y animaron con sus mejores deseos.

Agradecimientos

Agradezco profundamente a las siguientes personas, que gracias a ellos fue posible este trabajo de tesis:

A mi Director de Tesis: Dra. Teresa Alarcón Martínez Efigenia, por haber invertido gran parte de su valioso tiempo para la realización de este trabajo, por las palabras de aliento que siempre me brindo, por su excelente orientación, cuidado y paciencia y por darme un excelente ambiente para hacer posible esta investigación.

A mi Co-Director: Dr. Oscar Susano Dalmau Cedeño, por su gran apoyo, palabras de consejo y aliento y por compartir sus grandes conocimientos en la realización de este trabajo.

A mi asesor, Iván Esteban Villalón Turrubiates, quien me dio valiosos consejos y gran apoyo en el desarrollo de esta tesis.

Al Dr. Miguel Angel de la Torres Gómora, por su valiosa contribución y su intervención en la realización de esta investigación.

También me gustaría mostrar mi agradecimiento a:

Instituto de Información Territorial del Estado de Jalisco (IITEJ), quien nos proporcionó las imágenes utilizadas en esta investigación.

Guillermo Levine Gutiérrez, Maximiliano Bautista Andalón y Ana Teresa Ortega Minakata, por haber apoyado la información necesaria para esta investigación.

Por último, quiero agradecer al Centro Universitario de los Valles, por el apoyo en la condonación de un porcentaje de la matrícula y aportaciones especiales para llevar a buen término, el proceso de culminación de este posgrado.

Resumen

En este trabajo se propone una generalización de un modelo de Campo de Medida de Probabilidad que permite combinar verosimilitudes provenientes de diferentes fuentes de información. El algoritmo se aplica para identificar distintos tipos de vegetación en imágenes del satélite Landsat-5 TM. Para cada fuente de información que se considera, se obtienen histogramas tridimensionales. De cada histograma se estima una verosimilitud. La verosimilitud final es una combinación lineal de todas las calculadas. Los pesos de la combinación están en función de la entropía de las distribuciones de probabilidad derivadas de la verosimilitud estimada en cada histograma. Para procesar una imagen, se usa la verosimilitud de cada píxel en pertenecer a una clase (tipo de vegetación). Este dato es la entrada del algoritmo de segmentación probabilístico llamado Campos de medida Gaussianos Markovianos. Este algoritmo proporciona una estimación de la probabilidad de un píxel en pertenecer a una clase. La segmentación final se obtiene fácilmente mediante la maximización de la probabilidad discreta estimada para cada píxel. Los experimentos con datos reales muestran que el algoritmo propuesto obtiene resultados competitivos en comparación con otras técnicas reportadas.

Abstract

In this work we propose a generalization of a probability measure field model, that allows to combine likelihoods from different information sources. The algorithm is applied to identify vegetation types in images from Landsat-5 TM satellite. Firstly, we obtain 3D-histograms from different information sources. From each histogram we estimate a likelihood. The final likelihood is a lineal combination of all them. The weights of the combination are a function of the entropy of each probability distribution derived from the estimated likelihood. Then, given an image, we use the computed likelihood of pixels to belong to each class (vegetation type) as an input of probabilistic segmentation algorithm called Gaussian Markov Measure Fields. This algorithm gives an estimation of the probability of a pixel of belonging to a class. The final segmentation is easily obtained by maximizing the estimated discrete probability for each pixel of the image. Experiments with real data show that the proposed algorithm obtains competitive results compared with state of the art algorithms.

Índice general

Índice general	VII
Índice de figuras	X
Índice de tablas	XV
1. Introducción	1
1.1. Firmas espectrales a través de imágenes satelitales	1
1.2. Clasificación de cultivos a través de firmas espectrales	4
1.3. La tesis y sus contribuciones	6
1.3.1. Motivación	6
1.3.2. Objetivos	6
1.3.3. Contribuciones	7
1.4. Estructura del documento de tesis	7
2. Marco teórico	9
2.1. Clasificación supervisada y no supervisada de cultivos a través de firmas espectrales	10
2.2. Índices de Vegetación	16
2.3. Segmentación probabilística	19
3. Propuesta de tesis: Un algoritmo supervisado para el estudio de cultivos a través de firmas espectrales en imágenes de satélite	21
3.1. Construcción de histogramas	22
3.1.1. Suavizado del histograma	24
3.1.2. Normalización del histograma	24

3.2.	Calculo de verosimilitudes	24
3.3.	Segmentación probabilística mediante selección de fuentes por mínima entropía	25
3.4.	Segmentación probabilística mediante fusión de fuentes	26
4.	Experimentos y discusión	28
4.1.	Características del satélite usado	28
4.2.	Área de estudio	29
4.3.	Metodología del trabajo experimental	29
4.4.	Experimentos y discusión	35
4.4.1.	Experimento 1: Segmentación bajo el Espacio 1	35
4.4.2.	Experimento 2: Segmentación bajo el Espacio 1 y el Espacio 2. El Espacio 2 considera PCA sobre 10 índices de vegetación. Selección de pesos por mínima entropía	37
4.4.3.	Experimento 3: Segmentación bajo el Espacio 1 y Espacio 2. El Espacio 2 considera PCA sobre 6 índices de vegetación y mínima entropía para la selección de pesos	39
4.4.4.	Experimento 4: Segmentación bajo los Espacios 1 y 3. Mínima entropía para la selección de pesos	40
4.4.5.	Experimento 5: Segmentación bajo los Espacios 2 y 3. El Espacio 2 considera PCA sobre 10 índices de vegetación. Selección de pesos por mínima entropía	42
4.4.6.	Experimento 6: Segmentación bajo los Espacios 2 y 3. El Espacio 2 considera PCA sobre 6 índices de vegetación. Selección de pesos por mínima entropía	44
4.4.7.	Experimento 7: Segmentación bajo los Espacios 1, 2 y 3. El Espacio 2 considera PCA sobre 10 índices de vegetación. Mínima entropía para la selección de pesos	46
4.4.8.	Experimento 8: Segmentación bajo los Espacios 1, 2 y 3. El Espacio 2 considera PCA sobre 6 índices de vegetación. Mínima entropía para la selección de pesos	48
4.4.9.	Experimento 9: Segmentación bajo el Espacio 1 y 2. El espacio 2 considera PCA sobre 10 índices de vegetación. Criterio de fusión de fuentes para cálculo de pesos	49

4.4.10. Experimento 10: Segmentación bajo el Espacio 1 y Espacio 2. El Espacio 2 considera PCA sobre 6 índices de vegetación. Criterio de fusión de fuentes para cálculo de pesos	51
4.4.11. Experimento 11: Segmentación bajo el Espacio 1 y Espacio 3	52
4.4.12. Experimento 12: Segmentación bajo los Espacios 2 y 3. El Espacio 2 considera PCA sobre 10 índices de vegetación. Criterio de fusión de fuentes para cálculo de pesos	54
4.4.13. Experimento 13: Segmentación bajo los Espacios 2 y 3. El Espacio 2 considera PCA sobre 6 índices de vegetación. Criterio de fusión de fuentes para cálculo de pesos	55
4.4.14. Experimento 14: Segmentación bajo los Espacios 1, 2 y 3. El Espacio 2 considera PCA sobre 10 índices de vegetación. Criterio de fusión de fuentes para cálculo de pesos	57
4.4.15. Experimento 15: Segmentación bajo los Espacios 1, 2 y 3. El Espacio 2 considera PCA sobre 6 índices de vegetación. Criterio de fusión de fuentes para cálculo de pesos	58
4.5. Selección del algoritmo supervisado para el estudio de cultivos a través de firmas espectrales en imágenes de satélite	60
4.6. Aplicación de la propuesta seleccionada sobre imágenes sintéticas	61
4.7. Comparación del algoritmo supervisado propuesto con otros métodos reportados en la literatura	63
5. Conclusiones y trabajo futuro	66
A. Satelites de teledetección	69
B. Índice de kappa y precisión global	73
B.1. Cálculo del coeficiente de Kappa y la medida de precisión global	73
C. Algoritmo k-medias	75
D. Artículo MICAI 2014	77
E. Artículo MICAI 2015	87
Referencias	100

Índice de figuras

1.1. El espectro electromagnético.	2
1.2. Representación de las firmas espectrales de algunos objetos en una imagen de satélite.	2
1.3. Bandas espectrales adquiridas por un satélite artificial.	3
1.4. Similitud entre firmas espectrales en una imagen de satélite Landsat-5 TM, con información de diferentes tipos de cultivos.	5
2.1. Esquema que representa el modelo de retroalimentación multicapa en una red neuronal artificial.	11
2.2. Imagen hiperespectral del sensor AVIRIS; (a) representación en forma de cubo de las 124 bandas de la imagen Aviris Indian Pines, (b) banda número 4 de la imagen Aviris Indian Pines.	12
2.3. Resultados gráficos de la clasificación de la imagen Aviris de 224 bandas mediante una RNA; (a) Imagen clasificada (<i>Ground truth</i>), (b) Resultado de la segmentación utilizando la característica de las medias.	12
2.4. Imágenes del satélite Landsat-1: (a) Resultado de una clasificación por pixel aplicando MLC, (b) Resultado de una clasificación aplicando ECHO ESS.	13
2.5. Comparaciones de resultados de clasificación usando diferentes métodos y espacios, sobre una imagen del satélite SPOT 5. Primera fila: ground truth. Segunda Fila: Resultados usando las características 4 bandas espectrales: verde, roja, infrarroja cercana e infrarroja de onda corta Tercera fila: Resultados usando las características dado por las tres primeras componentes principales de PCA sobre las 4 bandas espectrales: verde, roja, infrarroja cercana e infrarroja de onda corta. Columnas (a) método MED, (b) método k-medias basado en MED, (c) PSO-kmedias basado en MED.	15

2.6. Firmas espectrales en las 4 bandas utilizadas para el cálculo de los índices de vegetación: azul visible, verde visible, rojo visible e infrarrojo cercano, sobre una imagen del sensor Landsat-5 TM.	16
2.7. Efectos de aplicar el índice de vegetación ($MSR = \frac{\rho_{NIR} - 1}{\sqrt{\frac{\rho_{NIR} + 1}{\rho_r}}}$) sobre las bandas satelitales roja (ρ_r) e infrarrojo cercano (ρ_{NIR}), del sensor Landsat 8.	18
3.1. Fases del algoritmo.	22
3.2. Representación gráfica de la construcción de histogramas en el espacio de características formado por las bandas verde (G), roja (R) e infrarroja (I) para dos clases. Cada cubo está asociado al histograma de una clase.	23
4.1. Imagen satelital Landsat-5 TM, ubicada en el estado de Jalisco, México.	29
4.2. Fases de la metodología del algoritmo propuesto.	30
4.3. Imagen izquierda: área de estudio (imagen del satélite Landsat-5 TM). Imagen derecha, ground truth.	31
4.4. Firmas espectrales de los 5 cultivos estudiados, sobre una imagen Landsat-5 TM.	31
4.5. Espacios de características en los que representa la imagen a estudiar.	32
4.6. Ejemplo de aplicación del filtro bilateral a una banda espectral del satélite Landsat-5 TM. (a) Imagen original (banda TM4). (b) Imagen aplicando el filtro bilateral a la banda TM4.	33
4.7. Asignación de verosimilitudes considerando los Espacios 1, 2 y 3.	34
4.8. (a) Imagen de estudio, (b) Bandas TM2, TM3 y TM4. (c) Bandas TM2, TM3 y TM4, luego de aplicar el filtro bilateral.	36
4.9. (a) Imagen de estudio. (b) Resultado de la segmentación del Experimento 1. (c) Ground truth.	36
4.10. Representación de los Espacios de características usados en el Experimento 2. A la izquierda: imagen de estudio. Arriba, a la derecha, representación del Espacio 1, luego de aplicar el filtro bilateral. Abajo, a la derecha, representación del Espacio 2 considerando las tres primeras componentes principales de PCA sobre 10 índices de vegetación.	37
4.11. (a) Imagen de estudio. (b) Resultado de la segmentación del Experimento 2. (c) Ground truth.	38
4.12. Representación de los 10 índices de vegetación calculados.	39

4.13. Representación de los Espacios de características usados en el Experimento 3. A la izquierda: imagen de estudio. Arriba, a la derecha, representación del Espacio 1, luego de aplicar el filtro bilateral. Abajo, a la derecha, representación del Espacio 2 considerando las tres primeras componentes principales de PCA sobre 6 índices de vegetación.	39
4.14. (a) Imagen de estudio. (b) Resultado de la segmentación del Experimento 3. (c) Ground truth.	40
4.15. Representación de los Espacios de características usados en el Experimento 4. A la izquierda: imagen de estudio. Arriba, a la derecha, representación del Espacio 1, luego de aplicar el filtro bilateral. Abajo, a la derecha, representación del Espacio 3 considerando las tres primeras componentes principales de PCA sobre 6 bandas espectrales.	41
4.16. (a) Imagen de estudio. (b) Resultado de la segmentación del Experimento 4. (c) Ground truth.	42
4.17. Representación de los Espacios de características usados en el Experimento 5. A la izquierda: imagen de estudio. Arriba, a la derecha, representación del Espacio 2 considerando las tres primeras componentes principales de PCA sobre 10 índices de vegetación. Abajo, a la derecha, representación del Espacio 3.	43
4.18. (a) Imagen de estudio. (b) Resultado de la segmentación del Experimento 5. (c) Ground truth.	44
4.19. Representación de los Espacios de características usados en el Experimento 6. A la izquierda: imagen de estudio. Arriba, a la derecha, representación del Espacio 2 considerando las tres primeras componentes principales de PCA sobre 6 índices de vegetación. Abajo, a la derecha, representación del Espacio 3.	45
4.20. (a) Imagen de estudio. (b) Resultado de la segmentación del Experimento 6. (c) Ground truth.	46
4.21. Representación de los Espacios de características usados en el Experimento 7. Al centro: imagen de estudio. Arriba, a la izquierda, representación del Espacio 1, luego de aplicar el filtro bilateral. Arriba, a la derecha, representación del Espacio 2 considerando las tres primeras componentes principales de PCA sobre 10 índices de vegetación. Abajo, representación del Espacio 3.	47
4.22. (a) Imagen de estudio. (b) Resultado de la segmentación del Experimento 7. (c) Ground truth.	47

4.23. Representación de los Espacios de características usados en el Experimento 8. Al centro: imagen de estudio. Arriba, a la izquierda, representación del Espacio 1, luego de aplicar el filtro bilateral. Arriba, a la derecha, representación del Espacio 2 considerando las tres primeras componentes principales de PCA sobre 6 índices de vegetación. Abajo, representación del Espacio 3. 48

4.24. (a) Imagen de estudio. (b) Resultado de la segmentación del Experimento 8. (c) Ground truth. 49

4.25. Primera fila: (a) Imagen de estudio y (b) Ground truth. Segunda fila: segmentación usando fusión de fuentes para el cálculo de pesos: (c) $\mu = 1$, (d) $\mu = 0.1$, (e) $\mu = 0.01$ y (f) $\mu = 0.001$ 50

4.26. Primera fila: (a) Imagen de estudio y (b) Ground truth. Segunda fila: segmentación usando fusión de fuentes para el cálculo de pesos: (c) $\mu = 1$, (d) $\mu = 0.1$, (e) $\mu = 0.01$ y (f) $\mu = 0.001$ 51

4.27. Primera fila: (a) Imagen de estudio y (b) Ground truth. Segunda fila: segmentación usando fusión de fuentes para el cálculo de pesos: (c) $\mu = 1$, (d) $\mu = 0.1$, (e) $\mu = 0.01$ y (f) $\mu = 0.001$ 53

4.28. Primera fila: (a) Imagen de estudio y (b) Ground truth. Segunda fila: segmentación usando fusión de fuentes para el cálculo de pesos: (c) $\mu = 1$, (d) $\mu = 0.1$, (e) $\mu = 0.01$ y (f) $\mu = 0.001$ 54

4.29. Primera fila: (a) Imagen de estudio y (b) Ground truth. Segunda fila: segmentación usando fusión de fuentes para el cálculo de pesos: (c) $\mu = 1$, (d) $\mu = 0.1$, (e) $\mu = 0.01$ y (f) $\mu = 0.001$ 56

4.30. Primera fila: (a) Imagen de estudio y (b) Ground truth. Segunda fila: segmentación usando fusión de fuentes para el cálculo de pesos: (c) $\mu = 1$, (d) $\mu = 0.1$, (e) $\mu = 0.01$ y (f) $\mu = 0.001$ 57

4.31. Primera fila: (a) Imagen de estudio y (b) Ground truth. Segunda fila: segmentación usando fusión de fuentes para el cálculo de pesos: (c) $\mu = 1$, (d) $\mu = 0.1$, (e) $\mu = 0.01$ y (f) $\mu = 0.001$ 59

4.32. Resultados de la clasificación con imágenes sintéticas usando la propuesta seleccionada con los espacios 1 y 3. Primera fila: 4 Imágenes sintéticas. Segunda fila: ground truth de las imágenes sintéticas. Tercera fila: Resultados de la clasificación usando el algoritmo seleccionado en la Sección 4.5. 62

4.33. Comparación de resultados finales de nuestra propuesta con otros métodos reportados en la literatura. Primera fila: (a) Imagen de estudio. (b) Ground Truth. (c) MED. Segunda fila: (d) ML. (e) FLL (f) ECHO ESS. Tercera fila: (g) MICAI 2014, (h) MICAI 2015. (i) Algoritmo propuesto.	65
--	----

Índice de tablas

2.1. Índices de vegetación calculados sobre una imagen Landsat-5 TM. ρ_r , ρ_g , ρ_b y ρ_{NIR} denotan los valores de reflectancia para las bandas del rojo (r), azul (b), verde (g) e infrarrojo cercano(NIR) respectivamente.	17
4.1. Bandas espectrales del sensor Landsat-5 Thematic Mapper (TM).	29
4.2. Validación de la segmentación en el Experimento 1.	37
4.3. Validación de la segmentación en el Experimento 2.	38
4.4. Validación de la segmentación en el Experimento 3.	40
4.5. Validación de la segmentación en el Experimento 4.	42
4.6. Validación de la segmentación en el Experimento 5.	44
4.7. Validación de la segmentación en el Experimento 6.	46
4.8. Validación de la segmentación en el Experimento 7.	48
4.9. Validación de la segmentación en el Experimento 8.	49
4.10. Validación de la segmentación en el Experimento 9.	50
4.11. Validación de la segmentación en el Experimento 10.	52
4.12. Validación de la segmentación en el Experimento 11.	53
4.13. Validación de la segmentación en el Experimento 12.	55
4.14. Validación de la segmentación en el Experimento 13.	56
4.15. Validación de la segmentación en el Experimento 14.	58
4.16. Validación de la segmentación en el Experimento 15.	59
4.17. Resultados finales de los 15 Experimentos realizados, usando los criterios de mínima entropía y fusión de fuentes.	60
4.18. Resultados de la clasificación de las imágenes sintéticas usando el algoritmo de la propuesta.	62
4.19. Resultados numéricos de diferentes métodos de clasificación.	63

A.1. Satélites de teledetección.	70
A.2. Satélites de teledetección.	71
A.3. Satélites de teledetección	72
B.1. Ejemplo para ilustrar el cálculo del coeficiente Kappa.	74
B.2. Valoración del Índice Kappa.	74

Capítulo 1

Introducción

En este capítulo se da una introducción del tema de investigación sobre el estudio de cultivos a través de imágenes satelitales utilizando técnicas de reconocimiento de patrones y se enuncian los objetivos y las contribuciones esperadas de la investigación.

1.1. Firmas espectrales a través de imágenes satelitales

La teledetección permite obtener información de objetos a distancia [10]. El fundamento teórico de la teledetección está basado en la propiedad que tienen los objetos de absorber, reflejar y transmitir la energía proporcionada por una fuente de energía sobre un objeto de la corteza terrestre. Esa energía electromagnética vibra con diferentes frecuencias (longitudes de onda) que se distribuyen a lo largo del espectro electromagnético [6, 13, 22, 31, 63] (ver Figura 1.1). Parte de la energía es transmitida y otra es absorbida. En el caso particular de la teledetección, la energía proporcionada por el sistema solar, que es reenviada (reflejada) a la atmósfera es capturada a través de un sensor satelital. La información recibida del satélite sobre cantidad de energía que recibió el sensor, es enviada a la tierra en forma de imágenes. Dichas imágenes antes de ser utilizadas, tienen que pasar por un proceso de correcciones, con el propósito de filtrar interferencias atmosféricas como la nubosidad y otros elementos que ocasionan ruido e imperfecciones que obstaculizan el análisis y procesamiento de la información. Típicamente, los rangos de las longitudes de onda utilizadas para la detección de cultivos, oscilan entre 430 *nm* y 12510 *nm* del espectro electromagnético y corresponden a las bandas llamadas: aerosol costero, azul visible, verde visible, rojo visible, rojo límite, infrarrojo cercano, infrarrojo medio, infrarrojo lejano e infrarrojo térmico.




Figura 1.1: El espectro electromagnético.

Una firma espectral es la curva que representa la variación de la reflectancia¹ de un objeto en función de la longitud de onda [46], y como se puede observar en la (Figura 1.2), la firma espectral caracteriza la interacción entre elementos de la corteza terrestre y el espectro electromagnético.

La firma espectral es una representación gráfica que especifica la siguiente información:

- 1.- Cuánta energía es reflejada por los objetos en la superficie terrestre.
- 2.- A qué longitud o longitudes de onda corresponde la energía reflejada.

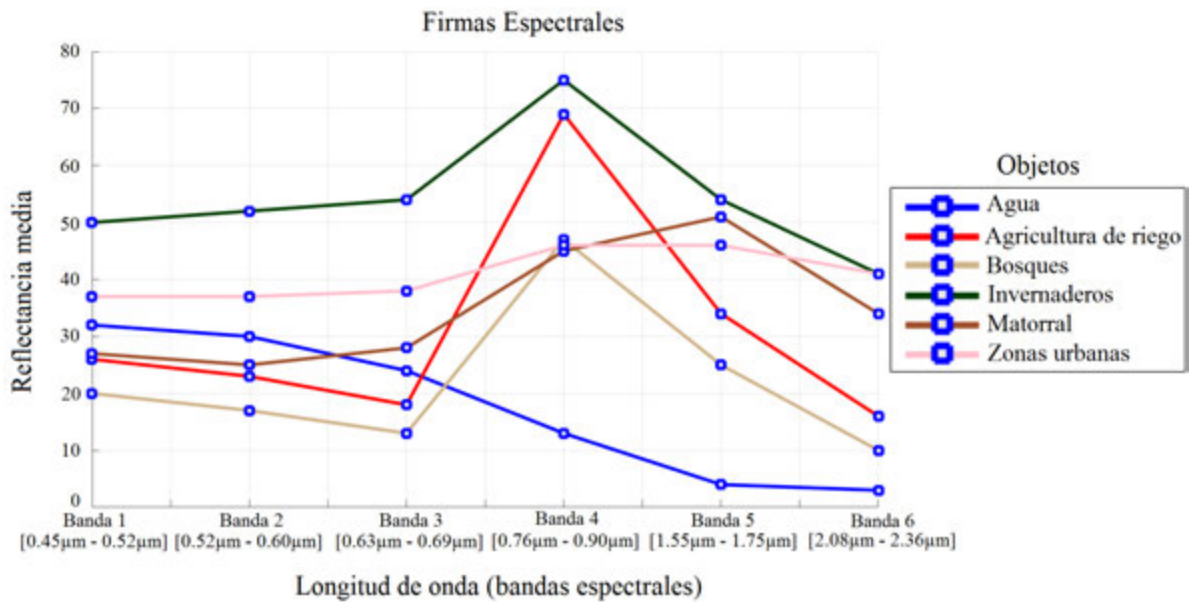


Figura 1.2: Representación de las firmas espectrales de algunos objetos en una imagen de satélite.

Las imágenes obtenidas por los sensores satelitales contienen entonces la firma espectral de los objetos de la cobertura terrestre. La información registrada por el satélite se compone de

¹Capacidad de las superficies de reflejar la luz.

varias imágenes, cada una de las cuales contiene la cantidad de luz reflejada en cierto rango o banda del espectro electromagnético. Cada píxel se describe con números digitales (ND) que describen la interacción con la radiación solar. Cada imagen se denomina banda espectral (ver Figura 1.3).




Figura 1.3: Bandas espectrales adquiridas por un satélite artificial.

El uso de la teledetección mediante satélites ha dado lugar a aplicaciones muy importantes como la planificación urbana, la vigilancia ambiental, la explotación petrolera, la exploración minera, el desarrollo de los mercados, la ubicación de bienes raíces y el estudio y clasificación de cultivos, tema que será abordado en esta tesis.

Actualmente los satélites tienen tecnología capaz de registrar 1 millón de km^2 por semana con una nueva visita de aproximadamente de menos de 1 día. Entre los satélites más utilizados se encuentran: los sensores Landsat TM, con una resolución espacial² de 30 $m.$, RAPIDEYE, con una resolución espacial de 5 $m.$, QUICKBIRD, con una resolución espacial de 2.44 $m.$, y WORLDVIEW-3, con una resolución espacial de 31 $cm.$ Para más detalles sobre las características de algunos satélites que aún se encuentran activos, consulte el Apéndice A. Es importante mencionar la facilidad que ofrecen algunos sitios web para descargar imágenes satelitales, como lo es la página de los servicios geológicos de los Estados Unidos (USGS), desde la cual podemos

²La resolución espacial se refiere al tamaño del píxel o la extensión angular del área captada por un sensor satelital. También existe el termino resolución espectral, que se refiere al número y ancho de las bandas espectrales registradas por un sensor. El termino resolución temporal, es la medida de la frecuencia con la que un satélite es capaz de obtener imágenes de una determinada área, y el termino resolución radiométrica, es la cantidad de números digitales utilizados para expresar los datos recogidos por un sensor.

descargar imágenes satelitales de diferentes sensores (<http://glovis.usgs.gov/>).

1.2. Clasificación de cultivos a través de firmas espectrales

La clasificación automatizada permite la interpretación asistida por computadoras de imágenes de sensores remotos.

Aunque algunos métodos son capaces de incorporar características de la imagen, tales como textura y el contexto, la mayoría de los métodos de clasificación de imágenes satelitales se basa únicamente en el estudio de las firmas espectrales de las clases de cobertura del suelo.

En general los algoritmos de clasificación son de dos tipos:

- Supervisados: Los algoritmos supervisados reciben información a priori de los objetos. Dicha información define las características que discriminan a los grupos presentes. Posteriormente a través de un proceso de entrenamiento con el conocimiento a priori, el algoritmo aprende a identificar (separar) el o los objetos que se buscan.
- No supervisados: En los algoritmos no supervisados, no hay información a priori y el algoritmo debe discriminar grupos u objetos presentes en la información. Esta técnica identifica las características que separan mejor los grupos.

Además de técnicas supervisadas y no supervisadas también existen técnicas híbridas, o sea combinación de algoritmos supervisados y no supervisados [20]. En todos los casos el problema fundamental es la selección de características o atributos significativos de los objetos a estudiar, pues esto define la calidad de la agrupación o clasificación.

La clasificación de cultivos y vegetación a través de firmas espectrales, es de gran importancia ya que nos permite hacer evaluaciones del uso de suelos; se pueden predecir tendencias y patrones de vegetación sobre la cobertura terrestre, y estimar el estado de las cosechas entre otras aplicaciones.

Para el reconocimiento y clasificación de cultivos mediante firmas espectrales se consideran una o varias bandas espectrales o la transformación de ellas [60]. Entre las técnicas supervisadas usadas para la clasificación de cultivos se encuentran: Redes Neuronales Artificiales [80], el método de mínima distancia euclidiana [82], máxima verosimilitud [1, 23]. Entre los métodos no supervisados y combinación de supervisados con supervisados se encuentran: cálculo de índices de vegetación y umbralamiento manual o automático [9, 38, 39, 41, 67, 76], clasificadores basados en estadísticos [42], k-medias [28], combinación del método optimización de enjambres

de partículas (PSO, sus siglas en inglés) con k-medias [72]. En [44, 47] a diferencia de otros enfoques, se considera no sólo la información espectral de un pixel sino también la información espectral de los píxeles vecinos. En [59] se propone un esquema de clasificación de cultivos basado en un algoritmo supervisado que combina la estimación de verosimilitudes, usando la característica banda espectral, con la segmentación a través de un enfoque probabilístico según el estimador de distribuciones *Gauss-Markov Measure Field* (GMMF) [52]. Aquí también se combina información puntual con información contextual.

El uso de diferentes técnicas de clasificación ha permitido el estudio y clasificación de cultivos y aunque los logros son notables, la precisión de los algoritmos de clasificación es afectada por problemas como la similitud de la respuesta espectral para diferentes cultivos [72], lo que se hace difícil la discriminación entre ellos (ver Figura 1.4). Otro problema que afecta el trabajo del clasificador es la elección del espacio de características, incluyendo el aspecto de la dimensionalidad. El espacio de características está definido por la información extraída de las bandas espectrales.

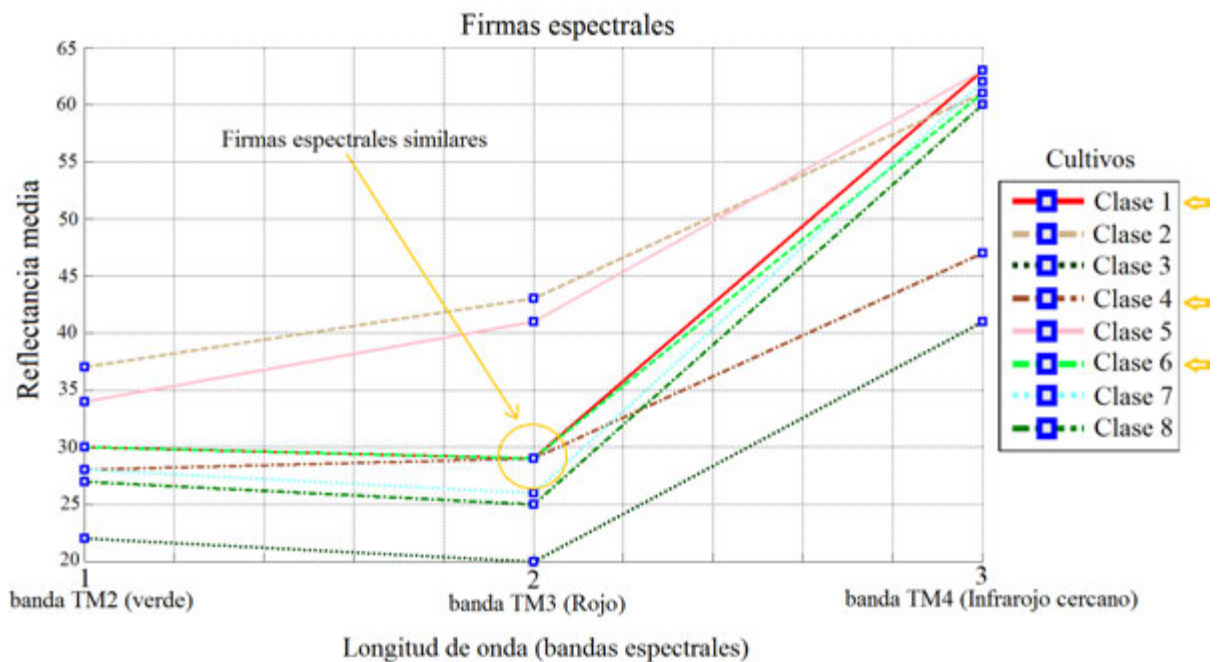


Figura 1.4: Similitud entre firmas espectrales en una imagen de satélite Landsat-5 TM, con información de diferentes tipos de cultivos.

1.3. La tesis y sus contribuciones

1.3.1. Motivación

Acorde al estudio realizado, el éxito de un algoritmo de clasificación de cultivos a partir de firmas espectrales está determinado por la respuesta a las siguientes preguntas de investigación:

1. ¿Cómo disminuir el efecto negativo de la similaridad de las firmas espectrales para diferentes cultivos en el trabajo del clasificador?
2. ¿Cuáles son las características espectrales de los cultivos que permiten una mayor precisión del clasificador y cómo seleccionarlas y combinarlas? , ¿Cómo definir la dimensionalidad del espacio de características?
3. ¿Cómo considerar la información espectral: puntual o puntual con información contextual?, ¿Es necesario transformar la información espectral o no?

Los trabajos analizados no responden a todas las preguntas enunciadas. Motivados por eso en este manuscrito se propone un algoritmo supervisado para el estudio de cultivos a través de firmas espectrales en imágenes de satélite. En el algoritmo se propone cómo combinar información de diferentes fuentes (espacios de características) y se mezcla el enfoque puntual con espacial. La información puntual es incluida en la primera fase a través de la construcción de histogramas. La información espacial o contextual se incluye en la fase de clasificación a través de un enfoque probabilístico. El uso de transformaciones sobre la información espectral original es una de las herramientas usadas por el algoritmo propuesto. Estas herramientas utilizadas contribuyen a responder las preguntas de investigación que motivaron este trabajo.

1.3.2. Objetivos

El objetivo principal de esta tesis es:

- Desarrollar un algoritmo supervisado para reconocer diferentes tipos de vegetación en imágenes satelitales mediante el estudio de firmas espectrales.

Los pasos para poder cumplir con este objetivo serán los siguientes:

1. Construcción de diferentes espacios de características.

2. Para cada espacio de características construir histogramas que permitan conocer la probabilidad de ocurrencia de cada clase de cultivo a analizar. Los histogramas se construyen a partir de información a priori suministradas por expertos.
3. Elección del espacio de características que permitan una mejor separación entre clases, teniendo como criterio de decisión la precisión del clasificador en la etapa de segmentación a través de una modificación de GMMF [52]. El espacio de características final es una combinación de espacios construidos en el paso 1 y procesados en el paso 2.

1.3.3. Contribuciones

Las contribuciones de esta tesis son las siguientes:

- Se propone un nuevo algoritmo supervisado para la clasificación de cultivos en el que se combina información puntual con espacial usando un enfoque probabilístico. El algoritmo tiene dos fases. En la primera se generan distribuciones de probabilidades para cierto espacio de características, usando la información de expertos. Esta primera etapa permite conocer la probabilidad de pertenencia de cada pixel a una clase de cultivo en particular. En la segunda etapa las distribuciones de probabilidades para cada pixel compiten entre sí y con las distribuciones de los pixeles vecinos siguiendo el criterio de mínima entropía.
- Se combinan fuentes de información (características) diferentes sin hacer crítico el problema de la dimensionalidad de los datos a procesar.
- Para la combinación de diferentes fuentes de información se considera el criterio de entropía de las diferentes distribuciones generadas (verosimilitudes) en la fase de construcción de histogramas. Teóricamente, con este criterio se pueden combinar un número ilimitado de fuentes de información.

1.4. Estructura del documento de tesis

La estructura del manuscrito en lo que sigue es:

- Capítulo 2: está dedicado a una revisión detallada de métodos de clasificación supervisados y no supervisados, usados en el estudio de cultivos a través de firmas espectrales. En la revisión realizada se da especial atención al espacio de características que considera cada

método y a la necesidad de incluir interacción espacial. Los trabajos revisados motivaron la investigación y la propuesta hecha.

- Capítulo 3: se describe el algoritmo que se generó como resultado de la investigación. El algoritmo elaborado es supervisado y se basa en la construcción de histogramas tridimensionales en diferentes espacios de características. A partir de los histogramas, se estiman verosimilitudes que se combinan usando como criterio de contraste la entropía. La verosimilitud final, producto de la combinación, es usada para la segmentación probabilística a través de GMMF. En este capítulo se detalla sobre las ventajas del método propuesto.
- Capítulo 4: se enuncian y describen los 15 experimentos realizados usando diferentes espacios de características. Cada experimento se valida teniendo en cuenta la precisión de la clasificación de los cultivos analizados. La discusión realizada conlleva a la selección del mejor experimento.
- Capítulo 5: se dan las conclusiones, ventajas y problemas de la propuesta, así como líneas de trabajo futuro.

Capítulo 2

Marco teórico

Los algoritmos de clasificación consisten en la asignación de un objeto o un fenómeno físico a una categoría o clase. La clasificación es una técnica que ha sido muy utilizada en diversos campos, tales como: la medicina, biología, biometría, sistemas de información geográfica (SIG), minería de datos espaciales, creación de mapas temáticos, estudios de campo, reconocimiento de patrones, gestión de catástrofes y aplicaciones de la industria y la ciencia [71].

La clasificación puede ser supervisada o no supervisada, aunque también existen algoritmos híbridos.

La clasificación supervisada considera conocimiento a priori, es decir, se cuenta con información de las características de los grupos en la clasificación. Los algoritmos de clasificación supervisada tienen dos fases:

1. **Fase de entrenamiento:** en esta fase se diseña el clasificador y para ello, se construyen dos conjuntos de datos: el conjunto de entrenamiento y el conjunto de validación o test. El conjunto de entrenamiento es el que hace posible el proceso de aprendizaje para el diseño del clasificador, utilizando para ello, un conjunto de características. El conjunto test es el que permite validar el clasificador diseñado.
2. **Fase de generalización:** en esta fase el clasificador cataloga muestras del mismo tipo de objeto con el que aprendió, estas corresponden a muestras nunca antes "*vistas*".

En la clasificación no supervisada a diferencia de la supervisada no hay conocimiento a priori. La finalidad de los algoritmos de clasificación no supervisada es el descubrimiento de grupos cuyas características afines, permitan separar las diferentes clases [71].

En este capítulo se revisan algoritmos de clasificación supervisada y no supervisada, así

como también algoritmos híbridos, los cuales han sido utilizados para la clasificación de cultivos a través de firmas espectrales en imágenes de satélite. Para la validación de la clasificación se tienen diferentes índices. Tomando como referencia los trabajos revisados en esta investigación, los criterios usados para la validación de la clasificación fueron la precisión global e índice Kappa [11, 50]. Información detallada del cálculo de estos índices aparece en el Apéndice B.

Uno de los aspectos a los que le dedica especial atención este capítulo, es el espacio de características o descriptores usados durante la clasificación, por un algoritmo en particular.

Junto al tema de clasificación, en este capítulo también se analiza el uso de los índices de vegetación [9, 38, 39, 41, 67, 76] para la clasificación de cultivos en imágenes satelitales.

Finalmente se revisa el uso de la segmentación probabilística, en la clasificación de imágenes satelitales como un instrumento muy eficaz en la clasificación.

Los tópicos mencionados y los trabajos publicados que se revisaron en esta sección, fueron el punto de partida para esta tesis doctoral.

2.1. Clasificación supervisada y no supervisada de cultivos a través de firmas espectrales

Al usar la clasificación supervisada en imágenes satelitales, el algoritmo supervisado seleccionado recibe descriptores numéricos de los tipos de coberturas terrestres presentes en la escena, que se desean estudiar. Con ese fin se toman muestras de sitios representativos de las coberturas a analizar, llamadas áreas o sitios de entrenamiento que permitan compilar un código de interpretación numérica que describe los atributos espectrales para cada cobertura de interés. Cada pixel de la escena, es entonces comparado con el código de cada categoría asignándole el nombre de aquella que es más similar, según el modelo del clasificador supervisado definido en el algoritmo seleccionado. Para validar numéricamente los resultados del clasificador se tiene una referencia que se conoce como *ground truth*. Esa referencia es resultado del conocimiento de un experto del área a estudiar, y puede ser una imagen clasificada manualmente o datos de exploración de campo.

Entre los algoritmos de clasificación supervisada que más se utilizan en el estudio de imágenes espectrales se encuentran los siguientes:

- 1.- Redes Neuronales Artificiales (RNA).
- 2.- Máxima verosimilitud (MLC, sus siglas en inglés).

3.- Mínima Distancia Euclidiana (MED).

Las Redes Neuronales Artificiales (RNA) son, como su nombre lo indica, redes computacionales que pretenden simular de forma general, a las redes de células nerviosas (neuronas) del sistema biológico nervioso central (humano ó animal) [27]. Existen diferentes modelos de RNA, entre los modelos que se utilizan con frecuencia para la clasificación de cultivos se encuentra el modelo llamado "modelo de retroalimentación multicapa" (MLF, sus siglas en inglés) [56]. Este modelo consiste en un conjunto de nodos fuente que forman la capa de entrada, una o más capas ocultas de nodos, y una capa de salida (ver Figura 2.1).

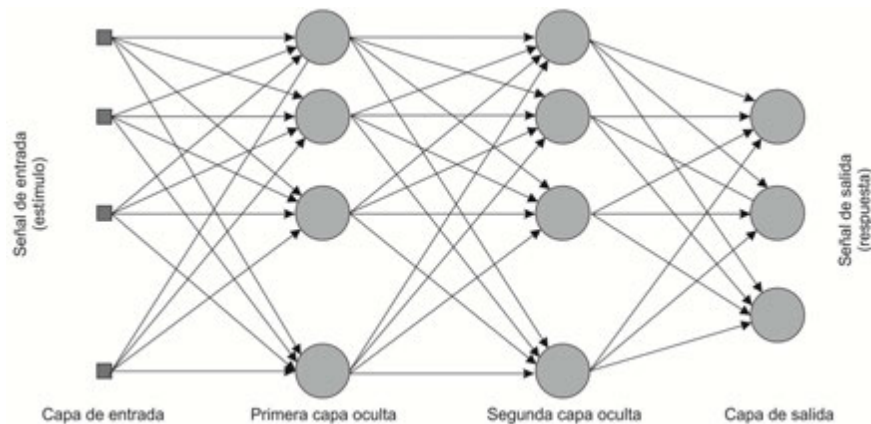


Figura 2.1: Esquema que representa el modelo de retroalimentación multicapa en una red neuronal artificial.

El funcionamiento de este tipo de red está basado en la regla de aprendizaje de corrección del error, el cual puede verse como una generalización del algoritmo de Mínimo Error Medio (LMS, sus siglas en inglés) [56].

En [42, 80] se usan las RNA para la clasificación de zonas agrícolas en imágenes multi-espectrales. En particular en [42] se considera que las RNA son más complicadas de usar en comparación con los clasificadores estadísticos, esto debido a problemas que se presentan en cuanto a su diseño e implementación, ya que siempre están sujetos a ajustes en el número de capas ocultas y otros parámetros tales como los pesos, que son los que definen las interacciones entre las neuronas. En la Figura 2.2 se observa una imagen de la base de datos del sensor AVIRIS [7, 65]. La imagen corresponde al noroeste de Indiana, tiene una resolución de 145×145 píxeles, resolución espectral de 224 bandas, resolución espacial de 20 metros, resolución radiométrica de 16 bits y contiene información de 17 tipos diferentes de cultivos.




Figura 2.2: Imagen hiperespectral del sensor AVIRIS; (a) representación en forma de cubo de las 124 bandas de la imagen Aviris Indian Pines, (b) banda número 4 de la imagen Aviris Indian Pines.

Al aplicar una red neuronal de retroalimentación multicapa utilizando los espacios de características: intensidades de los niveles de gris, media, varianza, media-varianza, entropía así como combinación entre ellas se llegó a la conclusión que el espacio de características dado por la media de intensidades fue el mejor en cuanto a la precisión global e índice Kappa [11, 50]. cuyos valores fueron de 0.66 % y 0.53 %. Los resultados gráficos de la clasificación, aparecen ilustrados en la Figura 2.3 Observe que los resultados gráficos se corresponden con la validación numérica. La solución de la clasificación es muy granular y muchas regiones no fueron bien clasificadas.

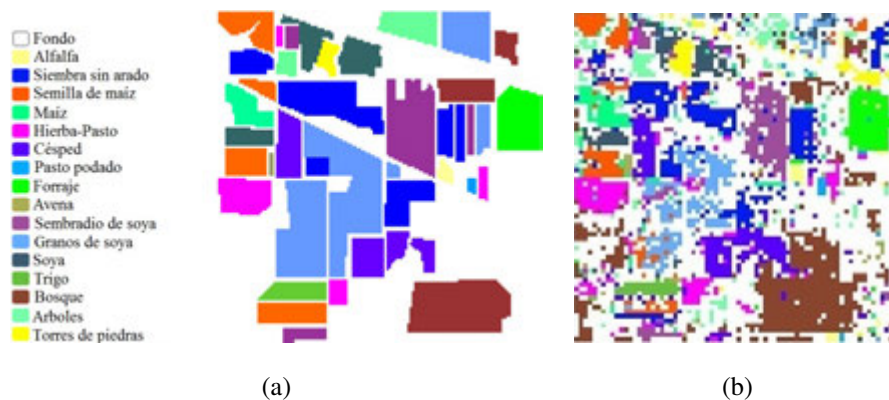


Figura 2.3: Resultados gráficos de la clasificación de la imagen Aviris de 224 bandas mediante una RNA; (a) Imagen clasificada (*Ground truth*), (b) Resultado de la segmentación utilizando la característica de las medias.

En [8] se utilizaron diferentes métodos supervisados y métodos no supervisados: distancia mínima euclidiana (MED, en inglés) [82], clasificador de caja [73], distancia mínima de Mahalanobis [18], máxima verosimilitud [30] y agrupamiento [28]. El objetivo de la investigación en [8] fue reconocer 5 diferentes tipos de coberturas de suelos (bosques/vegetación, cuerpos de

agua, humedales/tierras bajas, superficie artificial y tierra cultivada), en Rusia, basándose en las características de la reflectancia espectral de los datos de las imágenes satelitales. Se utilizaron imágenes aéreas con una escala de 1:5000 de 3 bandas (RGB). Los datos del ground truth fueron obtenidos basándose en los mapas de suelo y mapas topográficos existentes. El método que mejor se desempeñó fue el de máxima verosimilitud con una precisión global de 71.5%. En [44, 47], se elaboró un algoritmo supervisado de clasificación espacial espectral y de extracción de objetos homogéneos (ECHO ESS, sus siglas en inglés) sobre imágenes satelitales multispectrales. Este algoritmo utiliza como característica, la información espectral de cada píxel (ND), junto a la información contextual de los píxeles vecinos. El objetivo principal del algoritmo, es lograr encontrar regiones homogéneas "Objetos" y clasificarlos, este se conforma de dos pasos. En el primer paso, la escena se divide en regiones estadísticamente homogéneas. En el segundo paso los datos se clasifican usando el clasificador de máxima verosimilitud (MLC). El algoritmo se aplicó sobre dos imágenes aéreas y sobre dos imágenes satelitales, en el territorio de los Estados Unidos obtenidas por el satélite Landsat-1 con una resolución espectral de 4 bandas. En la imagen se detectaron 5 clases de objetos: agricultura, bosques, ciudad, minería y agua. En la Figura 2.4 se muestran los resultados de la clasificación por el método ECHO ESS (Figura 2.4 (b)) y los obtenidos por el método MLC como comparación (Figura 2.4 (a)).




Figura 2.4: Imágenes del satélite Landsat-1: (a) Resultado de una clasificación por píxel aplicando MLC, (b) Resultado de una clasificación aplicando ECHO ESS.

Obsérvese que los resultados de la clasificación por ECHO ESS son mejores ya que se logró capturar con mayor precisión las regiones y por tanto la solución fue menos granular [44]. El uso de información contextual contribuyó en gran medida a la obtención de zonas homogéneas en la clasificación y el desempeño del método fue mejor que otros que consideran sólo información puntual como MLC [19] y MED [40].

El algoritmo de *k*-medias [28] es un algoritmo no supervisado de clasificación usados para el análisis de la información en imágenes espectrales. El principal objetivo de este método es particionar un conjunto de datos en *k* grupos o clases, como resultado de minimizar la función objetivo¹ (Ver algoritmo *k*-medias en el Apéndice C).

En [72] se desarrolló un método para la extracción de la tierra agrícola utilizando información basada en imágenes de teledetección (SPOT 5) tomadas sobre Japón, las imágenes tienen una resolución espacial multispectral de 10 *mts*. El objetivo de este algoritmo fue identificar 5 tipos de coberturas: frijol, arroz, cuerpos de agua, trigo y otros. Este algoritmo combina métodos supervisados con métodos no supervisados, los métodos que se combinaron fueron: conglomerados de *k*-medias [28], PSO y Minimum Euclidean Distance (MED) [82].

El método PSO (Particle Swarm Optimization) es un método de optimización iterativo que está inspirado en el movimiento de las bandadas de los pájaros. El movimiento de los pájaros siempre está dirigido por el o los mejores guías de la banda hacia la búsqueda de cierto objetivo (alimento, lugar seguro, agua, etc.). El algoritmo PSO simula este comportamiento natural para resolver problemas de optimización y finalmente esto es usado para la clasificación. En el caso de imágenes, la partícula, es cada pixel de la imagen a estudiar. PSO permite que dada cierta función objetivo el pixel quede categorizado o clasificado en el grupo al que es más semejante teniendo en cuenta no sólo sus características (intensidad del nivel de gris por ejemplo), sino también la de sus vecinos. Para más detalles del método consultar en [43, 70].

En los experimentos realizados en [72] se utilizó el método de distancia mínima euclidiana [82], considerando diferentes espacios de características:

1. Espacio de características dado por las intensidades en 4 bandas espectrales: verde, roja, infrarroja cercana e infrarroja de onda corta.
2. Espacio de características dado por las tres primeras componentes principales de la transformación PCA (Principal Component Analysis) [37] aplicado sobre las 4 bandas espectrales: verde, roja infrarroja cercana e infrarroja de onda corta.

Los resultados de las clasificaciones fueron casi similares. Teniendo en cuenta la dimensión del espacio de características y el coste computacional, se seleccionó el espacio formado por las tres primeras componentes principales de la transformación PCA sobre las bandas verde,

¹Es una función que se maximiza o minimiza usando diferentes técnicas de optimización numérica. Es el resultado de expresar un problema real en términos matemáticos. Ejemplos de problemas reales son: la toma de decisiones, investigación de operaciones, clasificación, entre otros. En el área de clasificación muchos algoritmos se describen a través de una función objetivo, la cual constituye el criterio matemático para cuantificar la calidad de la clasificación de los datos.

roja, infrarroja cercana e infrarroja de onda corta. En [72] los autores también observaron que la precisión de la clasificación por k-medias junto a PSO es mejor que utilizar solamente el clasificador MED. La combinación permitió lograr un 93 % de precisión, lo que fue superior al 56 % logrado con MED. En la Figura 2.5 se muestran los resultados de la investigación hecha en [72].




Figura 2.5: Comparaciones de resultados de clasificación usando diferentes métodos y espacios, sobre una imagen del satélite SPOT 5. Primera fila: ground truth. Segunda Fila: Resultados usando las características 4 bandas espectrales: verde, roja, infrarroja cercana e infrarroja de onda corta Tercera fila: Resultados usando las características dado por las tres primeras componentes principales de PCA sobre las 4 bandas espectrales: verde, roja, infrarroja cercana e infrarroja de onda corta. Columnas (a) método MED, (b) método k-medias basado en MED, (c) PSO-kmedias basado en MED.

La mayor confusión estuvo dada por el gran número de campos de arroz que fueron clasificados incorrectamente como cuerpos de agua.

Los investigadores de [58] realizaron un análisis de desempeño de los siguientes clasificadores supervisados: máxima verosimilitud [1], paralelepípedo[45] y la distancia Mahalanobis

[18]. El espacio de características se construyó a partir de datos del sensor SPOT-5. El objetivo de la investigación fue la identificación de diferentes tipos de suelo en Barcelona, España. El clasificador de máxima verosimilitud supero a los otros clasificadores para casi todos los objetos presentes en la imagen del estudio, sin embargo, para los cuerpos de agua, la distancia de Mahalanobis condujo a mejores resultados de precisión. La precisión global para la máxima verosimilitud fue de 99.17%. La selección de las bandas espectrales y la selección del clasificador correcto fue un paso crítico.

2.2. Índices de Vegetación

Los índices de vegetación (IV) son uno de los métodos más empleados para resaltar la información de la vegetación, en imágenes de satélite. Estos son resultado de operaciones algebraicas en las que se combinan dos o más bandas espectrales [33]. El diseño de índices de vegetación se basa en la firma espectral de la vegetación (Ver Figura 2.6). Nótese que los valores más altos de reflectancia, para la vegetación, tienen lugar en la zona de la banda del infrarrojo cercano, y los más bajos en el visible; esto explica el diseño de los IV, los cuales se calculan usando las bandas ubicadas en la zona visible del espectro electromagnético y la banda del infrarrojo cercano.

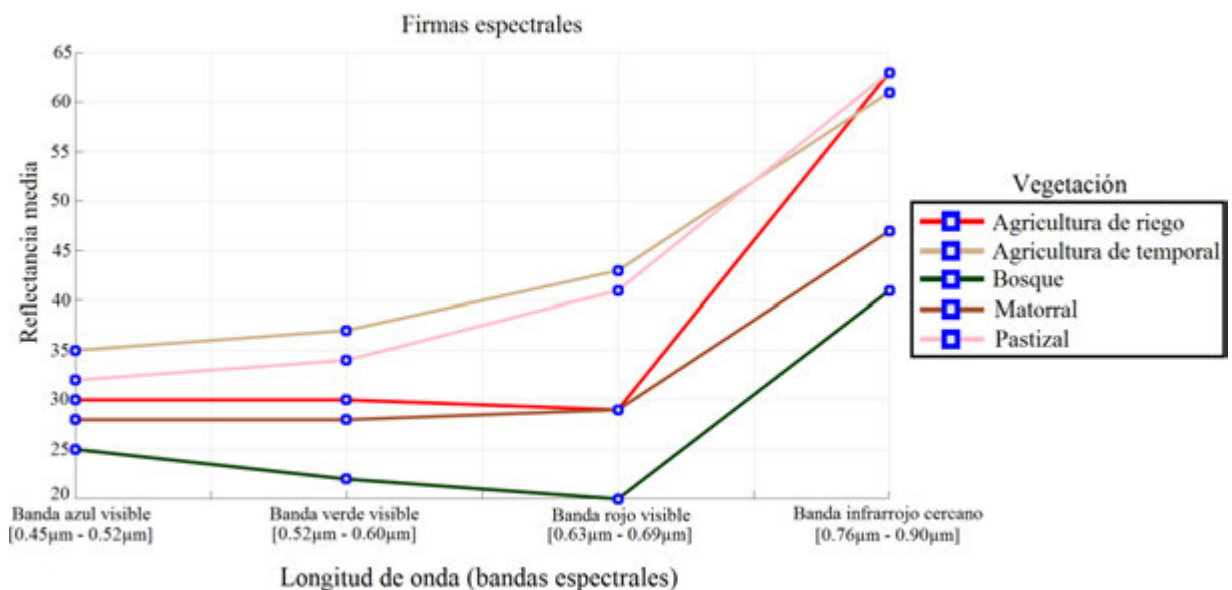


Figura 2.6: Firmas espectrales en las 4 bandas utilizadas para el cálculo de los índices de vegetación: azul visible, verde visible, rojo visible e infrarrojo cercano, sobre una imagen del sensor Landsat-5 TM.

En la Tabla 2.1 aparecen los índices de vegetación reportados en la literatura como muy valiosos para el estudio y clasificación de la vegetación a través de imágenes satelitales.

Tabla 2.1: Índices de vegetación calculados sobre una imagen Landsat-5 TM. ρ_r , ρ_g , ρ_b y ρ_{NIR} denotan los valores de reflectancia para las bandas del rojo (r), azul (b), verde (g) e infrarrojo cercano (NIR) respectivamente.

Índices de vegetación	Ecuación	Referencias
Modified Simple Ratio (MSR)	$\frac{\rho_{NIR} - 1}{\rho_r} \sqrt{\frac{\rho_{NIR}}{\rho_r} + 1}$	[38]
Green Chlorophyll Index (CI)	$\frac{\rho_{NIR}}{\rho_g} - 1$	[26]
Normalized Difference Vegetation Index (NDVI)	$\frac{\rho_{NIR} - \rho_r}{\rho_{NIR} + \rho_r}$	[77]
Green Normalized Difference Vegetation Index (GNDVI)	$\frac{\rho_{NIR} - \rho_g}{\rho_{NIR} + \rho_g}$	[76]
Enhanced Vegetation Index (EVI)	$2.5 \left[\frac{\rho_{NIR} - \rho_r}{1 + \rho_{NIR} + 6\rho_r - 7.5(\rho_b)} \right]$	[32]
Atmospherically Resistant Vegetation Index (SARVI)	$\frac{(1+L)(\rho_{NIR} - \rho_{rb})}{(\rho_{NIR} + R_{rb} + L)}$	[41]
Renormalized Difference Vegetation Index (RDVI)	$\frac{\rho_{NIR} - \rho_r}{\sqrt{\rho_{NIR} + \rho_r}}$	[38]
Soil-Adjusted Vegetation Index (SAVI)	$\frac{(1+L)(\rho_{NIR} - \rho_r)}{\rho_{NIR} + \rho_r + L}$	[39]
Modified SAVI (MSAVI)	$\frac{1}{2} \left[(2\rho_{NIR} + 1 - \sqrt{(2\rho_{NIR} + 1)^2 - 8(\rho_{NIR} - \rho_r)}) \right]$	[9]
Wide- Dynamic Range Vegetation Index (WDRVI)	$\frac{\alpha \times \rho_{NIR} - \rho_r}{\alpha \times \rho_{NIR} + \rho_r}$	[25]

En las expresiones que define cada índice de la Tabla 2.1, ρ denota reflectancia. De acuerdo al Instituto de Investigación de sistemas del Medio Ambiente (ESRI, sus siglas en inglés), la reflectancia permite ajustar los valores del brillo de imágenes (Números Digitales) de algunos sensores de satélite, entre los que se encuentran Landsat, IKONOS, y QuickBird. El cálculo de la reflectancia está basado en la elevación del sol, la fecha de adquisición de las imágenes y las propiedades del sensor. Entre los algoritmos que permiten calcular la reflectancia se encuentran los enunciados e implementados en [12, 35, 36, 66, 83].

En la Figura 2.7, se ilustra el cálculo del índice MSR. Las bandas que determinan este índice son la banda NIR (ρ_{NIR}) y la banda roja (ρ_r). La imagen fue capturada por el satélite Lansat 8 y corresponde a la zona del sur de Jalisco, México (latitud $19^\circ 46' 29.8'' N$, longitud $103^\circ 35' 29.4'' W$). Como resultado se obtiene una imagen en la que las regiones más brillantes corresponden a la vegetación.

Los índices de vegetación han sido ampliamente utilizados para examinar cosechas y para evaluar la influencia del fondo del suelo. En [61] se exploran varios índices de vegetación entre los que se encuentran (NDVI, GNDVI, RDVI, EVI, SARVI, SAVI, MSAVI, MSR, CI y WDRVI), sobre imágenes del satélite ASTER, combinándose esta información por la técnica conocida como árbol de decisión [68] para la clasificación de 13 tipos de cultivos (alfalfa, al-

$$\sqrt{\frac{\rho_{NIR} - 1}{\rho_r} \cdot \frac{\rho_{NIR} + 1}{\rho_r}} = \text{MSR}$$

Figura 2.7: Efectos de aplicar el índice de vegetación ($MSR = \frac{\rho_{NIR} - 1}{\sqrt{\rho_r(\rho_{NIR} + 1)}}$) sobre las bandas satelitales roja (ρ_r) e infrarrojo cercano (ρ_{NIR}), del sensor Landsat 8.

mendra, nogal, viña, maíz, arroz, cártamo, girasol, tomate, prado, avena, centeno y trigo). En [61], los autores señalan que el análisis utilizando la clasificación básica basada en el píxel, conduce a una identificación errónea de algunos cultivos, esto debido a la similaridad espectral y la variabilidad de los patrones de los cultivos. Para solucionar el problema se utilizaron técnicas de análisis de imágenes basada en objetos, en la cual se incorporan características espectrales basadas en IV, características texturales y características jerárquicas. Además, se tomaron diferentes muestras en 3 diferentes estaciones del año. Este algoritmo resulta muy adecuado para problemas donde se necesite identificar diferentes tipos de cultivos en diferentes etapas fenológicas y campos de cultivos temporales. Los resultados obtenidos en cuanto a sus medidas de validación fueron: para la precisión global 79 % y un índice de Kappa de 0.75.

En [77], NDVI [76], GNDVI [3] y NDRE [5, 81], son explorados junto a máquinas de soporte vectorial [78] para el estudio de maíz, algodón, suelo húmedo, suelo mojado, suelo seco y agua en Turquía a través de imágenes del satélite RapidEye². Estas imágenes, tienen una resolución espectral de 5 bandas y una resolución espacial de 5 metros.

Los índices de vegetación mencionados, son muy utilizados ya que todos incorporan a la banda del infrarrojo cercano. En [77], se estudiaron 4 espacios de características. El primer espacio de características está formado por los tres índices de vegetación: NDVI, GNDVI y NDRE, los demás espacios de características están formados solo por dos índices. Se realizaron diferentes combinaciones de los espacios generados por los índices y se llegó a la conclusión de que el índice de vegetación NDRE fue el que dio la mayor contribución al clasificador de

²El satélite RapidEye tiene una gran demanda para aplicaciones agrícolas y forestales por la presencia de la banda llamada "rojo límite" (red-edge, en inglés), que se encuentra en los límites entre la banda roja y la banda del infrarrojo cercano, esta banda tiene la característica de ser muy sensible a los cambios en los contenidos de la clorofila y puede ayudar al monitoreo de la sanidad vegetal, identificación de especies vegetales y cultivos.

máquinas de soporte vectorial y que el espacio compuesto por tres índices espectrales condujo al mejor rendimiento en la clasificación, alcanzándose una precisión global de 87.46 % y un índice Kappa de 85.66 %.

La propuesta en [79] toma en consideración los datos del sensor ASTER y estudia diferentes espacios de características para clasificar la vegetación de caña de azúcar en Uttarkhand, India. Los espacios analizados son: el espacio de características determinado por las tres bandas localizadas en la región VNIR (visible e infrarrojo cercano) del espectro; y una combinación entre las bandas VNIR y la transformación de la banda NDVI. El clasificador de máxima verosimilitud fue el clasificador seleccionado. Con la combinación entre las bandas VNIR y NDVI se logró el mejor rendimiento con la precisión global del 76.2 % y el valor Kappa de 0.74. Las firmas espectrales similares para todas las clases de vegetación de caña de azúcar fue un problema para los autores en [79].

2.3. Segmentación probabilística

La segmentación es la fase del procesamiento digital de la imagen, en la que ésta es dividida en partes acorde a cierto criterio. Por lo dicho anteriormente, podemos decir que la segmentación es un problema de agrupamiento y por tanto de clasificación. De ahí que los algoritmos como k-medias, c-medias difusas e ISODATA [2, 34] hayan sido exitosamente usados, sin embargo, estos métodos sólo incluyen los datos de cada pixel y omiten la interacción espacial, con la cual se tiene información adicional muy útil para resolver la segmentación como problema mal planteado [64]. Una vía eficiente para segmentar, teniendo en cuenta las observaciones en cada pixel y su información de contexto, es la estimación Bayesiana junto a modelos de campo aleatorio Markoviano (CAM) [24, 49, 51, 53, 64]. Con este enfoque se calcula un campo de etiquetas (la clasificación), asumiéndose que la dependencia de probabilidades que determinan la etiqueta en un pixel, tiene lugar solo con respecto a los pixeles de su vecindad. El modelo GMMF [52], Gauss-Markov Measure Field por sus siglas en inglés es un ejemplo del enfoque descrito. La expresión que determina el funcional para el modelo GMMF se indica en la Ecuación (2.1).

$$U(p) = \sum_{r \in \mathcal{L}} \|p(r) - \hat{v}(r)\|^2 + \lambda \sum_{\langle r,s \rangle} \|p(r) - p(s)\|^2 \quad (2.1)$$

Donde $\hat{v}(r)$, representa el vector de verosimilitudes normalizado en el pixel r .

De acuerdo al modelo GMMF, las distribuciones empíricas marginales $p(r)$, deben de ser si-

milares al vector de verosimilitudes $\hat{v}(r)$ de las observaciones en el sitio r y cambian suavemente en el *lattice* \mathcal{L} . El grado de suavizado depende del parámetro λ .

El campo $p(r)$ se construye a través del modelo de Gauss-Saidel, ver Ecuación (2.2).

$$p_k(r) = \frac{\hat{v}_k(r) + \lambda \sum_{s \in \mathcal{N}_r} p_k(s)}{1 + \lambda |\mathcal{N}_r|}, \quad (2.2)$$

Donde λ es el parámetro de suavizado, r indica el pixel en la imagen, s denota la vecindad del pixel r considerando conectividad 4. Una vez que el campo vectorial p se calcula, el campo óptimo de etiqueta $s(r)$ se calcula como la media para cada vector $p(r)$, como se muestra en la Ecuación (2.3).

$$s(r) = \arg \max_{k \in \{1, 2, \dots, K\}} p_k(r). \quad (2.3)$$

Muchas son los problemas de clasificación que a través de la segmentación con GMMF han tenido soluciones favorables [2, 4, 51, 54, 55, 64, 74]. Este enfoque junto a los trabajos revisados [8, 29, 42, 44, 47, 59–61, 72, 77, 80] explican el curso final de esta tesis doctoral y justifican la propuesta que en la sección 3 se describe.

Capítulo 3

Propuesta de tesis: Un algoritmo supervisado para el estudio de cultivos a través de firmas espectrales en imágenes de satélite

Existe una gran similitud entre las firmas espectrales de diferentes cultivos y en general entre diferentes tipos de elementos de la cobertura terrestre (ver Figura 1.4) [17, 61]. Por otro lado, al censar la escena la resolución del satélite no siempre permite que en un píxel quede plasmada la información de un solo tipo de cobertura. Todo esto hace pesado el proceso de clasificación. Los trabajos presentados en [8, 42, 61, 80] indican que considerar sólo información puntual no es suficiente, y que es necesario incluir información contextual para aumentar la precisión de la clasificación. Otro aspecto que aumenta la complejidad del problema de clasificación es la selección de características. En los trabajos discutidos [44, 47, 61, 72, 77] se utilizan diferentes espacios de características: intensidades del nivel de gris, media y varianza local, índices de vegetación, entropía, textura y características obtenidas por análisis de componentes principales. En todos los casos quedó sin resolver la manera de escoger el espacio de característica apropiado o la combinación de varios de ellos para aumentar la precisión de la clasificación. Hay que señalar además que la combinación de varios espacios mejora la clasificación, sin embargo, aumenta el costo computacional. La selección de un espacio de características apropiado o la combinación de varios de ellos es entonces un elemento crucial en esta área de investigación. La complejidad del problema justifica también la necesidad de incluir información a priori para guiar el trabajo del clasificador.

Considerando lo expresado anteriormente, en el 2014 propusimos un algoritmo supervisado basado en histogramas [59]. La propuesta consta de dos fases: en la primera fase se constru-

yen histogramas por cada clase de cultivo a estudiar, usando la información de un experto; en la segunda fase se realiza la segmentación a través de GMMF [52] tomando como estimación de la verosimilitud los histogramas contruidos en la primera fase. En esta propuesta se usó un solo espacio de características definido por las bandas espectrales verde, roja e infrarroja; para detalles del método consultar el artículo del Apéndice D. A pesar de que el trabajo experimental demostró un buen desempeño del algoritmo con respecto a lo reportado, siguieron sin responder las preguntas respecto al número de espacios a considerar y cómo hacerlo para lograr una mejor discriminación de las clases de cultivo con firmas espectrales similares. En este manuscrito se describe un algoritmo de clasificación en el que se combinan características de diferentes fuentes de información sin aumentar el costo computacional. Al igual que [59] el algoritmo propuesto utiliza un enfoque probabilístico de segmentación a través de GMMF [52] (ver Sección 2.3). A diferencia de [59] se propone una modificación de GMMF que permite combinar más de una verosimilitud. La verosimilitud considera información proveniente de varias fuentes de información (**espacios de características**) y es construida como una combinación lineal de fuentes que se consideran independientes. Los pesos de la combinación lineal están definidos por una función que depende de la entropía de las distribuciones de probabilidades, provenientes de cada fuente. El algoritmo propuesto se utiliza para la clasificación de diferentes tipos de cultivos representados en imágenes satelitales. En la Figura 3.1 se muestra la representación gráfica de las fases de la propuesta y en secciones siguientes se explica con detalles cada fase del algoritmo propuesto.

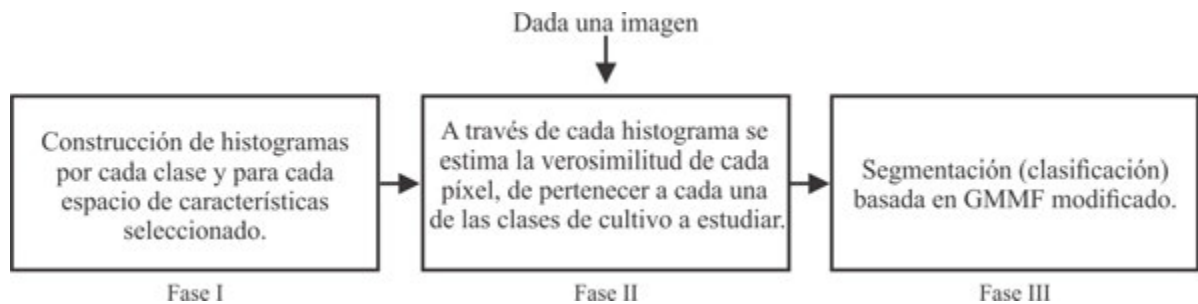


Figura 3.1: Fases del algoritmo.

3.1. Construcción de histogramas

A partir de la información dada a priori por un experto, se obtienen histogramas con los cuales podemos conocer la probabilidad que tiene cada pixel en pertenecer a diferentes clases. En

esta investigación se construyen histogramas por cada clase a analizar y para diferentes espacios de características tridimensionales o fuente de información.

Los espacios de características estudiados son:

1. Espacio dado por la información de las bandas espectrales infrarrojo, rojo y verde [59].
2. Espacio definido por las tres componentes principales obtenidas al aplicar PCA [37] sobre índices de vegetación [60].
3. Espacio compuesto por las tres componentes principales al aplicar PCA [37] sobre las bandas espectrales relativas al azul, al verde, al rojo, al infrarrojo cercano, al infrarrojo medio y al infrarrojo lejano.

Sea h_k^{3D} , el histograma tridimensional construido para la clase k , en cierto espacio tridimensional de características, Ecuación (3.1)

$$h_k^{3D}(x) = \frac{n_k(x)}{T_k}, \quad (3.1)$$

El voxel x tiene coordenadas x_1, x_2, x_3 y están definidas según cada componente del espacio de características seleccionado, $n_k(x)$ denota el número de veces en que el voxel x aparece en la clase k . T_k representa el número de voxeles en la clase k .

En la Figura 3.2, se explica gráficamente cómo se construyen los histogramas tridimensionales.

Luego de construido el histograma, éste se suaviza y normaliza.

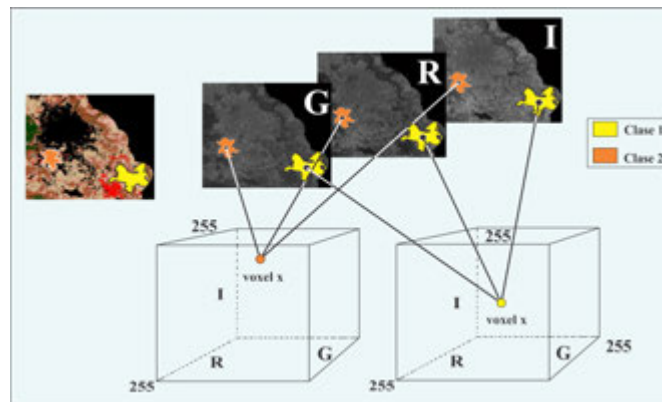


Figura 3.2: Representación gráfica de la construcción de histogramas en el espacio de características formado por las bandas verde (G), roja (R) e infrarroja (I) para dos clases. Cada cubo está asociado al histograma de una clase.

3.1.1. Suavizado del histograma

La información dada a priori por un experto, da lugar a histogramas en los que no todos los voxeles x del espacio tridimensional tienen información. Con el propósito de tener información en todo el espacio, se aplica un proceso de difusión el cual se muestra en la Ecuación (3.2).

$$h_k^{3D}(x) = \frac{\sum_{y \in \mathcal{V}_x} h_k^{3D}(y)}{|\mathcal{V}_x|}, \quad (3.2)$$

Donde \mathcal{V}_x representa la vecindad del voxel x . Se consideran vecinos a distancia 1 es decir, $\|x - y\|_1 = 1$ y $|\mathcal{V}_x|$ es la cardinalidad de la vecindad correspondiente. En (3.2) y denota los vecinos del voxel x . Como resultado del proceso de difusión, el histograma h_k^{3D} , $k = 1, 2, 3, \dots, \mathcal{K}$ se suaviza y por cada voxel x , se tiene un vector donde su k -ésima componente está definida por $h_k^{3D}(x)$.

3.1.2. Normalización del histograma

Una vez que se obtiene el histograma suavizado, se procede a la normalización del mismo, de modo que ahora en cada voxel se encuentre una distribución de probabilidad discreta, y así tener una interpretación probabilística (ver Ecuación (3.3)).

$$h_k^{3D}(\mathbf{x})_{\mathcal{V}_k}(x) = \frac{h_k^{3D}(x)}{t(x)}, \quad (3.3)$$

Donde $h_k^{3D}(\mathbf{x})_{\mathcal{V}_k}(x)$ es el k -ésimo componente normalizado en el voxel x , $t(x) = \sum_{k=1}^{\mathcal{K}} h_k^{3D}(x)$, es el factor de normalización aplicado, y \mathcal{K} es el número de clases a estudiar.

Luego de la normalización, se tiene que:

$$\sum \mathbf{h}_k^{3D}(x_1, x_2, x_3) = 1, \forall k, k = 1, 2, 3, \dots, \mathcal{K} \quad (3.4)$$

La fase del cálculo de histogramas permite, como se verá en las secciones 3.2 y 3.4, una estimación de la verosimilitud, aspecto muy importante para la fase de segmentación con GMMF [52].

3.2. Cálculo de verosimilitudes

Para el cálculo de verosimilitudes se hace la siguiente propuesta:

1. Dada una imagen, esta se representa en cada uno de los espacios seleccionados (ver Sección 3.1).
2. Para calcular la verosimilitud de que un píxel $r \in \mathcal{L}$ pertenezca a una clase k , donde \mathcal{L} es el enrejado de toda la imagen, primero se obtiene el vector de características, $(x_1(r), x_2(r), x_3(r))$, correspondiente al espacio de representación y después se asigna la verosimilitud según la Ecuación (3.5).

$$v_k(r) \propto h(x_1(r), x_2(r), x_3(r); k) \quad (3.5)$$

De modo que se cumple que: $\sum_{k \in \mathcal{K}} v_k(r) = 1$.

El paso 2 se realiza para cada una de las fuentes de información o espacios de características considerados (ver Sección 3.1).

3.3. Segmentación probabilística mediante selección de fuentes por mínima entropía

En la Sección 3.2 se explicó cómo se calcula el grado de pertenencia de un píxel r , a una clase k , considerando diferentes espacios de características. El reto ahora es el siguiente: ¿cómo combinar toda la información obtenida y construir un clasificador? La respuesta al reto es el modelo de segmentación probabilística que se propone; el mismo está basado en GMMF [52] y permite asignar a cada píxel de la imagen de estudio, una clase de cultivo. El modelo considera diferentes fuentes de información (espacios de características) y selecciona aquel que tenga menor entropía. La Ecuación (3.6) enuncia el modelo que se propone:

$$p^* = \arg \min_p \sum_{r \in \mathcal{L}} \sum_{k \in \mathcal{K}} \sum_{i=1}^{N_f} \omega_i(r) (p_k(r) - v_k^i(r))^2 + \lambda \sum_{s \in \mathcal{N}_r} (p_k(r) - p_k(s))^2 \quad (3.6)$$

Donde $v^i(r)$ es la probabilidad que proviene de i -ésima fuente, $\lambda > 0$ es el parámetro de regularización, \mathcal{N}_r representa al conjunto de píxeles vecinos del píxel r , N_f indica el número de fuentes. La función de peso $\omega_i(r)$ está dada por (3.7):

$$\omega_i(r) = \delta(i - i^*) \quad (3.7)$$

donde

$$i^* = \arg \min_i \mathcal{E}(v^i(r)) \quad (3.8)$$

$i \in \{1, 2, \dots, N_f\}$ y $\mathcal{E}(\cdot)$ es una medida de entropía, como por ejemplo la entropía de Shanon [69]. En esta investigación se utilizó el índice de Giny, como medida de entropía, Ecuación (3.9) :

$$\mathcal{E}(f) = 1 - f^T f \quad (3.9)$$

f representa una distribución de probabilidades, por tanto $1^T f = 1$, $f \succeq 0$. El problema de optimización definido en (3.10) se resuelve según el método de Gauss-Siedel , es decir:

$$p_k(r) = \frac{\sum_{i=1}^{N_f} \omega_i(r) v_k^i(r) + \lambda \sum_{s \in \mathcal{N}_r} p_k(s)}{1 + \lambda |\mathcal{N}_r|} \quad (3.10)$$

Acorde a la Ecuación (3.7) la función de peso selecciona sólo una verosimilitud y es aquella que corresponde a la fuente con menor entropía. Finalmente la segmentación se logra por la estrategia “El ganador se lo lleva todo”.

El vector p^* (Ecuación (3.6)) se calcula según:

$$s(r) = \arg \max_{k \in \mathcal{K}} p_k(r), \quad \forall r \in \mathcal{L} \quad (3.11)$$

3.4. Segmentación probabilística mediante fusión de fuentes

En la Sección 3.3 se explica la propuesta del modelo de segmentación en la que la asignación de una clase a un píxel r se realiza teniendo en cuenta la fuente de información con menor entropía (Ecuación (3.7)). En esta Sección se explica como generalizar la propuesta anterior.

Dada la expresión en (3.6), o sea:

$$p^* = \arg \min_p \sum_{r \in \mathcal{L}} \sum_{k \in \mathcal{K}} \sum_{i=1}^{N_f} \omega_i(r) (p_k(r) - v_k^i(r))^2 + \lambda \sum_{s \in \mathcal{N}_r} (p_k(r) - p_k(s))^2$$

ahora los pesos $\omega_i(r)$ se calculan según (3.12) y (3.13)

\mathcal{N}_f representa el número de fuentes de información y \mathcal{N}_r representa al conjunto de píxeles vecinos del píxel r . La función de peso $\omega_i(r)$ se calcula según (3.12):

$$\omega_i(r) = \frac{\omega_i^s(r)}{\sum_{i=1}^{N_f} \omega_i^s(r)} \quad (3.12)$$

$\omega_i^s(r)$ se define según (3.13):

$$\omega_i^s(r) = \frac{\mu}{\mu + (\mathcal{E}_i)^2} \quad (3.13)$$

$\mathcal{E}(\cdot)$ es una función de contraste que permite medir el grado de información contenido en la fuente o espacio de característica. Un ejemplo de función de contraste lo es la entropía y un caso particular para el cálculo de la misma fue definido según (3.9) en la Sección 3.3.

La solución del problema de optimización (3.6) conduce al esquema de Gauss-Seidel dado en (3.10), o sea:

$$p_k(r) = \frac{\sum_{i=1}^{N_f} \omega_i(r) v_k^i(r) + \lambda \sum_{s \in \mathcal{N}_r} p_k(s)}{1 + \lambda |\mathcal{N}_r|}$$

El término de verosimilitud, se expresa como una combinación lineal de verosimilitudes provenientes de fuentes diferentes, asumiéndose la independencia entre ellas. Lo explicado en esta Sección es una generalización de lo propuesto en la Sección 3.3.

La segmentación final se obtiene según Ecuación (3.11) presentada en la Sección 3.3.

En la Sección 4 se evalúa el comportamiento de la propuesta.

Capítulo 4

Experimentos y discusión

La identificación de los cultivos, es de gran interés para los análisis estadísticos del crecimiento y decrecimiento de las áreas urbanas con relación al crecimiento de la población; así como para el establecimiento de políticas de uso y protección del suelo. Este capítulo está dedicado a especificar la experimentación realizada para la detección de 5 tipos de cultivo en zonas del estado de Jalisco, usando los resultados de la investigación de esta tesis doctoral. En este capítulo se describe el sensor satelital que generó las imágenes utilizadas, el área de cultivos estudiada y la metodología que orientó el trabajo experimental incluyendo la discusión de todos los experimentos realizados para evaluar el comportamiento de la propuesta al clasificar diferentes tipos de cultivos. A partir del trabajo experimental, se selecciona el algoritmo supervisado apropiado para la identificación de cultivos y se hace una comparación de éste con otros métodos reportados en la literatura para el estudio de cultivos, a través de imágenes satelitales.

4.1. Características del satélite usado

La información usada durante esta investigación proviene del satélite Landsat-5 TM [21]. Este satélite genera imágenes compuestas por 7 bandas espectrales. Las características de cada una aparecen en la Tabla 4.1. El satélite Landsat-5 TM, tarda 16 días para recorrer completamente la Tierra y las imágenes que obtiene, tienen una resolución en color de 2^8 bits por pixel.

Observe que todas las bandas tienen una resolución espacial de 30 *metros*, excepto la banda TM6 (infrarrojo térmico) con 120 *metros* (Tabla 4.1). Debido a esto en nuestra investigación sólo se consideraron las bandas TM1, TM2, TM3, TM4, TM5 y TM7. La resolución espacial de 120 *metros* no aporta información clara a la solución del problema sobre la detección de cultivos

Tabla 4.1: Bandas espectrales del sensor Landsat-5 Thematic Mapper (TM).

Banda Thematic Mapper (TM)	Longitud de onda (μm)	Resolución espacial	Características
TM1	0.45 a 0.52	30	Visible - azul
TM2	0.52 a 0.60	30	Visible - verde
TM3	0.63 a 0.69	30	Visible - rojo
TM4	0.76 a 0.90	30	Infrarrojo cercano
TM5	1.55 a 1.75	30	Infrarrojo medio (SWIR-1)
TM6	10.4 a 12.50	120	Infrarrojo térmico
TM7	2.08 a 2.35	30	Infrarrojo lejano (SWIR-2)

que se investigó.

4.2. Área de estudio

El área para el estudio de cultivos está localizada en el oeste de México y las coordenadas son: latitud $20^{\circ}39'58''$ norte, longitud $103^{\circ}21'7''$ oeste. La altitud sobre el nivel del mar es de 1550 *metros*. Esta área geográfica es conocida como Valle de Atemajac [62], ver Figura 4.1. En esta región se pueden encontrar cultivos típicos de la zona como son: agricultura de riego, agricultura de temporal, bosque, matorral, pastizal, áreas verdes, entre otros. La imagen satelital que se observa en la Figura 4.1, a la derecha, fue capturada en el 2011 y suministrada por el Instituto de Información Territorial del Estado de Jalisco (IITEJ), para esta investigación.




Figura 4.1: Imagen satelital Landsat-5 TM, ubicada en el estado de Jalisco, México.

4.3. Metodología del trabajo experimental

La metodología del trabajo experimental consta de tres fases (ver Figura 4.2):

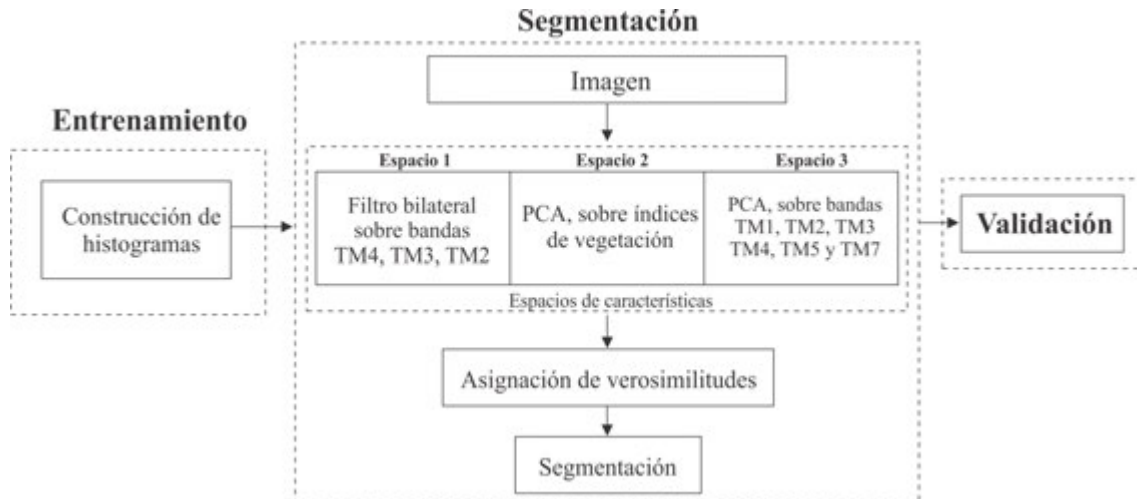


Figura 4.2: Fases de la metodología del algoritmo propuesto.

1. **Fase de Entrenamiento:** durante su desarrollo se construyen histogramas tridimensionales asociados a tres espacios de características derivados de imágenes del satélite Landsat-5 TM. Los espacios de características son:
 - a) **Espacio 1:** espacio de características dado por la información de las bandas espectrales infrarrojo (TM4), rojo (TM3) y verde (TM2). La selección de estas bandas está justificada por estudios previos que indican que éstas contienen información muy útil para el estudio de cultivos [59].
 - b) **Espacio 2:** espacio de características definido por las tres componentes principales obtenidas al aplicar PCA [37] sobre índices de vegetación. Como se indicó en la Sección 2.2, los índices de vegetación permiten realzar la información de la vegetación en imágenes satelitales. En este trabajo se consideraron 10 índices de vegetación (ver Tabla (2.1)), y sobre diferentes agrupamientos de los mismos se aplicó PCA [37], con el objetivo de reducir dimensión y perder la menor cantidad de información acerca de la vegetación, dada por los índices calculados.
 - c) **Espacio 3:** espacio de características compuesto por las tres componentes principales, resultado de aplicar PCA [37] sobre las bandas espectrales TM1, TM2, TM3, TM4, TM5 y TM7. Aunque en trabajos previos [59], se indica que las bandas TM2, TM3 y TM4 reflejan con mayor precisión coberturas terrestres relativas a la vegetación, en esta investigación se considera información de otras bandas con el objetivo de buscar más características de las zonas de cultivo que se estudian y que seguramente se reflejan en otras zonas del espectro.

Para la construcción de histogramas (**Fase de Entrenamiento**) fue utilizada la imagen que aparece en la parte derecha de la Figura 4.3 (ground truth). Esta imagen es un recorte de la escena satelital a la derecha de la Figura 4.1. Su contenido corresponde a Guadalajara y Zapopán. Fue segmentada manualmente por expertos del IITEJ y en ella aparecen señaladas 5 zonas de cultivos con colores diferentes. Cada zona identifica la clase a estudiar. Con la información de los píxeles correspondientes a cada zona se construyen histogramas por cada clase de cultivo y por cada uno de los espacios de características mencionados anteriormente, ver Figura 3.2. En la Figura 4.4, se ilustra la respuesta espectral de cada uno de los cultivos a detectar.




Figura 4.3: Imagen izquierda: área de estudio (imagen del satélite Landsat-5 TM). Imagen derecha, ground truth.

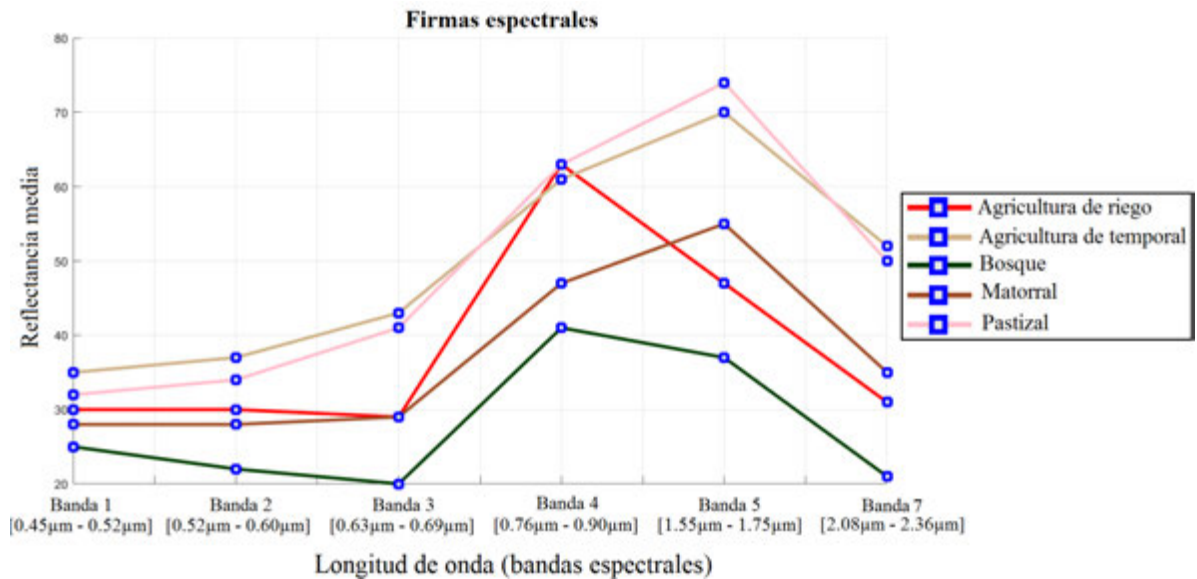


Figura 4.4: Firmas espectrales de los 5 cultivos estudiados, sobre una imagen Landsat-5 TM.

La Figura 4.4 evidencia la similitud que existe entre las firmas espectrales de las imágenes a estudiar. Esto es un obstáculo que la propuesta de esta tesis afronta durante el proceso de clasificación.

Los histogramas construidos por cada espacio de características y cada clase son procesados como aparece en la Sección 3.1. Los histogramas construidos para cada espacio se denotan como:

$$h_{B_{234}}(x_1(r), x_2(r), x_3(r)) \quad (4.1)$$

$$h_{PCA_{ind}}(x_1(r), x_2(r), x_3(r)) \quad (4.2)$$

$$h_{PCA_{Bs}}(x_1(r), x_2(r), x_3(r)) \quad (4.3)$$

$h_{B_{234}}(x_1(r), x_2(r), x_3(r))$, $h_{PCA_{ind}}(x_1(r), x_2(r), x_3(r))$ y $h_{PCA_{Bs}}(x_1(r), x_2(r), x_3(r))$ representando respectivamente los histogramas por clases para los **Espacios 1, 2 y 3**.

2. **Fase de Segmentación:** Dada una imagen se procede como a continuación:

- La imagen se representa en el **Espacio 1**, en el **Espacio 2** y en el **Espacio 3**. En la Figura 4.5, se destaca esta parte de la metodología.

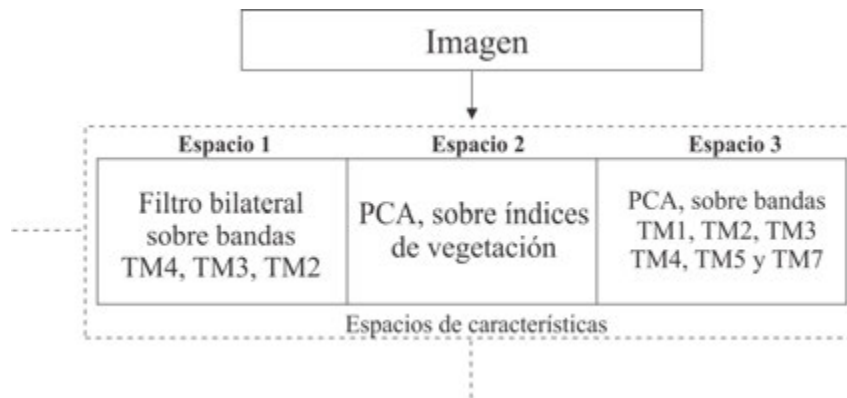


Figura 4.5: Espacios de características en los que representa la imagen a estudiar.

Observe que al considerar el **Espacio 1**, se aplica un proceso de mejoramiento mediante el filtro propuesto en [75]. El mismo se conoce como filtro bilateral, utiliza una función Gaussiana y suaviza regiones teniendo en cuenta similitud de niveles de grises o colores

y grado de cercanía espacial entre píxeles. En el proceso de suavizado se respetan los bordes. El filtro bilateral es local y no iterativo. Su aplicación conlleva a distinguir mejor zonas homogéneas y se atenúa el ruido producto del sensor. Los parámetros de este filtro son el tamaño de la ventana, $winsize$, y el ancho de la función gaussiana, σ . Con estos parámetros se define la cercanía y nivel de suavizado o promediación. Los valores usados durante la experimentación fueron: $winsize=3 \times 3$ y $\sigma = 1$. El filtrado se aplica sobre cada una de las bandas que se consideran en el espacio. En la Figura 4.6 se observa un ejemplo de este preprocesamiento.




Figura 4.6: Ejemplo de aplicación del filtro bilateral a una banda espectral del satélite Landsat-5 TM. (a) Imagen original (banda TM4). (b) Imagen aplicando el filtro bilateral a la banda TM4.

- Asignación de verosimilitudes según cada espacio de características: asignar la verosimilitud que tiene cada píxel, $v_k(r)$, en pertenecer a cada clase k , según el espacio de característica, Expresiones 4.1, 4.2 y 4.3:

$$v_k^1(r) \propto h_{B_{234}}(x_1(r), x_2(r), x_3(r)) \quad (4.4)$$

$$v_k^2(r) \propto h_{PCA_{ind}}(x_1(r), x_2(r), x_3(r)) \quad (4.5)$$

$$v_k^3(r) \propto h_{PCA_{Bs}}(x_1(r), x_2(r), x_3(r)) \quad (4.6)$$

Posteriormente se realizan diferentes combinaciones de fuentes según término $\sum_{i=1}^{N_f} \omega_i(r)v_k^i(r)$ del numerador de la Ecuación (2.2):

En la Figura 4.7, se ilustra el proceso de asignación de verosimilitudes considerando los **Espacios 1, 2 y 3**.




Figura 4.7: Asignación de verosimilitudes considerando los Espacios 1, 2 y 3.

Para nuestro trabajo experimental el máximo número de fuentes de información, N_f , es 3. Para el cálculo de los coeficientes $\omega_i(r)$ según la Sección 3.4, se utilizaron valores de $\mu = 0.001, 0.01, 0.1$ y 1.

Una vez calculada la combinación de verosimilitudes procedentes de diferentes fuentes, según término $\sum_{i=1}^{N_f} \omega_i(r)v_k^i(r)$, y los criterios dados en las Secciones 3.3 y 3.4 para el cálculo de pesos en la combinación lineal, se procede a la segmentación según GMMF [52] modificado, .

3. **Fase de Validación:** Se realizaron 15 experimentos. Para la evaluación de cada uno de los experimentos de segmentación se realiza un proceso de validación a través del cálculo de la precisión global [50] y el índice Kappa [11]. Para detalles del cálculo de este coeficiente consulte el Apéndice B. Como referencia para el proceso de validación se utiliza la imagen *ground truth* (Figura 4.3, derecha), que fue elaborada por un experto. Al mostrar la validación numérica de cada Experimento, se utiliza una tabla en la que por cada columna se indica la precisión de la clasificación por cada clase. La fila en la que los valores aparecen resaltados con color negro, corresponde al mejor resultado del experimento. Finalmente se incluye el índice de precisión global y el índice Kappa.

La **Fase de Entrenamiento** se ejecuta una sola vez para obtener la información a priori, que es necesaria para el algoritmo supervisado que se propone (Sección 3). La **Fase de Segmentación** se aplica sobre cada imagen a estudiar con los mismos tipos de cultivos que aprendió el algoritmo

en la **Fase de Entrenamiento**. La **Fase de Validación** se ejecuta para cada imagen segmentada considerando como referencia segmentaciones manuales o información de campo dada por un experto (ground truth).

En los 15 experimentos realizados se consideraron combinaciones entre los espacios **Espacio 1, 2 y 3**. Uno de los experimentos sólo considera un espacio de características [59].

Toda la codificación fue realizada en MATLAB 2012B, con licencia 04579-06243-56848-09969. Los experimentos se realizaron en un equipo de cómputo, con procesador Core i5-2400 a 3.10 GHz., 4 GB de RAM y 500 GB de Disco Duro.

4.4. Experimentos y discusión

Esta Sección está dedicada a describir y discutir los 15 experimentos realizados. En la Sección 4.3 se explicó que como parte de la metodología de la experimentación para el algoritmo supervisado que se propone, se tiene una **Fase de Entrenamiento**. Como resultado de la **Fase de Entrenamiento** se obtienen histogramas por cada clase de cultivo a analizar y por cada espacio de características: $h_{B_{234}}(x_1(r), x_2(r), x_3(r))$, $h_{PCA_{Ind}}(x_1(r), x_2(r), x_3(r))$ y $h_{PCA_{Bs}}(x_1(r), x_2(r), x_3(r))$.

4.4.1. Experimento 1: Segmentación bajo el Espacio 1

En este Experimento la imagen de estudio, Figura 4.8 (a), es representada considerando las bandas TM2 (verde), TM3 (roja) y TM4 (infrarroja), Figura 4.8 (b). Posteriormente es filtrada usando un filtro bilateral [75] (ver Sección 2). El filtro se aplica sobre cada banda espectral. Los resultados del filtro aparecen en la Figura 4.8 (c). Los parámetros utilizados fueron $winsize = 3 \times 3$ y $\sigma = 1$.

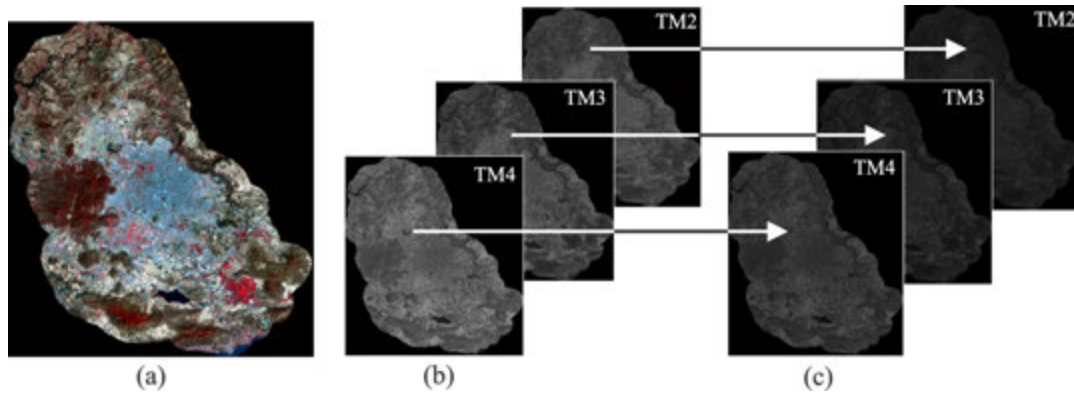


Figura 4.8: (a) Imagen de estudio, (b) Bandas TM2, TM3 y TM4. (c) Bandas TM2, TM3 y TM4, luego de aplicar el filtro bilateral.

Después del filtrado se realiza la asignación de verosimilitudes correspondientes al **Espacio 1**, $v_k^1(r)$, Ecuación (4.4). En la Figura 4.7 aparece un ejemplo que ilustra este proceso.

La imagen resultado del proceso de segmentación por GMMF aparece en la Figura 4.9.

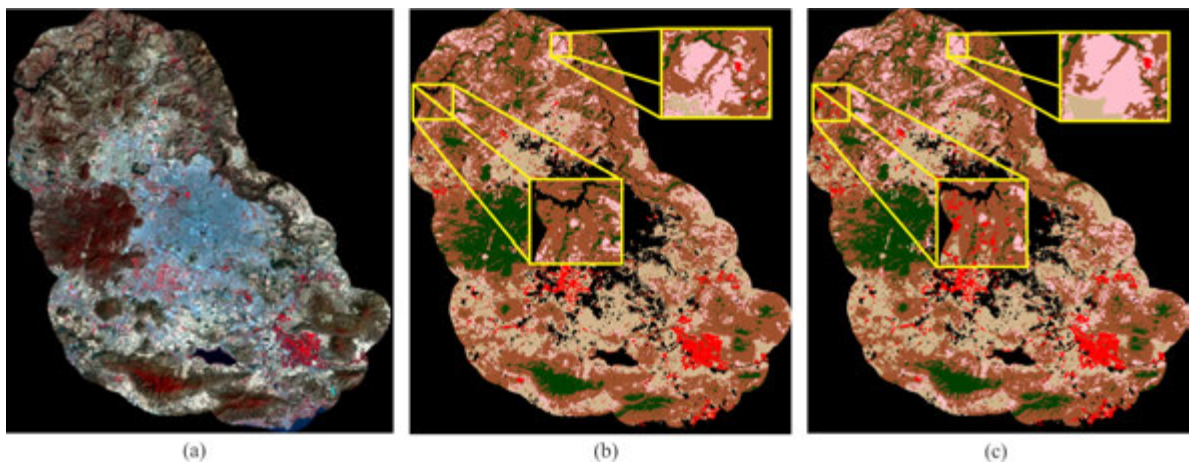


Figura 4.9: (a) Imagen de estudio. (b) Resultado de la segmentación del Experimento 1. (c) Ground truth.

En la Figura 4.9 (b), se puede observar que las zonas clasificadas como clase C4 (color café oscuro) invaden zonas correspondientes a las clases C1 (color rojo) y C5 (color rosa) acorde a la segmentación manual representada en la Figura 4.9 (c). Los resultados de la validación numérica del Experimento 1 aparecen en la Tabla 4.2.

Tabla 4.2: Validación de la segmentación en el Experimento 1.

Experimento	C1	C2	C3	C4	C5	Precisión global	Kappa
1	0.73	0.83	0.83	0.91	0.55	0.9109	0.8707

Los resultados numéricos de la Tabla 4.2 se corresponden con los representados en la Figura 4.9. Observe que las clases C1 y C5 obtuvieron los menores valores de precisión. En este Experimento no se combinaron diferentes espacios de características y se procedió como en [59].

4.4.2. Experimento 2: Segmentación bajo el Espacio 1 y el Espacio 2. El Espacio 2 considera PCA sobre 10 índices de vegetación. Selección de pesos por mínima entropía

La imagen de estudio es representada en el **Espacio 1** (ver Subsección 4.4.1) y en el **Espacio 2**. Para el caso del **Espacio 2** se consideran las tres primeras componentes principales obtenidas luego de aplicar PCA sobre los 10 índices de vegetación presentados en la Tabla 2.1. En la Figura 4.10 se ilustra la representación de la imagen de estudio en los **Espacios 1 y 2**.




Figura 4.10: Representación de los Espacios de características usados en el Experimento 2. A la izquierda: imagen de estudio. Arriba, a la derecha, representación del Espacio 1, luego de aplicar el filtro bilateral. Abajo, a la derecha, representación del Espacio 2 considerando las tres primeras componentes principales de PCA sobre 10 índices de vegetación.

Después de la representación de la imagen en los **Espacios 1 y 2**, se realiza la asignación de verosimilitudes a cada pixel r , usando los valores $v_k^1(r)$ y $v_k^2(r)$ correspondiente a cada clase k , Ecuaciones (4.4) y (4.5). La Figura 4.7 muestra un ejemplo del proceso de asignación de verosimilitudes.

En este Experimento, las verosimilitudes se combinan usando el criterio de mínima entropía, Sección 3.3, Ecuación (3.7).

La Figura 4.11 muestra el resultado del proceso de segmentación. Podemos observar nuevamente confusión entre las clases C1, C4 y C5, acorde a la información del experto (ver Figura 4.11 (b) y (c)).

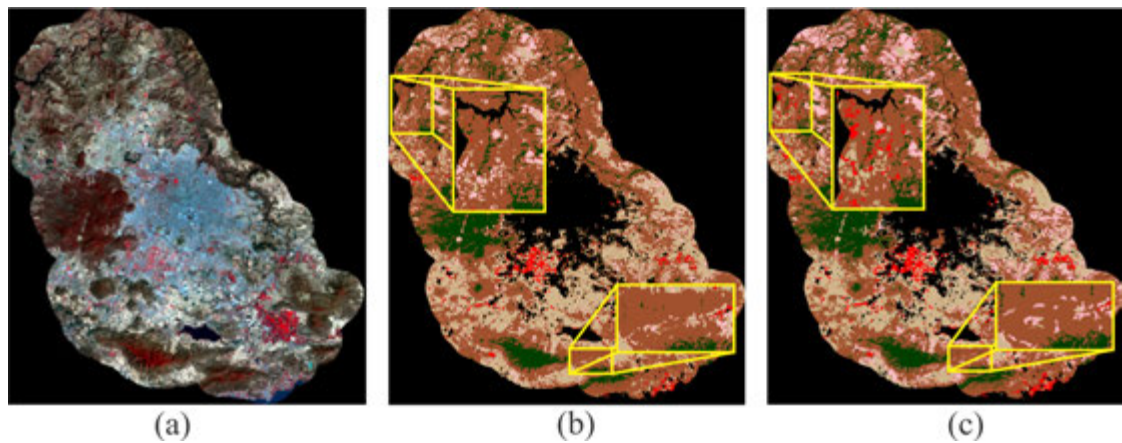


Figura 4.11: (a) Imagen de estudio. (b) Resultado de la segmentación del Experimento 2. (c) Ground truth.

La Tabla 4.3 muestra los resultados numéricos de la segmentación (**Validación**) del **Experimento 2**.

Tabla 4.3: Validación de la segmentación en el Experimento 2.

Experimento	C1	C2	C3	C4	C5	Precisión global	Kappa
2	0.72	0.84	0.87	0.92	0.53	0.9188	0.8819

4.4.3. Experimento 3: Segmentación bajo el Espacio 1 y Espacio 2. El Espacio 2 considera PCA sobre 6 índices de vegetación y mínima entropía para la selección de pesos

En este Experimento, la imagen de estudio (ver Figura 4.13 a la izquierda) es representada en el **Espacio 1** y en el **Espacio 2**. El **Espacio 2** considera las 3 primeras componentes principales sobre sólo 6 índices de vegetación, de los mostrados en la Tabla 2.1. Los índices seleccionados fueron: MSR, CI, NDVI, GNDVI, EVI y SARVI. La selección de estos índices está justificada porque el efecto de realce de la vegetación en estos índices es mayor en comparación con otros índices incluidos en la Tabla 2.1 (ver Figura 4.12).




Figura 4.12: Representación de los 10 índices de vegetación calculados.

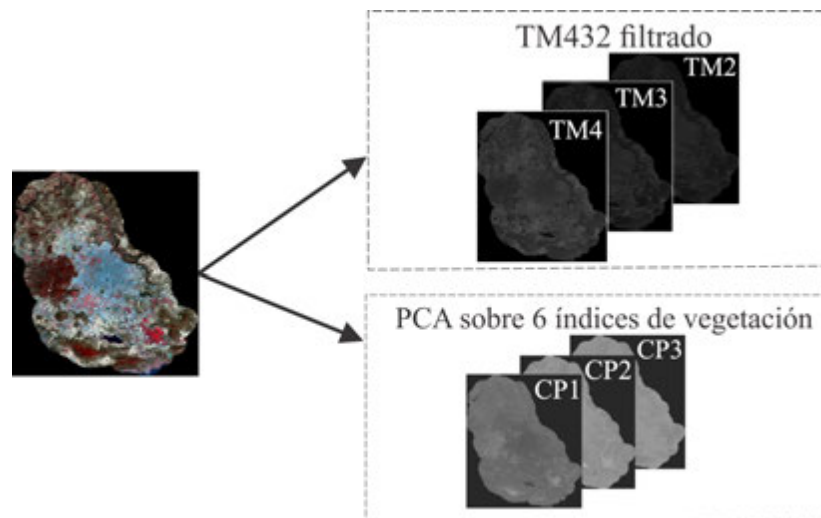


Figura 4.13: Representación de los Espacios de características usados en el Experimento 3. A la izquierda: imagen de estudio. Arriba, a la derecha, representación del Espacio 1, luego de aplicar el filtro bilateral. Abajo, a la derecha, representación del Espacio 2 considerando las tres primeras componentes principales de PCA sobre 6 índices de vegetación.

Después de representar la imagen de estudio en los **Espacios 1** y **2**, se realiza la asignación de verosimilitudes a cada pixel r usando los valores $v_k^1(r)$ y $v_k^2(r)$, correspondiente a cada clase

k , Ecuaciones (4.4) y (4.5). En la Figura 4.7 aparece un ejemplo que ilustra este proceso.

En el **Experimento 3**, se combinan las verosimilitudes usando el criterio de mínima entropía, Sección 3.3, Ecuación (3.7).

El resultado del proceso de segmentación de este Experimento se muestra en la Figura 4.14. Observe que la confusión entre las clases C1, C5 y C4 persiste.

Nótese que este Experimento se utilizaron los mismos espacios de características que el Experimento 4.4.2; la diferencia es que aquí se hizo PCA sobre los 6 índices que más realzan la información de vegetación. Los resultados de la validación numérica (Tabla 4.4) indican que el incluir la información de sólo 6 índices de vegetación, disminuye la precisión de la clasificación.

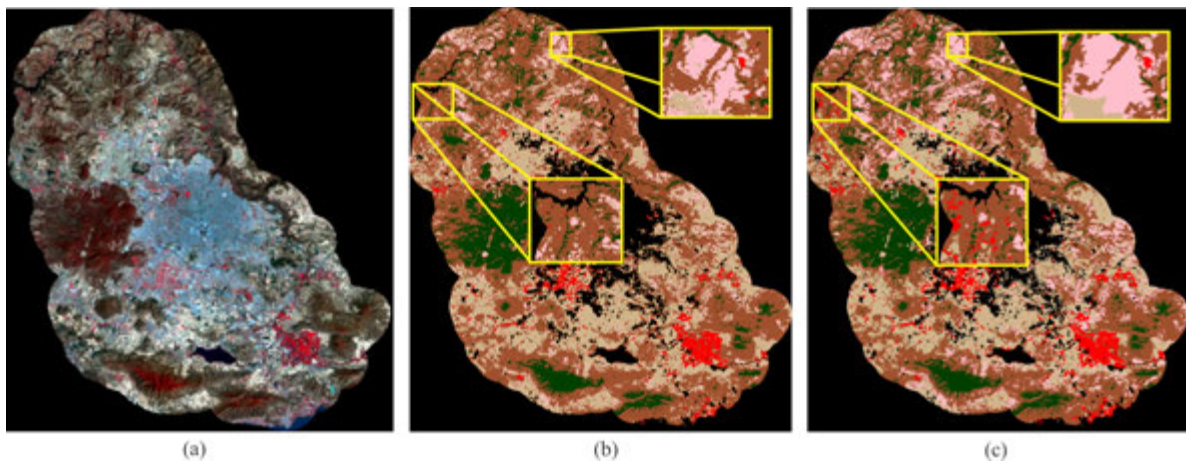


Figura 4.14: (a) Imagen de estudio. (b) Resultado de la segmentación del Experimento 3. (c) Ground truth.

Tabla 4.4: Validación de la segmentación en el Experimento 3.

	C1	C2	C3	C4	C5	Precisión global	Kappa
Experimento							
3	0.73	0.84	0.87	0.92	0.53	0.9197	0.8833

4.4.4. Experimento 4: Segmentación bajo los Espacios 1 y 3. Mínima entropía para la selección de pesos

En este Experimento, la imagen de estudio (ver Figura 4.15 a la izquierda) es representada en los **Espacios 1 y 3**.

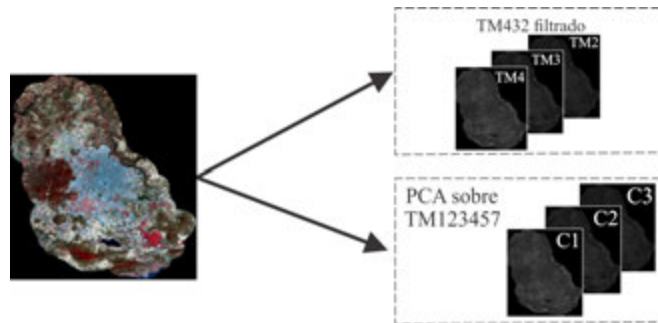


Figura 4.15: Representación de los Espacios de características usados en el Experimento 4. A la izquierda: imagen de estudio. Arriba, a la derecha, representación del Espacio 1, luego de aplicar el filtro bilateral. Abajo, a la derecha, representación del Espacio 3 considerando las tres primeras componentes principales de PCA sobre 6 bandas espectrales.

Después de representar la imagen en los **Espacios** descritos, se realiza la asignación de verosimilitudes a cada pixel r , usando los valores $v_k^1(r)$ y $v_k^3(r)$, correspondiente a cada clase k , Ecuaciones (4.4) y (4.6). En la Figura 4.7 aparece un ejemplo que ilustra este proceso.

Para el cálculo de pesos en la combinación de verosimilitudes, se usó el criterio de mínima entropía, Sección 3.3, Ecuación (3.7).

La Figura (4.16) muestra la representación gráfica de los resultados del proceso de segmentación. Podemos observar que existe, ligeramente, una disminución en la confusión entre las clases C1, C4 y C5, acorde a la información del experto (ver Figura (4.11) (b) y (c)). Los valores de precisión por clase, y los índices de precisión global y Kappa se incrementaron ligeramente (ver Tabla 4.5).

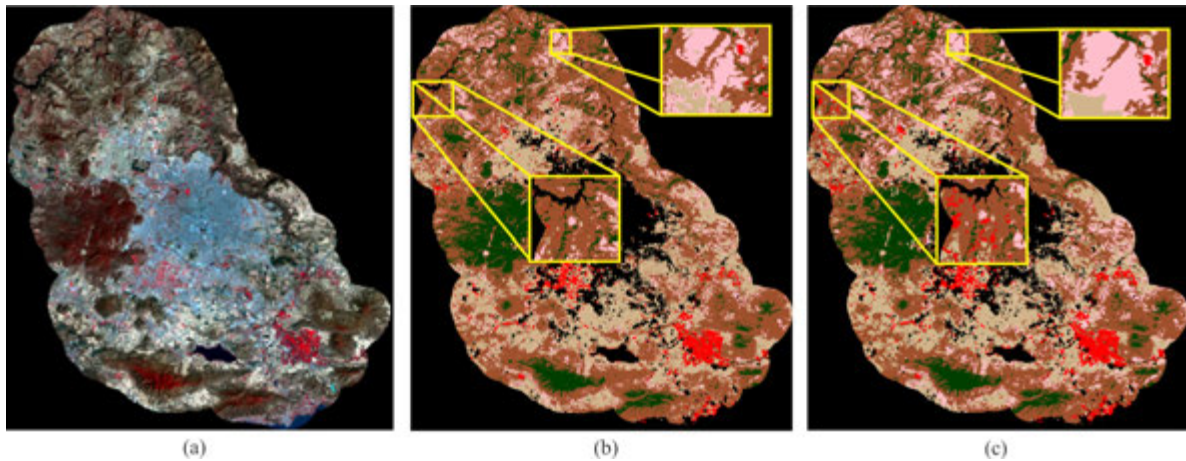


Figura 4.16: (a) Imagen de estudio. (b) Resultado de la segmentación del Experimento 4. (c) Ground truth.

Tabla 4.5: Validación de la segmentación en el Experimento 4.

	C1	C2	C3	C4	C5	Precisión global	Kappa
Experimento							
4	0.70	0.85	0.88	0.94	0.60	0.9268	0.8937

4.4.5. Experimento 5: Segmentación bajo los Espacios 2 y 3. El Espacio 2 considera PCA sobre 10 índices de vegetación. Selección de pesos por mínima entropía

En el **Experimento 5**, la imagen de estudio (ver 4.17 a la izquierda) es representada en el **Espacio 2** y en el **Espacio 3**. El **Espacio 2** considera las 3 primeras componentes principales sobre los 10 índices de vegetación, que aparecen en la Tabla 2.1. En la Figura 4.12 aparecen representados 10 índices calculados mediante imágenes.

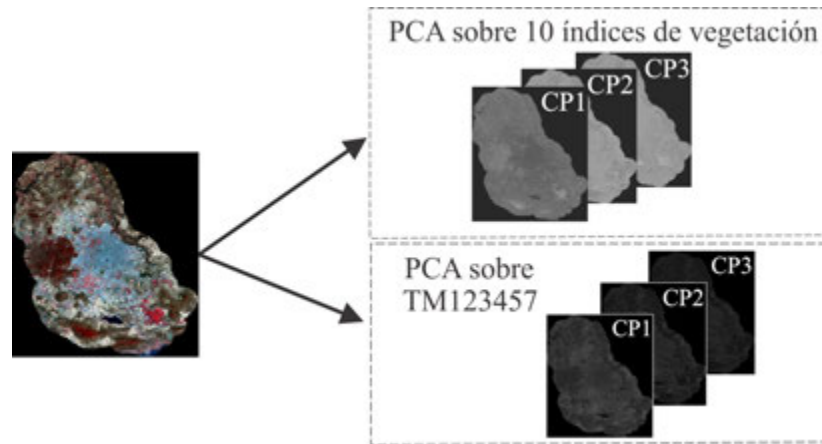


Figura 4.17: Representación de los Espacios de características usados en el Experimento 5. A la izquierda: imagen de estudio. Arriba, a la derecha, representación del Espacio 2 considerando las tres primeras componentes principales de PCA sobre 10 índices de vegetación. Abajo, a la derecha, representación del Espacio 3.

Después de la representación descrita, se realiza la asignación de verosimilitudes a cada pixel r usando los valores $v_k^2(r)$ y $v_k^3(r)$, correspondiente a cada clase k , Ecuaciones (4.5) y (4.6). En la Figura 4.7 podemos observar un ejemplo de este proceso.

En este Experimento, se utilizó el criterio de mínima entropía para combinar las verosimilitudes, Sección 3.3, Ecuación (3.7).

La imagen resultado del proceso de segmentación aparece en la Figura 4.18. Podemos observar que algunas zonas correspondientes a la C1 y C5, al igual que los anteriores experimentos siguen siendo invadidas por la clase C4.

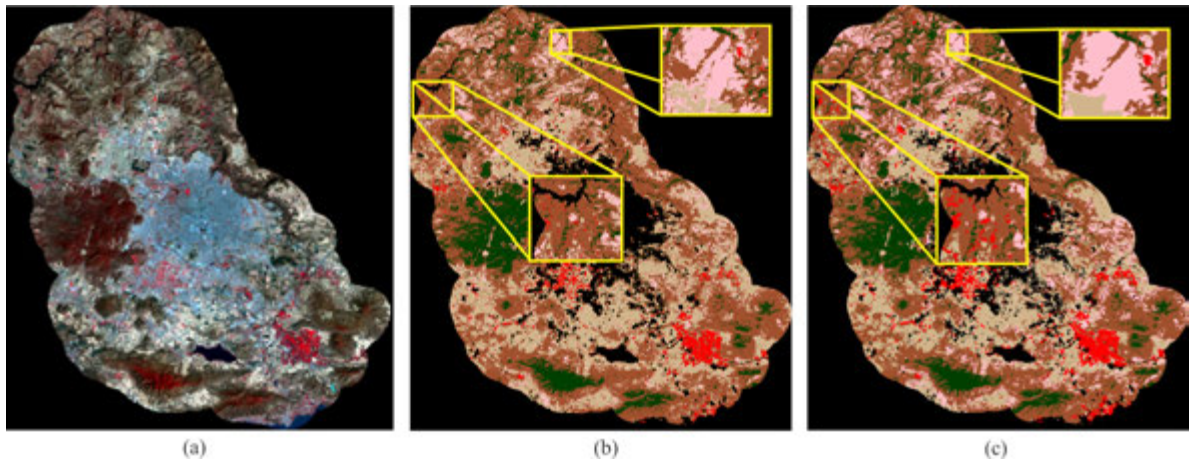


Figura 4.18: (a) Imagen de estudio. (b) Resultado de la segmentación del Experimento 5. (c) Ground truth.

En la Tabla 4.6. aparecen los resultados numéricos de la segmentación (**Validación**).

Tabla 4.6: Validación de la segmentación en el Experimento 5.

Experimento	C1	C2	C3	C4	C5	Precisión global	Kappa
5	0.67	0.82	0.89	0.91	0.65	0.9194	0.8832

4.4.6. Experimento 6: Segmentación bajo los Espacios 2 y 3. El Espacio 2 considera PCA sobre 6 índices de vegetación. Selección de pesos por mínima entropía

En este Experimento, la imagen de estudio (ver Figura 4.19 a la izquierda) es representada en el **Espacio 2** y en el **Espacio 3**. El **Espacio 2** considera las 3 primeras componentes principales sobre sólo 6 índices de vegetación, de igual forma que en el Experimento explicado en la Subsección 4.4.3.




Figura 4.19: Representación de los Espacios de características usados en el Experimento 6. A la izquierda: imagen de estudio. Arriba, a la derecha, representación del Espacio 2 considerando las tres primeras componentes principales de PCA sobre 6 índices de vegetación. Abajo, a la derecha, representación del Espacio 3.

Luego de representar la imagen en los **Espacios 2 y 3**, se realiza la asignación de verosimilitudes a cada pixel r usando los valores $v_k^2(r)$ y $v_k^3(r)$, correspondiente a cada clase k , Ecuaciones (4.5) y (4.6). Un ejemplo de este proceso es ilustrado en la Figura 4.7.

Para la combinación de las verosimilitudes en este Experimento, se usó el criterio de mínima entropía, Sección 3.3, Ecuación (3.7).

El resultado de la segmentación del **Experimento 6** se muestra en la Figura 4.20. Podemos observar nuevamente confusión entre las clases C1, C4 y C5, acorde a la información del experto (Ver Figura 4.20 (b) y (c)). En este Experimento se usaron los mismos espacios de características que el Experimento 4.4.5, sólo que en el **Espacio 2**, se utilizó un número menor de índices de vegetación (6 índices de vegetación).

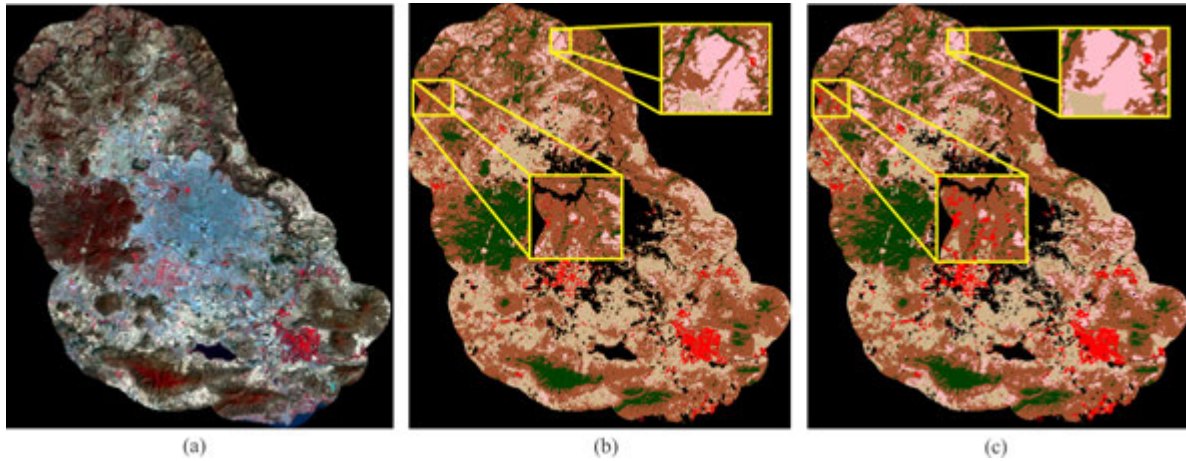


Figura 4.20: (a) Imagen de estudio. (b) Resultado de la segmentación del Experimento 6. (c) Ground truth.

Los resultados numéricos de la segmentación (**Validación**) aparecen en la Tabla 4.7.

Tabla 4.7: Validación de la segmentación en el Experimento 6.

Experimento	C1	C2	C3	C4	C5	Precisión global	Kappa
6	0.68	0.82	0.89	0.91	0.66	0.9204	0.8847

4.4.7. Experimento 7: Segmentación bajo los Espacios 1, 2 y 3. El Espacio 2 considera PCA sobre 10 índices de vegetación. Mínima entropía para la selección de pesos

En este Experimento, la imagen de estudio (ver Figura 4.21 al centro) es representada en el **Espacio 1, 2 y 3**. El **Espacio 2** considera las 3 primeras componentes principales sobre los 10 índices de vegetación representados en la Tabla 2.1.




Figura 4.21: Representación de los Espacios de características usados en el Experimento 7. Al centro: imagen de estudio. Arriba, a la izquierda, representación del Espacio 1, luego de aplicar el filtro bilateral. Arriba, a la derecha, representación del Espacio 2 considerando las tres primeras componentes principales de PCA sobre 10 índices de vegetación. Abajo, representación del Espacio 3.

Después de la representación descrita, se realiza la asignación de verosimilitudes a cada pixel r , usando los valores $v_k^1(r)$, $v_k^2(r)$ y $v_k^3(r)$, correspondiente a cada clase k , Ecuaciones (4.4), (4.5) y (4.6). En la Figura 4.7 se ilustra un ejemplo de este proceso.

Para el cálculo de pesos en la fusión de diferentes fuentes de información (espacios de características) se utiliza el criterio de mínima entropía, Sección 3.3, Ecuación (3.7).

En la Figura 4.22 muestra la representación gráfica de los resultados del proceso de segmentación.

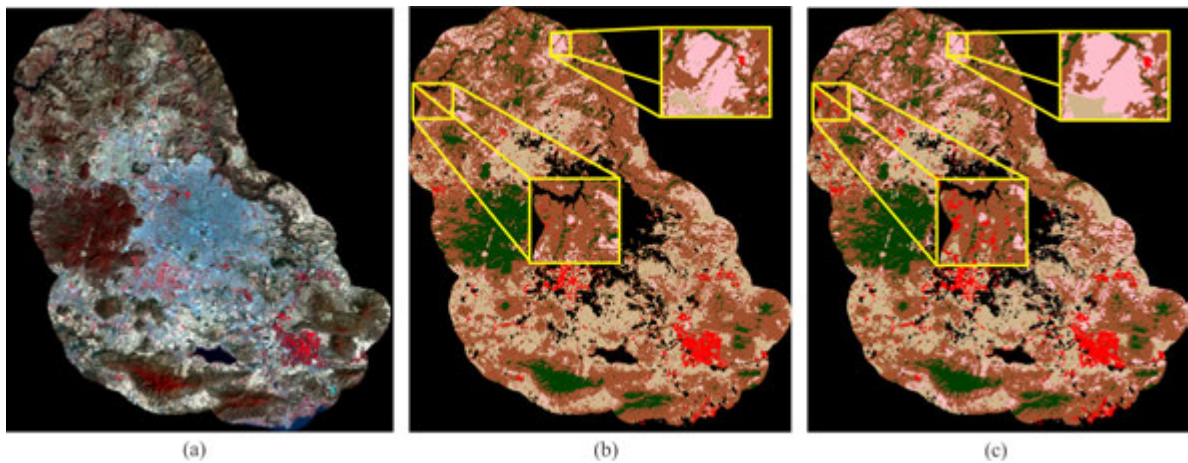


Figura 4.22: (a) Imagen de estudio. (b) Resultado de la segmentación del Experimento 7. (c) Ground truth.

En la Tabla 4.8 se muestran los resultados numéricos de la segmentación (**Validación**).

Tabla 4.8: Validación de la segmentación en el Experimento 7.

Experimento	C1	C2	C3	C4	C5	Precisión global	Kappa
7	0.71	0.84	0.88	0.93	0.59	0.9249	0.8909

4.4.8. Experimento 8: Segmentación bajo los Espacios 1, 2 y 3. El Espacio 2 considera PCA sobre 6 índices de vegetación. Mínima entropía para la selección de pesos

En este Experimento, la imagen de estudio (ver Figura 4.23 al centro) es representada en el **Espacio 1, 2 y 3**. El **Espacio 2** considera las 3 primeras componentes del análisis PCA sobre sólo 6 índices de vegetación de los representados en la Tabla 2.1, al igual que el Experimento dado en la Subsección 4.4.3).




Figura 4.23: Representación de los Espacios de características usados en el Experimento 8. Al centro: imagen de estudio. Arriba, a la izquierda, representación del Espacio 1, luego de aplicar el filtro bilateral. Arriba, a la derecha, representación del Espacio 2 considerando las tres primeras componentes principales de PCA sobre 6 índices de vegetación. Abajo, representación del Espacio 3.

La asignación de verosimilitudes a cada pixel r , se realiza usando los valores $v_k^1(r)$, $v_k^2(r)$ y $v_k^3(r)$, correspondiente a cada clase k , Ecuaciones (4.4), (4.5) y (4.6). En la Figura 4.7 aparece un ejemplo que ilustra este proceso.

El criterio para la combinación de pesos de las diferentes fuentes de información viene dado por mínima entropía, Sección 3.3, Ecuación (3.7).

La imagen resultado del proceso de segmentación aparece en la Figura 4.24. Podemos observar que en el Experimento descrito en la Subsección 4.4.7 se utilizaron los mismos espacios de características, solo que en este Experimento se contemplaron menos índices de vegetación,

sin embargo, los resultados numéricos en este Experimento fueron mejores al utilizar un número menor de índices de vegetación (Ver Tabla (4.9)).

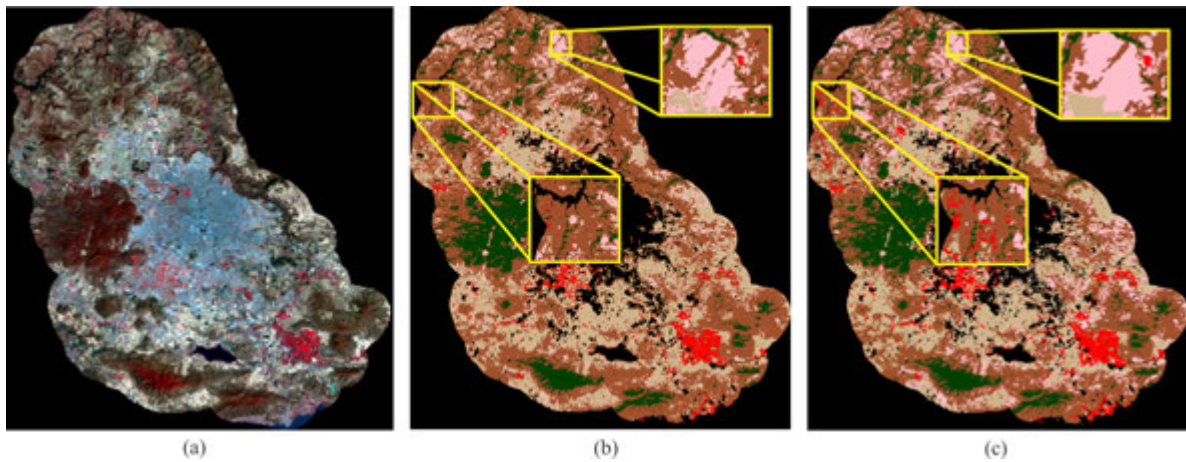


Figura 4.24: (a) Imagen de estudio. (b) Resultado de la segmentación del Experimento 8. (c) Ground truth.

Tabla 4.9: Validación de la segmentación en el Experimento 8.

	C1	C2	C3	C4	C5	Precisión global	Kappa
Experimento 8							
Mínima Entropía	0.71	0.84	0.88	0.93	0.59	0.9255	0.8918

4.4.9. Experimento 9: Segmentación bajo el Espacio 1 y 2. El espacio 2 considera PCA sobre 10 índices de vegetación. Criterio de fusión de fuentes para cálculo de pesos

En este Experimento, la imagen de estudio es representada en el **Espacio 1** y **Espacio 2**. El **Espacio 2** considera las 3 primeras componentes principales sobre 10 índices de vegetación (ver Tabla 2.1). La Figura 4.10 del Experimento de la Subsección 4.4.2 muestra la representación de la imagen de estudio en los espacios mencionados.

Después de la representación descrita, se realiza la asignación de verosimilitudes según $v_k^1(r)$ y $v_k^2(r)$, como se explica en la Sección 3.4.

La imagen se segmenta utilizando el criterio de fusión de fuentes de información (Sección 3.4). Los resultados se ilustran en la Figura 4.25.




Figura 4.25: Primera fila: (a) Imagen de estudio y (b) Ground truth. Segunda fila: segmentación usando fusión de fuentes para el cálculo de pesos: (c) $\mu = 1$, (d) $\mu = 0.1$, (e) $\mu = 0.01$ y (f) $\mu = 0.001$.

La Tabla 4.10 muestra los resultados numéricos de la segmentación (**Validación**).

Tabla 4.10: Validación de la segmentación en el Experimento 9.

Experimento 9	C1	C2	C3	C4	C5	Precisión global	Kappa
$\mu = 1$	0.73	0.84	0.87	0.92	0.56	0.9199	0.8837
$\mu = 0.1$	0.73	0.84	0.87	0.92	0.55	0.9199	0.8835
$\mu = 0.01$	0.73	0.84	0.87	0.92	0.55	0.9198	0.8834
$\mu = 0.001$	0.73	0.84	0.87	0.92	0.55	0.9198	0.8834

Para $\mu = 1$ se obtuvo el mayor valor de precisión global e índice de Kappa. En este Experimento se usaron los mismos espacios de características que en el Experimento descrito en la Subsección 4.4.2, sólo que el criterio para el cálculo de pesos en la combinación de verosimilitudes es según la Sección 3.4 y no por mínima entropía. Con este Experimento se superó el resultado obtenido en la prueba descrita en el Experimento 4.4.2.

4.4.10. Experimento 10: Segmentación bajo el Espacio 1 y Espacio 2. El Espacio 2 considera PCA sobre 6 índices de vegetación. Criterio de fusión de fuentes para cálculo de pesos

En este Experimento, la imagen de estudio es representada en el **Espacio 1** y en el **Espacio 2**. El **Espacio 2** considera las 3 primeras componentes principales sobre sólo 6 índices de vegetación, (ver Figura 4.13 del Experimento descrito en la Subsección 4.4.3).

Luego de la representación de la imagen en los espacios descritos, se realiza la asignación de verosimilitudes según $v_k^1(r)$ y $v_k^2(r)$ (Sección 3.4).

En este Experimento, la imagen se segmenta utilizando el criterio de múltiples fuentes de información (Sección 3.4). En la Figura 4.26 se muestran los resultados gráficos del proceso de segmentación.




Figura 4.26: Primera fila: (a) Imagen de estudio y (b) Ground truth. Segunda fila: segmentación usando fusión de fuentes para el cálculo de pesos: (c) $\mu = 1$, (d) $\mu = 0.1$, (e) $\mu = 0.01$ y (f) $\mu = 0.001$.

Los resultados numéricos de la segmentación (**Validación**) se muestran en la Tabla 4.11.

Tabla 4.11: Validación de la segmentación en el Experimento 10.

Experimento 10	C1	C2	C3	C4	C5	Precisión global	Kappa
$\mu = 1$	0.73	0.84	0.87	0.92	0.56	0.9208	0.8850
$\mu = 0.1$	0.73	0.84	0.87	0.92	0.56	0.9208	0.8850
$\mu = 0.01$	0.73	0.84	0.87	0.92	0.55	0.9208	0.8849
$\mu = 0.001$	0.73	0.84	0.87	0.92	0.55	0.9208	0.8849

En este Experimento se utilizaron los mismos espacios de características que el Experimento descrito en la Subsección 4.4.3, solo que con criterios de cálculo de pesos diferentes y con menos índices de vegetación (6 índices).

4.4.11. Experimento 11: Segmentación bajo el Espacio 1 y Espacio 3

En este Experimento, la imagen de estudio es representada en dos espacios: **Espacio 1**, y **Espacio 3**. La representación gráfica aparece en la Figura 4.15 del Experimento de la Subsección 4.4.4.

Después de representar a la imagen de estudio en el **Espacio1** y **Espacio 3**, se realiza la asignación de verosimilitudes según $v_k^1(r)$ y $v_k^3(r)$, como se explica en la Sección 3.4. En la Figura 4.7 aparece un ejemplo que ilustra este proceso.

Para la combinación de verosimilitudes se utilizó el criterio de múltiples fuentes de información (Sección 3.4). Los resultados se muestran en la Figura 4.27.




Figura 4.27: Primera fila: (a) Imagen de estudio y (b) Ground truth. Segunda fila: segmentación usando fusión de fuentes para el cálculo de pesos: (c) $\mu = 1$, (d) $\mu = 0.1$, (e) $\mu = 0.01$ y (f) $\mu = 0.001$.

En la Tabla 4.12 aparecen los resultados numéricos de la segmentación (**Validación**).

Tabla 4.12: Validación de la segmentación en el Experimento 11.

	C1	C2	C3	C4	C5	Precisión global	Kappa
Experimento 11							
CL $\mu = 1$	0.70	0.85	0.88	0.94	0.61	0.9280	0.8954
CL $\mu = 0.1$	0.70	0.85	0.88	0.94	0.61	0.9279	0.8953
CL $\mu = 0.01$	0.70	0.85	0.88	0.94	0.61	0.9279	0.8953
CL $\mu = 0.001$	0.70	0.85	0.88	0.94	0.61	0.9279	0.8953

Con este Experimento se logró aumentar la precisión por clases y la global, así como el índice Kappa. El valor óptimo de μ para la experimentación realizada fue de 1. Los resultados de este Experimento fueron mejores que los comentados en la Sección 3.3 en la que se utilizó el criterio de mínima entropía para el cálculo de pesos en la combinación lineal de verosimilitudes.

4.4.12. Experimento 12: Segmentación bajo los Espacios 2 y 3. El Espacio 2 considera PCA sobre 10 índices de vegetación. Criterio de fusión de fuentes para cálculo de pesos

En el **Experimento 12**, la imagen de estudio es representada en dos espacios: El **Espacio 2** con las 3 primeras componentes principales sobre 10 índices de vegetación y **Espacio 3** (ver Figura 4.17, Subsección 4.4.5).

Luego de la representación de la imagen en el **Espacio 2** y **Espacio 3**, se realiza la asignación de verosimilitudes según $v_k^2(r)$ y $v_k^3(r)$, como se explica en la Sección 3.4.

Las verosimilitudes procedentes de las fuentes **Espacio 2** y **Espacio 3** se combinan según criterio de fusión de múltiples fuentes (Sección 3.4). La representación gráfica de los resultados se ilustra en la Figura 4.28.




Figura 4.28: Primera fila: (a) Imagen de estudio y (b) Ground truth. Segunda fila: segmentación usando fusión de fuentes para el cálculo de pesos: (c) $\mu = 1$, (d) $\mu = 0.1$, (e) $\mu = 0.01$ y (f) $\mu = 0.001$.

Los resultados numéricos de la segmentación (**Validación**) aparecen en la Tabla 4.13.

Tabla 4.13: Validación de la segmentación en el Experimento 12.

	C1	C2	C3	C4	C5	Precisión global	Kappa
Experimento 12							
$\mu = 1$	0.67	0.84	0.89	0.91	0.63	0.9208	0.8852
$\mu = 0.1$	0.67	0.83	0.89	0.91	0.64	0.9207	0.8850
$\mu = 0.01$	0.67	0.83	0.89	0.91	0.64	0.9207	0.8850
$\mu = 0.001$	0.67	0.83	0.89	0.91	0.64	0.9207	0.8850

En este Experimento se utilizaron los mismos espacios de características que el Experimento descrito en la Subsección 4.4.5, solo que con criterios de cálculo de pesos diferentes (Sección 3.4). La clasificación logró mejorías con respecto al Experimento 4.4.5, lo que se evidencia con los valores de precisión por clases en general, el índice global y el índice Kappa.

4.4.13. Experimento 13: Segmentación bajo los Espacios 2 y 3. El Espacio 2 considera PCA sobre 6 índices de vegetación. Criterio de fusión de fuentes para cálculo de pesos

En el Experimento 13, la imagen de estudio es representada en dos espacios. El Espacio 2 considera las 3 primeras componentes principales sobre sólo 6 índices de vegetación y el Espacio 3. La Figura 4.19, Experimento 4.4.6 muestra la representación de la imagen de estudio en los Espacios 2 y 3 descritos.

Después de la representar a la imagen de estudio en el Espacio 2 y Espacio 3, se realiza la asignación de verosimilitudes según $v_k^2(r)$ y $v_k^3(r)$, como se explica en la Sección 3.4. En la Figura 4.7 aparece un ejemplo que muestra este proceso.

En este Experimento, se utilizó el criterio de fusión de fuentes de información para segmentar la imagen (Sección 3.4). Los resultados se ilustran en la Figura 4.29.




Figura 4.29: Primera fila: (a) Imagen de estudio y (b) Ground truth. Segunda fila: segmentación usando fusión de fuentes para el cálculo de pesos: (c) $\mu = 1$, (d) $\mu = 0.1$, (e) $\mu = 0.01$ y (f) $\mu = 0.001$.

Los resultados numéricos de la segmentación (**Validación**) aparecen en la Tabla 4.14.

Tabla 4.14: Validación de la segmentación en el Experimento 13.

	C1	C2	C3	C4	C5	Precisión global	Kappa
Experimento 13							
$\mu = 1$	0.67	0.84	0.89	0.91	0.63	0.9218	0.8867
$\mu = 0.1$	0.68	0.84	0.89	0.91	0.64	0.9217	0.8866
$\mu = 0.01$	0.68	0.83	0.89	0.91	0.64	0.9217	0.8865
$\mu = 0.001$	0.68	0.83	0.89	0.91	0.64	0.9217	0.8865

En este Experimento podemos observar nuevamente que con el valor $\mu = 1$, aumentó la precisión para la clase C5. Obsérvese que en este Experimento se utilizaron los mismos espacios de características que el Experimento descrito en la Subsección 4.4.12. La diferencia radica en el número de índices de vegetación incluidos al realizar PCA. Observe que se mejoraron los valores de precisión global e índice Kappa. El valor del parámetro $\mu = 1$ conllevó al mejor desempeño.

4.4.14. Experimento 14: Segmentación bajo los Espacios 1, 2 y 3. El Espacio 2 considera PCA sobre 10 índices de vegetación. Criterio de fusión de fuentes para cálculo de pesos

En este Experimento, la imagen de estudio es representada en el **Espacio 1, 2 y 3**. El **Espacio 2** considera las 3 primeras componentes principales sobre los 10 índices de vegetación descritos en la Tabla 2.1. En la Figura 4.21, Experimento Subsección 4.4.7 se ilustra la representación en los espacios del Experimento.

Luego de representar la imagen en el **Espacio1, Espacio 3 y Espacio 2**, usando 10 índices de vegetación, se realiza la asignación de verosimilitudes según $v_k^1(r)$, $v_k^2(r)$ y $v_k^3(r)$, como se explica en la Sección 3.4. En la Figura 4.7 se ilustra un ejemplo de este proceso.

La imagen se segmenta utilizando el criterio de múltiples fuentes de información (Sección 3.4). Los resultados se representan en la Figura 4.30.




Figura 4.30: Primera fila: (a) Imagen de estudio y (b) Ground truth. Segunda fila: segmentación usando fusión de fuentes para el cálculo de pesos: (c) $\mu = 1$, (d) $\mu = 0.1$, (e) $\mu = 0.01$ y (f) $\mu = 0.001$.

Los resultados numéricos de la segmentación (**Validación**) aparecen en la Tabla 4.15.

Tabla 4.15: Validación de la segmentación en el Experimento 14.

	C1	C2	C3	C4	C5	Precisión global	Kappa
Experimento 14							
$\mu = 1$	0.70	0.85	0.88	0.93	0.60	0.9254	0.8917
$\mu = 0.1$	0.71	0.85	0.88	0.93	0.60	0.9258	0.8922
$\mu = 0.01$	0.70	0.85	0.88	0.93	0.60	0.9259	0.8924
$\mu = \mathbf{0.001}$	0.71	0.85	0.88	0.93	0.60	0.9260	0.8925

En este Experimento, podemos observar que a diferencia de los experimentos anteriores los valores μ que dieron lugar a un mejor desempeño fueron $\mu = 0.001$ y $\mu = 0.01$. La precisión más baja fue para la clase C1. La precisión de la clasificación en este Experimento fue superior al obtenido en el Experimento dado en la Subsección 4.4.7 donde los pesos se calculan bajo el criterio de mínima entropía.

4.4.15. Experimento 15: Segmentación bajo los Espacios 1, 2 y 3. El Espacio 2 considera PCA sobre 6 índices de vegetación. Criterio de fusión de fuentes para cálculo de pesos

En el Experimento 15, la imagen de estudio es representada en el **Espacio 1, 2 y 3**. El **Espacio 2** considera las 3 primeras componentes principales sobre los 6 índices de vegetación descritos en la Tabla 2.1. En la Figura 4.23, Experimento Subsección 4.4.8 se ilustra la representación en los espacios del Experimento.

Después de la representación de la imagen en el **Espacio1, Espacio 3 y Espacio 2**, usando 6 índices de vegetación, se realiza la asignación de verosimilitudes según $v_k^1(r)$, $v_k^2(r)$ y $v_k^3(r)$, como se explica en la Sección 3.4. En la Figura 4.7 se ilustra un ejemplo de este proceso.

Para la segmentación de la imagen en este experimento, se utiliza el criterio de fusión de fuentes de información (Sección 3.4). La Figura 4.31 muestra la representación gráfica de los resultados del proceso de segmentación.




Figura 4.31: Primera fila: (a) Imagen de estudio y (b) Ground truth. Segunda fila: segmentación usando fusión de fuentes para el cálculo de pesos: (c) $\mu = 1$, (d) $\mu = 0.1$, (e) $\mu = 0.01$ y (f) $\mu = 0.001$.

Los resultados numéricos de la segmentación (**Validación**) aparecen en la Tabla 4.16.

Tabla 4.16: Validación de la segmentación en el Experimento 15.

	C1	C2	C3	C4	C5	Precisión global	Kappa
Experimento 15							
$\mu = 1$	0.71	0.85	0.89	0.93	0.61	0.9260	0.8926
$\mu = 0.1$	0.71	0.85	0.88	0.93	0.60	0.9265	0.8932
$\mu = 0.01$	0.71	0.85	0.88	0.93	0.60	0.9266	0.8934
$\mu = 0.001$	0.71	0.85	0.88	0.93	0.60	0.9266	0.8934

En este Experimento se usaron los mismos espacios de características que el Experimento de la Subsección 4.4.14, solo que con menos índices de vegetación (6 índices), sin embargo, nos podemos dar cuenta que el comportamiento es el mismo al usar 6 o 10 índices de vegetación en el **Espacio 2** (ver las Tablas 4.15. y 4.16).

4.5. Selección del algoritmo supervisado para el estudio de cultivos a través de firmas espectrales en imágenes de satélite

En la Tabla 4.17 se resume toda la experimentación realizada.

Tabla 4.17: Resultados finales de los 15 Experimentos realizados, usando los criterios de mínima entropía y fusión de fuentes.

Resultados de la segmentación usando el criterio de mínima entropía							
Experimento	C1	C2	C3	C4	C5	Precisión global	Kappa
1	0.73	0.83	0.83	0.91	0.55	0.9109	0.8707
2	0.72	0.84	0.87	0.92	0.53	0.9187	0.8819
3	0.73	0.84	0.87	0.92	0.53	0.9197	0.8833
4	0.70	0.85	0.88	0.94	0.60	0.9268	0.8937
5	0.67	0.82	0.89	0.91	0.65	0.9194	0.8832
6	0.68	0.82	0.89	0.91	0.66	0.9204	0.8847
7	0.71	0.84	0.88	0.93	0.59	0.9249	0.8909
8	0.71	0.84	0.88	0.93	0.59	0.9255	0.8918
Resultados de la segmentación usando el criterio de fusión de fuentes							
Experimento	C1	C2	C3	C4	C5	Precisión global	Kappa
9 ($\mu = 1$)	0.73	0.84	0.87	0.92	0.56	0.9199	0.8837
10 ($\mu = 1$)	0.73	0.84	0.87	0.92	0.56	0.9208	0.8850
11 ($\mu = 1$)	0.70	0.85	0.88	0.94	0.61	0.9280	0.8954
12 ($\mu = 1$)	0.67	0.84	0.89	0.91	0.63	0.9208	0.8852
13 ($\mu = 1$)	0.67	0.84	0.89	0.91	0.63	0.9218	0.8867
14 ($\mu = 0.001$)	0.71	0.85	0.88	0.93	0.60	0.9260	0.8925
15 ($\mu = 0.001$)	0.71	0.85	0.88	0.93	0.60	0.9266	0.8934

De todos los experimentos realizados utilizando el criterio de mínima entropía (ver Sección 3.3), el *Experimento 4* (ver Subsección 4.4.4) alcanzó los valores superiores de precisión por clase, global e índice de Kappa. La combinación de Espacios de características que permitieron una mejor clasificación en este grupo de experimentos fueron los **Espacios 1 y 3**.

En el caso del cálculo de pesos usando la propuesta de fusión de fuentes (Sección 3.4), el

Experimento 11 (Ver Subsección 4.4.11) superó los resultados de su grupo y al mejor obtenido por mínima entropía. El valor óptimo de μ fue 1. Aunque el problema de la confusión entre las clases C1, C4 y C5 es un obstáculo (firmas espectrales muy similares) la experimentación realizada con la propuesta explicada en la Sección 3 evidencia que los aspectos considerados: combinación de espacios, información contextual, enfoque probabilístico permiten en gran medida a resolver problemas complejos de clasificación. Tanto para los experimentos realizados bajo el criterio de mínima entropía (**Experimentos 1-8**), como para los hechos por fusión de múltiples fuentes (**Experimentos 9-15**), los espacios que condujeron a una mejor clasificación, fueron el **Espacio 1** y el **Espacio 3**. En este grupo de Experimentos la combinación de Espacios de características que permitieron una mejor clasificación al igual que el grupo de Experimentos obtenidos por mínima entropía fueron también los **Espacios 1 y 3**.

Teniendo en cuenta todos los resultados, se llegó a la conclusión de que el algoritmo supervisado para el estudio de cultivos a través de firmas espectrales en imágenes de satélite, es el implementado en el **Experimento 11**. En este experimento se utilizaron histogramas construidos en los **Espacios 1 y 3**, las verosimilitudes estimadas a partir de los histogramas se combinaron usando el criterio de fusión de múltiples fuentes (Sección 3.4) y finalmente la segmentación, se realizó mediante GMMF modificado (Ecuación 3.6).

De acuerdo a la literatura, las bandas espectrales TM4, TM3 y TM2, son las bandas que contienen la mayor información acerca de los cultivos en una imagen satelital (características que conforman el **Espacio 1**), sin embargo, en aras de no perder toda información de estos cultivos en las bandas restantes (TM1, TM2, TM5 y TM7), el **Espacio 3**, fue conformado con la información de todas las bandas (aplicando PCA, para reducir sus dimensiones). De acuerdo a los resultados de los Experimentos, se pudo comprobar que efectivamente estos 2 espacios (**Espacio 1 y Espacio3**), son los Espacios de características que nos proporcionan una mejor información acerca de los 5 tipos de cultivos estudiados.

4.6. Aplicación de la propuesta seleccionada sobre imágenes sintéticas

Adicionalmente se experimentó con 4 imágenes generadas sintéticamente para continuar la evaluación de la propuesta seleccionada. Estas imágenes se generaron a partir de la imagen de estudio (Figura 4.3), extrayendo información de cada tipo de cultivo (5 cultivos) en forma aleatoria y generando las nuevas imágenes a partir de esta información. Los resultados obtenidos se muestran en la Figura 4.32.

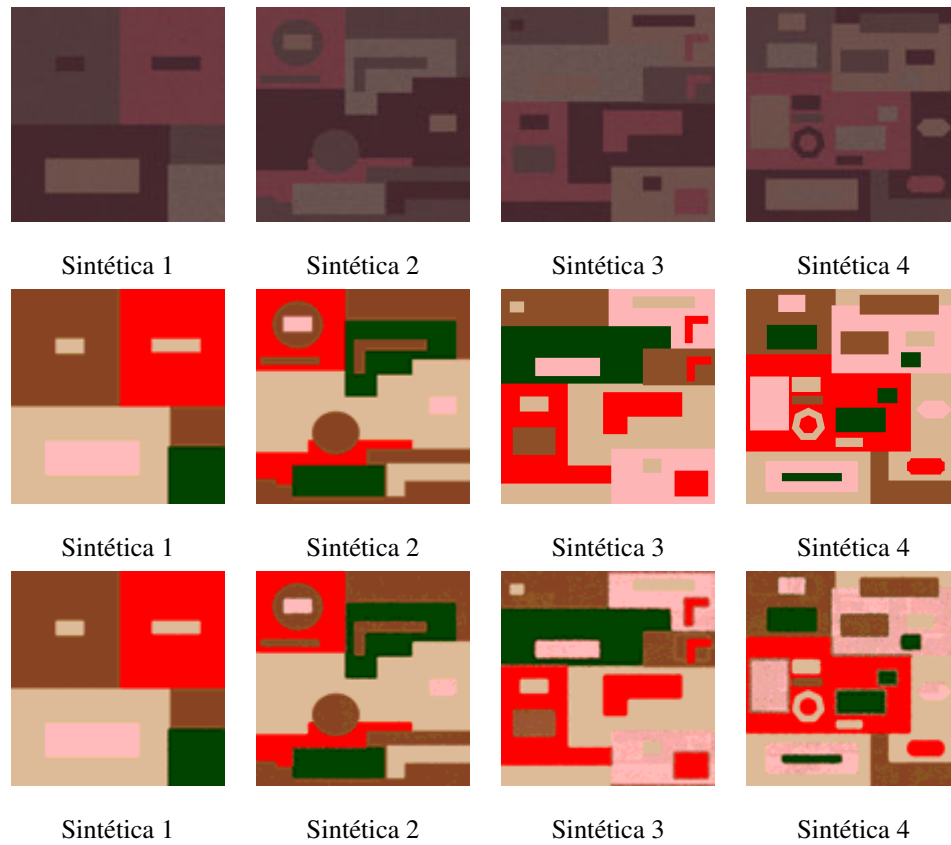


Figura 4.32: Resultados de la clasificación con imágenes sintéticas usando la propuesta seleccionada con los espacios 1 y 3. Primera fila: 4 Imágenes sintéticas. Segunda fila: ground truth de las imágenes sintéticas. Tercera fila: Resultados de la clasificación usando el algoritmo seleccionado en la Sección 4.5.

La evaluación numérica de los resultados obtenidos aparece en la Tabla 4.18.

Tabla 4.18: Resultados de la clasificación de las imágenes sintéticas usando el algoritmo de la propuesta.

Imagen	C1	C2	C3	C4	C5	Precisión global	Kappa
Sintética 1	0.99	0.99	0.99	0.99	0.99	0.9992	0.9989
Sintética 2	0.99	0.97	0.99	0.98	0.96	0.9912	0.9880
Sintética 3	0.97	0.96	0.99	0.95	0.86	0.9538	0.9418
Sintética 4	0.93	0.92	0.99	0.95	0.86	0.9372	0.9195

4.7. Comparación del algoritmo supervisado propuesto con otros métodos reportados en la literatura

En la Tabla 4.19, se muestran los resultados numéricos que evalúan el comportamiento del algoritmo seleccionado en la Sección 4.5 y el de otros métodos reportados en la literatura. Todos los algoritmos fueron aplicados sobre la misma imagen (Figura 4.3), con el objetivo de detectar los 5 tipos de cultivos descritos en la Sección 4.3. Los espacios de características usados por cada método, se indican en la columna 2. Observe que los índices de precisión alcanzados por nuestro algoritmo, son mayores que los alcanzados por los métodos revisados en el estado del arte.

Tabla 4.19: Resultados numéricos de diferentes métodos de clasificación.

Experimento	Espacio de características	C1	C2	C3	C4	C5	Precisión Global	Kappa
MED [82]	bandas TM1, TM2, TM3, TM4, TM5 y TM7	0.30	0.42	0.88	0.69	0.62	0.7995	0.7140
ML [30]	bandas TM1, TM2, TM3, TM4, TM5 y TM7	0.53	0.60	0.85	0.75	0.53	0.8367	0.7445
FLL [57]	bandas TM1, TM2, TM3, TM4, TM5 y TM7	0.44	0.56	0.89	0.80	0.55	0.8461	0.7770
ESS [47]	bandas TM1, TM2, TM3, TM4, TM5 y TM7	0.53	0.66	0.67	0.87	0.35	0.8542	0.7865
MICAI 2014 [59]*	Espacio 1	0.73	0.83	0.83	0.91	0.55	0.9109	0.8707
MICAI 2015 [60]*	Espacio 1 y Espacio 2	0.70	0.84	0.88	0.93	0.59	0.9249	0.8909
Propuesta	Espacio 1 y Espacio 3	0.70	0.85	0.88	0.94	0.61	0.9280	0.8954

El contenido del espacio definido por las bandas TM1, TM2, TM3, TM4, TM5 y TM7 aparece explicado en la Tabla 4.1. El **Espacio 1**, **Espacio 2** y **Espacio 3** están descritos en la sección 4.3. Los resultados numéricos dados en la Tabla 4.19 indican que el espacio de características dado por las bandas TM4, TM3 y TM2 (**Espacio 1**) junto a las 3 componentes principales de las bandas TM1, TM2, TM3, TM4, TM5 y TM7 (**Espacio 3**), en nuestra propuesta conllevó a los mejores resultados respecto a trabajos similares antes reportados.

*Los algoritmos reportados en MICAI 2014 y 2015 forman parte de dos propuestas anteriores, hechas por el autor de este manuscrito durante la realización de la tesis doctoral.

En la Figura 4.33, se muestra la comparación gráfica entre la propuesta elaborada y los métodos reportados en la Tabla 4.19 . Como se puede observar en la Figura 4.33 (i), nuestro algoritmo presenta menor confusión en las clases C1 (color rojo), C5 (color rosa) y C4 (color café oscuro).




Figura 4.33: Comparación de resultados finales de nuestra propuesta con otros métodos reportados en la literatura. Primera fila: (a) Imagen de estudio. (b) Ground Truth. (c) MED. Segunda fila: (d) ML. (e) FLL (f) ECHO ESS. Tercera fila: (g) MICAI 2014, (h) MICAI 2015. (i) Algoritmo propuesto.

Capítulo 5

Conclusiones y trabajo futuro

El algoritmo de clasificación propuesto combina características de diferentes fuentes de información. Al igual que [59] el algoritmo propuesto utiliza un enfoque probabilístico de segmentación a través de GMMF [52] (ver Sección 2.3). A diferencia de [59] se propone una modificación de GMMF que permite combinar más de una verosimilitud. La verosimilitud final, resultado de la información proveniente de varias fuentes (espacios de características) es construida como una combinación lineal de fuentes que se consideran independientes. Los pesos de la combinación lineal están definidos por una función de contraste. Para esta tesis fue elegida como función de contraste la entropía de Gini [15]. El algoritmo propuesto se utiliza para la clasificación de diferentes tipos de cultivos representados en imágenes satelitales. Los espacios de características usados fueron el **Espacio 1**: espacio construido luego de aplicar un filtro bilateral a las bandas TM4, TM3 y TM2 del sensor Landsat-5 TM, el **Espacio 2**: espacio que considera las 3 primeras componentes principales de PCA sobre índices de vegetación y el **Espacio 3**: espacio que considera las 3 primeras componentes principales de PCA sobre 6 bandas espectrales del satélite Landsat-5 TM. Los mejores resultados en la segmentación se obtuvieron con la combinación del **Espacio 1** y el **Espacio 3**. Dichos espacios demostraron contener información suficiente respecto a los 5 tipos de cultivos estudiados, de acuerdo a los resultados obtenidos en los experimentos realizados en la Sección 4. Al utilizar las combinaciones del **Espacio 1** y **3**, no se está descartando a ninguna de las 6 bandas espectrales del Satélite Landsat-5 TM, con lo cual podemos deducir que para una buena segmentación es necesario tomar en cuenta la información de todas las bandas. El uso de PCA [37] nos permitió reducir dimensionalidad y conservar información valiosa en los **Espacios 2** y **3**. El algoritmo supervisado que se seleccionó inspirado en las preguntas de investigación planteadas en la Sección 1.3.1 y toda la discusión realizada

en la Sección 2, para el estudio de cultivos a través de firmas espectrales en imágenes de satélite; sin embargo, su alcance, acorde a nuestra investigación, incluye cualquier otro problema de clasificación donde la similitud entre clases es una dificultad y para aumentar la precisión de la clasificación se necesita una alta dimensión en cuanto a fuentes de información.

El reconocimiento de cultivos en imágenes de satélite es una tarea muy difícil, debido a la similaridad de las firmas espectrales de algunos tipos de cultivos. La propuesta se basa en la información de histogramas, generados a partir de características de diferentes fuentes de información y el enfoque probabilístico denominado GMMF. De acuerdo a los resultados de validación obtenidos por el algoritmo propuesto, estos fueron competitivos comparados con algunos algoritmos encontrados en la literatura. El algoritmo aún presenta errores al clasificar clases cuyas firmas espectrales son muy similares. Con el fin de atenuar los errores de clasificación, se pretende llevar la investigación actual con otros métodos probabilísticos que tienen más complejidad computacional, pero son más robustos ante la similaridad de características entre clases diferentes. Entre estos métodos se encuentra el conocido como *Alpha Markov Measure Field Model* [16].

Para enriquecer el trabajo experimental se realizarán experimentos utilizando imágenes de bases de datos de otros sensores como Landsat 8, que nos proporciona mayor resolución espectral (11 bandas). En este trabajo de tesis sólo se trabajó con 10 índices de vegetación, sin embargo, existen otros que también son útiles para el estudio de vegetación y que en esta tesis no fueron considerados por la ausencia de la información espectral que se requiere para su cálculo, porque el sensor usado (Landsat-5 TM) no la contiene. Una banda muy utilizada es la llamada "rojo limite" (red-edge, en inglés), esta banda está presente en imágenes del sensor RapidEye, esta banda espectral proporciona mayor información relativa a los cultivos y vegetación, de acuerdo a la literatura [77, 81]. En base a lo anterior, en el trabajo futuro se podrían incorporar este tipo de imágenes esperando obtener mejores resultados.

Los métodos comparados con nuestro algoritmo en la Sección 4.7, utilizan diferentes espacios de características, se pretende hacer una comparación de esos mismos métodos pero esta vez, utilizando el mismo espacio de características usados en nuestra propuesta y observar el comportamiento de los mismos.

Otros trabajos con los que se pretende continuar esta investigación, están los del análisis de etapas de crecimiento de cultivos, vigor, estimación del daño en la vegetación, detección de plagas y enfermedades, entre otros, mediante imágenes aéreas tomadas desde un vehículo aéreo no tripulado (dron), utilizando información de bandas termales capturada por cámaras especiales acopladas al dron.

Apéndice A

Satelites de teledetección

En las Tablas [A.1](#), [A.2](#) y [A.3](#), se muestran los satélites activos que actualmente se encuentran orbitando la Tierra.

Tabla A.1: Satélites de teledetección.

Satélite Disaster Monitoring Constellation (DMC)				Resolución		
Satelite	País	Lanzamiento	Cobertura	Espacial	Espectral	Temporal
ALSAT-1	Argelia	28-11-2002	600 km.	32 m.	3	< 1
NIGERIASAT-1	Nigeria	27-09-2003	600 km.	32 m.	3	< 1
UK-DMC	Reino Unido	27-09-2003	600 km.	32 m.	3	< 1
BEIJING	China	27-10-2005	600 km.	32 m.	3	< 1
DEIMOS-1	España	27-09-2009	660 km.	22 m.	3	< 1
UK-DMC2	Reino Unido	27-09-2009	660 km.	22 m.	3	< 1
Satélite EARTH OBSERVING-1 (EO-1)				Resolución		
Satelite	País	Lanzamiento	Cobertura	Espacial	Espectral	Temporal
ALI	Estados Unidos	21-11-2000	37 km.	multiespectral: 30 m. pancromática: 10 m	10	16
HYPERION	Estados Unidos	21-11-2000	7.7 km.	30 m.	220	16
Satélite Earth Resources Observation Satellite (EROS) EROS-A/EROS-B				Resolución		
Satelite	País	Lanzamiento	Cobertura	Espacial	Espectral	Temporal
CCD (EROS A)	Israel	05-12-2000	14 km.	pancromática: 1.8 m.	1	4
CC-TDI (EROS B)	Israel	25-04-2006	7 km.	pancromática: 0.7 m.	1	4
Satélite FORMOSAT-2				Resolución		
Satelite	País	Lanzamiento	Cobertura	Espacial	Espectral	Temporal
FORMOSAT-2	Taiwan	21-05-2004	24 km.	multi espectral: 8 m. pancromática: 2 m.	4	1

Tabla A.2: Satélites de teledetección.

Satélite IKONOS				Resolución		
Satelite	País	Lanzamiento	Cobertura	Espacial	Espectral	Temporal
IKONOS	Estados Unidos	24-09-1999	11.3 km	multi espectral: 4m. pancromática: 1 m.	4	3-5
Satélite GEOEYE-1				Resolución		
Satelite	País	Lanzamiento	Cobertura	Espacial	Espectral	Temporal
GEOEYE-1	Estados Unidos	06-09-2008	15.2 km.	multiespectral: 2 m. pancromática: 0.5 m.	4	3
Satélite KOMPSAT-2				Resolución		
Satelite	País	Lanzamiento	Cobertura	Espacial	Espectral	Temporal
KOMPSAT-2	Corea	26-07-2006	790 km.	multiespectral: 4 m. pancromática: 1 m.	4	3
Satélite LANDSAT-7				Resolución		
Satelite	País	Lanzamiento	Cobertura	Espacial	Espectral	Temporal
ETM+	Estados Unidos	15-04-1999	172 km. ×183 km.	multiespectralms: 30 m. pancromática: 15 m.	8	16
Satélite QUICKBIRD				Resolución		
Satelite	País	Lanzamiento	Cobertura	Espacial	Espectral	Temporal
QUICKBIRD	Estados Unidos	18-10-2001	16.5 km.	multiespectral: 2.44 m. pancromática: 0.61 m.	4	2-4
Satélite RAPIDEYE				Resolución		
Satelite	País	Lanzamiento	Cobertura	Espacial	Espectral	Temporal
RAPIDEYE	Alemania	29-08-2008	77 km.	6.5 m.	5	1
Satélite RESOURCESAT-2				Resolución		
Satelite	País	Lanzamiento	Cobertura	Espacial	Espectral	Temporal
LISS-IV	India	20-04-2011	70 km.	5.8 m.	3	5
LISS-III				India		
Satélite SPOT-5	Resolución					
Satelite	País	Lanzamiento	Cobertura	Espacial	Espectral	Temporal

Tabla A.3: Satélites de teledetección

Satélite Terra (EOS-AM 1)				Resolución		
Satelite	País	Lanzamiento	Cobertura	Espacial	Espectral	Temporal
ASTER	Japón	18-12-1999	60 km.	15-90 m.	14	16
Satélite THEOS				Resolución		
Satelite	País	Lanzamiento	Cobertura	Espacial	Espectral	Temporal
THEOS	Tailandia	01-10-2008	1,000 km.	multiespectral: 15 m. pancromática: 2 m.	4	1.5
Satélite WORLDVIEW-2				Resolución		
Sensor	País	Lanzamiento	Cobertura	Espacial	Espectral	Temporal
WORLDVIEW-2	Estados Unidos	08-10-2009	16.4 km.	multiespectral: 2 m.	8	1-3
Satélite WORLDVIEW-3				Resolución		
Sensor	País	Lanzamiento	Cobertura	Espacial	Espectral	Temporal
WORLDVIEW-3	Estados Unidos	13-08-2014	13.1 km.	multiespectral: 0.31 m. pancromática: 1.24 m.	29	< 1

Apéndice B

Indice de kappa y precisión global

B.1. Cálculo del coeficiente de Kappa y la medida de precisión global

El coeficiente Kappa, k , también conocido como coeficiente de Cohen Cohen [14], es una medida del grado de acuerdo o concordancia en la clasificación hecha por dos observadores. La expresión que define k es:

$$k = \frac{P_0 - P_e}{1 - P_e} \quad (\text{B.1})$$

En (B.1) denota la probabilidad de acuerdos entre los observadores durante la clasificación, Ecuación (B.2) y p_e indica la probabilidad de acuerdos debido al azar, Ecuación (B.3).

$$P_0 = \frac{\text{No. de acuerdos}}{\text{total de observaciones}} \quad (\text{B.2})$$

$$P_e = \sum_{i=1}^n P_{i1}P_{i2} \quad (\text{B.3})$$

n es el número de categorías o clases; i denota la categoría; p_{i1} expresa la probabilidad con la que el observador 1 asignó la categoría i ; p_{i2} expresa la probabilidad con la que el observador 2 asignó la categoría i .

La expresión (B.2) es también conocida como la **precisión global**.

Veamos esto con un ejemplo (Tabla B.1). Suponga que se tienen los observadores A y B; hay 50 observaciones y dos categorías : **1** y **2**.

Tabla B.1: Ejemplo para ilustrar el cálculo del coeficiente Kappa.

		B	
		1	2
A	1	20	5
	2	10	15

En la diagonal principal de la tabla, 20 indica que al observar las 50 muestras los observadores A y B coincidieron en asignar la categoría 1 en 20 muestras; 15 indica que al observar las 50 muestras los observadores A y B coincidieron en asignar la categoría 2 en 15 muestras. La suma de los elementos de la diagonal principal permite el cálculo de la probabilidad de acuerdos, P_0 , o sea:

$$P_0 = \frac{20+15}{50} = 0.70$$

Para conocer P_e necesitamos analizar el resto de los valores de la tabla:

La clase 1 fue asignada a 25 muestras (20+5) por el observador A: $25/50 = \frac{1}{2}$

La clase 1 fue asignada a 30 muestras (20+10) por el observador B: $30/50 = \frac{3}{5}$

La clase 2 fue asignada a 25 (10+15) muestras por el observador A: $25/50 = \frac{1}{2}$

La clase 2 fue asignada a 20 (15 +5) muestras por el observador B: $20/50 = \frac{2}{5}$.

Esto significa que:

$$P_e = \frac{1}{2} * \frac{3}{5} + \frac{1}{2} * \frac{2}{5} = \frac{1}{2}$$

finalmente,

$$k = \frac{0.70-0.50}{1-0.50} = 0.40$$

Para poder interpretar el valor de k es útil disponer de una escala para expresar cualitativamente la fuerza de la concordancia o acuerdo Landis and Koch [48], Tabla B.2.

Tabla B.2: Valoración del Índice Kappa.

Valor de K	Fuerza de la concordancia
0.00	Pobre
0.01 - 0.20	Leve
0.21 - 0.40	Aceptable
0.41 - 0.60	Moderada
0.61 - 0.80	Considerable
0.81 - 1.00	Casi perfecta

Apéndice C

Algoritmo k-medias

El algoritmo k-medias, es uno de los métodos no supervisados de agrupamiento más utilizados en aplicaciones científicas e industriales, así como para la clasificación de cultivos. Su objetivo es particionar un conjunto de datos en k grupos, como resultado de minimizar una función objetivo. El Algoritmo k-medias se describe a continuación.

Algoritmo C.1 Algoritmo k-means.

Dado el conjunto de datos X y un número de grupos k

1. Se eligen los centroides c_j para cada grupo, $j = 1, 2, \dots, k$
2. Para cada dato del conjunto X se calcula la distancia con respecto a cada centroide c_i .
3. A cada dato se le asigna el grupo c_i cuya distancia respecto al centroide haya sido menor (paso de asignación).

$$S_i^{(t)} = \left\{ x_p : d(x_p, c_i^{(t)}) \leq d(x_p, c_j^{(t)}) \forall 1 < j < k \right\} \quad (\text{C.1})$$

4. Se actualizan los centroides c_j a través del cálculo de las medias de los datos de cada grupo obtenido en el paso tres (ver Ecuación C.2) (Paso de actualización).

$$c_i^{(t+1)} = \frac{1}{|S_i^{(t)}|} \sum_{x_j \in S_i^{(t)}} x_j \quad (\text{C.2})$$

5. Se repiten los pasos 2, 3 y 4 hasta que los centroides c_i no cambien.
-

En la Ecuación C.2 $|S_i^{(t)}|$ = número de elementos dentro del conjunto $S_i^{(t)}$ en la iteración t .

Apéndice D

Artículo MICAI 2014

A Supervised Segmentation Algorithm for Crop Classification Based on Histograms Using Satellite Images

Francisco E. Oliva^{1,*}, Oscar S. Dalmau², and Teresa E. Alarcón³

^{1,3}Centro Universitario de los Valles, Universidad de Guadalajara, Jalisco, México

{francisco.oliva,teresa.alarcon}@profesores.valles.udg.mx

²Centro de Investigación en Matemáticas, Guanajuato, México

dalmau@cimat.mx

Abstract. Recognizing different types of crops through satellite imagery is an important application of Digital Image Processing in Agriculture. A supervised algorithm for identifying different types of crops is proposed. In the training stage, the studied images are preprocessed using a bilateral filter, and then the histogram of intensity levels is constructed for every crop class. The segmentation stage begins with the assignment of the likelihood of each pixel to belong to each class, which is based on the histogram information. Finally the segmentation is obtained using Gauss-Markov Measure Field. For this research Landsat-5 TM satellite images are used. The experimental work included synthetic and real images. In the case of the real image, the ground truth image was given by an expert. The results of the proposed algorithm were compared with other methods such as Maximum likelihood, Fisher linear likelihood, and Minimum Euclidean distance, among others.

Keywords: image segmentation, remote sensing, crop classification, histogram, likelihood estimation.

1 Introduction

The classification of crops in satellite imagery have been done with different techniques. The method proposed in [16] obtained a satisfying effect for the classification of agricultural multispectral TM images using an Artificial Neural Networks (ANNs), in [8] was noticed that ANN is more complicated to use than statistical classifiers due to problems encountered in their design and implementation and it is always subject to adjustments in the hidden layers. In [11] Maximum Likelihood Classifier (ML) was used for the problem of crop cover mapping of a cultivated region using high resolution satellite imagery. In [4] was notice that MLC has a basic limitation that is too sensitive to the parameters values predefined by the user. In [14] was developed a method for extraction of agricultural land using information based on remote sensing imagery by combining particle swarm optimization (PSO), k-means clustering algorithm and

* Corresponding author.

Minimum Euclidean Distance (MED). In [14] the authors also noted that the performance of k-means and PSO-k-means is better than the MED method due the large number of paddy fields that were incorrectly classified as water bodies. In [9], [10] is elaborated a two step algorithm that considers spectral information together with the contextual information from neighboring pixels. The method is called ECHO (Extraction and Classification of Homogeneous Objects) spectral spatial classifier (ESS). In the proposal, firstly, the scene is segmented into statistically homogeneous regions, then the data are classified using the maximum likelihood scheme. The selection of the proper parameters in the segmentation impacts the performance of the algorithm. An improvement of this proposal is achieved in [5]. The last commented works lead to higher accuracy value of classification process respect to per- pixel approaches like ML, MED and Fisher Linear Likelihood (FLL) [7].

Inspired in the previous commented works we proposed a supervised algorithm for recognizing different types of crops on satellite imagery. In order to remove some granularities of the layers we apply a bilateral filter and then we construct a 3D histogram for each types of crops using the TM432 combination. Finally a segmentation strategy based on GMMF model is applied [6].

The rest of this paper is structured as follows: section 2 describes the steps of the proposed algorithm. In section 3 we present experiments and discussion of the results and finally in section 4 the conclusions are given.

2 The Proposed Algorithm

The proposed algorithm is composed of two stages: the training stage and the segmentation stage as shown in Fig. 1.

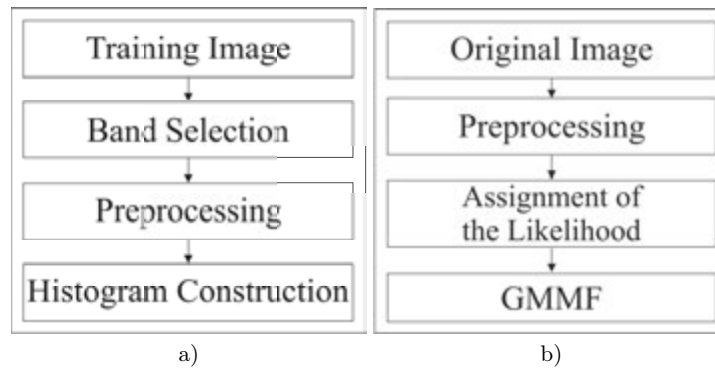


Fig. 1. Stages of the proposed algorithm. (a) Training stage, (b) Segmentation stage.

Next we explain each step of the elaborated algorithm.

2.1 Training Stage

The training step basically consists in computing a histogram which is used for the segmentation step. The main challenge here is how to select the information in order to construct the histogram. In particular we use a prior information about the classes, provided by an expert. The details of each step of the training stage are explained below.

Band Selection: In this research satellite images from LANSAT-5 Thematic Mapper are used (see Table 1). The information in Table 1, is taking from <http://gif.berkeley.edu/>. It is known that the information related to the crops are well recognized in the infrared (TM4), red (TM3) and green (TM2) bands. For that reason the color scheme TM432 is widely used for the study of vegetation as explained in <http://g1cfapp.g1cf.umd.edu:8080/esdi/index.jsp>. Therefore in this work the selected bands were TM2, TM3 y TM4.

Table 1. Spectral bands of the Lansat-5 Thematic Mapper (TM) Sensor

Thematic Mapper (TM) Bands	Wavelength (μm)	Features
TM1	0.45 - 0.52	B (Blue)
TM2	0.52 - 0.60	G (Green)
TM3	0.63 - 0.69	R (Red)
TM4	0.76 - 0.90	near infrared
TM5	1.55 - 1.75	mid-infrared
TM6	10.4 - 12.50	thermal infrared
TM7	2.08 - 2.35	mid-infrared

Preprocessing: For enhancing the information about the crops and improving the quality of the image a bilateral filter [15] was applied on the three selected bands (TM4, TM3, TM2) independently. Bilateral filtering smooths images and preserves edges, using a non-linear combination of nearby image values. The method is noniterative and local. The filter uses a gaussian function and combines gray levels or colors based on both their spatial closeness and their gray or color similarity. Bilateral filter opts for near values considering both spatial location and gray level or color information [15].

Figure 2 shows the result of preprocessing the band TM4 using the bilateral filter with window size 3×3 and $\sigma = 1$.

Histogram Construction: Based on the ground truth image and considering the information of the 3 selected bands, a 3-D histogram for every class k is computed, h_k^{3D} , $k = 1, 2, 3, \dots, K$, where K denotes the number of classes, see Equation (1).




Fig. 2. Preprocessing step using the TM4 band. (a) Original image, (b) Filtered image.

$$h_k^{3D}(x) = \frac{n_k(x)}{T_k}, \quad (1)$$

where the voxel x is defined by the gray intensity information of the three selected bands, i.e., $x = (g_2, g_3, g_4)$, where $g_i \in \{0, 1, \dots, 255\}$ corresponds to the TM i band, with $i = \{2, 3, 4\}$. In Equation (1) $n_k(x)$ denotes the number of times the voxel x was in class k , T_k is the total number of voxels in class k . The constructed histograms are used for computing the likelihood of pixel of a given image to belong to each class.

The constructed histograms have information in only few voxels x in the whole space, Ω , which is defined by the combinations of g_2, g_3 and g_4 bands of the training image. In order to have the information in the whole space, a diffusion process is then applied according to the Equation (2):

$$h_k^{3D}(x) = \frac{\sum_{y \in \mathcal{V}_x} h_k^{3D}(y)}{|\mathcal{V}_x|}, \quad (2)$$

where \mathcal{V}_x represents the neighbourhood of voxel x , in particular, we consider the neighbors at distance 1, i.e., $\|x - y\|_1 = 1$, $|\mathcal{V}_x|$ is the cardinality of the corresponding neighborhood. In Equation 2, y denotes the neighbors of voxel x . As a result of the diffusion process the histogram, h_k^{3D} , $k = 1, 2, 3, \dots, K$, is smoothed and for each $x \in \Omega$ one has a vector whose k th component is defined by $h_k^{3D}(x)$.

In order to simplify the computational cost, we can perform a further step by normalizing the histograms, so that at each voxel we have a discrete probability distribution which gives us a probabilistic interpretation, see Equation (3)

$$v_k(x) = \frac{h_k^{3D}(x)}{t(x)}, \quad (3)$$

where $v_k(x)$ is the normalized k th component at voxel x and $t(x) = \sum_{k=1}^K h_k^{3D}(x)$ the corresponding normalization factor.

2.2 Segmentation Step

GMMF [6] is derived from classical discrete Markov random fields, which are widely used in image processing for solving ill-posed problems. The GMMF model is an estimator of marginal distributions, see details in Ref. [6]. The functional for GMMF is the following:

$$U(p) = \sum_{r \in \mathcal{L}} \|p(r) - \hat{v}(r)\|^2 + \lambda \sum_{\langle r,s \rangle} \|p(r) - p(s)\|^2, \quad (4)$$

in the previous equation $\hat{v}(r)$ represents the normalized likelihood at pixel r . The value of $\hat{v}(r)$ at is derived from the Histogram construction step in the training stage, Equation (3), as follows

$$\hat{v}_k(r) = v_k(g_2(r), g_3(r), g_4(r)). \quad (5)$$

According to the GMMF model, the marginal empirical distributions $p(r)$ should be similar to the likelihood $\hat{v}(r)$ of the observations in site r and they change smoothly in the lattice \mathcal{L} . The smoothing grade depends on the parameter λ .

The field $p(r)$ is computed through a Gauss-Saidel approach, see equation (6)

$$p_k(r) = \frac{\hat{v}_k(r) + \lambda \sum_{s \in \mathcal{N}_r} p_k(s)}{1 + \lambda |\mathcal{N}_r|}, \quad (6)$$

where λ is the smoother parameter, r indicates the pixel in the image, s denotes the neighbors of pixel r considering 4-connectivity. Once the vector field p is estimated the optimal label field, $f(r)$ is computed as the mode of each vector $p(r)$

$$f(r) = \arg \max_{k \in \{1,2,\dots,K\}} p_k(r). \quad (7)$$

3 Experiments and Discussion

In the experiment a real 7-band satellite image Lansat-5 of size 2517×2800 pixels¹ was used. This image corresponds to Guadalajara and Zapopan regions and theirs surroundings in Jalisco state, México in 2011 [13], see Fig. (3). The experimental work also included 4 synthetic images obtained from the real one. The aim in each experiment is to identify 8 types of crops Table (2).

Identification of the crops mentioned in the Table 2, has been of great interest for the statistical analysis of the growth or decrease of urban areas, because of

¹ Image provided by the Instituto de Información Territorial del Estado de Jalisco, México (IITEJ).




Fig. 3. Lansat-5 TM satellite image from Jalisco, México

Table 2. Types of crops studied in the proposed algorithm

Class	Crop Name
C1	Irrigation agriculture
C2	Seasonal agriculture
C3	Forest
C4	Scrub
C5	Pastureland
C6	Green area
C7	Aquatic vegetation
C8	Riparian vegetation

relation between the population growth and the mentioned crops. However, the recognition task is very difficult due the similarity of the spectral characteristics for the 8 types of analyzed crops.

Below we discuss about the experimental work done in this research.

Table 3 shows a comparison of our approach with 4 reported methods: Echo spectral-spatial (ESS) [9], [10], Fisher Linear Likelihood (FLL) [7], Maximum Likelihood (ML) [11] and Minimum Euclidean Distance (MED) [12]. We used the implementation reported in <https://engineering.purdue.edu/~biehl/MultiSpec/hyperspectral.html> for programing the methods in the comparison.

Note that our proposal has the better overall accuracy and Kappa value. However the classes 6, 7 and 8 present a poor individual classification accuracy. The similarity of these mentioned classes with water bodies affected the classification process by our proposal. Fig. 4 shows the segmentation results obtained by our proposal and by ESS, which was the second best result according to the overall accuracy and Kappa values. The solution given by ESS presents more granularities than our solution, see Fig.4.




Fig. 4. (a) Ground truth, (b) segmentation results obtained by the proposed algorithm, (c) segmentation results by ESS

Table 3. Numerical results of different classification methods

Method	C1	C2	C3	C4	C5	C6	C7	C8	OverAll Accuracy	Kappa
ESS	0.80	0.41	0.31	0.75	0.56	0.09	0.18	0.09	0.7773	0.6880
FLL	0.43	0.35	0.39	0.74	0.79	0.10	0.36	0.16	0.7770	0.6867
ML	0.54	0.40	0.30	0.73	0.61	0.11	0.29	0.29	0.7676	0.6751
MED	0.15	0.22	0.53	0.77	0.89	0.11	0.24	0.13	0.7721	0.6768
The Proposal	0.75	0.90	0.65	0.90	0.45	0.003	0.03	0.0003	0.8962	0.8499

Additionally, other experiments were performed using 4 synthetic images. Results of the segmentation of these synthetic images are depicted in Fig. 5.

As you can see the classification done by ESS method have a good performance, however some classes are missed. On the other hand in the segmentation obtained by our proposal, the majority of the classes are identified more accurately. Table 4 and Table 5 present numerical results about the performance of the ESS and our approach respectively. The notation I1, I2, I3, I4 in Tables 4 and 5 is related to the images represented in the first row in Fig. 5, from the left to the right.

Table 4. Segmentation results for synthetic images using ESS

Image	C1	C2	C3	C4	C5	C6	C7	C8	OverAll Accuracy	Kappa
I1	0.94	0.97	0.98	0.97	0.98	0.90	0.98	0.49	0.952	0.942
I2	0.87	0.97	0.98	0.97	0.98	0.89	0.96	0.49	0.934	0.921
I3	0.95	0.98	0.98	0.96	0.98	0.97	0.97	0.01	0.942	0.927
I4	0.95	0.98	0.98	0.97	0.98	0.96	0.98	0.32	0.951	0.939




Fig. 5. Segmentation of synthetic images. In the first row are depicted synthetic images, the second one represents the results obtained by ESS and the last row illustrated the segmented images by our proposal.

Table 5. Segmentation results for synthetic images using our proposal

Image	C1	C2	C3	C4	C5	C6	C7	C8	OverAll Accuracy	Kappa
I1	0.998	1.000	0.993	0.998	0.998	0.021	0.845	0.884	0.974	0.967
I2	0.977	1.000	0.995	0.982	0.989	0.264	0.806	0.800	0.947	0.936
I3	0.815	0.998	0.991	0.989	0.988	0.833	0.704	0.919	0.942	0.928
I4	0.913	0.992	0.987	0.988	0.991	0.691	0.856	0.736	0.928	0.913

Numerical results in Tables 4 and 5 together with the graphical representation in Fig. 5 demonstrated, in general, the good performance of the proposed segmentation strategy. In order to avoid the misclassification for the classes 6,7 and 8 we are conducting a research with other probabilistic approaches different to GMMF, like those reported in[3], [1], [2].

4 Conclusions

The proposed algorithm takes into account pixel information with contextual information from neighboring pixels. The proposal is based on the histogram information and the probabilistic approach called GMMF. We are addressing the

current research with other probabilistic frameworks that have more computational complexity, but more accurate and robust when the features of the objects to recognize are similar.

Acknowledgments. The authors wish to thank IITEJ, especially to Guillermo Levine Gutiérrez, Maximiliano Bautista Andalón and Ana Teresa Ortega Minakata, for having supported with the ground truth and information needed for this research.

References

1. Dalmau, O., Rivera, M.: A general bayesian markov random field model for probabilistic image segmentation. In: Wiederhold, P., Barneva, R.P. (eds.) IWCIA 2009. LNCS, vol. 5852, pp. 149–161. Springer, Heidelberg (2009)
2. Dalmau, O., Rivera, M.: Beta-measure for probabilistic segmentation. In: Sidorov, G., Hernández Aguirre, A., Reyes García, C.A. (eds.) MICAI 2010, Part I. LNCS, vol. 6437, pp. 312–324. Springer, Heidelberg (2010)
3. Dalmau, O., Rivera, M.: Alpha markov measure field model for probabilistic image segmentationl 412(15), 1434–1441 (2011)
4. Duda, R.O., Hart, P.E.: Pattern Classification and Scene Analysis. Wiley (1973)
5. Hastie, T., Tibshirani, R., Friedman, J.: The elements od Statical Learning. Data Mining, Inference, and Prediction. Springer (2001)
6. José, L., Marroquín, S.B., Calderón, F., Vemuri, B.C.: The mpm-map algorithm for image segmentation. Pattern Recognition 1, 303–308 (2000)
7. Karakahya, H., Yazgan, B., Ersoy, O.K.: A spectral-spatial classification algorithm for multispectral remote sensing data. In: ICANN, pp. 1011–1017 (2003)
8. Kavzoglu, T., Mather, P.M.: The use of backpropagating artificial neural networks in land cover classification. Int. J. Remote Sensing 24(23), 4907–4938 (2003)
9. Kettig, R.L., Landgrebe, D.A.: Computer classification of remotely sensed multispectral image data by extraction and classification of homogeneous objects. IEEE Transactions on Geoscience Electronics 14(1), 19–26 (1976)
10. Landgrebe, D.: The development of a spectral-spatial classifier for earth observational data. Pattern Recognition 12(3), 165–175 (1980)
11. Omkar, S.N., Senthilnath, J., Mudigere, D., Kumar, M.M.: Crop classification using biologically-inspired techniques with high resolution satellite image. Journal of the Indian Society of Remote Sensing 36(2), 175–182 (2008)
12. Peuquet, D.J.: An algorithm for calculating minimum euclidean distance between two geographic features. Computers & Geosciences 18(8), 989–1001 (1992)
13. Pulido, H.G., Andalón, M.B., Rubio, M.G.: Jalisco territorio y problemas de desarrollo. Iterritorial (2013)
14. Su, B., Noguchi, N.: Agricultural land use information extraction in miyajimanuma wetland area based on remote sensing imagery. Environmental Control in Biology 50(3), 277–287 (2012)
15. Tomasi, C., Manduchi, R.: Bilateral filtering for gray and color images. In: ICCV, pp. 839–846 (1998)
16. Wang, H., Zhang, J., Xiang, K., Liu, Y.: Classification of remote sensing agricultural image by using artificial neural network. In: International Workshop on Intelligent Systems and Applications, pp. 1–4 (2009)

Apéndice E

Artículo MICAI 2015

Classification of Different Vegetation Types Combining Two Information Sources Through a Probabilistic Segmentation Approach

Francisco E. Oliva¹ (✉), Oscar S. Dalmau², Teresa E. Alarcón¹,
and Miguel De-La-Torre¹

¹ Centro Universitario de los Valles, Universidad de Guadalajara,
Ameca, Jalisco, Mexico

{francisco.oliva,teresa.alarcon,
miguel.delatorre}@profesores.valles.udg.mx

² Centro de Investigación en Matemáticas, Guanajuato, Mexico
dalmau@cimat.mx

Abstract. In this work we propose a new probabilistic segmentation model that allows us to combine more than one likelihood. The algorithm is applied to identify vegetation types in images from Landsat 5 satellite. Firstly, we obtain histograms from two information sources: spectral bands and principal components obtained from vegetation indices. Then, given an image, we compute two likelihoods of pixels to belong to each class (vegetation type), one for each source of information. The computed likelihoods are the inputs of the proposed probabilistic segmentation algorithm. This algorithm gives an estimation of the probability of a pixel of belonging to a class. The final segmentation is easily obtained by maximizing the estimated discrete probability for each pixel of the image. Experiments with real data show that the proposed algorithm obtains competitive results compared with state of the art algorithms.

Keywords: Probabilistic segmentation · Remote sensing · Vegetation indices · Histogram

1 Introduction

There are different approaches for extracting and classifying vegetation in remotely sensed imagery, some of them are: Artificial Neural Networks (ANNs) [32], Maximum Likelihood Classifier (ML) [22], Particle Swarm Optimization (PSO), Minimum Euclidean Distance (MED) [28], ECHO (Extraction and Classification of Homogeneous Objects) Spectral Spatial classifier (ESS) [15, 16], Fisher Linear Likelihood (FLL) [13] and probabilistic approach [21] among others. On the other hand, vegetation indices (VI) are one of the methods employed to enhance the vegetation information. These indices are a result of algebraic operations in which two or more spectral bands are combined [8]. The design of vegetation indices is based on the spectral signature of the vegetation

and they are widely used to analyze and monitor temporal and spatial variations of crop patterns [30]. VIs that are computed through visible and near-infrared spectral regions such as: Normalized Difference Vegetation Index (NDVI) [26], Green Normalized Difference Vegetation Index (GNDVI) [29], Renormalized Difference Vegetation Index (RDVI) [11], Modified Simple Ratio (MSR) [11], Green Chlorophyll Index (CI) [5], Enhanced Vegetation Index (EVI) [7], Wide-Dynamic Range Vegetation Index (WDRVI) [6], Soil-Adjusted Vegetation Index (SAVI) [12], Modified SAVI (MSAVI) [2] and Atmospherically Resistant Vegetation Index (SARVI) [14] among others are indices reported to examine the different spectral responses of the crop and for assessing the influence of background soil. In [23] several vegetation indices are explored and together with textural features derived from visible, near-infrared and short-wave infrared bands of ASTER satellite, a Decision Tree [19] is constructed to classify 13 types of crops. In [30] NDVI, GNDVI and Normalized Difference Red Edge Index (NDRE) [1, 33] derived from Rapid Eye imagery, are investigated and the effect of each one is studied for classification accuracy by means of a Support Vector Machine [31].

The similarity of spectral characteristic of some agricultural classes, the spectral variability of the canopy reflectance, and the bare soil background together with the presence of mixed pixels at the boundary between classes, lead to a complex process of crops classification [4, 23]. For that reason the conventional pixel based methodology is not enough to discriminate different crops, and it is necessary to incorporate the contextual information to diminish the misclassification rate. The work described in [23] is an example of the technique based on objects, in order to include contextual information around the pixel. In [21] an algorithm was elaborated in which pixel information is combined with local information through a Gaussian Markov Measure Fields (GMMF) [18]. The works proposed in [21, 23, 30] lead to improve the discrimination of crops, however the classification accuracy could be improved. In [21], an algorithm that combines the use spectral bands with a probabilistic segmentation algorithm was presented, this approach proved to be successful in comparison with other algorithms. Based on the previous approaches and by taking into consideration the advantages of vegetation indices to examine vegetation, we propose an algorithm that combines information from different sources: spectral bands and principal components obtained from vegetation indices. For the final segmentation we propose a new probabilistic segmentation model, which is based on GMMF [18]. This new approach results in a *fusion probabilistic segmentation algorithm*. Although we apply this algorithm to detect vegetation types in remote sensing images, the formulation is more general and could be applied to other types of segmentation problems in which the feature space comes from different sources.

The structure of this work is as follows. Section 2 describes in detail of the proposed algorithm. Section 3 presents experiments along with the discussion of the results and finally, Sect. 4 presents the conclusions.

2 Classification Algorithm

The segmentation approach has three stages. In the first stage we obtained histograms from two information sources: spectral bands and principal components obtained from vegetation indices. Then, given an image, we compute two likelihoods of pixels to belong to each class (vegetation type), one for each source of information. For the final segmentation we propose a new probabilistic segmentation model, which is based on a modification to the GMMF model, that allows us to combine more than one likelihood. We explain the details in next subsections.

2.1 Histogram Computation

We propose to compute two likelihood sources. As histograms give information about the likelihood of a pixel to belong to different classes, we first compute the corresponding histogram. For that, one needs to identify the features on which to build the histogram. In particular, we use the spectral bands [21], and principal components based on vegetation indices [2, 11, 12, 14, 26, 29]. On the other hand, we also use information about the classes provided by an expert, which allows us to obtain the histograms, i.e., using a supervised learning. Let us denote the normalized histogram as:

$$h(x_1, x_2, x_3; k) \propto N(x_1, x_2, x_3; k), \quad (1)$$

$$\sum_{x_1, x_2, x_3} h(x_1, x_2, x_3; k) = 1, \quad \forall k \in \mathcal{K}, \quad (2)$$

where K is the number of classes, $\mathcal{K} = \{1, 2, \dots, K\}$, (x_1, x_2, x_3) corresponds to a 3D feature vector, for example, three spectral bands; and $N(x_1, x_2, x_3; k)$ denotes the number of times the feature vector (x_1, x_2, x_3) is in class k .

Spectral-Band Histogram. In this work, we use satellite images from LANSAT-5 Thematic Mapper. Therefore, and similar to [21], we use the color scheme TM432, i.e., spectral bands TM2, TM3 and TM4; to compute the histogram based on spectral bands. This, because it is well-known that the infrared (TM4), red (TM3) and green (TM2) bands provide information related to crops and are commonly used in vegetation studies. The Spectral-Band histogram is denoted as $h_{SB}(\dots; \cdot)$, see Eq. (1).

PCA-Vegetation Index Histogram. To compute the histogram based on vegetation indices, denoted here as $h_{PV}(\dots; \cdot)$ Eq. (1), we obtain the first 3 principal components computed on 10 vegetation indices. The vegetation indices are computed from reflectance values, ρ , of the acquired images. The reflectance values are calculated according to the algorithm in [3, 9, 10, 25, 34]. Table 1 shows the mathematical expressions for each examined spectral vegetation index where

Table 1. Explored vegetation indices. ρ_r , ρ_g , ρ_b and ρ_{NIR} denote the reflectance values for the red, blue, green and infrared bands respectively

Spectral vegetation index	Equation
MSR [11]	$\frac{\rho_{NIR} - 1}{\sqrt{\frac{\rho_r}{\rho_r + 1}}}$
CI [5]	$\frac{\rho_{NIR} - 1}{\rho_g}$
NDVI [30]	$\frac{\rho_{NIR} - \rho_r}{\rho_{NIR} + \rho_r}$
GNDVI [29]	$\frac{\rho_{NIR} - \rho_g}{\rho_{NIR} + \rho_g}$
EVI [7]	$2.5 \left[\frac{\rho_{NIR} - \rho_r}{1 + \rho_{NIR} + 6\rho_r - 7.5(\rho_b)} \right]$
SARVI [14]	$\frac{(1+L)(\rho_{NIR} - \rho_{rb})}{(\rho_{NIR} + R_{rb} + L)}$ $\rho_{rb} = \rho_r - \gamma(\rho_b - \rho_r)$
RDVI [11]	$\frac{\rho_{NIR} - \rho_r}{\sqrt{\rho_{NIR} + \rho_r}}$
SAVI [12]	$\frac{(1+L)(\rho_{NIR} - \rho_r)}{\rho_{NIR} + \rho_r + L}$
MSAVI [2]	$\frac{1}{2} \left[(2\rho_{NIR} + 1) - \sqrt{(2\rho_{NIR} + 1)^2 - 8(\rho_{NIR} - \rho_r)} \right]$
WDRVI [6]	$\frac{\alpha \times \rho_{NIR} - \rho_r}{\alpha \times \rho_{NIR} + \rho_r}$

ρ_r , ρ_g , ρ_b and ρ_{NIR} denote the reflectance values for the red, blue, green and infrared bands respectively. According to [12] we considered $L = 0.5$ to compute the SAVI and SARVI expressions. The authors of SARVI [14], recommended $\gamma = 1$. The images corresponding to the computed indices are shown in Fig. 1. Observe that in the obtained images the vegetation information is enhanced. Although the first four indices provide more details about vegetation regions, all the 10 indices were considered for the PCA.




Fig. 1. Images of the calculated vegetation indices. First column contains the ground truth. The remainder columns represent: in the first row from left to right MSR, CI, NDVI, GNDVI and EVI image indices; in the second row from left to right SARVI, RDVI, SAVI, MSAVI and WDRVI image indices.

2.2 Likelihood Computation

In order to compute the likelihood of a pixel $r \in \mathcal{L}$ to belong to a class k , where \mathcal{L} is the lattice of the image, one first obtains the corresponding feature vector $(x_1(r), x_2(r), x_3(r))$ and then assigns

$$v_k(r) \propto h(x_1(r), x_2(r), x_3(r); k), \quad (3)$$

such that $\sum_{k \in \mathcal{K}} v_k(r) = 1$. Note that, we need to compute the likelihood for both information sources, i.e., based on *Spectral-Band Histogram* and *PCA-Vegetation Index Histogram*.

2.3 Segmentation Approach

In the previous section, we provided two ways to compute the likelihood of pixels to belong to a class. The challenge is how to combine both information sources in order to get a good segmentation result. Here, we present a segmentation model for probabilistic segmentation, that allows us to compute the discrete probability of each pixel to belong to a class (vegetation type). This model is based on the GMMF algorithm [17] and allows us to combine two likelihoods that come from two information sources.

$$\mathbf{p}^* = \arg \min_{\mathbf{p}} \sum_{r \in \mathcal{L}} \sum_{k \in \mathcal{K}} \sum_{i=1}^2 \omega_i(r) (p_k(r) - v_k^i(r))^2 + \lambda \sum_{s \in \mathcal{N}_r} (p_k(r) - p_k(s))^2, \quad (4)$$

where $v^i(r)$ is the likelihood that comes from the i -th source, $\lambda > 0$ is a regularization parameter, \mathcal{N}_r represents a set of neighboring pixels to the pixel r . The weight function $\omega_i(r)$ is given by

$$\omega_i(r) = \begin{cases} 1 & \text{if } \mathcal{E}(v^i(r)) < \mathcal{E}(v^{3-i}(r)) \\ 0 & \text{otherwise,} \end{cases} \quad (5)$$

$i \in \{1, 2\}$ and $\mathcal{E}(\cdot)$ is an entropy measure, for example, Shannon's entropy [27]. In the experiment we use the Gini impurity index, i.e.,

$$\mathcal{E}(\mathbf{f}) = 1 - \mathbf{f}^T \mathbf{f}, \quad (6)$$

such that $\mathbf{1}^T \mathbf{f} = 1$, $\mathbf{f} \succeq 0$. The solution of the optimization problem (4) yields the following Gauss-Seidel scheme

$$p_k(r) = \frac{\sum_{i=1}^2 \omega_i(r) v_k^i(r) + \lambda \sum_{s \in \mathcal{N}_r} p_k(s)}{1 + \lambda |\mathcal{N}_r|}. \quad (7)$$

According to Eq. (7) the weight function basically selects one likelihood for each pixel. The final segmentation is obtained by using 'the winner takes it all'

strategy, i.e., given the vector field \mathbf{p}^* , Eq. (4), the segmentation is computed with the following equation:

$$s(r) = \arg \max_{k \in \mathcal{K}} p_k(r), \forall r \in \mathcal{L}. \quad (8)$$

In the experiment we use

$$v_k^1(r) \propto h_{SB}(x_1(r), x_2(r), x_3(r); k), \quad (9)$$

$$v_k^2(r) \propto h_{PV}(y_1(r), y_2(r), y_3(r); k), \quad (10)$$

where $(x_1(r), x_2(r), x_3(r))$, $(y_1(r), y_2(r), y_3(r))$ are 3D feature vectors obtained from the selected spectral bands and the first 3 principal components computed on 10 vegetation indices.

3 Experiments and Discussion

3.1 Study Area

The study area is located in western México at coordinates Lat. $20^\circ 39' 58''$ N, Long. $103^\circ 21' 7''$ W, an altitude of 1550 m above sea level, in the geographical area known as Valle de Atemajac [24]. The examined vegetation species are: irrigation agriculture (C1), seasonal agriculture (C2), forest (C3), scrub (C4), pastureland (C5), green area (C6), aquatic vegetation (C7) and riparian vegetation (C8), Fig. 2.

3.2 Data Sources

Data sources are from Landsat 5 TM satellite imagery. The images have resolution of 30 m and 2^8 radiometric resolution. The studied images correspond to March 1st 2011. Data was delivered in level 1T, in which geometric correction was applied [20]. These multispectral images were obtained from the




Fig. 2. Study area: Lansat-5 TM satellite image from Guadalajara Jalisco, México.

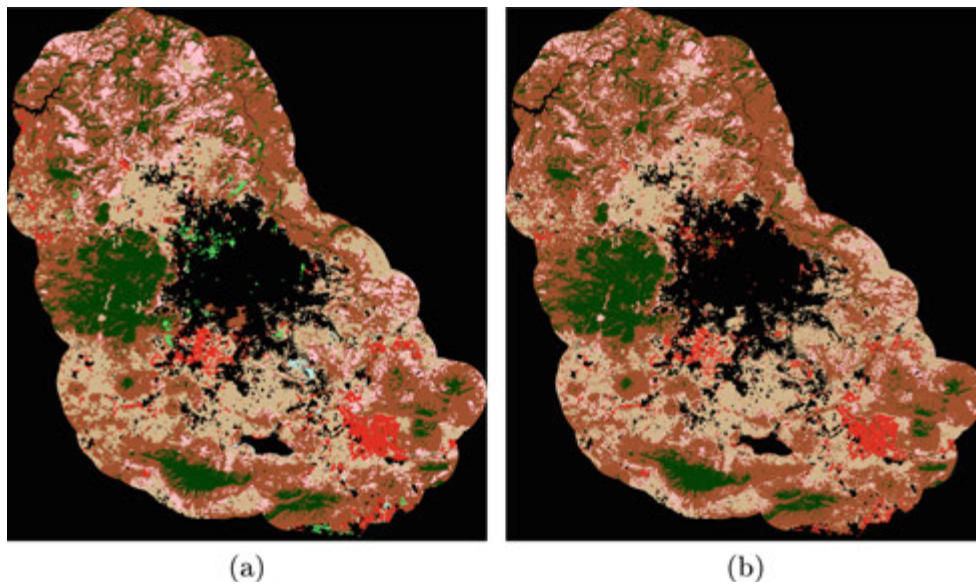


Fig. 3. (a) Ground truth, (b) segmentation result by the new proposal

Table 2. Numerical results of different classification methods

Method	C1	C2	C3	C4	C5	C6	C7	C8	Overall accuracy	Kappa
ESS	0.80	0.41	0.31	0.75	0.56	0.09	0.18	0.09	0.7773	0.6880
FLL	0.43	0.35	0.39	0.74	0.79	0.10	0.36	0.16	0.7770	0.6867
ML	0.54	0.40	0.30	0.73	0.61	0.11	0.29	0.29	0.7676	0.6751
MED	0.15	0.22	0.53	0.77	0.89	0.11	0.24	0.13	0.7721	0.6768
Proposal in [21]	0.75	0.90	0.65	0.90	0.45	0.003	0.03	0.0003	0.8962	0.8499
Our Proposal	0.69	0.84	0.87	0.92	0.54	0.04	0.06	0.02	0.9120	0.8731

USGS Global Visualization Viewer site (<http://glovis.usgs.gov/>). For comparison purposes and error analysis, the explored image was manually segmented by experts¹, see Fig. 3(a).

3.3 Experimental Work

Figure 3 shows the labeled image by an expert and the segmentation results obtained by our new approach.

Table 2 shows a comparison of our approach with five different reported methods, whose numerical results are taken from [21]. C1, C2, C3, C4, C5, C6, C7 and C8 denote the study classes mentioned in Sect. 3.1. According to the numerical result in Table 2, the overall accuracy and the kappa index reached by our proposal are competitive with state of the art algorithms, obtaining an improvement in both measures, with respect to the algorithm proposed in [21]. Note that the classification of classes C2, C3 and C4 is good. Nevertheless, classes C6, C7

¹ The experts work at Land Information Institute of Jalisco (IITEJ).

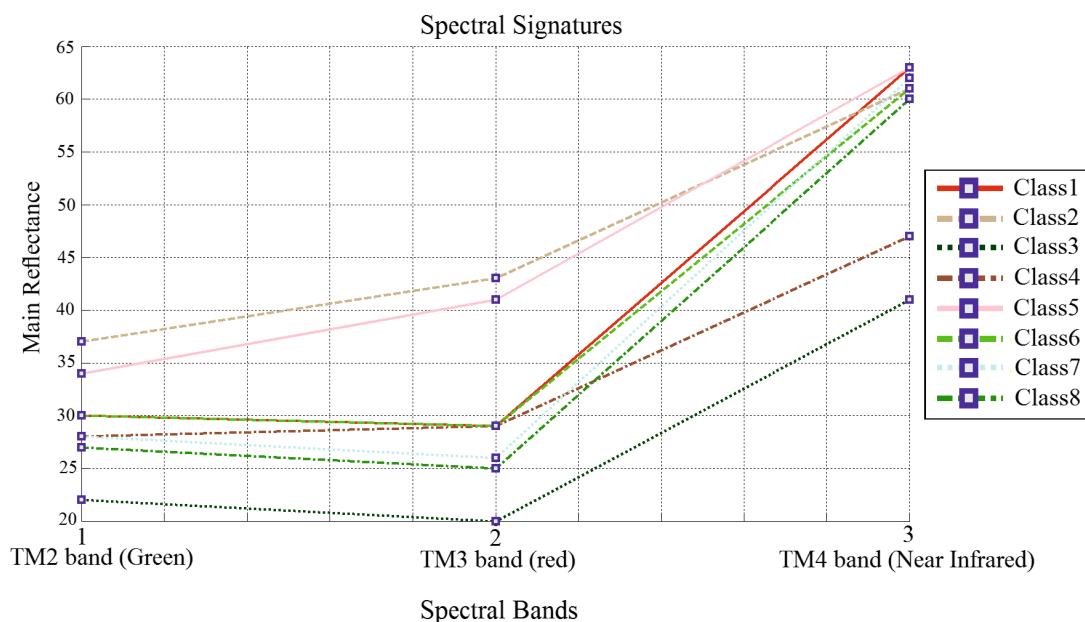


Fig. 4. Mean reflectance values for the TM432 bands for each vegetation type under study (Color figure online).

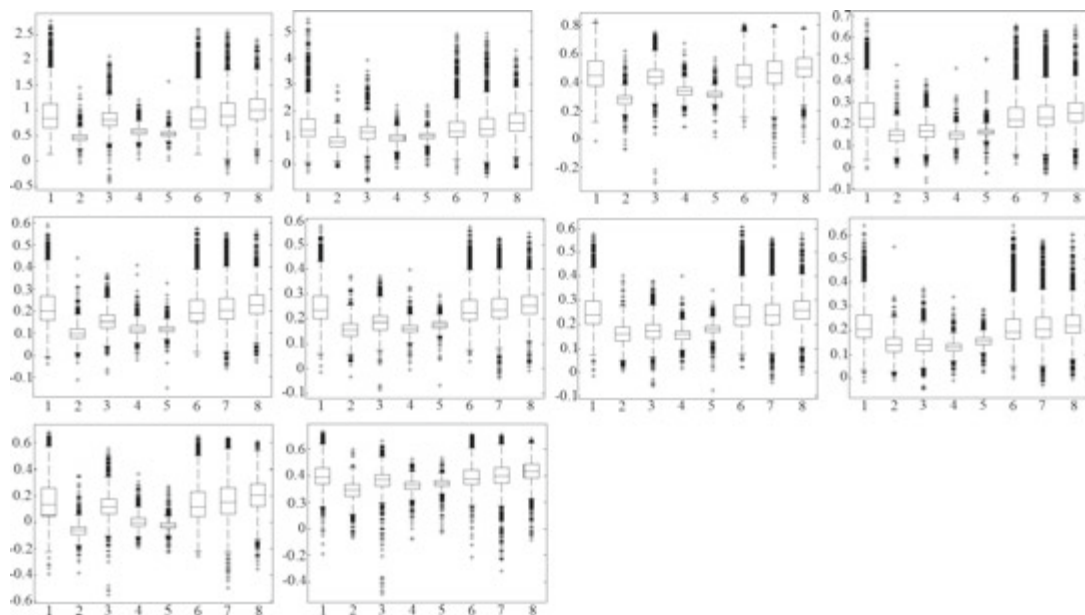


Fig. 5. Boxplot vegetation index per classes. First row (from left to right): boxplot for MSR, CI, NDVI and GNDVI indices. Second row (from left to right): EVI, SARVI, RDVI and SAVI indices. Third row (from left to right): boxplot for MSAVI and WDRVI indices.

and C8 present a poor classification. On the other hand, the algorithm presented in [21] and our approach present the worse results for classes C6, C7 and C8. In order to understand the misclassification of the proposed algorithm, we show in

Fig. 4 the mean reflectance values in the color scheme TM432 under study. The Figure depicts the spectral signatures of the eight classes for all experiments. As we can see, classes C1 and C6 overlap in some bands; similarly classes C7 and C8 appear very close in all bands, which leads to misclassification of these classes.

Furthermore, Fig. 5 depicts the boxplot by class for each vegetation index. Observe that, the mean value of class C1 is similar to the mean value of classes C6, C7 and C8; and the variance of class C1 is, for almost all indices, greater than the variance of classes C6, C7 and C8. This can help to comprise the misclassification of these classes when using the vegetation indices.

This insight allows us to take into account two possible strategies in order to tackle this problem. One alternative is a hierarchical solution, in which, for the first level only 5 classes $C0 = \{C1, C6, C7, C8\}$, C2, C3, C4, C5 are considered; and in a second level, a refinement could be carried out with the estimated C0, by classifying C0 in 4 classes. Another strategy is to improve the feature space or to propose new indices or features that discriminate better these classes. Both strategies are beyond the scope of this work.

4 Conclusions

We proposed a new probabilistic segmentation model that combines more than one likelihood. This new approach results in a *fusion probabilistic segmentation algorithm*. In this work, the algorithm was applied to detect vegetation types in remote sensing images, however, our formulation is more general and can be applied on other types of segmentation problems in which the feature space comes from different sources. In particular, for solving the segmentation of vegetation types, here we proposed to combine the information of spectral bands and principal components obtained from vegetation indices. Experiments with real images show that the proposed algorithm obtains competitive results compared with algorithms found in the literature.

Acknowledgments. We thank Maximiliano Bautista Andalón and Ana Teresa Ortega Minakata, members of Land Information Institute of Jalisco (IITEJ), for providing the ground truth images and the required information for this research.

References

1. Barnes, E.M., Clarke, T.R.: Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data. In: Proceedings of the Fifth International Conference on Precision Agriculture (2000)
2. Broge, N.H., Leblanc, E.: Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. *Remote Sens. Environ.* **76**(2), 156–172 (2001)
3. Chen, D., Huan, J., Jackson, T.J.: Vegetation water content estimation for corn and soybeans using spectral indices derived from modis near- and short-wave infrared bands. *Remote Sens. Environ.* **98**, 225–236 (2005)

4. De Wit, A.J.W., Clevers, J.G.P.W.: Efficiency and accuracy of per-field classification for operational crop mapping. *Int. J. Remote Sens.* **25**(20), 4091–4112 (2004)
5. Gitelson, A.A., Merzlyak, M.N.: Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *J. Plant Physiol.* **160**(3), 271–282 (2003)
6. Gitelson, A.A.: Wide dynamic range vegetation index for remote quantification of biophysical characteristics of vegetation. *J. Plant Physiol.* **161**(2), 165–173 (2004)
7. Huete, A.R., Liu, H., Batchily, K., Van Leeuwen, W.: A comparison of vegetation indices over a global set of TM images for EOS-MODIS. *Elsevier* **59**, 440–451 (1997)
8. Jackson, R.D., Huete, A.R.: Interpreting vegetation indices. *Remote Sens. Environ.* **8**(2), 185–200 (1979)
9. Ji, L., Zhang, L., Bruce, W.: Analysis of dynamic thresholds for the normalized difference water index. *Photogram. Eng. Remote Sens.* **75**(11), 1307–1317 (2009)
10. Jiang, H., Feng, M., Zhu, Y., Lu, N., Huang, J., Xiao, T.: An automated method for extracting rivers and lakes from landsat imagery. *Remote Sens.* **6**(6), 5067–5089 (2014)
11. Jordan, C.: Derivation of leaf area index from quality of light on the forest floor. *Ecology* **50**(4), 663–666 (1969)
12. Jordan, C.: A soil-adjusted vegetation index (SAVI). *Remote Sens. Environ.* **25**(3), 295–309 (1988)
13. Karakahya, H., Yazgan, B., Ersoy, O.K.: A spectral-spatial classification algorithm for multispectral remote sensing data. In: Kaynak, O., Alpaydın, E., Oja, E., Xu, L. (eds.) ICANN 2003 and ICONIP 2003. LNCS, vol. 2714, pp. 1011–1017. Springer, Heidelberg (2003)
14. Kaufman, Y., Tanre, D.: Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. *Geosci. Remote Sens.* **30**(2), 261–270 (1992)
15. Kettig, R.L., Landgrebe, D.A.: Computer classification of remotely sensed multi-spectral image data by extraction and classification of homogeneous objects. *IEEE Trans. Geosci. Electron.* **14**(1), 19–26 (1976)
16. Landgrebe, D.: The development of a spectral-spatial classifier for earth observational data. *Pattern Recogn.* **12**(3), 165–175 (1980)
17. Marroquín, J.L., Botello, S., Calderón, F., Vemuri, B.C.: The MPM-MAP algorithm for image segmentation. *Pattern Recogn.* **1**, 303–308 (2000)
18. Marroquin, J.L., Velasco, F.A., Rivera, M., Nakamura, M.: Gauss-markov measure field models for low-level vision. *IEEE Trans. Pattern Anal. Mach. Intell.* **23**(4), 337–348 (2001)
19. Moore, D.M., Lees, B.G., Davey, S.M.: A new method for predicting vegetation distributions using decision tree analysis in a geographic information system. *Environ. Manage.* **15**(1), 59–71 (1991)
20. Northrop, A., Team, L.S.: Ideas-lansat products description document. Technical report, Telespazio VEGA UK Ltd. (2015)
21. Oliva, F.E., Dalmau, O.S., Alarcón, T.E.: A supervised segmentation algorithm for crop classification based on histograms using satellite images. In: Gelbukh, A., Espinoza, F.C., Galicia-Haro, S.N. (eds.) MICAI 2014, Part I. LNCS, vol. 8856, pp. 327–335. Springer, Heidelberg (2014)
22. Omkar, S.N., Senthilnath, J., Mudigere, D., Kumar, M.M.: Crop classification using biologically-inspired techniques with high resolution satellite image. *J. Indian Soc. Remote Sens.* **36**(2), 175–182 (2008)

23. Pena-Barragán, J., Ngugi, M., Plant, R., Six, J.: Object-based crop identification using multiple vegetation indices, textural features and crop phenology. *Remote Sens. Environ.* **115**, 1301–1316 (2011)
24. Pulido, H.G., Bautista, A.M., Guevara, R.M.: *Jalisco territorio y problemas de desarrollo. iterritorial* (2013)
25. Rokni, K., Ahmad, A., Selamat, A., Hazini, S.: Water feature extraction and change detection using multitemporal landsat imagery. *Remote Sens.* **6**(5), 4173–4189 (2014)
26. Rouse, J.W., Haas, R.H., Schell, J.A., Deering, D.W., Harlan, J.C.: Monitoring the vernal advancements and retrogradation of natural vegetation. Technical report, NASA/GSFC (1974)
27. Shannon, C.E.: A mathematical theory of communication. *Bell Syst. Tech. J.* **27**, 379–423 (1948)
28. Su, B., Noguchi, N.: Agricultural land use information extraction in miyajimanuma wetland area based on remote sensing imagery. *Environ. Control. Biol.* **50**(3), 277–287 (2012)
29. Tucker, C.J.: Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sens. Environ.* **8**(2), 127–150 (1979)
30. Ustuner, M., Sanli, F., Abdikan, S., Esetlili, M., Kurucu, Y.: Crop type classification using vegetation indices of rapideye imagery. In: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, pp. 195–198 (2014)
31. Vapnik, V.N.: *The Nature of Statistical Learning Theory*. Springer, New York (2001)
32. Wang, H., Zhang, J., Xiang, K., Liu, Y.: Classification of remote sensing agricultural image by using artificial neural network. In: *International Workshop on Intelligent Systems and Applications*, pp. 1–4, May 2009
33. Weichelt, H., Rosso, P., Marx, A., Reigber, S., Douglass, K., Heynen, M.: The rapideye red edge band. Technical report, BlackBridge (2012)
34. Yashon, O., Tateishi, R.: A water index for rapid mapping of shoreline changes of five east african rift valley lakes: an empirical analysis using landsat TM and ETM+ data. *Int. J. Remote Sens.* **27**(15), 3153–3181 (2006)

Referencias

- [1] Akaike, H. (1998). Information theory and an extension of the maximum likelihood principle. *Selected Papers of Hirotugu Akaike 1*, 199–213.
- [2] Alarcón, T. E. (2007, Mayo). *Segmentación lingüística del color mediante un modelo Bayesiano jerárquico*. Doctor en ciencias de la computación, Centro de Investigación en Matemáticas A.C.
- [3] Anatoly, A. G., N. M. Mark, and K. L. Hartmut (1996). Detection of red edge position and chlorophyll content by reflectance measurements near 700 nm. *Journal of Plant Physiology* 148(3), 501–508".
- [4] Barmpoutis, A., B. C. Vemuri, M. S. Timothy, and J. R. Forder (2007). Tensor splines for interpolation and approximation of dt-mri with applications to segmentation of isolated rat hippocampi. *IEEE Transactions on Medical Imaging* 26, 1537–1546.
- [5] Barnes, E. M., T. Clarke, and S. E. Richards (2000). Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data. In *Proceedings of the Fifth International Conference on Precision Agriculture*.
- [6] Bauer, W. and G. D. Westfall. *Física para ingeniería y ciencias con física moderna*, Volume 2.
- [7] Baumgardner, M. F., L. L. Biehl, and D. A. Landgrebe (2015, Sep). 220 band aviris hyperspectral image data set, june 12, 1992 indian pine test site 3.
- [8] Bogoliubova, A. and P. Tymków (2014). Land cover changes and dynamics of yuntolovsky reserve. *Electronic Journal of Polish Agricultural Universities (EJPAU)* 17.

- [9] Broge, N. H. and E. Leblanc (2001, May). Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. *Remote Sens Environ* 76(2), 156–172.
- [10] Canada (1998). *Fundamentals of Remote Sensing*. Canada Centre for Remote Sensing.
- [11] Cerda L., J. and L. Villarroel del P. (2008). *Evaluación de la concordancia inter-observador en investigación pediátrica: Coeficiente de Kappa*, Volume 79. Bioestadística, Revista Chilena de Pediatría.
- [12] Chen, D., J. Huan, and T. J. Jackson (2005, July). Vegetation water content estimation for corn and soybeans using spectral indices derived from modis near and short wave infrared bands. *Remote Sensing of Environment* 98, 225–236.
- [13] Cheng, D. K. (1993). *Fundamentos de electromagnetismo para ingeniería*. Addison-Wesley.
- [14] Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educational and Psychological Measurement* 20, 37–46.
- [15] Dagum, C. (1997). Decomposition and interpretation of gini and the generalized entropy inequality measures. In *American Statistical Association*, pp. 200–205.
- [16] Dalmau, O. and M. Rivera (2011, Marzo). Alpha markov measure field model for probabilistic image segmentation. *Elsevier Science Publishers Ltd* 412(15), 1434–1441.
- [17] De Wit, A. J. W. and J. G. P. W. Clevers (2004). Efficiency and accuracy of per-field classification for operational crop mapping. *International Journal of Remote Sensing* 25(20), 4091–4112.
- [18] Donal, B. R. (1980). Bias reduction using mahalanobis metric matching. *International Biometric Society* 36, 293–298.
- [19] Duda, R. O., P. E. Hart, and D. G. Stork (2001). *Pattern Classification*. Wiley-Interscience.
- [20] Eastman, J. R. (2001). *IDRISI Guide to GIS and Image Processing*, Volume 1. Idrisi production.

- [21] Eceolaza, E., I. Oroz, and I. Zahino (2009). Aplicación de las técnicas de tratamiento de imágenes multiespectrales de satélite al estudio de la superficie terrestre. *Revista Didáctica ambiental* 8, 78–91.
- [22] Feynman, R. P., R. B. Leighton, and M. Sands (1964). *Electromagnetismo y materia*, Volume II. Addison-Wesley.
- [23] Fisher, R. A. (1932, 7). Inverse probability and the use of likelihood. *Mathematical Proceedings of the Cambridge Philosophical Society* 28, 257–261.
- [24] Geman, S. and D. Geman (1984). Stochastic relaxation, gibbs distributions and bayesian restoration of images. *IEEE-PAMI* 6, 721–741.
- [25] Gitelson, A. A. (2004, Noviembre). Wide dynamic range vegetation index for remote quantification of biophysical characteristics of vegetation. *Journal of Plant Physiology* 161(2), 165–173.
- [26] Gitelson, A. A. and M. N. Merzlyak (2003, Noviembre). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of Plant Physiology* 160(3), 271–282.
- [27] Graupe, D. (2007). *Principles of artificial neural networks*, Volume 6. World Scientific Publishing.
- [28] Hartigan, J. A. and M. Wong (1979). A k-means clustering algorithm. *Journal of the Royal Statistical Society. Series C (Applied Statistics)* 28, 100–108.
- [29] Hastie, T., R. Tibshirani, and J. Friedman (2001). *The elements of Statistical Learning. Data Mining, Inference, and Prediction*. Springer.
- [30] Hazewinkel, M. (2001). *Maximum likelihood method*. Encyclopedia of Mathematics, Springer.
- [31] Hecht, E. (2002). *Fundamentos de electromagnetismo para ingeniería*, Volume 4. Addison-Wesley.
- [32] Huete, A. R., H. Liu, K. Batchily, and W. Van Leeuwen (1997, April). A comparison of vegetation indices over a global set of tm images for eos-modis. *Elsevier* 59, 440–451.

- [33] Jackson, R. D. and A. R. Huete (1979). Interpreting vegetation indices. *Remote Sensing of Environment* 8(2).
- [34] Jain, A. and C. Dubes (1988). *Algorithm for clustering data*. Prentice-Hall.
- [35] Ji, L., L. Zhang, and W. Bruce (2009, Noviembre). Analysis of dynamic thresholds for the normalized difference water index. *Photogrammetric Engineering and Remote Sensing* 75(11), 1307–1317.
- [36] Jiang, H., M. Feng, Y. Zhu, N. Lu, J. Huang, and T. Xiao (2014, May). An automated method for extracting rivers and lakes from landsat imagery. *Remote Sensing* 6(6), 5067–5089.
- [37] Jolliffe, I. T. (1986). *Principal Component Analysis*. Berlin; New York: Springer-Verlag.
- [38] Jordan, C. (1969, July). Derivation of leaf area index from quality of light on the forest floor. *Ecology* 50(4), 663–666.
- [39] Jordan, C. (1988, August). A soil-adjusted vegetation index (savi). *Remote Sensing Environment* 25(3), 295–309.
- [40] Karakahya, H., B. Yazgan, and O. K. Ersoy (2003). A spectral-spatial classification algorithm for multispectral remote sensing data. In *ICANN*, pp. 1011–1017.
- [41] Kaufman, Y. and D. Tanre (1992, March). Atmospherically resistant vegetation index (arvi) for eos-modis. *Geoscience and Remote Sensing* 30(2), 261–270.
- [42] Kavzoglu, T. and P. M. Mather (2003, Diciembre). The use of backpropagating artificial neural networks in land cover classification. *Int. J. Remote Sensing* 24(23), 4907–4938.
- [43] Kennedy, J. and R. Eberhart (1995). Particle swarm optimization. In *Proceedings of IEEE International Conference on Neural Networks IV*, pp. 1942–1948.
- [44] Kettig, R. L. and D. A. Landgrebe (1976, Enero). Computer classification of remotely sensed multispectral image data by extraction and classification of homogeneous objects. *IEEE Transactions on Geoscience Electronics* 14(1), 19–26.
- [45] Khan, U., N. Minallah, A. Junaid, K. Gul, and N. Ahmad (2015, Diciembre). Parallelepiped and mahalanobis distance based classification for forestry identification in pakistan. In *2015 International Conference on Emerging Technologies (ICET)*, pp. 1–6.

- [46] Labrador García, M., J. A. Évora Brondo, and M. Arbelo Pérez (2012). *Satélites de tele-detección para la gestión de territorio*, Volume 5. Litografía Romero.
- [47] Landgrebe, D. A. (1980, Octubre). The development of a spectral-spatial classifier for earth observational data. *Pattern Recognition* 12(3), 165–175.
- [48] Landis, J. R. and G. G. Koch (1977, 03). The measurement of observer agreement for categorical data. *Biometrics* 33(1), 159–174.
- [49] Li., S. Z. (2001). *Markov random field modeling in image analysis*. Springer-Verlag Tokyo.
- [50] López de Ullibarri, G. I. and F. P. S. (1999). *Medidas de concordancia: el coeficiente kappa*. Cad aten primaria.
- [51] Marroquín, J. L., E. Arce, and S. Botello (2003). Hidden markov measure field models for image segmentation. *IEEE-PAMI* 25, 1380–1387.
- [52] Marroquín, J. L., S. Botello, F. Calderón, and B. C. Vemuri (2000, September). The mpm-map algorithm for image segmentation. *Pattern Recognition* 1, 303–308.
- [53] Marroquín, J. L., F. Velazco, M. Rivera, and M. Nakamura (2001). Gauss-markov measure field models for low-level vision. *IEEE-PAMI* 23, 337–348.
- [54] Marroquín, J. L., B. C. Vemuri, S. Botello, E. Calderon, and A. Fernandez-Bouzas (2002). An accurate and efficient bayesian method for automatic segmentation of brain mri. *IEEE Transactions on Medical Imaging* 21, 934–945.
- [55] Marroquín Zaleta, J. L., S. Botello, and M. Rivera (1998). Adaptive quantization and filtering using gauss-markov measure field models. In *Vision and Probabilistic Image Processing II*.
- [56] Michie, D., D. Spiegelhalter, and C. Taylor (1994). *Neural and Statistical Classification*. Machine Learning.
- [57] Mika, S., G. Ratsch, J. Weston, B. Scholkopf, and K. R. Mullers (1999). Fisher discriminant analysis with kernels. In *Neural Networks for Signal Processing IX*, pp. 41–48.
- [58] Nawaz, A., Z. Iqbal, and S. Ullah (2015, Septiembre). Performance analysis of supervised image classification techniques for the classification of multispectral satellite imagery. In

- 2015 *Fourth International Conference on Aerospace Science and Engineering (ICASE)*, pp. 1–5.
- [59] Oliva, F. E., O. S. Dalmau, and T. E. Alarcón (2014, Noviembre). A supervised segmentation algorithm for crop classification based on histograms using satellite images. *LNAI 8856: Human-Inspired Computing and Its Applications 13*, 327–335.
- [60] Oliva, F. E., O. S. Dalmau, T. E. Alarcón, and M. De-La-Torre (2015, Noviembre). Classification of different vegetation types combining two information sources through a probabilistic segmentation approach. *LNAI 8856: Human-Inspired Computing and Its Applications 14*, 327–335.
- [61] Peña Barragán, J., M. Ngugi, R. Plant, and J. Six (2011). Object-based crop identification using multiple vegetation indices, textural features and crop phenology. *Remote Sensing of Environment 115*, 1301–1316.
- [62] Pulido, H. G., A. M. Bautista, and R. M. Guevara (2013). *Jalisco territorio y problemas de desarrollo*. territorial.
- [63] Purcell, E. M. (1969). *Electricidad y magnetismo*, Volume 2. reverté.
- [64] Rivera, M., O. Ocegueda, and J. L. Marroquín (2005). Entropy controlled gauss-markov random measure field models for early vision. *VLSM, LNCS 3752*, 137–148.
- [65] Rojas Muriel, M. (2009, Diciembre). *Caracterización de imágenes hiperespectrales utilizando Support Vector Machines y técnicas de extracción de características*. Universidad de extremadura, Escuela Politécnica, Ingeniería Informática.
- [66] Rokni, K., A. Ahmad, A. Selamat, and S. Hazini (2014, May). Water feature extraction and change detection using multitemporal landsat imagery. *Remote Sensing 6*(5), 4173–4189.
- [67] Rouse, J. W., R. H. Haas, J. A. Schell, D. W. Deering, and J. C. Harlan (1974). Monitoring the vernal advancements and retrogradation of natural vegetation. Technical report, NASA/GSFC.
- [68] Safavian, S. R. and D. Landgrebe (1990). A survey of decision tree classifier methodology. Technical report, Purdue Univ. School of Electrical Engineering. West Lafayette, IN, United States.

- [69] Shannon, C. E. (1948, July). A mathematical theory of communication. *The Bell System Technical Journal*, 379–423.
- [70] Shi, Y. and R. Eberhart (1998, 5). A modified particle swarm optimizer. *Proceedings of IEEE International Conference on Evolutionary Computation*, 69–73.
- [71] Sierra Araujo, B. (2006). *Aprendizaje automático; : conceptos básicos y avanzados : aspectos prácticos utilizando el software Weka*. Prentice-Hall.
- [72] Su, B. and N. Noguchi (2012, Junio). Agricultural land use information extraction in miyajimanuma wetland area based on remote sensing imagery. *Environmental Control in Biology* 50(3), 277–287.
- [73] Thomas, I. L., V. M. Benning, and N. P. Ching (1987). *Classification of Remotely Sensed Images*. Bristol, Adam Hilger.
- [74] Thon, K., H. Rue, S. O. Skrovseth, and F. Godtliebsen (2012). Bayesian multiscale analysis of images modeled as gaussian markov random fields. *Computational Statistics and Data Analysis IEEE Transactions on Medical Imaging* 56, 49–61.
- [75] Tomasi, C. and R. Manduchi (1998). Bilateral filtering for gray and color images. In *ICCV*, pp. 839–846.
- [76] Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment* 8(2).
- [77] Ustuner, M., F. Sanli, S. Abdikan, M. Esetlili, and Y. Kurucu (2014). Crop type classification using vegetation indices of rapideye imagery. In *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, pp. 195–198.
- [78] Vapnik, V. N. (2001). *The Nature of Statistical Learning Theory*. Springer.
- [79] Vikesh, K., K. Vinod, and J. Kamal (2010). Development of spectral signature and classification of sugarcane using aster data. *International Journal of Computer Science Communication* 1, 245–251.
- [80] Wang, H., J. Zhang, K. Xiang, and Y. Liu (2009, Mayo). Classification of remote sensing agricultural image by using artificial neural network. *International Workshop on Intelligent Systems and Applications*, 1–4.

-
- [81] Weichelt, H., P. Rosso, A. Marx, S. Reigber, K. Douglass, and M. Heynen (2012). The rapideye red edge band. Technical report, BlackBridge.
- [82] Wolfowitz, J. (1957, 03). The minimum distance method. *Ann. Math. Statist.* 28(1), 75–88.
- [83] Yashon, O. and R. Tateishi (2006, August). A water index for rapid mapping of shoreline changes of five east african rift valley lakes: an empirical analysis using landsat tm and etm+ data. *International Journal of Remote Sensing* 27(15), 3153–3181.