



**I  
N  
A  
O  
E**

**Obtención y clasificación de píxeles mezclados  
generados por regiones de transición en imágenes  
satelitales**

Por

Jorge Morales Cruz

Tesis sometida como requisito parcial para obtener el grado de  
**DOCTOR EN CIENCIAS EN LA ESPECIALIDAD DE CIENCIAS  
COMPUTACIONALES**

Supervisada por:

Dr. Carlos A. Reyes García  
Dr. Jesús A. González Bernal

© Coordinación de Ciencias Computacionales  
INAOE

Luis Enrique Erro 1  
Sta. Ma. Tonantzintla,  
72840, Puebla, México.





## Agradecimientos

A mis asesores el Dr. Jesús A. González y el Dr. Carlos A. Reyes García por depositar su confianza en mí, por haberme guiado y apoyado en el transcurso de la tesis, pero sobre todo el conocimiento que ha compartido conmigo durante el desarrollo de este trabajo.

A mis sinodales la Dra. María del Pilar Gómez Gil, al Dr. Lepoldo Altamirano Robles, al Dr. Francisco Trinidad, al Dr. Enrique Sucar y al Dr. Oscar Catillo, por el tiempo dedicado a la revisión de esta tesis, así también como sus valiosos comentarios.

A los doctores de que me impartieron sus conocimientos a través de las materias cursadas en el INAOE.

A los doctores Juan Manuel Ramírez Cortés y José de Jesús Moreno Vásquez.

Al Consejo Nacional de Ciencia y Tecnología (CONACYT) por el apoyo otorgado con la beca No. 204415 y al Instituto Nacional de Astrofísica, Óptica y Electrónica (INAOE) por la formación académica.

## Dedicatoria

A Dios por concederme la realización de este sueño.

A mis padres por que siempre han estado conmigo para apoyarme.

A mi esposa y a mi hijo por que son mi fuente de inspiración.

A mis hermanos porque siempre han confiado en mi.

A mis amigos que comparten su tiempo y me acepta tal como soy.

## Resumen

Una imagen sensada remotamente es una representación simple de la forma en que la radiación interactúa con la superficie de la tierra. En una imagen sensada remotamente es posible observar distintos tipos de coberturas de suelo, tales como: cuerpos de agua, bosques, pastizales, zonas desérticas, construcciones hechas por el ser humano, etc. Estas coberturas son denominadas coberturas homogéneas que están formadas por píxeles puros (un solo tipo de cobertura de suelo). Por otra parte, es posible notar en una imagen satelital la presencia de píxeles mezclados. Estos píxeles mezclados son generados por la combinación de dos o más coberturas homogéneas.

En este trabajo de tesis se abordó el estudio de los píxeles mezclados generados por la transición gradual entre dos coberturas de suelo. Los píxeles mezclados contienen ambigüedad e incertidumbre por la forma en que se generan en la adquisición de la imagen digital. De esta manera, es de gran importancia conocer la cantidad y ubicación de los píxeles mezclados contenidos en una imagen satelital. La cantidad de píxeles mezclados depende de la resolución espacial y de los tipos de coberturas de suelo de la imagen satelital. Para resolver este problema se propuso un método para obtener los píxeles mezclados generados por una región de transición. Este método consiste en determinar las fronteras (límites definidos) entre las coberturas homogéneas y las regiones de transición (R<sub>ST</sub>) que contienen a los píxeles mezclados. Para llevar a cabo esta tarea, el proceso inicia con una segmentación basada en el crecimiento de regiones en el que se controla el *crecimiento* de cada cobertura homogénea. Los parámetros utilizados por el segmentador se obtienen utilizando Algoritmos Genéticos. Una vez localizadas las coberturas homogéneas en la imagen, se han delimitado los píxeles mezclados. Los resultados mostrados mejoran los encontrados usando otros métodos comerciales.

Resulta indispensable para el rendimiento de la clasificación de la imagen realizar el tratamiento adecuado de todos los píxeles que forman una imagen satelital. Clasificar a los píxeles puros usando métodos tradicionales y clasificar los píxeles mezclados usando métodos de clasificación suave. En este sentido se propuso un método para la clasificación de los píxeles mezclados que agrega información de las regiones de transición de las coberturas de suelo extraídas en una imagen satelital real. Se construyen curvas de pertenencia para ajustar la descomposición de cada píxel mezclado con respecto a cada cobertura homogénea presente en él. Los resultados obtenidos por el método propuesto mejoran hasta en un 17 % de exactitud los obtenidos por diversos clasificadores suaves.

## Abstract

A remotely sensed image is a representation of the way in which radiation interacts with the surface of the earth. In a remotely sensed image, it is possible to observe different types of land covers, such as water bodies, forests, grasslands, deserts zones, man-made constructions, etc. These land covers are known as homogeneous land covers that are formed by pure pixels (pixels representing a single type of land cover). Moreover, it is possible to observe the presence of mixed pixels in a satellite image. The mixing of two or more homogeneous land covers generates these mixed pixels.

In this thesis, we addressed the study of mixed pixels generated by the gradual transition between two land covers. Mixed pixels contain ambiguity and uncertainty in the way in which they are generated during the digital image acquisition process. Thus, it is of great importance to know the amount and location of mixed pixels contained in a satellite image. The mixed pixels count depends on the spatial resolution and the land cover types detected in the satellite image. To solve this problem, we proposed a method to obtain the mixed pixels generated by a transition region. This method determines the frontiers (defined boundaries) between homogeneous land covers and transition regions containing mixed pixels. In order to accomplish this task, the process starts with a region growing segmentation process, which controls the growth of each homogeneous land cover. The parameters used during the segmentation process are obtained through genetic algorithms. Once we located the homogeneous land covers present on the image, the mixed pixels have been identified. Our results show that we obtained a clear improvement to solve this problem compared with other commercial methods.

It is essential, for the performance of the satellite image classification task, to apply the proper technique to every pixel that composes the satellite image. In this way, we classify pure pixels by using traditional classification methods while we use soft classification methods for mixed pixels. Here, we proposed a method for the classification of mixed pixels that adds information about transition regions of land cover from a real satellite image. We generate membership curves in order to adjust the decomposition of each pixel with respect to each homogeneous land cover present in it. The results obtained with the proposed method improve up to 17% the accuracy of different soft classifiers.

# Contenido

I. Introducción.....	1
1.1 Fuentes de píxeles mezclados en imágenes satelitales.....	4
1.2 Obtención de regiones de transición (RsT) en imágenes satelitales .....	7
1.2.1 Obtención de las regiones de transición usando segmentación de imágenes.....	9
1.2.2 Clasificación de los píxeles mezclados que se localizan en las regiones de transición.	10
1.3 Problemática .....	11
1.4 Objetivos .....	13
1.4.1 Objetivo General .....	13
1.4.2 Objetivos Específicos.....	14
1.5 Descripción general de los métodos propuestos. ....	14
1.6 Organización de la tesis .....	16
II. Conceptos básicos .....	17
2.1 Percepción Remota.....	17
2.2 Incertidumbre en las imágenes satelitales .....	18
2.2.1 Objetos difusos .....	21
2.2.2 Representación de entidades geográficas como objetos difusos .....	22
2.2.3 Generación de incertidumbre en el manejo de datos sensados remotamente .....	25
Resumen .....	28
III. Estado del arte.....	29
3.1 Localización de regiones de transición .....	29
3.2 Píxeles mezclados .....	37
Resumen .....	55
IV. Método propuesto .....	57
4.1 Repositorios de imágenes satelitales .....	59
4.1.1 Selección de imágenes satelitales reales (ISR) .....	59
4.1.2. Construcción de imágenes satelitales sintéticas (ISS).....	60
4.2 Obtención de las regiones de transición .....	65

4.2.1	Extracción de características .....	66
4.2.2	Obtención de semillas, umbrales de crecimiento y coberturas homogéneas.....	69
4.2.3	Segmentación basada en crecimiento de regiones.....	76
4.2.4	Evaluación de las regiones de transición .....	77
4.3	Fuzzy C-Means-Modificado para la clasificación de píxeles mezclados .....	78
4.3.1	Construcción de las curvas de ajuste .....	78
4.3.2	Clasificador FCM-Modificado (FCMM) .....	83
4.3.3	Construcción de Mapas de incertidumbre .....	85
	Resumen .....	86
V.	Experimentos y resultados obtenidos.....	87
5.1	Metodología usada para realizar los experimentos .....	88
5.2	Experimentos utilizando imágenes satelitales sintéticas .....	89
5.2.1	Experimento 1 .....	90
5.2.2	Experimento 2 .....	101
5.3	Experimentos utilizando imágenes satelitales reales.....	104
5.3.1	Experimento 1 .....	104
5.3.2	Experimento 2 .....	109
5.3.3	Validación de las regiones de transición a través del experto en el dominio.....	113
5.4	Análisis de eficiencia .....	118
5.5	Análisis de los métodos propuestos .....	119
	Resumen .....	120
VI.	Conclusiones, Aportaciones y Trabajo futuro .....	122
6.1	Conclusiones .....	122
6.2	Aportaciones .....	123
6.3	Trabajo futuro .....	124
VII.	Referencias .....	125
	Apéndice .....	134
A.1	Clasificación usando clasificadores de IDRISI TAIGA .....	134
A.2	Experimentos usando imágenes sintéticas .....	139
A.2.1	Descripción del experimento .....	139

A.2.2 Construcción de las imágenes sintéticas .....	139
A.2.3 Clasificación de los píxeles mezclados usando FCM-Modificado y otros métodos....	147
A.2.4 Mapas de incertidumbres .....	150
A.3 Publicaciones .....	153
A.3.1 Artículos publicados.....	153
A.3.2 Artículos sometidos .....	153

## Lista de figuras

Figura 1.1. Proceso de análisis de imágenes satelitales. Figura adaptada de (Robles, 2007). .....	3
Figura 1.2. Origen del problema de píxeles mezclados en imágenes sensadas remotamente (De Jong, 2005).....	6
Figura 1.3. (a) Obtención de la cobertura bosque usando límites bien definidos, (b) Obtención de la cobertura bosque y las regiones de transición de bosque a otras coberturas de suelo (Schiewe, 2009b). .....	8
Figura 1.4. Generación de regiones de transición: (a) Imagen sensada remotamente, (b) Ubicación de las coberturas homogéneas con límites definidos y (c) Demarcación de las regiones de transición. ....	12
Figura 2.1. Medidas de incertidumbres basados en diversas teorías matemáticas. Traducida al español a partir de (Shi, 2010). ....	20
Figura 2.2. Descripción de entidades geográficas como objetos difusos. ....	23
Figura 2.3. Cuatro maneras para representar los objetos difusos. (a) Áreas fuzzy-fuzzy, (b) Límites de corte $\alpha$ , (c) Límites condicional, (d) Zonas de transición. Figura traducida al español de (Cheng, 2002).....	24
Figura 2.4. Distintos modelos conceptuales por los que pasan los datos sensados remotamente. Figura traducida al español de (Gahegan, 2000).....	25
Figura 3.1. Distintos modelos conceptuales por los que pasan los datos sensados remotamente. Figura traducida al español de (Gahegan, 2000).....	30
Figura 3.2. Construcción de la región de transición entre los objetos A y B. (b) Regiones de transición que delimitan al objeto A, (Schiewe, 2009a).....	31
Figura 3.3. (a) Localicación de objetos bien definidos en la imagen satelital, (b) ubicación de zonas indeterminadas a partir de los objetos bien definidos, (Galton, 2005). ....	34
Figura 3.4. Zona de transición generada por dos objetos difusos. Figura traducida al español de (Cheng, 2002).....	37
Figura 3.5. Clasificación suave usando la FPM de la región de Mérida, Venezuela (Gutierrez, 2005).....	40
Figura 3.6. (a) Imagen satelital, (b) Ubicación de las regiones de transición (Schiewe, 2009b)...	41

Figura 3.7. Clasificación de píxeles mezclados usando funciones lineales de pertenencia difusa. Figura traducida al español a partir de (Schiewe, 2009b).....	42
Figura 3.8. Construcción de la medida CFCM para la evaluar la clasificación de píxeles mezclados. Figura traducida al español a partir de (Schiewe, 2009b).....	44
Figura 3.9. (a) Dor maneras diferentes de trazar las regiones de transición de forma manual, (b) Definición de las regiones de transición para la cobertura bosque con diferentes amplitudes para agricultura y zona residencial (Schiewe, 2009b).....	45
Figura 3.10. (a) Grados de pertenencia para la cobertura bosque, (b) Distribución de la CFCM para la cobertura bosque (Schiewe, 2009b). ....	46
Figura 3.11. Modelo MLA basado en el algoritmo de regresión no-paramétrico. Figura traducida al español a partir de (Liu, 2010a).....	48
Figura 3.12. Imagen sintética construida en (Liu, 2010a). ....	49
Figura 3.13. Método propuesto para la descomposición de píxeles mezclados. Figura traducida al español a partir de (Liu, 2010b).....	50
Figura 3.14. La técnica de etiquetado para muestras de entrenamiento. Figura traducida al español a partir de (Liu, 2010b).....	51
Figura 3.15. Red neuronal SOM después del entrenamiento supervisado. Figura traducida al español a partir de (Liu, 2010b).....	51
Figura 3.16. Imágenes satelitales multicanales sintéticas (25×25). ....	53
Figura 3.17. Diagrama del algoritmo GA-MNMF. Figura traducida al español a partir de (Liaoying, 2009).....	55
Figura 4.1. Método propuesto para la obtención y clasificación de píxeles mezclados.....	58
Figura 4.2. Ejemplos de píxeles mezclados generados por regiones de transición en imágenes satelitales reales (Banda delimitada por las líneas amarillas).....	60
Figura 4.3. Método propuesto para la construcción de imágenes satelitales sintéticas. ....	61
Figura 4.4. (a) Ventana satelital base, (b) Ventana sintética suave. ....	64
Figura 4.5. Método <i>TreDet</i> propuesto para la obtención de regiones de transición basado en el crecimiento de regiones. ....	66

Figura 4.6. Estructura de tres niveles de filtros pasa bajas y pasa altas de la familia wavelet usada para la extracción de 10 características de textura, (Meher, 2007).....	68
Figura 4.7. Selección de semillas usando algoritmos genéticos.....	71
Figura 4.8. (a) Imagen original, (b) Obtención de las regiones iniciales a partir de una imagen satelital presegmentada por la técnica watershed.....	72
Figura 4.9. Asignación de cada región (gen) a un clúster determinado, (b) Individuo codificado (Jiao, 2010). .....	73
Figura 4. 10. Operación de cruce entre dos individuos virtuales. Figura traducida de (Jiao, 2010). .....	75
Figura 4.11. Método FCM-Modificado agregando información de las curvas de ajuste, integrando los métodos propuestos en las secciones anteriores y la construcción de mapas de incertidumbre.....	78
Figura 4.12. La curva de ajuste definida como una función de pertenencia. ....	79
Figura 4.13. Ejemplo de la distribución de píxeles mezclados y puros en una región de transición. .....	80
Figura 4.14. Curvas de ajuste para dos coberturas de suelo en sus tres bandas espectrales. ....	82
Figura 5. 1. Resultados de la localización de las regiones de transición entre las coberturas de suelo de vegetación y suelo descubierto utilizando diferentes herramientas comerciales de software especializado. (a) imagen sintética, (b) resultados obtenidos con Idrisi Taiga, (c) resultados obtenidos con eCognition, (d) resultados obtenidos con el Método propuesto, (e) resultados obtenidos con EDISON, y (f) resultados obtenidos con <i>Canny</i> .....	92
Figura 5.2. Clasificación de píxeles mezclados usando el método FCM, (a) Pertenencia a la clase vegetación, (b) Pertenencia a la clase suelo descubierto. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %). .....	94
Figura 5.3. Clasificación de píxeles mezclados usando el método FCM-Modificado, (a) Pertenencia a la clase vegetación, (b) Pertenencia a la clase suelo descubierto. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %). .....	95

Figura 5.4. Clasificación de píxeles mezclados usando el método difuso, (a) Pertenencia a la clase vegetación, (b) Pertenencia a la clase suelo descubierto. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %).	95
Figura 5.5. Clasificación de píxeles mezclados usando el método de una red bayesiana, (a) Pertenencia a la clase vegetación, (b) Pertenencia a la clase suelo descubierto. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %).	95
Figura 5.6. Clasificación de píxeles mezclados usando el método k-nn-suave, (a) Pertenencia a la clase vegetación, (b) Pertenencia a la clase suelo descubierto. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %).	96
Figura 5.7. Clasificación de píxeles mezclados usando una red neuronal SOM, (a) Pertenencia a la clase vegetación, (b) Pertenencia a la clase suelo descubierto. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %).	96
Figura 5.8. Construcción de mapas de incertidumbre usando el clasificador FCM: (a) para vegetación, (b) para suelo descubierto.	97
Figura 5.9. Construcción de mapas de incertidumbre usando el clasificador FCM-Modificado: (a) para vegetación, (b) para suelo descubierto.	98
Figura 5.10. Construcción de mapas de incertidumbre usando el clasificador difuso: (a) para vegetación, (b) para suelo descubierto.	98
Figura 5.11. Construcción de mapas de incertidumbre usando el clasificador bayesiano: (a) para vegetación, (b) para suelo descubierto.	98
Figura 5.12. Construcción de mapas de incertidumbre usando el clasificador k-nn-suave: (a) para vegetación, (b) para suelo descubierto.	99
Figura 5.13. Construcción de mapas de incertidumbre usando el clasificador red neuronal SOM: (a) para vegetación, (b) para suelo descubierto.	99

Figura 5.14. Resultados de la obtención de las regiones de transición: (a) Imagen original, (b) Localización de las semillas en las coerturas de suelo vegetación (azul) y suelo descubierto (rojo) y (c) Coberturas homogéneas que delimitan los píxeles mezclados.....	105
Figura 5.15. Resultados de la obtención de las regiones de transición: (a) Imagen original, (b) Localización de las semillas en las coerturas de suelo vegetación (rojo) y suelo descubierto (verde) y (c) Coberturas homogéneas que delimitan los píxeles mezclados. ....	106
Figura 5.16. Resultados de la obtención de las regiones de transición: (a) Imagen original, (b) Localización de las semillas en las coerturas de suelo vegetación (rojo) y suelo descubierto (azul) y (c) Coberturas homogéneas que delimitan los píxeles mezclados.....	107
Figura 5.17. Resultados de la obtención de las regiones de transición: (a-c) Imágenes originales, (d-f) Pertenencia de los píxeles mezclados con respecto a la cobertura vegetación y (g-i) Pertenencia de los píxeles mezclados con respecto a la cobertura suelo descubierto. ....	109
Figura 5.18. (a) Imagen satelital original con coberturas de suelo: bosque y matorrales, (b) Localización espacial de la región de transición (color café claro). ....	110
Figura 5.19. (a) Imagen satelital original con coberturas de suelo: bosque y carretera, (b) Localización espacial de la región de transición (color café claro). ....	110
Figura 5.20. (a) Imagen satelital original con coberturas de suelo: selva y carretera, (b) Localización espacial de la región de transición (color café claro). ....	111
Figura 5.21. (a) Imagen satelital original con coberturas de suelo: selva y playa, (b) Localización espacial de la región de transición (color gris). ....	111
Figura 5.22. (a) Imagen satelital original con coberturas de suelo: selva y playa, (b) Localización espacial de la región de transición (color café claro). ....	112
Figura 5.23. (a) Imagen satelital original con coberturas de suelo: bosque y pastizal, (b) Localización espacial de la región de transición (color café claro). ....	112
Figura 5.24. (a) Imagen satelital original con coberturas de suelo: bosque y pastizal, (b) Localización espacial de la región de transición (color café claro). ....	112
Figura 5.25. Localización de las regiones de transición: (a) eCognition, (b) EDISON, (c) Idrisi TAIGA y (d) Método Propuesto. ....	114

Figura 5.26. Localización de las regiones de transición: (a) eCognition, (b) EDISON, (c) Idrisi TAIGA y (d) Método Propuesto. ....	114
Figura 5.27. Localización de las regiones de transición: (a) eCognition, (b) EDISON, (c) Idrisi TAIGA y (d) Método Propuesto. ....	115
Figura 5.28. Localización de las regiones de transición: (a) eCognition, (b) EDISON, (c) Idrisi TAIGA y (d) Método Propuesto. ....	115
Figura 5.29. Localización de las regiones de transición: (a) eCognition, (b) EDISON, (c) Idrisi TAIGA y (d) Método Propuesto. ....	116
Figura 5.30. Localización de las regiones de transición: (a) eCognition, (b) EDISON, (c) Idrisi TAIGA y (d) Método Propuesto. ....	116
Figura 5.31. Localización de las regiones de transición: (a) eCognition, (b) EDISON, (c) Idrisi TAIGA y (d) Método Propuesto. ....	117
Figura A.1.1. Selección de las regiones de entrenamiento. ....	134
Figura A.1.2. Digitalización de las regiones de entrenamiento. ....	135
Figura A.1.3. Módulo para construcción de las firmas espectrales de cada clase. ....	136
Figura A.1.4. Asignación de los nombres para cada clase de la firma espectral. ....	136
Figura A.1.5. Módulo para la realizar la clasificación Bayesiana. ....	137
Figura A.1.6. Módulo para la realizar la clasificación Fuzzy. ....	137
Figura A.1.7. Módulo para realizar la clasificación SOM. ....	138
Figura A.2.1. (a) Ventana satelital real formada por las coberturas selva y playa, (b) Ventana sintética suave construida a partir de la imagen satelital real. ....	139
Figura A.2.2. (a) Ventana satelital real formada por las coberturas bosque y matorrales, (b) Ventana sintética suave construida a partir de la imagen satelital real. ....	140
Figura A.2. 3. (a) Ventana satelital real formada por las coberturas bosque y suelo descubierto, (b) Ventana sintética suave construida a partir de la imagen satelital real. ....	140
Figura A.2.4. (a) Ventana satelital real formada por las coberturas bosque y matorrales, (b) Ventana sintética suave construida a partir de la imagen satelital real. ....	141
Figura A.2.5. (a) Ventana satelital real formada por las coberturas bosque y matorrales, (b) Ventana sintética suave construida a partir de la imagen satelital real. ....	141

Figura A.2.6. Imágenes sintéticas construidas. ....	142
Figura A.2.7. Localización de las regiones de transición de la imagen A.2.6(a) usando: (a) Idrisi Taiga, (b) eCognition, (c) EDISON y (d) TreDet. ....	143
Figura A.2.8. Localización de las regiones de transición de la imagen A.2.6(b) usando: (a) Idrisi Taiga, (b) eCognition, (c) EDISON y (d) TreDet. ....	144
Figura A.2.9. Localización de las regiones de transición de la imagen A.2.6(c) usando: (a) Idrisi Taiga, (b) eCognition, (c) EDISON y (d) TreDet. ....	145
Figura A.2.10. Localización de las regiones de transición de la imagen A.2.6(d) usando: (a) Idrisi Taiga, (b) eCognition, (c) EDISON y (d) TreDet. ....	146
Figura A.2.11. Localización de las regiones de transición de la imagen A.2.6(e) usando: (a) Idrisi Taiga, (b) eCognition, (c) EDISON y (d) TreDet. ....	147
Figura A.2.12. Clasificación de píxeles mezclados usando el clasificador FCM, (a) Pertenencia a la clase selva, (b) Pertenencia a la clase playa. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %). ....	148
Figura A.2.13. Clasificación de píxeles mezclados usando el clasificador FCM-Modificado, (a) Pertenencia a la clase selva, (b) Pertenencia a la clase playa. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %). ....	148
Figura A.2.14. Clasificación de píxeles mezclados usando el clasificador difuso, (a) Pertenencia a la clase selva, (b) Pertenencia a la clase playa. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %). ....	149
Figura A.2.15. Clasificación de píxeles mezclados usando el clasificador bayesiano, (a) Pertenencia a la clase selva, (b) Pertenencia a la clase playa. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %). ....	149
Figura A.2.16. Clasificación de píxeles mezclados usando el clasificador k-nn-suave, (a) Pertenencia a la clase selva, (b) Pertenencia a la clase playa. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %). ....	149

Figura A.2.17. Clasificación de píxeles mezclados usando el clasificador red neuronal SOM, (a) Pertenencia a la clase selva, (b) Pertenencia a la clase playa. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %).	150
Figura A.2.18. Construcción de mapas de incertidumbre usando el clasificador FCM: (a) para selva, (b) para playa.	150
Figura A.2.19. Construcción de mapas de incertidumbre usando el clasificador FCM-Modificado: (a) para vegetación, (b) para suelo descubierto.	151
Figura A.2.20. Construcción de mapas de incertidumbre usando el clasificador difuso: (a) para selva, (b) para playa.	151
Figura A.2.21. Construcción de mapas de incertidumbre usando el clasificador bayesiano: (a) para selva, (b) para playa.	151
Figura A.2.22. Construcción de mapas de incertidumbre usando el clasificador k-nn-suave: (a) para selva, (b) para playa.	152
Figura A.2.23. Construcción de mapas de incertidumbre usando el clasificador red neuronal SOM: (a) para selva, (b) para playa.	152

## Lista de tablas

Tabla 2. 1 Tipos de incertidumbres y sus fuentes de generación en los cuatro modelos del espacio geográfico (Gahegan, 2000). .....	27
Tabla 3.1. Trabajos relacionados con las propiedades de las regiones de transición.....	30
Tabla 3.2. Comparación de las relaciones de regiones de transición para diferentes coberturas de suelo (Schiewe, 2009a). .....	33
Tabla 3. 3. Resumen de trabajos relacionados con píxeles mezclados. ....	38
Tabla 3.4. Matriz de Partición Difusa. ....	39
Tabla 5.1. Resultados de la evaluación de la calidad en la detección de las regiones de transición. ....	93
Tabla 5.2. CFCM para los clasificadores suave. ....	100
Tabla 5.3. Medidas de similitud entre las imágenes reales y sintéticas. ....	101
Tabla 5.4. Evaluación cuantitativa de la localización de las regiones de transición para las figuras A.2.7 – A.2.11 mostradas en el apéndice A.2. ....	102
Tabla 5.5. CFCM para la clasificación de las imágenes sintéticas de la figura A.2.6. ....	103
Tabla 5.6. Prueba de significancia estadística usando el método Wilcoxon para los métodos de clasificación de la tabla 5.5. ....	104
Tabla 5.7. Cálculo de la eficiencia de los métodos de segmentación (segundos). ....	118
Tabla 5.8. Cálculo de la eficiencia de los métodos de clasificación suave (segundos). ....	119

## I. Introducción

Los impactos ambientales registrados durante las últimas décadas pueden ser los más severos en la historia de la humanidad. En lo transcurrido a través de estos años, el crecimiento demográfico mundial ha sido una de las causas importantes del desajuste ambiental en diversos aspectos del planeta como son: disminución de zonas forestales, reducción de mantos acuíferos, desaparición de manglares, cambio en la línea costera, entre otros. De acuerdo con estos acontecimientos, distintas organizaciones de diferentes países han iniciado programas para mejorar y restablecer los daños ecológicos que el ser humano ha generado. Estos programas han sido diseñados para tomar distintas medidas que reduzcan o controlen las siguientes actividades:

- ***Cambios en la línea de costa por ascenso del nivel del mar.*** Consiste en monitorear fijando distintos periodos del año para identificar y caracterizar las áreas más vulnerables en la costa debido al ascenso del nivel del mar (Boateng, 2012).
- ***Análisis de cambio de uso de suelo y vegetación.*** La función de la vegetación en las ciudades, tanto áreas verdes como naturales, ha sido reconocida en numerosos estudios como proveedora de beneficios sociales y naturales. También se ha dado gran valor como parte de la infraestructura urbana. Sin embargo, conservarla y darle un manejo adecuado resulta difícil debido a la gran necesidad de espacio para el desarrollo de vivienda e infraestructura. Esto origina un déficit dentro de las zonas urbanas (Trabucchi, 2012).
- ***Mal uso del recurso del suelo.*** Esta actividad ha permitido el uso indiscriminado y descontrolado del suelo, modificando grandes extensiones de áreas verdes que se encuentran incluso protegidas. Estas regiones son dedicadas a: cultivos, tierra labrada, área de pastizales nativos, pastoreo, etc. El propósito del buen uso del recurso del suelo consiste en cuantificar estas áreas, identificar su posición geográfica y estimar su productividad y variabilidad espacial (Trabucchi, 2012).

- **Monitoreo de vegetación debido a incendios.** El monitoreo de las amenazas a las regiones naturales protegidas resulta de gran relevancia para la prevención de los cambios dinámicos provocados por el ser humano a las áreas verdes. Éste va desde el análisis de los cambios registrados en el uso de la tierra hasta el monitoreo de la salud de la diversidad biológica y los objetos de conservación identificados para el área protegida en cuestión.

El estudio de las actividades descritas anteriormente se hace posible llevando a cabo un proceso de análisis de imágenes sensadas remotamente, el cual nos da la posibilidad de cuantificar los cambios significativos en cada una de las situaciones planteadas.

En este contexto, debemos establecer la definición de percepción remota. De acuerdo a Weng en (Weng, 2009), Percepción Remota (*Remote Sensing*) se refiere a las actividades de almacenamiento, observación y percepción (adquisición) de objetos o eventos localizados en lugares distantes (remotos). La salida de un sistema de percepción remota es normalmente una imagen que representa la escena que está siendo observada. En un sentido más estricto, percepción remota se refiere a la ciencia y tecnología para la adquisición de información acerca de la superficie de la tierra (por ejemplo, suelo y océano) y atmósfera mediante el uso de sensores localizados a bordo de aviones o satélites artificiales.

El proceso de análisis de imágenes satelitales consta de diversas etapas que van desde la adquisición de la imagen hasta la presentación de resultados, tal como se muestra en la figura 1.1 (Robles, 2007), (Lillesand, 2008). A continuación se describe de manera breve cada una de las etapas que forman parte de este proceso:

- ❖ **Adquisición de la Imagen.** Se refiere al proceso de representar los datos obtenidos por varios sensores que trabajan en diferentes intervalos de longitud de onda (diversas bandas). Esta adquisición puede ser pasada por los procesos de corrección para tratar de

representar los datos del sensor con la menor cantidad de errores posibles generados durante la adquisición de la misma.

- ❖ **Pre-procesamiento.** Permite corregir la imagen a través de técnicas de filtrado. En esta etapa se encuentra la segmentación de la imagen, la cual agrupa una cantidad de píxeles con características similares para generar regiones de interés. Finalmente, se extraen de esas regiones de interés un conjunto de características descriptivas que ayudarán a la interpretación y reconocimiento de los distintos tipos de regiones según el tipo de aplicación.

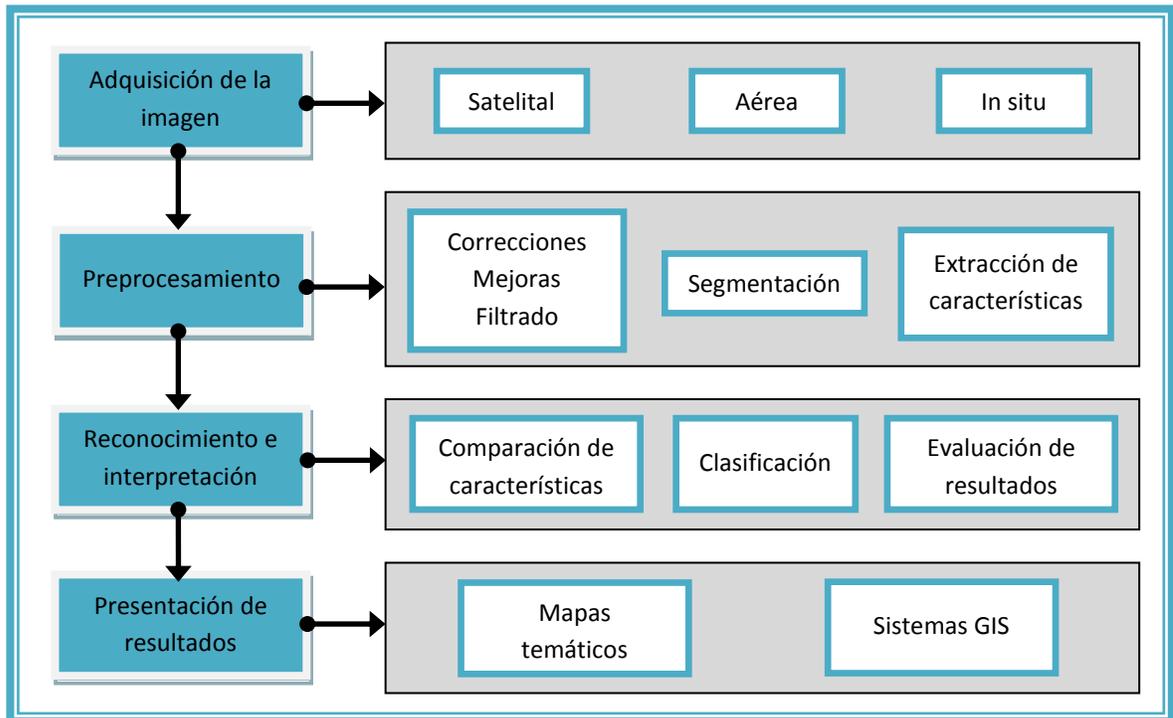


Figura 1.1. Proceso de análisis de imágenes satelitales. Figura adaptada de (Robles, 2007).

- ❖ **Reconocimiento e Interpretación.** En esta etapa se emplean técnicas de aprendizaje automático para realizar la clasificación de las imágenes. También se utilizan técnicas de evaluación para calificar el desempeño de los algoritmos de clasificación.

**Presentación de Resultados.** Traduce los resultados en un formato que pueda ser entendido por el experto en el dominio, usuario final o sistema de cómputo. La información generada la adquiere un Sistema de Información Geográfica (GIS, por sus siglas en inglés) que es utilizado para crear el mapa temático.

En una imagen sensada remotamente se pueden distinguir distintos tipos de coberturas de suelo, tales como: bosques, pastizales, masas de agua, suelo descubierto, etc. Una imagen satelital está formada generalmente por dos tipos de píxeles: puros y mezclados. Definimos un píxel puro como aquel que está formado por un solo tipo de cobertura de suelo. Por otra parte, un píxel mezclado, es un píxel que está formado por más de un tipo de cobertura de suelo. La problemática que se propone resolver en este trabajo de investigación es la de localizar y clasificar de forma suave a los píxeles mezclados presentes en una imagen satelital.

## 1.1 Fuentes de píxeles mezclados en imágenes satelitales

Una imagen sensada remotamente es una representación simple de la forma en que la radiación interactúa con la superficie de la tierra. Al tratarse de una representación del ambiente, se pueden esperar diferentes tipos de inconsistencias con la realidad, las cuales pueden ser identificadas en dichas imágenes.

Típicamente, la imagen está formada por datos *raster*, cuya unidad espacial fundamental es el píxel. *Comúnmente el área representada por un píxel contiene más de una clase temática (vegetación, bosque, cuerpos de aguas, suelo descubierto, construcciones hechas por el ser humano, etc.).* Esta situación se puede presentar por muchas razones (ver figura 1.2). Esto hace que los datos sean inadecuados para su uso con algunas técnicas convencionales de análisis de imágenes. Consecuentemente, el uso de enfoques convencionales “duros” (un píxel, una clase) para asignar una clase a los píxeles de una imagen sensada remotamente generará errores en caso de contener píxeles mezclados. De esta manera, la problemática se origina debido a la

aparición de píxeles mezclados en una imagen satelital. A continuación se describen brevemente las distintas fuentes de generación de píxeles mezclados (De Jong, 2005):

a) Mezcla causada por la presencia de pequeños objetos (subpíxel) dentro del área del píxel. En este caso, la resolución espacial es muy baja, lo que permite que objetos de menor extensión espacial se encuentren incluidos para generar el píxel mezclado.

b) Mezcla como consecuencia de píxeles que contienen límites discretos de clases temáticas. La resolución espacial del píxel permite que distintas coberturas de suelo con límites bien definidos puedan combinarse para dar como resultado un píxel mezclado.

**c) Mezcla debido a la transición gradual observada entre las clases temáticas continuas.**

Regularmente, las coberturas de suelo presentes en una imagen sensada remotamente no presentan límites bien definidos, más bien presentan un cambio transicional entre un tipo de cobertura de suelo a otro.

d) Mezcla debido a la contribución de un objeto exterior al área representada por un píxel pero influenciado por su punto de función de dispersión (se observa que el píxel aparece aparentemente puro, pero su respuesta espectral es influenciada por los objetos pequeños que se encuentran fuera del área representada).

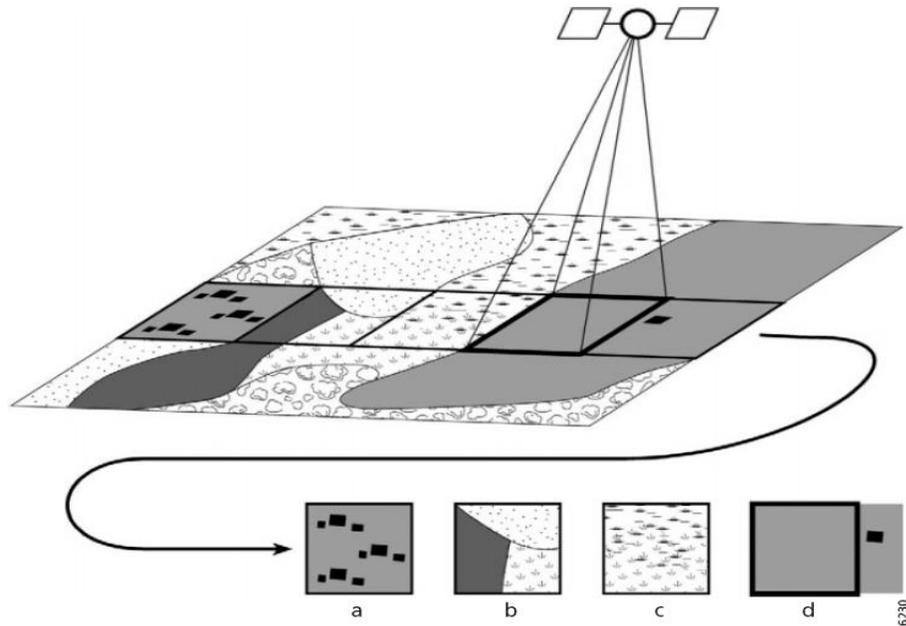


Figura 1.2. Origen del problema de píxeles mezclados en imágenes sensadas remotamente (De Jong, 2005).

En este trabajo de tesis se aborda el problema de la obtención de las regiones de transición (RsT) presentes en una imagen sensada remotamente. La transición gradual, que generalmente se presenta entre dos o más coberturas homogéneas, genera una combinación de píxeles que provoca que muchos algoritmos de clasificación y segmentación de imágenes satelitales incurran en diversos errores en la construcción de mapas temáticos (inciso c de la figura 1.2).

Por otra parte, tomando en cuenta las entidades geográficas presentes en una imagen satelital, su naturaleza indeterminada ayuda a la formación de píxeles mezclados debido a los puntos siguientes (Cheng, 2002):

1. *Continuidad.* Las entidades geográficas, tales como pastizales y bosques, son distribuidos de manera continua en el espacio. Se sabe donde se encuentra la parte homogénea pero no se conocen las fronteras entre éstas y otras entidades geográficas. Por lo tanto, debido a su contribución continua en el espacio, no existe un límite bien definido entre ellos. Además, cuando se interpretan visualmente estos límites usando imágenes sensadas remotamente, los límites pueden ser diferentes de una persona a otra.

2. *Heterogeneidad*. Las entidades espaciales pueden ser heterogéneas (una mezcla entre ellas). La mezcla de árboles y pasto o de distintos tipos de árboles es común en bosques.

3. *Dinámico*. Muchas entidades geográficas son dinámicas y cambian con el tiempo. Resulta muy difícil medirlas con exactitud porque cambian después de la medición original.

4. *Dependencia con la escala*. La definición de entidades geográficas es comúnmente dependiente de la escala y del contexto. En coberturas de suelo, por ejemplo, incrementar la resolución espacial, frecuentemente resulta en la identificación de nuevas áreas o clases, particularmente en las zonas fronterizas del nivel más alto de agregación (nivel de mayor resolución).

## 1.2 Obtención de regiones de transición (RsT) en imágenes satelitales

En una imagen sensada remotamente se pueden observar diferentes coberturas de la superficie terrestre. Entre éstas se incluyen zonas urbanas, de vegetación (bosque, pastizales, manglares, etc.), cuerpos de agua (mares, ríos, lagos, etc.), y zonas dedicadas al cultivo de plantas, entre otras. Estas coberturas, a las que llamaremos *coberturas homogéneas*, presentan límites o fronteras no definidas derivadas por el cambio gradual de una cobertura a otra. De esta manera, el cambio de una cobertura homogénea (bosque) a otra cobertura homogénea (pastizal) se presenta de forma gradual y no de manera abrupta. Debido a esto, las fronteras que delimitan este par de coberturas tienen una amplitud que varía de acuerdo a la forma que tienen las mismas. Las zonas intermedias limitadas por coberturas homogéneas se denominan *regiones de transición* (Schiewe, 2009a).

En la figura 1.3 se presenta un ejemplo en el que se muestran dos tipos de enfoques para el trazado de fronteras que delimitan los tipos de coberturas: primero, en la figura 1.3a, se muestra la obtención de las fronteras entre las coberturas de bosque y de agricultura usando

límites bien definidos. Segundo, en la figura 1.3b se muestra la obtención de fronteras entre una cobertura de bosque y otros tipos de coberturas pero utilizando límites indeterminados, los cuales generan las regiones de transición entre cada par de cobertura de suelo.



**Figura 1.3. (a) Obtención de la cobertura bosque usando límites bien definidos, (b) Obtención de la cobertura bosque y las regiones de transición de bosque a otras coberturas de suelo (Schiewe, 2009b).**

En la figura 1.3b se han obtenido las regiones de transición de manera manual. Sin embargo, en este trabajo de investigación se propone la obtención de las regiones de transición con la ayuda de herramientas como el aprendizaje automático, y otras herramientas de la inteligencia artificial (como la segmentación de imágenes y la extracción de características) para obtener la clasificación de las imágenes. En la clasificación de imágenes se cuenta con los clasificadores tradicionales o clasificadores duros que producen una decisión dura acerca de la composición de cada píxel. Así por ejemplo, cuando se realiza la clasificación de la imagen, cada píxel es asignado a una sola clase, no importando si el píxel en turno pueda estar compuesto por más de una cobertura de suelo. Por tal motivo, una desventaja de los clasificadores duros es que asignan los píxeles mezclados a una sola cobertura de suelo aunque en la realidad pertenezcan a más de una.

La posibilidad de realizar una clasificación con mejor exactitud, además de tomar en cuenta los problemas de ambigüedad generados durante la adquisición de la imagen provoca la necesidad de utilizar clasificadores suaves. Los clasificadores suaves permiten expresar el grado de

pertenencia de un píxel respecto a cada una de las coberturas que lo componen. Así, por ejemplo, en lugar de decidir que un píxel representa un bosque de coníferas o de hojas caedizas, podría indicar que su grado de pertenencia a la clase de hojas caedizas es de 0.43 y a la de coníferas es 0.57 (con esta evidencia, un clasificador duro concluiría que el píxel pertenece a la clase coníferas). Además, en la tarea de clasificación de imágenes, existe el problema de determinar los umbrales adecuados (límites máximos o intervalo de la variable) de los valores de los atributos que ayuden a discriminar entre los distintos tipos de coberturas. Sin embargo, las regiones de transición presentan características que pueden llegar a coincidir con más de una cobertura de suelo, lo cual lleva a los algoritmos de clasificación a cometer errores.

Como se ha mencionado anteriormente, el propósito de este trabajo de investigación es determinar las regiones de transición a partir de las coberturas homogéneas que las generan. Para esto, el presente trabajo se ha dividido en dos partes principales: obtención de las regiones de transición usando segmentación de imágenes. Estas secciones se describen brevemente a continuación.

### **1.2.1 Obtención de las regiones de transición usando segmentación de imágenes**

El proceso de segmentación consiste en separar una imagen en unidades significativas para realizar el posible reconocimiento de los objetos presentes en la misma. Existen diversas técnicas para la segmentación de regiones basadas a nivel píxel o a nivel región. En nuestro caso, el proceso de segmentación debe contemplar las siguientes condiciones:

1. Primeramente, determinar las coberturas homogéneas en una imagen satelital sin considerar las regiones de transición. Esto es posible debido a que los algoritmos de segmentación cometen menos errores para obtener las coberturas homogéneas.
2. Controlar la homogeneidad de la cobertura para que los píxeles de esta región pertenezcan a una misma categoría (agua, vegetación, etc.).

Una vez encontrados los píxeles puros (asociados con las coberturas homogéneas) de manera visual y analítica, los píxeles restantes son considerados como píxeles mezclados contenidos en las regiones de transición.

### 1.2.2 Clasificación de los píxeles mezclados que se localizan en las regiones de transición

Existen distintos enfoques que intentan descomponer (clasificar de forma suave) cada píxel mezclado contenido en una región de transición. El uso de clasificadores suaves permite la asignación parcial de un tipo de cobertura presente en un píxel mezclado. Entre los métodos más relevantes se encuentran los basados en:

- **Probabilidades.** Basado en la repetición de un experimento  $n$  veces, la probabilidad de ocurrencia de un evento  $A$  puede ser estimada usando la relación  $m/n$  (llamada frecuencia relativa del evento  $A$  en estos  $n$  veces que se realiza el experimento), donde  $m$  representa el número de ocurrencia de  $A$  en el experimento, por ejemplo (Singh, 2008), (Shi, 2010). Cuando  $n$  es suficientemente grande, es posible aproximar la relación  $m/n$  a una constante  $p$  usando la teoría del límite central. Esto es:

$$\lim_{n \rightarrow \infty} \frac{m}{n} = p \quad (1.1)$$

La constante  $p$  es la probabilidad del evento  $A$ , denotado por  $P(A) = p$ . El valor de  $p$  proporciona una descripción objetiva de que si el evento  $A$  ocurre, donde  $0 \leq P(A) \leq 1$ . La probabilidad del espacio muestral es  $P(\Omega) = 1$ , y la probabilidad de que cualquier evento imposible  $P(\emptyset) = 0$ . La relación  $m/n$  está dependiente del resultado de los experimentos repetidos, y este resultado no modifica el valor de  $p$ . Sin embargo, la probabilidad ( $m/n$ ) es una aproximación del valor verdadero de la probabilidad del evento  $A$ , donde el valor más grande de  $n$ , da la más alta precisión de la aproximación.

- **Lógica difusa.** Basada en los conjuntos difusos propuestos por Zadeh en (Zadeh, 1966). Permite otorgar un grado de pertenencia para cada tipo de cobertura que se encuentra presente en el píxel mezclado, por ejemplo (Schiewe, 2009b).
- **Redes neuronales artificiales (RNAs).** Las RNAs se entrenan para que aprendan de los atributos que representan a los píxeles mixtos, de tal manera que al clasificar un nuevo píxel se le asigne la clase más similar, por ejemplo (Gosh, 2009).
- **Sub-píxel.** Utilizada en imágenes sensadas a una alta resolución espacial. Este método se realiza a través de dos clasificaciones de la misma área de estudio: en la primera clasificación se utiliza una imagen de baja resolución donde la idea principal es obtener la composición de cada píxel con respecto a las clases que lo componen. Un píxel de la imagen de baja resolución está formado por píxeles más pequeños (subpíxeles) correspondiente a la imagen de alta resolución. La segunda clasificación consiste en clasificar la imagen de alta resolución a nivel subpixel. La información obtenida en la primera clasificación es usada para mejorar la segunda clasificación. Las técnicas utilizadas son el modelo lineal mezclado y el Algoritmo de intercambio de pixel, entre otros, (Pu, 2008).

La ubicación y clasificación de los píxeles mezclados en una imagen satelital es de gran importancia para mejorar el rendimiento de los clasificadores suaves. En la siguiente sección se describe la problemática que se propone resolver en este trabajo.

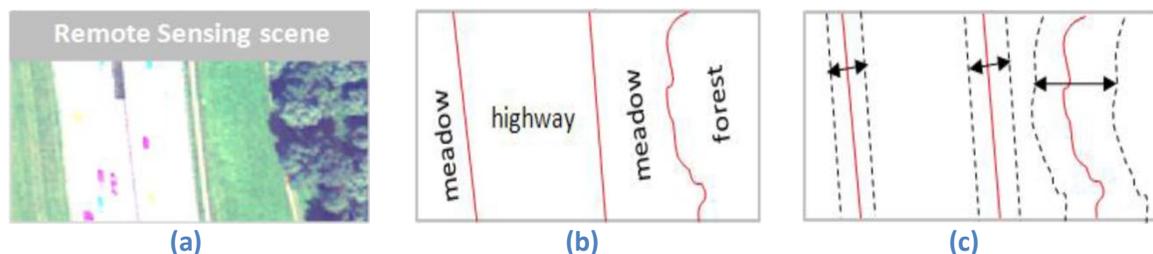
### 1.3 Problemática

En el contexto de las imágenes sensadas remotamente, las coberturas presentes en la superficie terrestre incluyen zonas urbanas, zonas de vegetación (bosque, pastizales, manglares, etc.), cuerpos de agua (mares, ríos, lagos, etc.), y zonas dedicadas al cultivo de plantas, entre otras coberturas. La extracción de mapas temáticos a partir de la clasificación de imágenes sensadas

remotamente es un área de investigación importante por su aplicación para la obtención de conocimiento del medio ambiente global, usos de suelo, recursos renovables y no renovables, desastres naturales, geología y muchos otros. Por lo anterior, se trabaja en la obtención mapas de alta calidad, lo cual no se ha logrado del todo con los esquemas de clasificación utilizados hasta el momento.

Una desventaja que se presenta en la construcción de mapas temáticos, ha sido que los ecologistas han estudiado regiones homogéneas (constituidas por un solo tipo de suelo) para caracterizar y entender los procesos de los ecosistemas y han evitado las áreas heterogéneas (combinación de dos o más tipos de suelo) entre ecosistemas. Como resultado, las zonas de transición han sido frecuentemente ignoradas o reducidas a líneas sobre un mapa temático. Sin embargo, estas zonas de transición, llamadas “ecotonos”, controlan el flujo de materiales entre ecosistemas y la influencia de la biodiversidad (Fortin, 2000).

En la generación de mapas temáticos, la mejor calidad en la clasificación se presenta cuando se clasifican las coberturas que son básicamente homogéneas. Sin embargo, para el caso de las coberturas no homogéneas se suele incurrir en una serie de errores que disminuyen la calidad del mapa temático. Por ejemplo, el paso de bosque a pastizal, no se realiza de manera abrupta sino de una forma gradual, generándose una zona de transición formada por las coberturas homogéneas (en este caso, por el bosque y el suelo descubierto), ver figura 1.4. Esta zona de transición está delimitada por fronteras indefinidas debido a que se encuentra compuesta de manera proporcional por las coberturas que la generan. Por lo tanto, determinar su composición no resulta trivial para los esquemas tradicionales usados.



**Figura 1.4. Generación de regiones de transición: (a) Imagen sensada remotamente, (b) Ubicación de las coberturas homogéneas con límites definidos y (c) Demarcación de las regiones de transición.**

En el contexto del procesamiento digital de imágenes, la imagen de la figura 1.4c está formada por píxeles puros (que forman a las coberturas homogéneas) y por píxeles mezclados (que constituyen a las regiones de transición). De esta manera, al investigar la naturaleza de las regiones de transición, surgen dos principales problemáticas:

1. Delimitación de una cobertura homogénea, es decir, localización correcta del área que le corresponde a dicha cobertura sin agregar ninguna parte correspondiente a la zona de transición.
2. Obtención de un método que permita descomponer los píxeles mezclados de la zona de transición para determinar las coberturas presentes en cada una de estas zonas.

Dentro de los diversos problemas que involucran las regiones de transición, se encuentra la ambigüedad que presentan los píxeles mezclados debido a la presencia de más de un tipo de cobertura. Por lo tanto, determinar la composición de estos píxeles no resulta en una tarea fácil para los métodos de clasificación, incluso para los suaves. Para sobrellevar estos errores en la clasificación, es necesario contar con la suficiente provisión de información para representar los diversos tipos de incertidumbres asociadas a cada una de las etapas del procesamiento digital de imágenes, esto es, la incertidumbre generada desde la adquisición de la imagen hasta la incertidumbre obtenida en la generación de un mapa temático.

## **1.4 Objetivos**

### **1.4.1 Objetivo General**

Diseñar un método para la localización espacial y clasificación suave de los píxeles mezclados generados por las regiones de transición en imágenes sensadas remotamente.

### **1.4.2 Objetivos Específicos**

- i. Implementar, y en su caso extender, un segmentador de imágenes que permita segmentar las coberturas homogéneas sin agregar píxeles mezclados.
- ii. Extraer características de textura para cada cobertura homogénea.
- iii. Proponer un método para la clasificación suave de los píxeles mezclados generados por una región de transición.
- iv. Comparar el método propuesto para comprobar su eficacia frente a otras propuestas.

### **1.5 Descripción general de los métodos propuestos.**

Para cumplir con los objetivos planteados, en este trabajo de investigación se propusieron tres métodos para la solución del problema de los píxeles mezclados generados por las regiones de transición. El primer método consiste en la construcción de imágenes satelitales sintéticas basada en imágenes satelitales reales utilizando el método de modelo lineal de mezclas. Estas imágenes sintéticas permiten validar cualitativa y cuantitativamente los experimentos realizados en los dos siguientes métodos propuestos en esta investigación. La contribución principal de este método se debe a que en la literatura no se encuentran disponibles bases de datos de imágenes satelitales donde se obtengan y clasifiquen los píxeles mezclados generados por una región de transición que ayuden a validar los trabajos relacionados con estas problemáticas. Los resultados obtenidos en la construcción de las imágenes sintéticas indican que dichas imágenes contienen las propiedades de las imágenes originales además de conocerse la composición (mezcla) de cada píxel de la región de transición.

El segundo método consiste en determinar las fronteras que delimitan a las regiones de transiciones que son generadas por dos más coberturas de suelo (Morales, 2014). Estas regiones de transición agrupan un sin número (dependiendo del tamaño y resolución espacial

de la imagen satelital) de distintas combinaciones (mezclas) de píxeles que son generados por vecindad de las coberturas homogéneas dentro. Este segundo método permite localizar dentro de una imagen satelital las regiones donde se encuentran los píxeles mezclados. Para realizar esto, se propone una segmentación basada en el crecimiento de regiones donde, mediante la ayuda de los algoritmos genéticos, se determinan las semillas (píxeles) iniciales de cada cobertura homogénea y el umbral de crecimiento para cada cobertura homogéneas. Para la clasificación de píxeles mezclados existen técnicas de clasificación suave que permiten descomponer a estos píxel según las coberturas de suelo presentes en ellos. Un error cometido en la clasificación de píxeles mezclados se presenta cuando las técnicas tradicionales de clasificación realizan la clasificación de estos píxeles de manera dura, entendiéndose que estos no son píxeles puros (una sola cobertura de suelo), sino más bien se tiene la presencia (de manera proporcional) de más de una cobertura de suelo en el píxel. Este mismo error es cometido en sentido inverso cuando los clasificadores suaves realizan la clasificación de todos los píxeles de una imagen satelital tomándo en cuenta de que no existen píxeles puros en la imagen. Esto conlleva a añadir incertidumbre en el momento de realizar la clasificación suave. De esta manera, la contribución principal de este segundo método radica en determinar primeramente a los píxeles puros mediante la segmentación, aislando a los píxeles mezclados para ser analizados posteriormente usando el tercer método propuesto en este trabajo de investigación.

Una vez obtenidos los píxeles mezclados de la imagen satelital se procede a su clasificación suave utilizando el tercer método propuesto. Este tercer método consiste en una modificación realizada al algoritmo de clasificación Fuzzy C-Means. Las modificaciones realizadas a este algoritmo son las siguientes: no se realiza el agrupamiento de clúster para calcular los centroides, sino que se toman como centroides fijos a los píxeles semillas calculados en la segmentación por crecimiento de regiones. También se añade información de las regiones de transición de las coberturas de suelo reales. Esta información es agregada a través de las curvas de ajuste que ayudan a determinar la composición de cada píxel mezclado. Finalmente, es

posible mencionar que la clasificación suave no es aplicada a toda la imagen satelital sino únicamente a los píxeles mezclados de la región de transición.

## **1.6 Organización de la tesis**

El resto de la tesis está organizada de la siguiente manera: en el capítulo dos se describen los conceptos básicos que ayudan a entender los temas relacionados con percepción remota usados en este trabajo. En este capítulo también se muestran los conceptos fundamentales para el manejo de incertidumbre en imágenes satelitales. En el capítulo tres se describe los principales trabajos del estado del arte organizados de acuerdo a dos vertientes principales: los relacionados con la localización de regiones de transición y los relacionados con la clasificación de los píxeles mezclados. En el capítulo cuatro se muestran las partes principales que describen al método propuesto para la solución del problema de investigación. Los experimentos se encuentran organizados en el capítulo 5. Finalmente, en el capítulo 6 se presentan las conclusiones, aportaciones y trabajo futuro relacionados con el trabajo de investigación desarrollado.

## II. Conceptos básicos

### 2.1 Percepción Remota

La percepción remota es la ciencia y el arte de obtener información acerca de un objeto, área o fenómeno a través del análisis de los datos adquiridos por un dispositivo que no se encuentra en contacto con el objeto área o fenómeno bajo investigación, (Reddy, 2008). A continuación se describen los conceptos importantes relacionados con percepción remota:

**Banda espectral.** Canal dentro del intervalo de frecuencias disponibles del sensor con el cual se adquiere la imagen satelital (Weng, 2009).

**Endmember.** Elemento (píxel) que presenta las características más representativas de una región de píxeles en una imagen.

**Datos raster.** Conjunto de datos que representa un atributo cualitativo o cuantitativo que pueden ser organizados mediante una matriz de celdas (píxeles).

**Ground truth.** Conjunto de datos reales extraídos por un experto en el dominio que puede ser utilizado para validar los métodos de segmentación y clasificación.

**Imagen raster.** Imagen constituida por una serie de puntos arreglados en forma matricial. Cada punto (píxel) corresponde a un elemento de la imagen y representa una característica como elevación, ángulo de inclinación, nivel de gris del tipo de cobertura, etc.

**Imagen vectorial.** Imagen constituida únicamente por los puntos que forman a los polígonos de un objeto.

**Píxel puro.** Píxel formado por un solo tipo de cobertura de suelo, tal como bosque, zona urbana, agua, etc.

**Píxel mezclado.** Píxel formado por la combinación de dos o más tipos de coberturas de suelo.

**Resolución espacial.** Frecuentemente expresada en términos de la distancia de muestreo del suelo (*Ground Sampling Distance, GSD*) y se refiere al área cubierta sobre la tierra por un solo píxel. La resolución espacial se basa en varios factores, tal como el campo de vista del sensor (*Field of View, FOV*), altitud a la que se encuentra el sensor, y el número de detectores del sensor, (Navulur, 2006).

**Resolución espectral.** Se refiere al número de bandas espectrales para un sensor dado. Dependiendo del número de bandas en los sensores, diversos términos resultan con el uso de prefijos tales como *multi*, *super*, e *hiper*, son usados en percepción remota. Las imágenes multiespectrales tienen menos de diez bandas, las superespectrales, más de diez bandas y las hiperespectrales, comúnmente tienen cientos de bandas, (Navulur, 2006).

**Respuesta espectral.** Es la cantidad de radiación que refleja cada tipo de cobertura de suelo y que es detectada por el sensor del satélite para obtener la imagen. La respuesta espectral permite la identificación de materiales y características encontradas sobre la superficie de la tierra, tal como bosques, pastizales, aguas oceánicas, etc.

**RGB.** Composición de tres bandas en las que se utilizan los canales del verde, rojo y azul. Cuando se utilizan los tres primeros canales del espectro visible se le denomina composición en verdadero color, si se utilizan otros tres canales es una composición en falso color.

## 2.2 Incertidumbre en las imágenes satelitales

La incertidumbre puede representarse en términos de su imprecisión, ambigüedad o vaguedad. Según el diccionario inglés Oxford es: “lo que no se conoce o no se sabe con certeza” (Clarendon, 1993). De manera general, incertidumbre es algo que conlleva poca información,

(Foody, 2002). Por ejemplo, si algo es incierto, sabemos que no se está 100% seguro de ello, pero no se sabe más que eso. Por otra parte, según la ciencia de la información geográfica (*GISci, Geographic Information Science*) la incertidumbre de una medición puede ser descrita por un rango de valores que posiblemente incluyan el valor verdadero del objeto medido (Shi, 2010).

En la figura 2.1 se muestran las interpretaciones de incertidumbre y su correspondiente teorías matemáticas para manejar las incertidumbres (Shi, 2010). La imprecisión se refiere al nivel de variación asociado con un conjunto de mediciones o falta de precisión. La ambigüedad es asociada con una o muchas relaciones, o también con una forma de falta de claridad, el cual implica uno o más significados. Por ejemplo, la ambigüedad puede causar dificultad en decidir a que cobertura de suelo, en una clasificación de imágenes satelitales, pertenece un píxel. La vaguedad se refiere a la falta de claridad en para la descripción de los objetos y normalmente es asociado con la dificultad de realizar una distinción clara o precisa en relación a un objeto en el mundo real.

Distintos aspectos de incertidumbre son dirigidos mediante diferentes teorías matemáticas correspondientes. Por ejemplo, la probabilidad y estadística son empleadas para la descripción de la imprecisión, un tipo de incertidumbre. La teoría de los conjuntos difusos es usada para evaluar a dos diferentes categorías de incertidumbre. Las mediciones difusas pueden ser usadas para describir vaguedad, mientras la ambigüedad puede ser cuantificada por la medida de contrariedad, medida de confusión y la medida de no especificidad. Una medida de información fue introducida por Hartley en 1928 (conocido como Medida de Hartley) para describir ambigüedad en un conjunto duro. La medida de incertidumbre de la entropía de Shannon en la teoría de la información se basa en la teoría de la probabilidad. La teoría de la topología difusa se usa para modelar relaciones topológicas inciertas entre objetos espaciales (Shi, 2010).

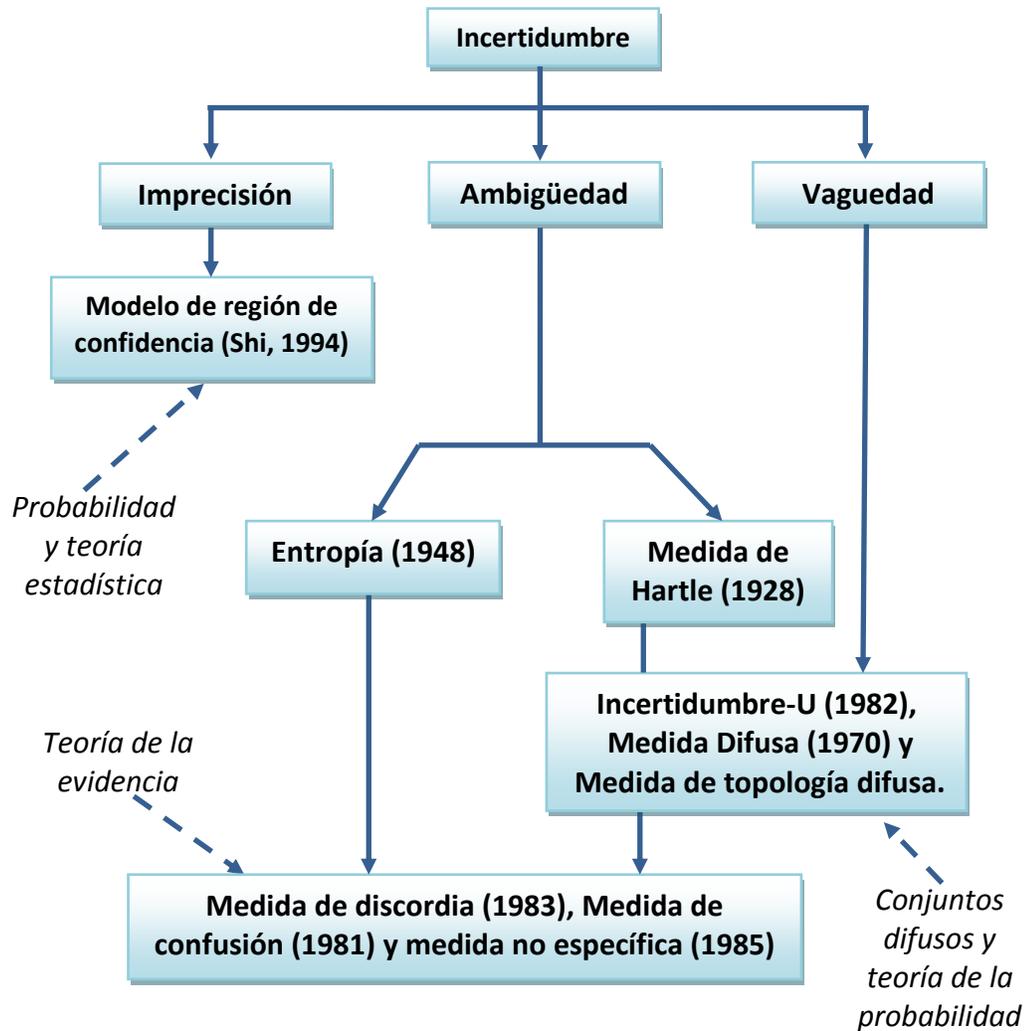


Figura 2.1. Medidas de incertidumbres basados en diversas teorías matemáticas. Traducida al español a partir de (Shi, 2010).

A continuación se definen algunos conceptos importantes relacionados con la incertidumbre:

**Ambigüedad.** Es la incertidumbre asociada a los conjuntos duros. Por ejemplo, en percepción remota, una cobertura de suelo frecuentemente se mapea usando clasificación dura (en la cual cada píxel en una imagen es asignado a una de varias clases). Cada asignación dura se hace con alguna ambigüedad. Esta ambigüedad es más frecuentemente expresada a través de una probabilidad (Foody, 2002).

**Vaguedad.** Relacionada con los conjuntos que no son duros, sino más bien son difusos o suaves. Por ejemplo, en percepción remota, una cobertura de suelo varía continuamente de un lugar a otro (por ejemplo, ecotonos y zonas de transición). Bajo estas circunstancias, las clases deben ser definidas como difusas, no duras (Foody, 2002).

### 2.2.1 Objetos difusos

A pesar de que muchas entidades geográficas se representan dentro de un GIS (*Geographic Information System*) a través de límites claros (bien definidos), en realidad pueden tener límites indeterminados así como una extensión espacial difusa. Esto se debe a que son distribuidos continuos en el espacio y tiempo. Desde principios de los 1970s, la teoría de los conjuntos difusos ha sido introducida y aplicada para modelar incertidumbre en las descripciones temáticas de las entidades geográficas, por ejemplo, en la clasificación difusa de tipos de entidades que presentan ambigüedad en la definición de clases, (Cheng, 2002). En este caso, los atributos temáticos (clasificaciones) que describen a estas unidades de mapeo son tratados como ambiguos e inciertos, mientras que las unidades espaciales son representadas usualmente por límites definidos, (Cheng, 2002). Hoy en día, la teoría difusa está siendo aplicada para modelar la incertidumbre en los aspectos geométricos de las unidades de mapeo, tratando con las ubicaciones indeterminadas de los límites debido a la clasificación incierta o definición difusa de las unidades de mapeo, (Lowell, 1994; Edwards, 1996; Usery, 1996; Brown, 1998), límites difusos (Wang, 1996), geometría (Altman, 1994) y topología (Dijkmeijer, 1996).

Las entidades geográficas son inherentemente indeterminados debido a la influencia de diversos aspectos. A continuación se presentan los más comunes:

**Continuidad.** Las entidades geográficas, tales como praderas, líneas costeras y bosques, se encuentran distribuidas continuamente en el espacio. Se sabe donde coinciden sus límites definidos con la instancia prototipo (cobertura homogénea) pero resulta menos claro entre los límites de la cobertura continua y otra instancia. Por lo tanto, debido a su distribución continua en el espacio, no existen límites claramente diferenciables entre distintas coberturas de suelo.

Cuando se interpretan estas entidades en una imagen satelital, los límites pueden parecer diferentes de una persona a otra.

**Heterogeneidad.** Otro aspecto de indeterminación resulta cuando las entidades espaciales pueden ser heterogéneas o una mezcla entre diversos tipos de coberturas. Por ejemplo, en la mezcla de árboles y pasto, o de diversos tipos de árboles presentes en un bosque.

**Dinamismo.** Muchas entidades geográficas son dinámicas y cambian con el tiempo. Es difícil tomar medidas precisas porque cambian después de la medición original.

**Dependencia con la escala** (Resolución espacial). La definición de las entidades geográficas es usualmente dependiente a la escala y contexto. Con coberturas de suelo, por ejemplo, aumentando el nivel de resolución, regularmente resulta en la identificación de nuevas áreas o clases, en particular en las zonas fronterizas del nivel de mayor resolución.

### 2.2.2 Representación de entidades geográficas como objetos difusos

Comúnmente diversos tipos de incertidumbre son encontrados en la definición de una categoría y/o en la observación de datos los cuales darán como resultado una clasificación difusa (con gran incertidumbre). Una incertidumbre temática es determinada después del proceso de clasificación. Este tipo de incertidumbre es asociada con el error final donde se identifica cada tipo de cobertura de suelo en el mapa temático construido (Schiewe, 2008). A pesar de que la incertidumbre en la clasificación es considerada principalmente como temática, dará lugar a la vaguedad geométrica (forma difusa de una cobertura de suelo), (Schiewe, 2008). Por ejemplo, durante la clasificación de imágenes, la certeza de que un píxel pertenezca a una clase temática podría ser expresada a través de una función de verosimilitud, la cual es evaluada en el proceso de clasificación. Los segmentos de la imagen entonces pueden ser formados por conjuntos de píxeles contiguos que caen dentro de la misma clase. Si estos segmentos representan la extensión espacial (región de una cobertura de suelo) de los objetos, entonces la incertidumbre de la geometría de estos objetos se debe a que el valor de la función de verosimilitud varía para cada píxel, sobre todo en las fronteras que delimitan la definición del objeto.

Sin embargo, con esta clasificación difusa llena de incertidumbre, es difícil identificar los límites definidos o la extensión espacial exacta de los objetos. En tal caso, el área de interés no es homogénea en términos de la clasificación, y la descripción convencional de los objetos definidos no es válida. Por lo tanto, el concepto de objetos con extensión espacial difusa puede ser aplicado. Esto significa que la geometría del objeto no puede ser representada por un polígono claramente definido, sino más bien por un conjunto de píxeles contiguos o rejilla de celdas, donde cada uno de ellos es homogéneo en términos de la pertenencia difusa. Cuando una celda se asigna a un objeto  $O_k$  con una extensión exclusiva  $S_k$ , entonces vamos a encontrar que  $\mu_{sk} > \mu_{sl}$  ( $l \neq k$ ), donde  $S_k$  y  $S_l$  representan la extensión espacial de un objeto  $O_k$  y  $O_l$ , respectivamente, y  $\mu_{sk}$  y  $\mu_{sl}$  representan la certeza correspondiente de la celda perteneciente a  $S_k$  y  $S_l$ . Bajo este concepto, las entidades geográficas se representan como un campo difuso, (figura 2.2).

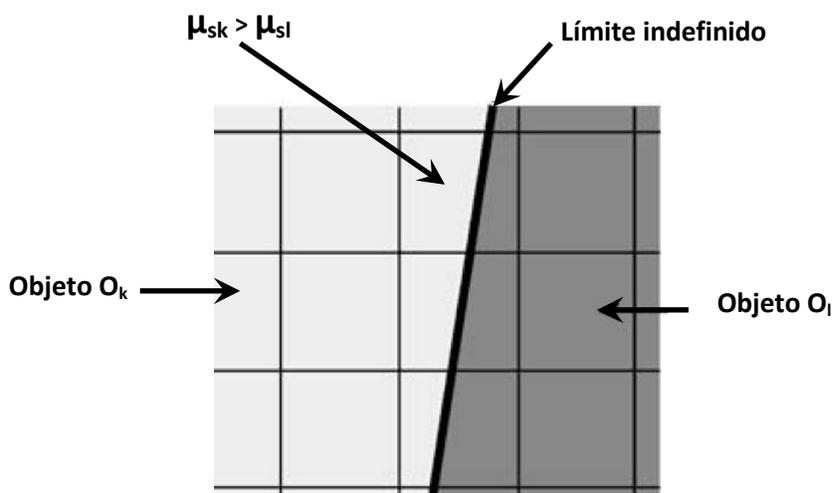


Figura 2.2. Descripción de entidades geográficas como objetos difusos.

La estimación de la extensión espacial de los objetos a partir de estas clasificaciones difusas se relaciona con la interpretación de difusión de los objetos y sus relaciones topológicas (Cheng, 2002), tal como su representación. En general, se pueden aplicar cuatro formas distintas de representar los objetos difusos que se describen a continuación (ver figura 2.3):

- a) **Area fuzzy-fuzzy.** Esta representación de los objetos es intuitivamente procedente del resultado de la clasificación difusa. Los objetos espaciales pueden ser extraídos a partir

de estos resultados de la clasificación con segmentos de imagen consistentes de conjuntos contiguos de píxeles o rejilla de celdas que pertenecen a la clase. Entonces, los objetos de una clase pueden ser representados como una capa del raster, de modo que son formadas  $N$  capas de objetos, cada una consistente de regiones difusas. Si cada región representa la extensión espacial de un objeto, el objeto se denomina objeto fuzzy-fuzzy (FF-O), donde el primer “fuzzy” significa que su extensión espacial es difusa y el segundo “fuzzy” significa que su temática interior es difusa, porque contiene celdas que han sido asignadas a la clase temática de la región con una certeza menor que 1 (ver figura 2.3a).

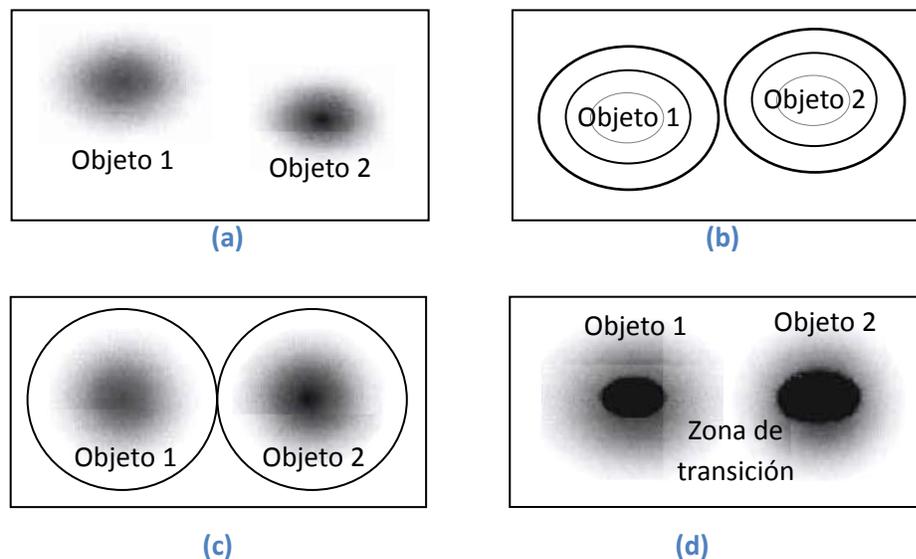


Figura 2.3. Cuatro maneras para representar los objetos difusos. (a) Áreas fuzzy-fuzzy, (b) Límites de corte  $\alpha$ , (c) Límites condicional, (d) Zonas de transición. Figura traducida al español de (Cheng, 2002).

- b) **Límite de corte  $\alpha$ .** Si se define un valor de umbral  $\alpha$ , para la clasificación de cada capa de las áreas fuzzy-fuzzy, se formará un límite de corte  $\alpha$  (Figura 2.3b). En este caso, los segmentos de cada capa tendrán límites de corte  $\alpha$ .
- c) **Límite condicional.** En otras aplicaciones, el área de los objetos se define como espacialmente disjunta, por ejemplo, no se traslapan de manera que cada celda pertenece en un principio a un solo objeto. Si los objetos forman una partición espacial, entonces cada celda debe pertenecer a solo un objeto, como en el caso de estudio de una zona costera, donde las aguas, la playa y la arena se consideran como objetos

espacialmente disjuntos. Aunque los límites entre la playa y la arena no pueden ser localizados de manera clara, el modelo conceptual sugiere que una posición específica debería pertenecer ya sea a la playa o a la arena, pero no a ambas. El modelo conceptual define lo que debe interpretarse cuando se describe un objeto (cobertura de suelo). En este caso es necesario combinar los objetos de diferentes capas en una capa y formar una partición espacial completa del área.

- d) **Zona de transición.** En este caso no es posible elegir un límite bien definido debido a que existen zonas de transición entre los objetos. En las zonas de transición resulta difícil asignar un píxel a un solo objeto. De esta manera, ciertos criterios son aplicados para asignar el píxel ya sea como centro de los objetos (píxel puro) o a la zona de transición (píxel mezclado).

### 2.2.3 Generación de incertidumbre en el manejo de datos sensados remotamente

Cuando se transforman los datos a través de los diferentes modelos conceptuales del espacio geográfico, las características de la incertidumbre en los datos pueden cambiar. Esto se debe a que las técnicas utilizadas para transformar los datos también alteran la incertidumbre inherente a los mismos y, además, pueden introducir mayor incertidumbre que al inicio. Las cuatro etapas del análisis de imágenes satelitales se muestran en la figura 2.4, las cuales representan los cuatro modelos del espacio geográfico: los datos de campo, los datos de la imagen, las coberturas temáticas, y los objetos geográficos. Estos modelos son típicos de los utilizados en la integración de los GIS (Sistema de Información Geográfica) y las actividades de percepción remota. Estos modelos representan solamente las propiedades conceptuales de los datos y pueden ser considerados aquí como independientes de cualquier estructura de datos específica que pueda ser utilizada para codificar y organizar los datos.

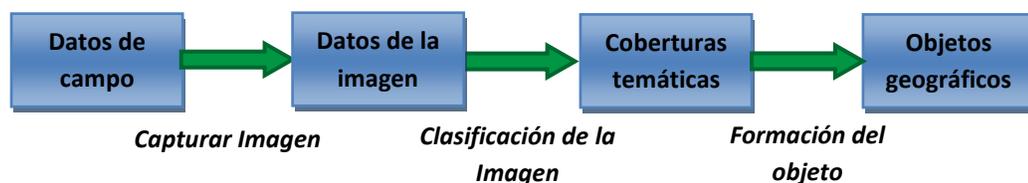


Figura 2.4. Distintos modelos conceptuales por los que pasan los datos sensados remotamente. Figura traducida al español de (Gahegan, 2000).

Con base en estos modelos, Gahegan y Ehlers en (Gahegan, 2000) desarrollaron un modelo general de simulación del error de integración que inicia a partir de los datos de campo (datos en bruto sensados remotamente) hasta los datos de los objetos geográficos. Esta descripción cubre las fuentes de error tal como son generadas en percepción remota y GIS. Los tipos de incertidumbre se originan a partir de las siguientes propiedades:

**Valor.** Se refiere a la incertidumbre generada en el manejo numérico de los datos. Limitación en la representación infinita de los números, truncamiento de la longitud del número, etc.

**Espacial.** Se debe a la imprecisión en la ubicación exacta de los píxeles pertenecientes a un tipo de cobertura de suelo.

**Temporal.** Errores en la imprecisión en los registros de los momentos exactos en que se adquieren las imágenes satelitales.

**Consistencia.** Incertidumbre provocada por inconsistencias debido al medio entre el satélite y el suelo que se detecta, como caer fuera de luz, sombras, entre otras.

**Integridad.** Falta de datos importantes (ángulo de inclinación del sensor, factores de corrección de la imagen al momento del sensado) que no fueron almacenados durante el proceso de captura.

Estas fuentes de incertidumbre, los errores de medición y etiquetado, así como la incertidumbre espacial y temporal afecta de forma individual a un dato o a un conjunto de datos. Las dos últimas propiedades de consistencia e integridad sólo afectan a conjuntos de datos definidos, ya que son comparativas (ya sea internamente entre los datos o algún tipo de marco externo). La tabla 2.1 resume los distintos tipos de incertidumbres que se generan en los distintos modelos conceptuales, partiendo de los datos de campo, datos de la imagen, datos clasificados hasta los datos para la formación de los objetos.

**Tabla 2. 1 Tipos de incertidumbres y sus fuentes de generación en los cuatro modelos del espacio geográfico (Gahegan, 2000).**

Tipo de incertidumbre	Modelos del espacio geográfico			
	Campo	Imagen	Temático (Clasificación)	Objeto
Valor	Errores de medición y precisión.	Cuantificación de las bandas espectrales y rango dinámico.	<b>Incertidumbre de etiquetado (Error de clasificación).</b>	Asignación incorrecta al tipo de objeto, incertidumbre en la definición del objeto.
Espacio	Error de ubicación y posición.	Error de registro, precisión del muestreo.	<b>Efectos mezclados cuando se combinan los datos representados por diferentes propiedades espaciales.</b>	Error de la forma del objeto, inconsistencia topológica, errores en "split y merge".
Tiempo	Error temporal y de precisión.	El error temporal y la precisión son generalmente insignificantes para los datos de la imagen.	<b>Efectos mezclados cuando se combinan los datos que representan diferentes momentos.</b>	Efectos mezclados cuando se combinan los datos que representan diferentes momentos.
Consistencia	Muestras / lecturas recolectadas o medidas en forma similar.	Imagen capturada de forma idéntica para cada píxel, pero: inconsistencias debido al medio entre el satélite y el suelo de detección, caen fuera de luz, sombras.	<b>Las estrategias del clasificador suelen ser consistentes en el tratamiento de un conjunto de datos.</b>	Los métodos para la formación del objeto pueden ser consistentes, pero a menudo no lo son; depende de la estrategia de clasificación.
Integridad	Estrategia de muestreo de coberturas adecuadas en espacio, tiempo y dominio de atributos.	La imagen está completa, pero partes de tierra pueden ser oscurecidas (nubes, árboles).	<b>Depende de la estrategia de clasificación (clasificación del conjunto de datos completo o sólo algunas clases).</b>	Depende de la estrategia de extracción: las inconsistencias espaciales y topológicas pueden resaltar como resultado de la formación del objeto.

## Resumen

En este capítulo se describieron las distintas definiciones relacionadas con percepción remota y sistemas de Información Geográfica (GIS) que fueron utilizados durante el desarrollo de la tesis de investigación. También se describieron detalladamente la forma en que influyen los diversos tipos de incertidumbre para la formación de los objetos difusos (coberturas de suelo) que aparecen en una imagen satelital. Por último, se describió la forma en que se conceptualizan las fronteras indefinidas que delimitan a las entidades geográficas en una imagen satelital.

### III. Estado del arte

La revisión de los principales trabajos relacionados con esta investigación ha sido dividida en dos vertientes principales: (1) la localización de regiones de transición en imágenes satelitales y (2) Clasificación de los píxeles mezclados generados por regiones de transición. El análisis de la literatura se ha realizado con base en estas dos líneas relevantes, las cuales se detallan a continuación.

#### 3.1 Localización de regiones de transición

La tabla 3.1 muestra los principales trabajos relacionados con el análisis de las propiedades de las regiones de transición. Las propiedades enlistadas se describen a continuación:

**Detección:** Esta propiedad se refiere a la obtención de los bordes (límites discretos) de cada cobertura de suelo presente en la imagen. Los límites discretos no contienen amplitud (región de transición) para separar espacialmente a dos coberturas de suelo.

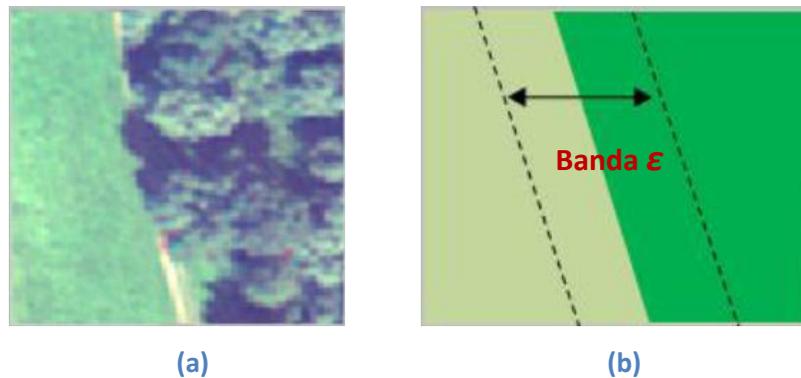
**Localización:** Se refiere a la ubicación de las fronteras que delimitan a dos coberturas de suelo. Las fronteras recorren de forma paralela a ambos lados de las coberturas de suelo. Los límites son no discretos por lo que contienen una amplitud.

**Amplitud:** Propiedad relacionada al análisis para determinar la amplitud cualitativa o cuantitativa de la región de transición.

**Tabla 3.1. Trabajos relacionados con las propiedades de las regiones de transición.**

Propiedad analizada de la región de transición	Método de detección utilizado	Referencia
Detección	Filtrado	(Pitas, 2000)
	Estadísticos	(Wiens, 1985; Cornelius, 1991; Johnston, 1992).
	Detección por bordes	(DeFries, 1995)
	Mediante econotonos	(Fortin, 2000)
Localización	Modelo Geométrico	(Christman, 1982; Edwards, 1996; Galton, 2005; Schiewe, 2009a)
Amplitud	Modelo Semántico	(Jalas, 1955; Sukopp, 1972; Christman, 1982; Edwards, 1996; Schiewe, 2009b)

Uno de los primeros trabajos orientados a modelar regiones de transición describe a estas regiones como bandas  $\epsilon$ , propuesta realizada por Christman en 1982 (Christman, 1982). Estas bandas  $\epsilon$  se refieren a zonas de transición generadas por dos tipos diferentes de coberturas homogéneas. Las bandas  $\epsilon$  recorren paralela y simétricamente a los objetos (coberturas de suelo) que la generan, ver figura 3.1.

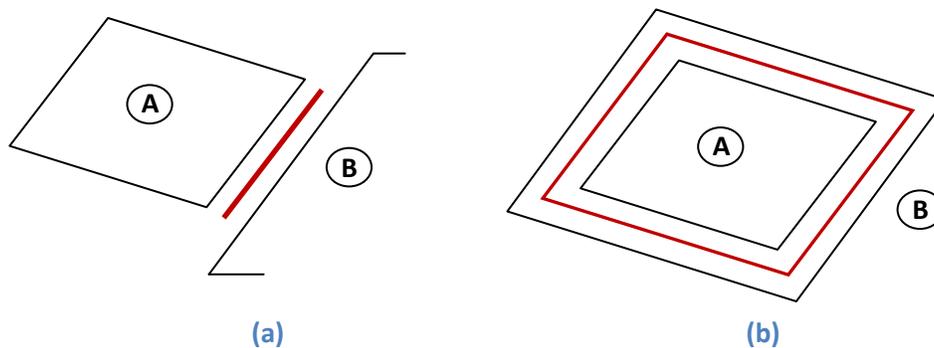


**Figura 3.1. Distintos modelos conceptuales por los que pasan los datos sensados remotamente. Figura traducida al español de (Gahegan, 2000).**

Schiewe et al., en (Schiewe, 2009a) propusieron la localización de las regiones de transición utilizando imágenes satelitales de alta resolución espacial. Su contribución se centra en modelar

las regiones de transición indeterminadas para describir las incertidumbres asociadas a ellas. Los autores basan su trabajo en el modelado de regiones de transición combinando las bandas e (Christman, 1982) y la teoría de la lógica difusa. Para determinar el modelado de las regiones de transición toman en cuenta dos aspectos: el geométrico y el semántico, los cuales son descritos a continuación.

- a) *Modelado geométrico.*- Las regiones de transición sirven como un modelo del área que delimita a dos objetos geográficos clasificados. Su geometría es construida de acuerdo al tipo de objetos adyacentes. Schiewe et al., asumen que las regiones de transición se presentan de forma simétrica, es decir, dos objetos adyacentes comparten la misma geometría de la región de transición. La geometría de las regiones de transición se forma resguardando parcialmente una banda de transición a cada lado de la frontera que comparten dichos objetos (figura 3.2a). La amplitud de las bandas de transición depende de las coberturas de suelo.



**Figura 3.2. Construcción de la región de transición entre los objetos A y B. (b) Regiones de transición que delimitan al objeto A, (Schiewe, 2009a).**

- b) *Modelado semántico.*- La pertenencia temática de los objetos vecinos en consideración tiene una influencia significativa en la difusión y amplitud de las regiones de transición. De esta manera, las estructuras creadas por el ser humano (carreteras, edificios, etc.) presentan regiones de transición más pequeñas (por su compactés o forma elongada) que objetos naturales que muestran un mayor comportamiento difuso (por ejemplo, entre océano y costa).

En este mismo sentido, definir la amplitud de las regiones de transición en términos de números absolutos no es posible debido a dos factores: (a) La influencia estacional, el estado y amplitud de las regiones que delimitan a tipos de vegetación dependen de la situación fenológica de la comunidad examinada (por ejemplo, la etapa de crecimiento y desarrollo de la vegetación). La reflectancia espectral de la vegetación está cambiando siempre durante su crecimiento y depende del estado fisiológico de la vegetación. (b) Tamaño y forma de las regiones vecinas. Edwards y Lowell en (Edwards, 1996) descubrieron que el tamaño de los polígonos examinados tiene una influencia en la formación de una frontera y por tanto, en la amplitud de la frontera. En consecuencia, regiones más pequeñas tienden a ser más difusas comparadas con regiones más grandes, suponiendo que las demás condiciones permanecen estables. Con esto, resulta difícil relacionar una y solo una amplitud absoluta a todas las regiones de una clase de objetos.

Alternativamente, fue tomado a partir de la ecología un enfoque cualitativo para la definición de la amplitud de los límites de las regiones de transición. Jalas (Jalas, 1955) y Sukopp (Sukopp, 1972) desarrollaron un sistema que describe la intensidad de la influencia humana, donde se distinguen “los hábitats naturales” y “los hábitats artificiales”. Basado en esto, las regiones en cuestión se clasifican en una escala que va desde “lo natural” hasta “lo artificial”. Como resultado se tiene una medida de la influencia del hombre sobre el paisaje.

En (Schiewe, 2009a) se muestra los resultados que definen los primeros intentos para la definición de la amplitud de la región de transición. El resultado de su investigación es una clasificación ordinal donde se muestra cada clase (tipo de cobertura de suelo) asociada a una amplitud cualitativa que representa la manera en que se encuentran relacionadas las clases analizadas. Utilizan una escala cualitativa para la descripción de la amplitud de las regiones de transición, a partir de "0" para una amplitud muy pequeña hasta terminar con "+ + + +" para una amplitud muy grande, tal como se muestra en la tabla 3.2. Finalmente, asumen que en la comparación de clases adyacentes, la clase más artificial siempre asigna la amplitud de la región de transición. De esta manera determinan la amplitud de las regiones de transición para cada tipo de cobertura de suelo.

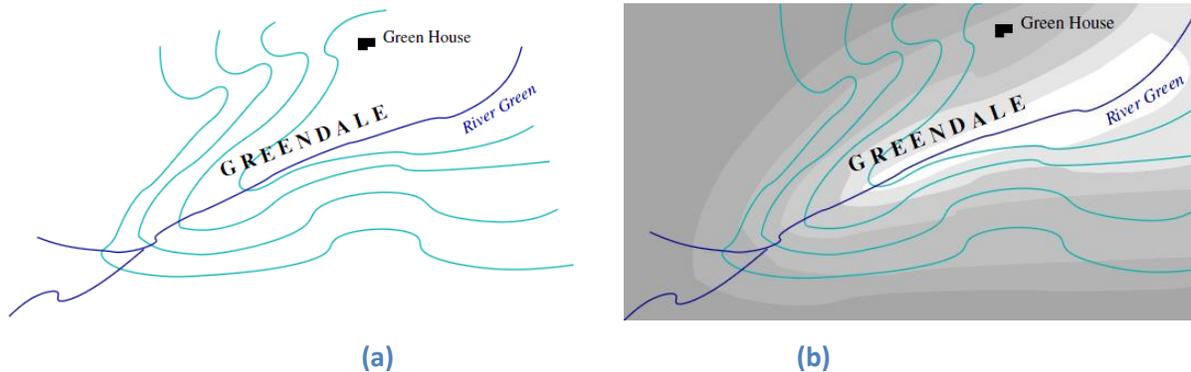
**Tabla 3.2. Comparación de las relaciones de regiones de transición para diferentes coberturas de suelo (Schiewe, 2009a).**

Orden	Clase (Cobertura de suelo)	Clasificación	Amplitud
1	Habitat	Muy grande	+++++
2	Agua	Grande	++++
2	Estructuras pequeñas sin llegar a ser bosque (por ejemplo, cobertura arboleada)	Grande	++++
3	Bosque	Mediano	+++
4	Pradera	Mediano	++
4	Tierra labrada (suelo descubierto)	Mediano	++
5	Tierras de cultivo	Marginal	+
5	Frutas y zonas vitivinícolas	Marginal	+
5	Asentamientos e industrias	Marginal	+
6	Vías de tráfico (Puentes, carreteras)	Muy marginal	0

La principal aportación del trabajo de Schiewe et al., es el análisis de la amplitud y localización de las regiones de transición. No presentan una sección de experimentación para validar su investigación. Una desventaja que se presenta cuando se trazan las regiones de transición de forma lineal, es que es posible añadir píxeles puros a las regiones de transición o también, evitar píxeles mezclados tomándolos como parte de las coberturas homogéneas. Además, en la naturaleza, las regiones de transición se generan de manera caprichosa sin mantener una estructura determinada (excepto para las construcciones creadas por el hombre), es decir, el paso de una cobertura de suelo a otra se presenta de forma transicional y sobre todo de manera no lineal.

Galton y Hood en (Galton, 2005) propusieron un enfoque para representar vaguedad o incertidumbre de la información relacionada con la ubicación espacial. La ubicación de los objetos en la información espacial la expresan mediante diversas relaciones de “anclaje”. Estas relaciones indican exactamente lo que se conoce acerca de la ubicación espacial de un objeto sin forzar a identificar esa ubicación, ya sea con esa región precisa dentro del mismo espacio o mediante alguna construcción matemática precisa a partir de tales regiones, tal como conjuntos duros o conjuntos difusos. Un ejemplo de anclaje puede ser: “mi casa se encuentra al norte del centro del pueblo”. En este ejemplo, no se da una especificación precisa de la ubicación de la

“mi casa”, sino mas bien se describe su ubicación utilizando la información que puede ser conocida. La figura 3.3 muestra la descripción de las regiones conocidas (figura 3.3a, zona de color blanca) y de las imprecisiones que aparecen al irnos alejando de estas regiones (figura 3.3b, tonos de gris claro a gris oscuro).



**Figura 3.3. (a) Localización de objetos bien definidos en la imagen satelital, (b) ubicación de zonas indeterminadas a partir de los objetos bien definidos, (Galton, 2005).**

Mediante el anclaje, Galton y Hood mantienen presente la vaguedad e incertidumbre de la ubicación del objeto, describiendo solo lo que puede decirse con precisión acerca del objeto y dejando lo demás para un análisis posterior. En otras palabras, lo único que puede ser descrito de manera precisa acerca de una región cuyos límites son imprecisos o vagos, se da mediante el uso de sus relaciones topológicas con respecto a regiones cuyos límites son precisos. La idea central es que un objeto en el espacio de información puede ser anclado a ubicaciones del espacio preciso de diferentes maneras. Estas relaciones incluyen enunciados como: El objeto  $O$  está anclado en la región  $R$ , El objeto  $O$  está anclado sobre la región  $R$ , El objeto  $O$  está anclado alrededor de la región  $R$ , El objeto  $O$  está anclado a lo largo de la región  $R$ , etc.

En resumen, este trabajo (Galton, 2005) modela la vaguedad e imprecisión de los objetos utilizando relaciones topológicas que permiten ubicar de forma general la posición exacta del objeto manteniendo la incertidumbre del mismo. No realizan un análisis cuantitativo de sus resultados al usar las relaciones de anclaje. La desventaja radica en que no es posible realizar

una cuantificación del error acerca de la posición del objeto, sino más bien se describe a través de aproximaciones obtenidas a partir del anclaje.

Fortin y sus colegas en (Fortin, 2000) presentaron un estudio de los métodos de detección de límites para caracterizar las fronteras desde el punto de vista ecológico. Su trabajo se basa en el análisis de los sistemas dinámicos o regiones de transición denominados “ecotonos”. Un ecotono es una zona de transición entre sistemas ecológicos adyacentes, los cuales tienen un conjunto de características únicas definidas por escalas de espacio y tiempo, además de la fuerza de interacción entre los sistemas ecológicos adyacentes. La delineación de los ecotonos depende del fenómeno de interés y de los métodos estadísticos usados, así como de la resolución espacial y temporal de los datos disponibles.

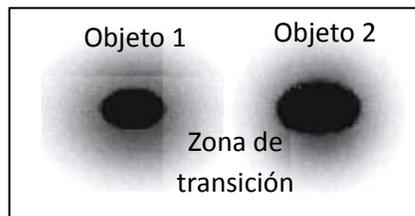
La idea principal del trabajo (Fortin, 2000) es presentar las técnicas más comunes usadas para detectar zonas de transición. A continuación se agrupan las principales técnicas descritas por Fortin et al.:

1. *Método de detección de bordes (límites).* Diversas metodologías relevantes desarrolladas para el análisis de imágenes se han centrado en mejorar la identificación de los bordes, sin embargo, han puesto menos atención en determinar si los bordes se encuentran bien definidos o más aún, en determinar su ubicación (encontrar su posición). Los mayores problemas en la detección de bordes en el contexto del procesamiento de imágenes se deben al ruido y a la mala resolución espacial de la imagen. Por ejemplo, en los datos adquiridos, el nivel más fino en el cual un borde puede ser detectado depende de la resolución de las muestras (píxeles, tamaño del cuadrante, etc.), además de que la textura por sí misma agrega ruido así como la intensidad de las discontinuidades. Los métodos más simples para detectar bordes son los basados en diferencias lineales, tales como los operadores Sobel y Kirsch, las derivadas locales de primer orden llamados kernels y los detectores de bordes o simplemente filtros de bordes (Pitas, 2000).

2. *Técnicas de agrupamiento espacial (Segmentación de imágenes)*. Existen tres grandes categorías de técnicas de segmentación: crecimiento de regiones, detección de bordes y los híbridos. Las técnicas de crecimiento de regiones necesitan de regiones “semillas” determinadas por algún algoritmo o por un operador humano. Estas regiones se expanden usando un criterio de homogeneidad basado en la contigüidad espacial hasta determinar las regiones en sus zonas límites. Las técnicas de detección de bordes identifican las fronteras para todos los objetos presentes y posteriormente intentan conectar las discontinuidades para formar una partición espacial.
3. *Métodos estadísticos*. Principalmente se basan en la disponibilidad y estructura de los datos. Estadísticamente, un límite puede ser definido como la posición donde ocurre la más alta tasa de cambio. Diversos métodos han sido desarrollados utilizando la técnica de ventana deslizante para calcular la cantidad de varianza en muestras adyacentes, por lo que un límite representa la posición donde se encuentra la varianza más alta (Wiens, 1985; Cornelius, 1991; Johnston, 1992).

El trabajo de Fortin y sus colegas se centra en el análisis de las regiones de transición mediante el uso de diversos métodos de segmentación y filtrado para determinar los límites indefinidos. No presentan resultados cuantitativos de los métodos mencionados.

Cheng, en el año 2002, propuso un trabajo relacionado con la representación espacial de objetos difusos (Lowell, 1994). En este trabajo se determinan cuatro vistas para representar los objetos difusos (detallados en la sección 2.2.2). La vista más importante relacionada con el presente trabajo de tesis es el de la *zona de transición*. Un límite claro no puede ser definido porque existen zonas de transición entre los objetos. En las zonas de transición no es posible tomar alguna decisión dado un píxel para saber a qué objeto podría pertenecer, ver figura 3.4.



**Figura 3.4. Zona de transición generada por dos objetos difusos. Figura traducida al español de (Cheng, 2002).**

La idea principal aportada por Cheng es la presencia de objetos difusos dentro de una imagen satelital. Estos objetos difusos contienen incertidumbre que debe ser tomada en cuenta para no cometer errores en la clasificación suave de las coberturas de suelo. Para realizar sus experimentos utilizaron imágenes reales de coberturas de suelo de mar y playa de los años de 1989-1991. Su estudio fue llevado a cabo con la ayuda del experto en el dominio que analizó los cambios presentados por los tipos de cobertura de suelo en este periodo de tiempo. Presentan sus resultados suelo utilizando distintos niveles de incertidumbre comprendidos entre 0.5 y 1.0. No realizan la validación cuantitativa, solo la cualitativa mediante la ayuda del experto en el dominio.

Otros trabajos relacionados con el estudio de las regiones de transición son: fronteras en coberturas de suelo (Malanson, 2006), razonamiento difuso en regiones geográficas (Guesgen, 2005), píxel de transición (Ramírez, 2010) y objetos difusos (Cheng, 2001).

### **3.2 Píxeles mezclados**

Para realizar el análisis del estado del arte relacionado con píxeles mezclados se tomaron en cuenta los siguientes aspectos:

1. Enfoque propuesto para la descomposición de píxeles mezclados.
2. Fuente de generación de los píxeles mezclados.

3. Tipo de imágenes satelitales utilizadas: selección de imágenes reales y forma de construcción de las imágenes sintéticas utilizadas.
4. Resultados relevantes obtenidos en la descomposición de los píxeles mezclados.

La tabla 3.3 muestra los principales trabajos relacionados con la clasificación de píxeles mezclados organizados de acuerdo a la fuente que los genera.

**Tabla 3. 3. Resumen de trabajos relacionados con píxeles mezclados.**

Fuente de píxeles mezclados	Método de clasificación utilizado	Referencia
Por la presencia de pequeños objetos (subpíxel) dentro del área de cada píxel	Separación espectral	Huguenin, 1997.
	Clasificador difuso	Shalan, 2003; Zhang, 2001.
	Sistema experto difuso	Penaloza, 1996.
	Red Neuro-Difusa	Foody, 2000.
	Modelo Lineal Mezclado	Lu, 2003; He, 2008.
Píxeles que contienen límites discretos entre clases temáticas	Máquina de vectores de Soporte	Dey, 2009.
	Máxima Verosimilitud	Lesparre, 2003.
	Clasificador difuso	Gutierrez, 2005.
	Clasificador neuronal	Plaza, 2009; Wang, 2007.
Transición gradual observada entre coberturas de suelo continuas	Clasificador difuso	Schiewe, 2009 <sup>a</sup> .
	Modelo de Mezcla de Gaussianas	Liu, 2009.
	Fuzzy clustering	Maulik, 2009.
Contribución de un objeto externo al área representada por un píxel	Clasificador Dempster-Shafer	Kaftandjian, 2002.

En seguida se describen los trabajos más importantes de la tabla.

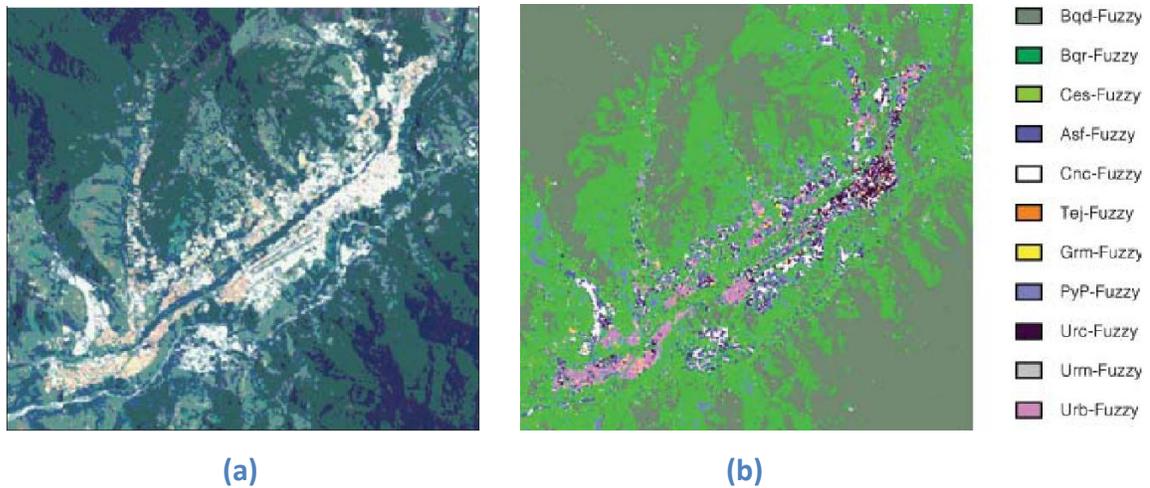
Gutierrez y Jegat presentaron en (Gutierrez, 2005) el uso de la Teoría de la Lógica Difusa para la clasificación de imágenes satelitales. La aportación principal del trabajo desarrollado se basa en el análisis de píxeles mezclados usando la matriz de partición difusa (Fuzzy Partition Matrix, FPM) propuesta por Wang en (Wang, 1990). La matriz FPM le indica al clasificador acerca de la composición de los píxeles mezclados con respecto a las clases (coberturas de suelo) presentes

en ellas. La proporción que cada clase aporta a la combinación de un píxel mezclado se determina por el experto en el dominio que analiza la imagen satelital y construye la FPM. El experto en el dominio observa la imagen a clasificar y determina los tipos de mezclas presentes. Posteriormente, asigna (según su experiencia) el porcentaje para cada clase que contiene la mezcla. Esta información se organiza a través de una matriz cuadrada, donde cada fila y columna representa un tipo de cobertura de suelo presente en la imagen. Primeramente se organizan las coberturas homogéneas que tendrán una pertenencia del 100%, posteriormente se organizan las coberturas mezcladas asignando en cada columna (cobertura homogénea presente en la mezcla) el porcentaje de pertenencia asignada por el experto en el dominio. La tabla 3.4 muestra un ejemplo de una FPM utilizada por Gutierrez y Jegat.

**Tabla 3.4. Matriz de Partición Difusa.**

IDRI_ID	1	2	3	4	5	6	7	8	9	10	11
1 Bosque denso	1	0	0	0	0	0	0	0	0	0	0
2 Bosque ralo	0	1	0	0	0	0	0	0	0	0	0
3 Césped	0	0	1	0	0	0	0	0	0	0	0
4 Asfalto	0	0	0	1	0	0	0	0	0	0	0
5 Concreto	0	0	0	0	1	0	0	0	0	0	0
6 Tejas	0	0	0	0	0	1	0	0	0	0	0
7 Gramíneas	0	0	0	0	0	0	1	0	0	0	0
8 Parque y pista	0	0	0.1	0.1	0	0	0	0.8	0	0	0
9 Urbano centro	0	0	0	0.5	0.5	0.10	0.05	0	0.75	0	0
10 Urbano milla	0	0.05	0	0.5	0.5	0.05	0.05	0	0	0.75	0
11 Urbanización	0	0	0	0	0	0.10	0.15	0	0	0	0.75

Para realizar sus experimentos Gutierrez y Jegat utilizaron una imagen satelital Landsat-TM, bandas 1, 2 y 3, con una composición en verdadero color de la región de Mérida, Venezuela. La figura 3.5 muestra los resultados de la clasificación suave usando un clasificador difuso disponible en el software comercial IDRISI. No realizaron una validación cuantitativa de los resultados de sus clasificaciones suave, únicamente realizaron la validación de manera visual mediante la ayuda del experto en el dominio.

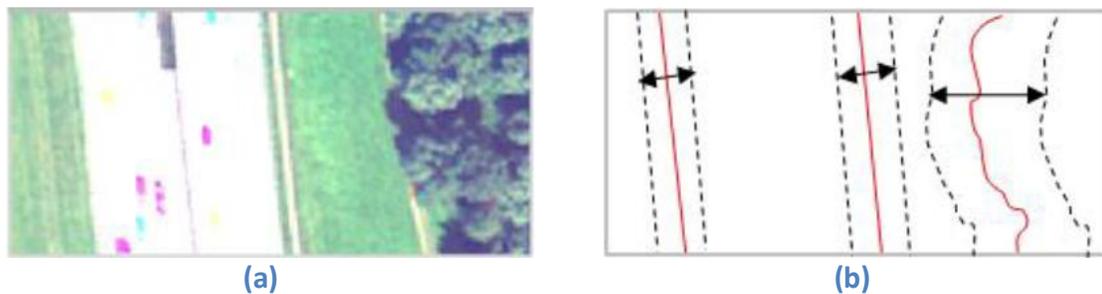


**Figura 3.5. Clasificación suave usando la FPM de la región de Mérida, Venezuela (Gutierrez, 2005).**

La aportación principal del trabajo de Gutierrez y Jegat es el uso de la FPM, a través de esta matriz se le instruye al clasificador acerca de información relacionada con la mezcla de los diversos tipos de coberturas de suelo. De esta manera, a partir de esta aportación presentada, surge una gran desventaja de su trabajo. En la naturaleza, la mezcla entre dos o mas tipos de coberturas de suelo, se traduce en la generación de múltiples (cientos o miles, dependiendo de la resolución espacial de la imagen) píxeles combinados. Gutierrez y Jegat solo pueden mapear un solo píxel mezclado a través de la FPM el cual representa a todos los múltiples píxeles mezclados generados por un caso particular de dos o más tipos de coberturas. Por ejemplo, dadas dos tipos diferentes de coberturas de suelo, el experto en el dominio asigna 70% para una clase y 30% para la otra. Sin embargo, en la imagen satelital pueden existir diferentes formas de combinación entre estas dos clases. Esto origina que los errores de omisión puedan traducirse a errores en los resultados de la clasificación. Además, en este trabajo no utilizan imágenes sintéticas para evaluar cuantitativamente los resultados que obtienen.

Schiewe y Kinkeldey en (Schiewe, 2009b) propusieron un trabajo centrado en el análisis de píxeles mezclados generados por regiones de transición. El modelado de las regiones de transición es realizado con base en los modelos geométrico y semántico de los objetos presentes en la imagen satelital propuesto por Edwards y Lowell en (Edwards, 1996). El modelo geométrico determina la forma geométrica de la región de transición a partir de la geometría

que presentan las coberturas de suelo que comparten la región de transición. Asumen que las bandas de transición son simétricas en ambos lados de la banda que se está trazando, por ejemplo, dos coberturas de suelo diferentes comparten la misma forma geométrica de la región de transición. El modelo semántico determina la amplitud de la región de transición tomando en cuenta que coberturas de suelo más naturales (las que no son alteradas por el ser humano) presentarán una mayor banda de transición. La figura 3.6 muestra la manera en que trazan las regiones de transición usando los modelos geométrico y semántico.



**Figura 3.6. (a) Imagen satelital, (b) Ubicación de las regiones de transición (Schiewe, 2009b).**

En la figura 3.6 se puede apreciar dos tipos de coberturas: pastizal (color verde claro) y bosque (color verde) donde se trazó la banda de transición en el dominio espacial. Primeramente, realizan el trazado de los límites de forma discreta (color rojo) entre cada par de coberturas de suelo. Posteriormente, basándose en la clasificación cualitativa de las regiones de transición mostrada en la tabla 3.2, determinan la amplitud de cada una de las regiones de transición presentes en su imagen original (líneas punteadas ubicadas a ambos lados del trazo discreto). Para realizar la clasificación suave de los píxeles mezclados, Schiewe y Kinkeldey, construyeron funciones de pertenencia de tipo lineal tal como se muestra en la parte inferior de la figura 3.7.

El grado de pertenencia de cada píxel mezclado se obtiene mapeando la ubicación espacial (distancia a la cobertura de suelo) del píxel en turno hacia la función lineal trazada para cada tipo de cobertura. En la función lineal se observa que los grados de pertenencia en la región de transición van desde la pertenencia total (1) hasta la no pertenencia (0) para cada tipo de

cobertura de suelo. Schiewe y Kinkeldey asumen una transición lineal de los píxeles mezclados sobre la amplitud de la región de transición.

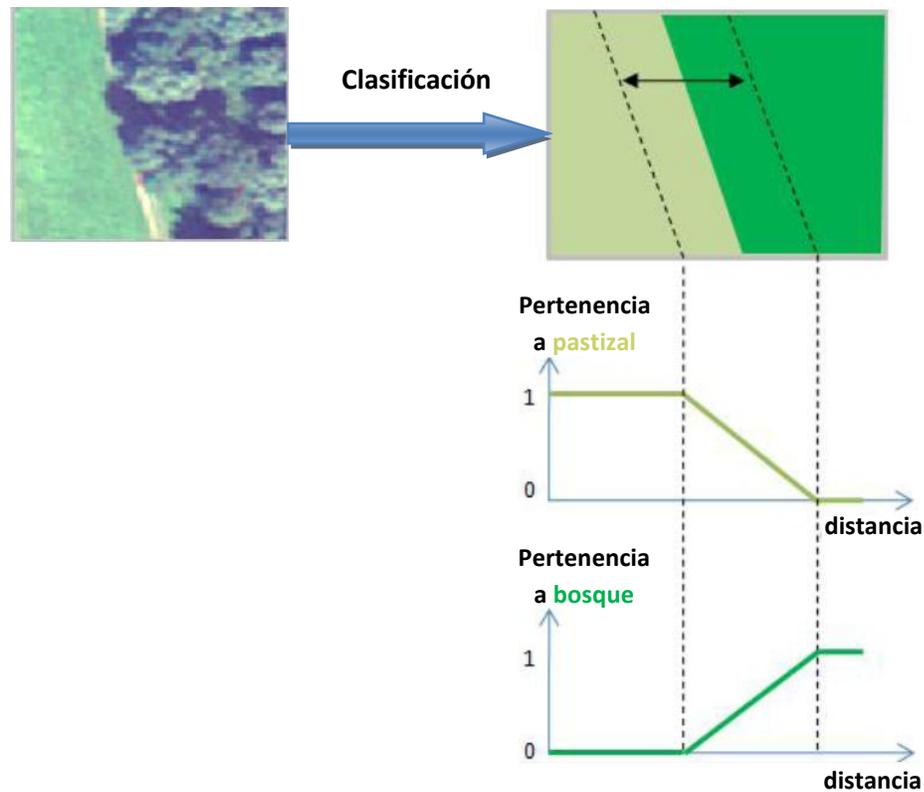


Figura 3.7. Clasificación de píxeles mezclados usando funciones lineales de pertenencia difusa. Figura traducida al español a partir de (Schiewe, 2009b).

La contribución principal del trabajo reportado en (Schiewe, 2009b) es la definición de una medida de la certeza difusa por clase (Class-specific Fuzzy Certain Measure, *CFCM*). La *CFCM* considera la incertidumbre presente en las regiones de transición tanto en la imagen de referencia como en la imagen clasificada. Alrededor de las regiones de transición la pertenencia a la clase puede ser 1.0 (si el píxel cae dentro del objeto en cuestión) y 0.0 (en caso contrario). En el interior de las regiones de transición, las pertenencias a las clases son determinadas por la función difusa que produce un valor en el intervalo [0.0, 1.0]. La medida de certeza difusa total se obtiene mediante el cálculo de la diferencia entre las pertenencias a las clases  $\mu_{REF}$  y  $\mu_{CLAS}$  para cada clase como se muestra a continuación:

$$CFCM(c) = 1 - \frac{1}{n} \sum_{i=1}^n |\mu_{i,REF} - \mu_{i,CLAS}| \quad (3.1)$$

$$\forall i | \mu_{i,REF} > 0 \vee \mu_{i,CLAS}$$

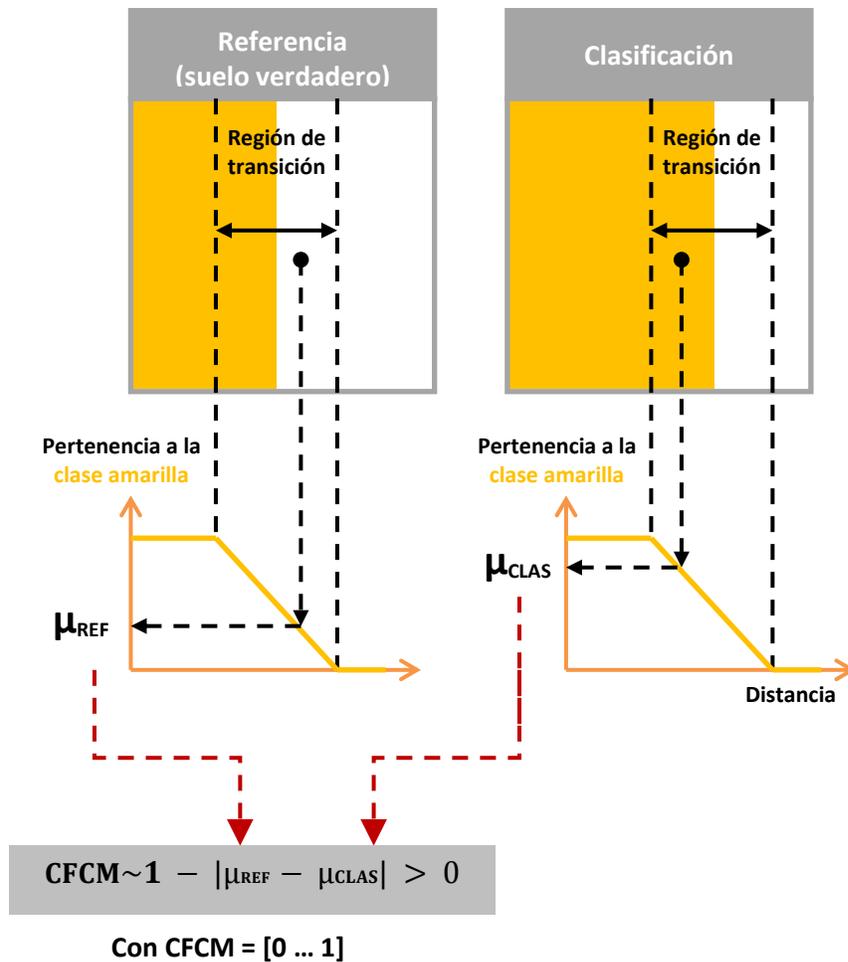
Donde:

$\mu_{REF}(c)$ : Valor de pertenencia de un píxel/área para una clase  $c$  en los datos de referencia.

$\mu_{CLASS}(c)$ : Valor de pertenencia de un píxel/área para una clase  $c$  en los datos de la clasificación.

$n$ : Número de píxeles/áreas bajo prueba.

De acuerdo a la ecuación 3.1, si se obtiene un alto valor para de  $CFCM$ , significa que existe una alta coincidencia del objeto de la clase entre el conjunto de datos de referencia y la clasificación. La figura 3.8 describe la manera en que puede ser utilizada la  $CFCM$  para la validación de clasificación de píxeles mezclados.

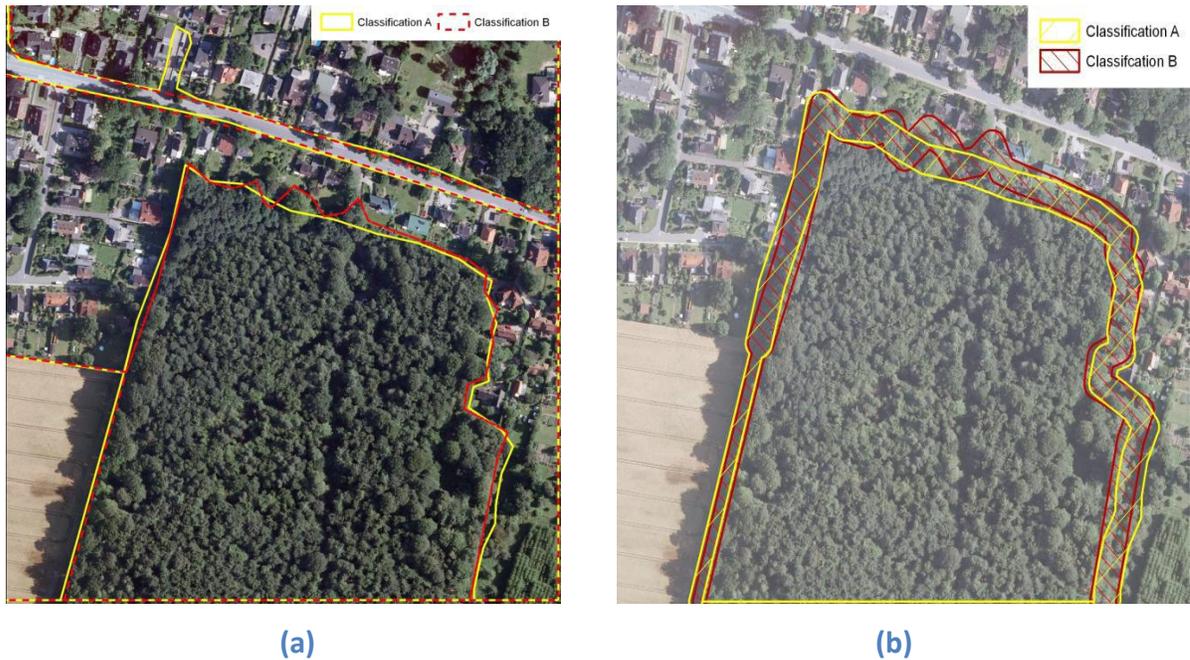


**Figura 3.8. Construcción de la medida CFCM para la evaluar la clasificación de píxeles mezclados. Figura traducida al español a partir de (Schiewe, 2009b).**

En la figura 3.8 se aprecia cómo se extraen las pertenencias (en este caso usando funciones lineales) de los datos de referencia ( $\mu_{\text{REF}}$ ) y de los resultados de la clasificación ( $\mu_{\text{CLAS}}$ ). Se calcula el valor absoluto de la diferencia de estos dos valores y el resultado es sustraído de la unidad para finalmente obtener la CFCM del píxel en turno. La ecuación 3.1 puede ser aplicado a un solo píxel o a un grupo de píxeles para un mismo tipo de cobertura de suelo.

Para realizar sus experimentos Schiewe y Kinkeldey utilizaron imágenes reales de Hamburgo, Alemania. El área de estudio comprende tres tipos de coberturas: zona residencial, bosque y zona de agricultura. La ubicación de las regiones de transición la obtuvieron de manera manual

mediante el apoyo del experto en el dominio, ver figura 3.9a. La amplitud de las regiones de transición fueron obtenidas usando los modelos semánticos y geométricos descritos en la sección 3.5. La figura 3.9b muestra los resultados de la ubicación de las regiones de transición para la imagen analizada.

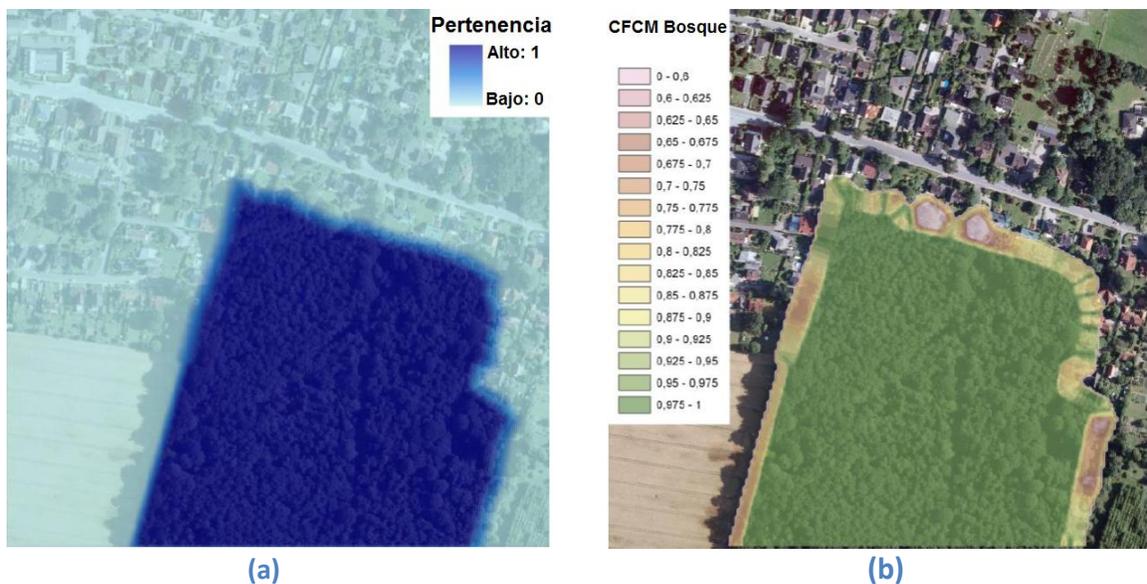


**Figura 3.9. (a) Dos maneras diferentes de trazar las regiones de transición de forma manual, (b) Definición de las regiones de transición para la cobertura bosque con diferentes amplitudes para agricultura y zona residencial (Schiewe, 2009b).**

La figura 3.10a muestra los resultados de la clasificación suave de la imagen de la figura 3.9a. Como se observa en esta figura se asigna un grado de pertenencia a cada píxel de la cobertura de suelo de bosque. El grado de pertenencia va desde un valor alto (pertenencia total mostrada en color azul fuerte) hasta un valor bajo (pertenencia nula mostrada en color azul claro). En este caso, se aprecia cómo los píxeles que se encuentran en los bordes modifican su intensidad al estar ubicados en la parte exterior de la cobertura. Por otro lado, la figura 3.10b muestra la evaluación de los resultados de la clasificación suave de la figura 3.10a utilizando la medida de certeza CFCM propuesta en (Schiewe, 2009b) . La interpretación de esta figura es la siguiente: cuando se observa un color verde en la cobertura de bosque indica que se obtuvo una mayor certeza, es decir, el resultado del clasificador suave coincidió con el resultado real de la

clasificación suave. Cuando se observa un píxel de color café claro, indica que se obtuvo baja certeza en la clasificación, esto quiere decir que el resultado del clasificador suave no coincidió con el resultado real de la clasificación suave.

Los autores no mencionan como obtienen los datos de referencia (ground truth) que es un detalle muy importante para realizar la comparación de la clasificación suave, de esta manera, los resultados de su clasificación que van desde una exactitud de 78.37% hasta 96.77%. Estas exactitudes solo son validadas por el experto en el dominio.



**Figura 3.10. (a) Grados de pertenencia para la cobertura bosque, (b) Distribución de la CFM para la cobertura bosque (Schiewe, 2009b).**

Las principales desventajas del trabajo de Schiewe y Kinkeldey se describen a continuación:

- La obtención de los límites de las regiones de transición la hacen de manera manual, esto conlleva a cometer errores de comisión, debido a que se agregan píxeles puros a zona mezclada.

- La amplitud de las regiones de transición la realizan de manera muy definida, y en la naturaleza esto se da manera abrupta donde difícilmente se encuentran patrones geométricos.
- La evaluación de los píxeles mezclados lo realizan utilizando funciones de pertenencia lineal, suponiendo que el cambio de una región a otra, en una región de transición se de manera lineal. Esto no sucede en la naturaleza, los cambios son graduales de manera no lineal.

Liu y sus colegas en (Liu, 2010a) propusieron un enfoque para la clasificación de píxeles mezclados presentes en una imagen sensada remotamente basado en el análisis de etiqueta-mezclada (*Mixed-Label Analysis*, MLA). La tarea del modelo MLA es encontrar una función  $f(x)$  que tome como entrada una instancia  $x_i$  y regrese las proporciones de las clases en los datos de etiqueta mezclada. Primeramente,  $T = \{(x_1, Y_1) \dots (x_i, Y_i) \dots (x_m, Y_m)\} (x_i \in X, Y_i \in Y)$  es una secuencia de ejemplos de entrenamiento, donde  $x_i$  pertenece a un dominio o espacio de instancias  $X$  y  $Y$  es el espacio de salida. Cada instancia tiene  $n$  atributos, por ejemplo,  $x_i = (a_i^1 \dots a_i^n)$ . El número total de clases (etiquetas) para el conjunto de datos de entrenamiento es  $C$ ;  $Y_i$  se refiere a las proporciones de clases, por ejemplo,  $Y_i = (p_i^1 \dots p_i^C)$ ,  $\sum_{c=1}^C p_i^c = 1$ , donde  $p_i^c$  se refiere a la  $c$ -ésima proporción de clase en la  $i$ -ésima muestra. Para obtener la función  $f(x)$  utilizan un modelo de regresión no-paramétrica que determina un valor estimado  $\widehat{f}_m(x)$  de la función de regresión  $f(x)$  para una muestra dada  $T$ ; aquí,  $\widehat{f}_m(x)$  es estimado usando:

$$\hat{Y} = \widehat{f}_m(x) = \sum_{i=1}^m W_i(x, x_1, x_2 \dots x_m) Y_i \quad (3.2)$$

Donde  $W_i(x, x_1, x_2 \dots x_m)$  es una función de peso, la cual es una medida de la influencia o contribución de la muestra  $(x_i, Y_i)$  para estimar  $\widehat{f}_m(x)$ . El método  $k$ -NN es usado para determinar los pesos de MLA. La figura 3.11 muestra de manera general las etapas de este método. Primeramente se selecciona un conjunto de entrenamiento que contiene una etiqueta mezclada (etiqueta perteneciente a más de un tipo de cobertura de suelo). Con estos datos se entrena un clasificador  $k$ -NN para que calcule el vector de pesos y se obtenga la función de

regresión no paramétrica. Esta función es utilizada para realizar a clasificación de los datos de prueba.

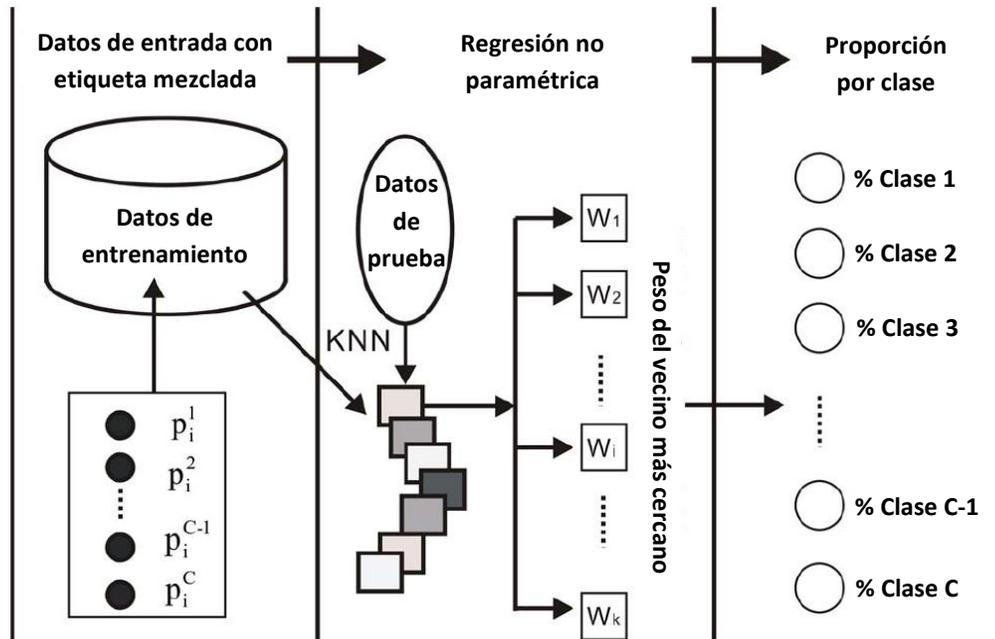


Figura 3.11. Modelo MLA basado en el algoritmo de regresión no-paramétrico. Figura traducida al español a partir de (Liu, 2010a).

Para realizar sus experimentos Liu y sus colegas utilizaron dos conjuntos de datos. Construyeron imágenes sintéticas a partir de las imágenes reales, ver figura 3.12. El proceso de construcción de sus imágenes sintéticas se muestra en los pasos siguientes:

1. Inicialmente, toman una imagen de tamaño 500 x 350 píxeles usando cinco bandas espectrales que contienen cinco coberturas de suelo: zona urbana, bosque, agua, agricultura, y desarrollo de suelo. Cada píxel de la imagen tiene un número digital (nivel de gris) que se encuentra en el intervalo de 10 a 255.
2. A partir de la imagen original, aplican una degradación espacial que consiste en tomar ventanas de tamaño 4x4 donde se promedia los niveles de gris de los 16 píxeles para obtener el nuevo valor de gris para generar un píxel de la imagen sintética.

- Finalmente, se calculan las proporciones de las clases presentes en cada píxel de la imagen sintética tomando en cuenta el número de clases contenidas en cada ventana de tamaño 4x4 de acuerdo al número total de píxeles de la ventana.

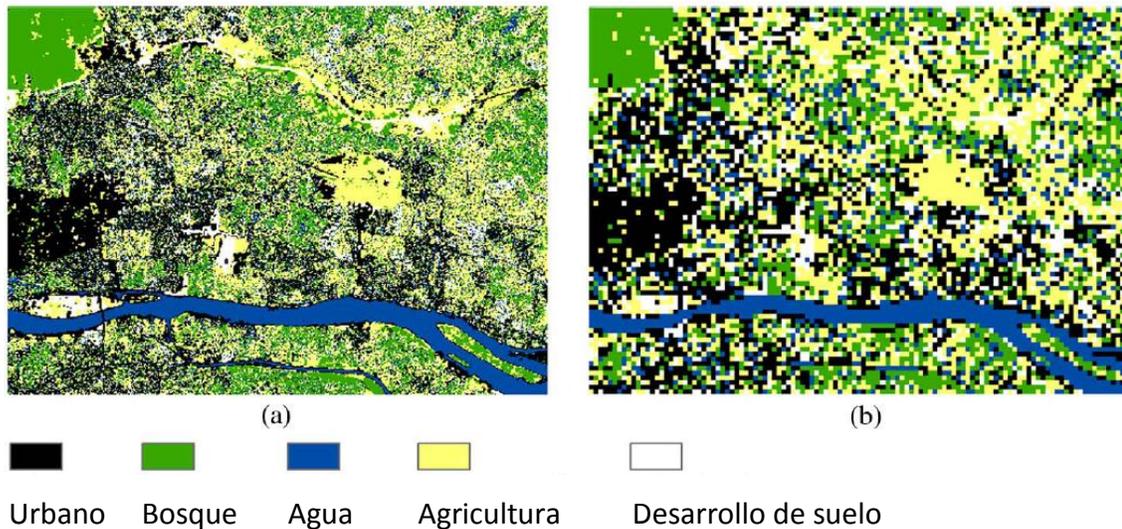


Figura 3.12. Imagen sintética construida en (Liu, 2010a).

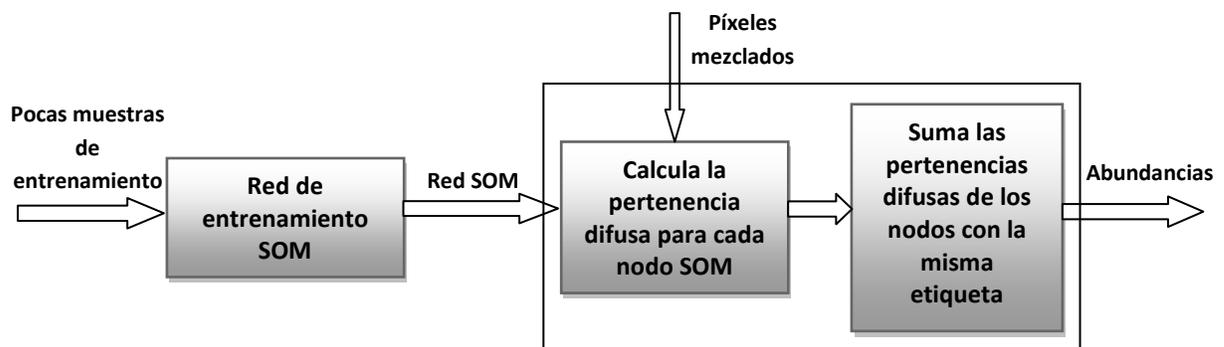
El segundo conjunto de datos incluyen las imágenes satelitales reales tipo Landsat TM con una resolución de 30 m y QuickBird con una resolución de 0.61 m correspondientes al año 2003. Para el caso de los experimentos usando las imágenes sintéticas no reportan las exactitudes determinadas en la clasificación de los píxeles mezclados. Sin embargo, para el caso de los experimentos usando las imágenes satelitales reales obtuvieron exactitudes que van desde 88.4% hasta 96.8%.

Las principales desventajas de este trabajo se describen a continuación:

- Dependencia directa con la cantidad de datos de referencia para usarlos como entrenamiento, es decir, necesitan seleccionar mediante la ayuda del experto en el dominio un conjunto de datos entrenamiento de gran tamaño. El experto en el dominio evalúa subjetivamente agregando incertidumbre a cada píxel del conjunto de entrenamiento.

2. Las imágenes sintéticas construidas solo son aplicables al tipo de clasificador utilizado, ya que éstas imágenes no presentan las mismas propiedades que la imagen original. De igual manera, para construir la imagen sintética utilizaron una imagen satelital previamente clasificada en distintos tipos de coberturas de suelo, pero no aseguran que esta clasificación dura tengan el 100 % de certeza para saber que un píxel solo contenga el tipo de cobertura señalada en su imagen original.
3. No obtienen la ubicación de las regiones de transición, y tratan de forma equitativa a todos los tipos de píxeles mezclados presentes en la imagen, lo que puede disminuir el rendimiento del clasificador propuesto.
4. La validación de sus experimentos lo realizan con la ayuda del experto en el dominio, quien es el que decide la clase del píxel de referencia.

Liu y sus colegas en (Liu, 2010b) propusieron un trabajo basado en mapas auto-organizados (Self-Organizing Map, SOM) y pertenencia difusa para la clasificación de píxeles mezclados en imágenes hiperespectrales. La descomposición de los píxeles mezclados se basa en el modelo difuso, que satisface la restricción de las abundancias no negativas (*Abundances Non-negative Constraint, ANC*) y la restricción de que las abundancias sumen un valor de uno (*Abundances Summed-to-one Constraint, ASC*) de forma automática. El método incluye tres partes: el entrenamiento de la red neuronal SOM, el cálculo de la pertenencia difusa y la estimación de la abundancia. La figura 3.13 muestra el proceso de clasificación de los píxeles mezclados.



**Figura 3.13. Método propuesto para la descomposición de píxeles mezclados. Figura traducida al español a partir de (Liu, 2010b).**

Para estimar la abundancia Liu y sus colegas aplican una técnica llamada “tagging” sobre las muestras de entrenamiento para realizar una versión supervisada de SOM, mostrada en la figura 3.14. La figura 3.15 muestra la red SOM donde se observan tres tipos de nodos (verde, azul y rojo) que representan el número de endmembers.



Figura 3.14. La técnica de etiquetado para muestras de entrenamiento. Figura traducida al español a partir de (Liu, 2010b).

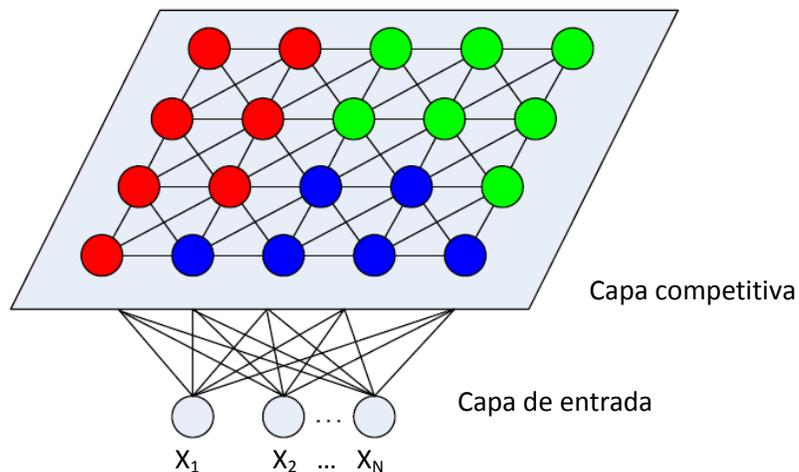


Figura 3.15. Red neuronal SOM después del entrenamiento supervisado. Figura traducida al español a partir de (Liu, 2010b).

Para cada píxel mezclado, se calcula su pertenencia difusa usando el método FCM para cada nodo en la capa competitiva de la red neuronal SOM después del entrenamiento. Posteriormente, se suman las pertenencias difusas que contienen la misma información de clase, y la suma corresponde a la abundancia estimada al *endmember* especificado.

Para realizar sus experimentos Liu y sus colegas utilizaron imágenes sintéticas generadas a través de una mezcla lineal de cuatro *endmembers* de minerales (antigorita, axinita, brucita y andradita). Los cuatro *endmembers* con 220 bandas hiperespectrales fueron seleccionados a partir de una librería de imágenes satelitales AVIRIS (Airborne Visible/Infrared Imaging Spectrometer). Además, realizaron experimentos utilizando imágenes reales satelitales tipo AVIRIS con coberturas de suelo agricultura/silvicultura.

Una desventaja de del trabajo reportado en (Liu, 2010b) es que no realizan la evaluación de los resultados de sus clasificaciones a través de alguna medida de exactitud para la clasificación de píxeles mezclados. Esto es debido a la falta de imágenes hiperespectrales reales que hayan sido clasificadas donde se conozcan las abundancias estandarizadas para cada píxel mezclado. Además, sus imágenes simuladas no corresponden a imágenes satelitales con coberturas de suelo que puedan ser validadas frente a otros métodos propuestos en la literatura.

Zhou y sus colegas en (Zhou, 2005) propusieron un trabajo para descomposición de píxeles mezclados generados por la baja resolución espectral de las imágenes, donde en muchos casos, un píxel puede cubrir cientos de metros cuadrados con diversas coberturas. Su trabajo es basado en el método de Factorización de Matrices No-negativas (*Non-negative Matrix Factorization*, NMF). NMF descompone una matriz positiva en un producto de dos matrices positivas. Esto es aplicado para descomponer los píxeles mezclados en imágenes multicanal sensadas remotamente. Adicionalmente, utilizan la técnica de Análisis de Componentes Principales (*Principal Component Analysis*, PCA) para determinar el número de “*endmembers*” en imágenes multicanal sensadas remotamente.

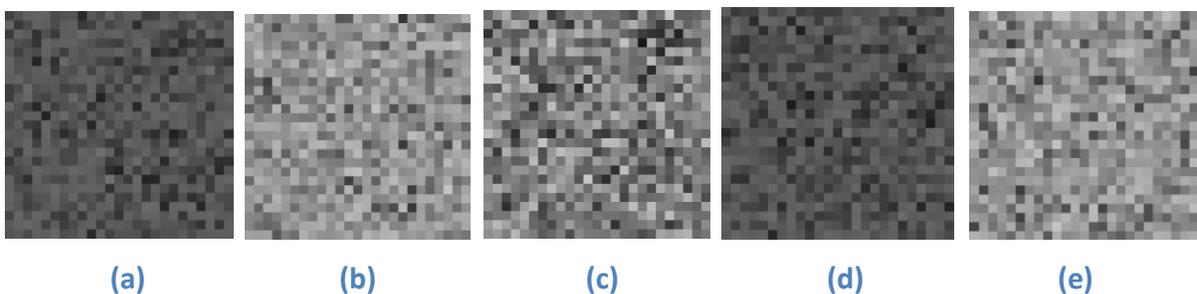
En el trabajo (Zhou, 2005) se describe el problema de la descomposición de píxeles mezclados, donde se define a  $V$  como un conjunto de imágenes sensadas remotamente multicanal de  $n$  bandas y entonces,  $W$  es una matriz característica de reflectancia compuesta de reflectancia de cada objeto en cada banda espectral, y  $H$  es una matriz compuesta del porcentaje de cada

objeto en cada píxel. Es posible determinar dos matrices positivas  $W$  y  $H$  mediante la técnica NMF, y las dos matrices satisfacen la ecuación  $V = WXH$ .

Para realizar sus experimentos Zhou y sus colegas utilizaron dos tipos de imágenes: imágenes reales multiespectrales tipo Landsat del satélite de Julio del 2000. Estas imágenes corresponden a la región de Shanghai que presentan un tamaño de  $256 \times 256$  píxeles. El segundo tipo de imágenes corresponden a imágenes sintéticas construidas mediante los siguientes pasos:

1. Producir aleatoriamente tres vectores positivos de  $1 \times 10000$  y usarlos para simular los porcentajes de tres objetos en cada píxel.
2. Hacer que los tres vectores satisfagan la condición sean mayores a cero.
3. Definiendo la matriz artificial  $W$ , es posible obtener imágenes simuladas con la técnica descrita en este trabajo y usarlo para simular los píxeles mezclados en imágenes multiespectrales e hiperespectrales.

La figura 3.16 muestra ejemplos de imágenes creadas usando el método propuesto por Zhou y sus colegas.



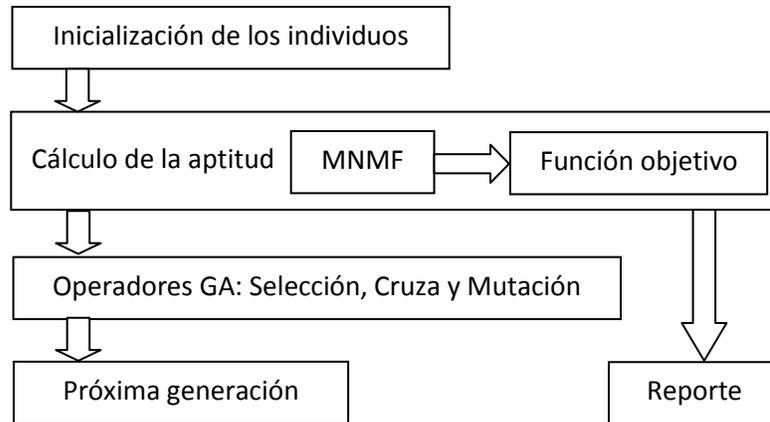
**Figura 3.16. Imágenes satelitales multicanales sintéticas ( $25 \times 25$ ).**

Las principales desventajas del trabajo de Zhou y sus colegas se enlistan a continuación:

1. Los autores muestran los resultados de sus clasificaciones mediante imágenes satelitales pero no presentan una evaluación del rendimiento de su clasificador así como la exactitud alcanzada en cada cobertura clasificada.
2. Construir sus imágenes sintéticas mediante el mismo método propuesto conlleva a un sesgo en la experimentación de su clasificación de píxeles mezclados.

Liaoying y sus colegas presentaron en (Liaoying, 2009) una modificación a la técnica de NMF al combinarla con algoritmos genéticos (GA-MNMF: *Modified Nonnegative Matrix Factorization and Genetic-Algorithm*) para descomponer los píxeles mezclados en imágenes hiperespectrales de percepción remota. Los “*endmembers*” obtenidos por MNMF son usados como la población inicial de individuos para el GA. La solución óptima del GA es retomada como los nuevos “*endmembers*” iniciales en la siguiente ejecución del MNMF. Este procedimiento se repite hasta obtener la solución óptima global. La figura 3.17 muestra un diagrama esquemático del algoritmo GA-MNMF.

Para realizar sus experimentos Liaoying y sus colegas utilizaron dos tipos de imágenes: el primer tipo corresponde a imágenes sintéticas de tamaño 36x36 que son generados usando un conjunto de reflectancias seleccionadas a partir de una librería digital espectral. Las proporciones de las clases en cada píxel son generadas de acuerdo a la distribución de Dirichlet, el cual satisface que una matriz sea positiva (Nascimento, 2005). El segundo tipo de imágenes corresponde a imágenes capturadas por el satélite AVIRIS (Airborne Visible/Infrared Imaging Spectrometer) de la región de Cuprite, Nevada. La imagen es de tamaño de 250 x 190 píxeles. Su interés principal en este trabajo es el de evaluar el cálculo de los endmembers determinados por su algoritmo propuesto. De esta manera, calculan la similitud entre los endmembers reales y el estimado usando medidas como: coeficientes de correlación (alcanzando 0.9997), distancia de ángulo espectral (alcanzando 0.005), y divergencia de información espectral (alcanzando 0.0001).



**Figura 3.17. Diagrama del algoritmo GA-MNMF. Figura traducida al español a partir de (Liaoying, 2009).**

Las desventajas del trabajo de Liaoying y sus colegas se enlistan a continuación:

- El tamaño demasiado pequeño de sus imágenes sintéticas para realizar sus experimentos no pueden ser utilizados para validarlos frente a otros métodos propuestos en el estado del arte.
- Disponibilidad del número de bandas para poder realizar los experimentos.
- Finalmente, no presentan una evaluación cuantitativa de la clasificación de los píxeles mezclados

## Resumen

En este capítulo se presentaron diversos trabajos relacionados con la localización espacial de las regiones de transición que incluyen la presencia de límites indefinidos en imágenes satelitales. Además, se muestra una tabla donde se resumen los diversos métodos de clasificación organizados de acuerdo a la fuente que genera los píxeles mezclados. Ambas problemáticas aun son temas abiertos debido a que no se encuentran resueltas completamente.

Los puntos relevantes descubiertos en el análisis del estado del arte que se contrasta con esta tesis de investigación son las siguientes:

- En la mayoría de los trabajos relacionados solo existen técnicas o métodos para la detección de bordes de objetos (coberturas de suelo) pero no para determinar las regiones de transición. Los intentos por localizar las regiones de transición se basan principalmente en el trazado de bandas de transición con una forma geoméricamente bien definida, lo cual no sucede en la naturaleza. Por tal motivo, se propuso un método que obtiene las regiones de transición de manera similar a la forma que se localizan en la naturaleza, descrito en el siguiente capítulo.
- Los clasificadores suaves descritos en el estado del arte, son aplicados para la clasificación de toda la imagen bajo estudio. Esta imagen está formada por píxeles puros y mezclados, sin embargo, nuestro método de clasificación suave es aplicado sólo a los píxeles mezclados reduciendo la incertidumbre en la clasificación.
- Ciertos trabajos del estado del arte mostrados en la sección 3.1, describen que cada cobertura de suelo presenta una zona de transición diferente. Esto indica que los píxeles que se encuentran en la zona exterior del objeto muestran una difusión con respecto a los píxeles centrales para cada tipo de cobertura de suelo. Este comportamiento es caracterizado mediante las curvas de ajuste las cuales agregan información cuantitativa para la clasificación de los píxeles mezclados.
- Al realizar el análisis del estado del arte, se ha observado que no existe disponible un banco de imágenes satelitales que permitan evaluar los métodos propuestos para la clasificación suave. Para resolver este inconveniente, en este trabajo de tesis se propuso un método para la construcción de imágenes sintéticas que se detalla en el siguiente capítulo. Mediante la construcción de imágenes sintéticas, es posible evitar la dependencia directa con el experto en el dominio para validar la clasificación suave, lo cual es una de las ventajas buscadas en este trabajo.

En el siguiente capítulo se describen los métodos propuestos para alcanzar los objetivos planteados en este trabajo de tesis.

## IV. Método propuesto

El objetivo principal de este trabajo de tesis es resolver el problema de los píxeles mezclados generados por las regiones de transición que forman dos o más tipos de coberturas homogéneas. De esta manera, la importancia primordial para la solución del problema radica en la localización espacial de los píxeles mezclados. Diversos intentos han sido descritos en la literatura, el inconveniente común es que agregan píxeles puros (una sola cobertura de suelo) a zonas donde se encuentra exclusivamente una combinación múltiple de píxeles mezclados. *Debido a lo anterior, en este trabajo de tesis se localiza espacialmente las regiones de transición presentes en la imagen satelital.*

Las regiones de transición son localizadas utilizando el segmentador basado en el crecimiento de regiones, el cual permite emerger una cobertura homogénea sin permitir añadir aquellos píxeles mezclados de las zonas indeterminadas. Una vez segmentadas las coberturas homogéneas en la imagen satelital bajo estudio, quedan delimitadas los píxeles mezclados generados por las regiones de transición.

*La segunda parte de esta investigación está relacionada con la clasificación suave de los píxeles mezclados utilizando el enfoque difuso para el manejo de la incertidumbre asociada con dichos píxeles.* En esta etapa, se propusieron las curvas de ajuste las cuales son construidas tomando en cuenta la distribución de los píxeles mezclados de las coberturas de suelo en imágenes satelitales reales. Las curvas de ajuste contienen información del comportamiento natural (distribución espacial con respecto a la entidad geográfica) de las zonas indeterminadas de las coberturas de suelo. Esta información es proporcionada al clasificador difuso para brindarle mayor soporte (conocimiento extra) en su decisión para la clasificación.

Finalmente, para validar los resultados del método propuesto se propuso la construcción de imágenes satelitales sintéticas. Esto es debido a que no se cuenta con un banco de imágenes estandarizadas para realizar la evaluación de la clasificación suave de los píxeles mezclados.

Estas imágenes satelitales sintéticas mantienen las propiedades espaciales (textura) muy similares a las imágenes satelitales reales.

La figura 4.1 muestra los bloques del método general propuesto para la obtención y clasificación de píxeles mezclados en una región de transición.

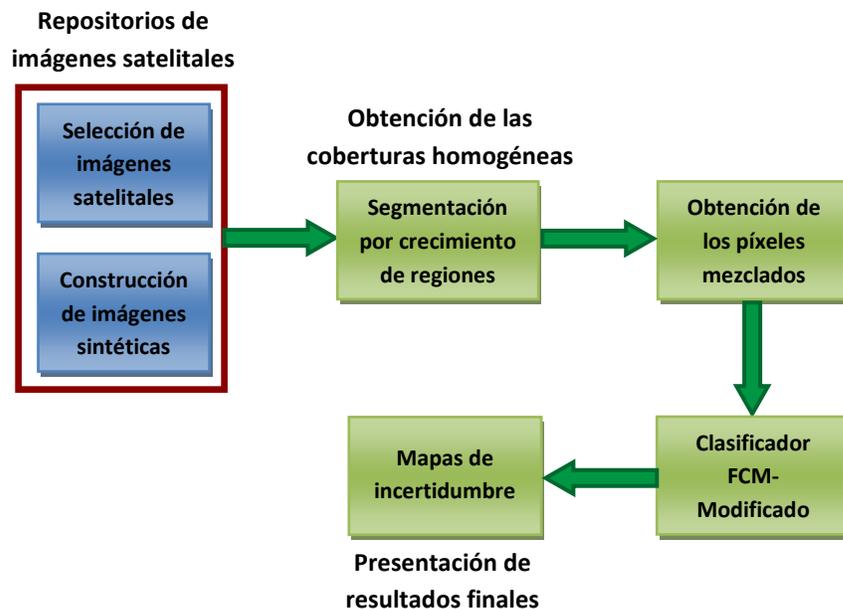


Figura 4.1. Método propuesto para la obtención y clasificación de píxeles mezclados.

Los bloques se describen de forma general a continuación:

**Repositorios de imágenes satelitales.** Para realizar los experimentos se han usado dos tipos de imágenes satelitales. A) *Reales*: selección de subimágenes que contengan regiones de transición. B) *Sintéticas*: construcción de imágenes artificiales usando la técnica de modelo lineal mezclado LMM (Tiwari, 1999).

**Obtención de coberturas homogéneas.** Son obtenidas usando la segmentación basada en el crecimiento de regiones usando información de textura. Las semillas son obtenidas usando algoritmos genéticos.

**Obtención de regiones de transición.** Se realiza una diferencia de imágenes para obtener los píxeles pertenecientes a la región de transición.

**Descomposición de píxeles mezclados.** Se realiza una clasificación suave para determinar la proporción de cada cobertura presente en cada píxel mezclado.

**Creación de mapas de incertidumbre.** En esta etapa se crearán mapas de incertidumbre para mostrar la certeza obtenida en la clasificación suave.

## 4.1 Repositorios de imágenes satelitales

### 4.1.1 Selección de imágenes satelitales reales (ISR)

Las imágenes satelitales reales usadas para el análisis de píxeles mezclados deben cumplir con las siguientes condiciones:

1. Tener una resolución espacial de al menos 30-60 metros para que se puedan notar visualmente los píxeles mezclados.
2. La cantidad de píxeles mezclados debe ser proporcional a las coberturas homogéneas presentes en el área de estudio. Esta condición es con la finalidad de mantener aproximadamente la misma cantidad de píxeles para cada una de las clases analizadas.

La figura 4.2 muestra algunos ejemplos de imágenes satelitales reales que contienen píxeles mezclados originados por las regiones de transición.



**Figura 4.2. Ejemplos de píxeles mezclados generados por regiones de transición en imágenes satelitales reales (Banda delimitada por las líneas amarillas).**

#### **4.1.2. Construcción de imágenes satelitales sintéticas (ISS)**

Un gran problema que se encuentra en el proceso de clasificación de píxeles mezclados es la validación de los resultados encontrados por el clasificador suave. La validación consiste en calcular la exactitud mediante la verificación de las proporciones de las coberturas presentes en cada píxel de la región de transición.

Para realizar la validación es indispensable contar con los datos de referencia (*ground truth*) de la zona bajo estudio. Estos datos de referencia permitirán evaluar la calidad de los resultados de la clasificación suave. Esta validación se puede hacer de dos maneras:

- a) Con la ayuda de un experto en el dominio, quien conoce la zona de estudio y tiene la capacidad de construir los datos de referencia. Cabe señalar que esta opción además de ser dependiente del experto en el dominio, puede llevar a cometer errores asociados a la incertidumbre inherente de los píxeles mezclados.
- b) Construcción de imágenes sintéticas, las cuales permiten validar los resultados sin la dependencia y la subjetividad agregada por el experto en el dominio.

En la construcción de imágenes satelitales sintéticas (ISS) es necesario tener presentes las siguientes condiciones:

1. Conocer la cantidad de píxeles homogéneos y mezclados en la ISS.
2. Para una cobertura mezclada (región de transición), se deberán determinar las proporciones de las coberturas homogéneas que serán combinadas para formar cada píxel mezclado.
3. Mantener las relaciones espaciales entre píxeles (textura) similares a las de una imagen satelital real (Imagen base).

El método propuesto en este trabajo cumple con las tres condiciones anteriores. La figura 4.3 muestra el método propuesto para la construcción de imágenes satelitales sintéticas.

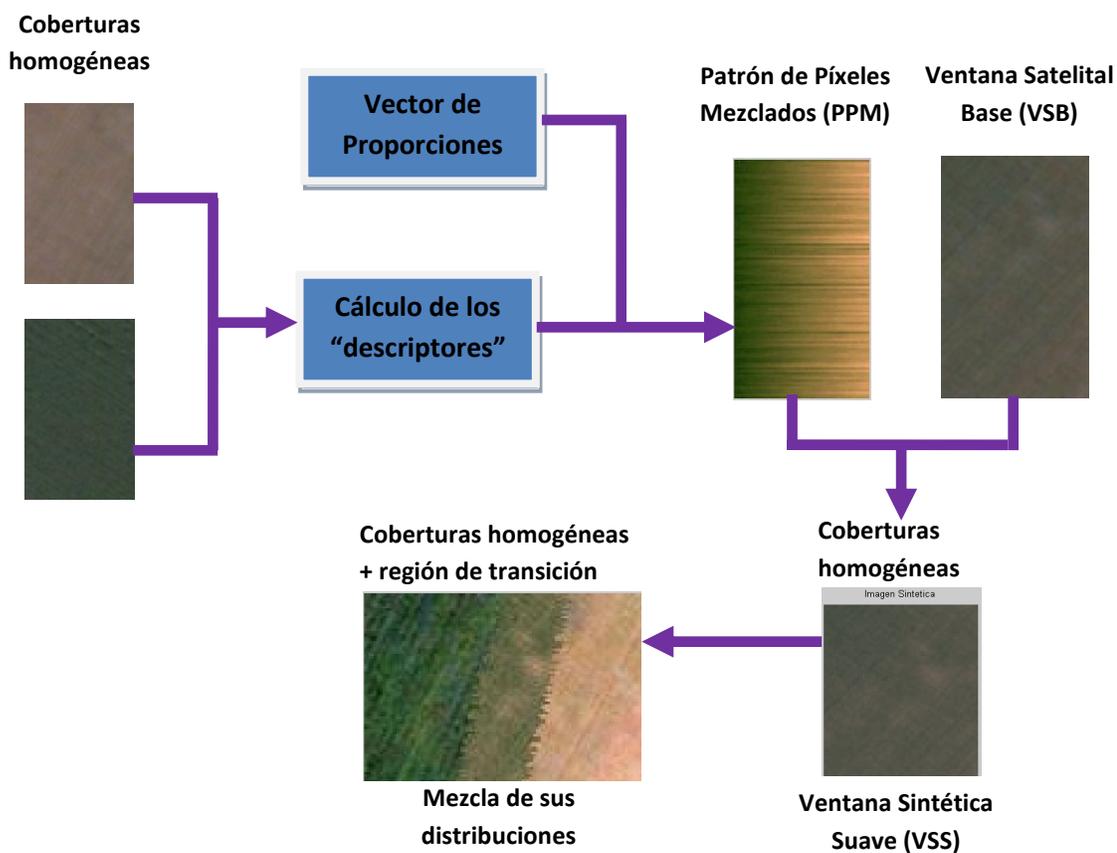


Figura 4.3. Método propuesto para la construcción de imágenes satelitales sintéticas.

A continuación se describen los bloques principales de la figura 4.3 para la construcción de la ISS.

**Coberturas homogéneas y medias (descriptores).** El primer paso consiste en encontrar las coberturas homogéneas. Para obtenerlas, se observa cuidadosamente de forma manual la imagen satelital original para localizar las ventanas (región que contiene una sola cobertura de suelo) en que éstas se encuentran para asegurar que solo contiene píxeles puros. Posteriormente, a cada subimagen se le calcula la media de sus niveles de gris. Esta media se utiliza como descriptor de la cobertura homogénea.

**Vector de proporciones.** El vector de proporciones contiene la proporción de cada píxel mezclado respecto a cada una de las coberturas homogéneas, por ejemplo, el vector de proporciones guardará las proporciones de 0.7 y 0.3, para la mezcla de dos coberturas homogéneas. El vector de proporciones se genera usando valores que se encuentran en el intervalo de 0.05 a 0.95 con incrementos seleccionados por el usuario. Si se desea una mayor diversidad en la mezcla de píxeles el incremento deberá ser pequeño (por ejemplo, 0.0018).

**Patrón de Píxeles Mezclados (PPM).** El PPM consiste en una paleta de colores formada por una combinación en verdadero color RGB. *El número de bandas utilizada para la construcción del PPM corresponde al número de bandas de las imágenes satelitales reales que están siendo utilizadas en este trabajo de investigación.* El PPM se deriva a partir de cada banda espectral, donde el nivel de gris del píxel resultante representa la mezcla de proporciones multiplicada por el descriptor de cada cobertura de suelo que genera al píxel mezclado. Para crear el PPM, se utilizó el método de Modelado Lineal Mezclado (LMM), (Lu, 2003).

Esta técnica se basa en la suposición de que la respuesta espectral de un píxel mezclado resulta de la suma lineal de las respuestas espectrales de las coberturas de suelo presentes en el píxel, además, ponderadas por un vector de proporciones correspondiente a cada cobertura de suelo (Thomas, 1996).

En el trabajo de (Lu, 2003), la suposición principal del LMM se basa en la respuesta espectral de los valores de Niveles Digitales (ND) de un píxel mezclado, los cuales corresponden a la suma lineal de las clases que los componen (Tiwari, 1999). Además, estos valores se ponderan por el área proporcional correspondiente de cobertura de suelo. Los valores NDs de un píxel mezclado se pueden considerar como una suma simple de los valores NDs de cada clase de cobertura de suelo (CL) y se calcula como:

$$f_1\mu_{b1} + f_2\mu_{b2} + f_3\mu_{b3} + \dots + f_c\mu_{bc} = \mathbf{M}\mathbf{f} = \mathbf{PPM} \quad (4.1)$$

Donde:

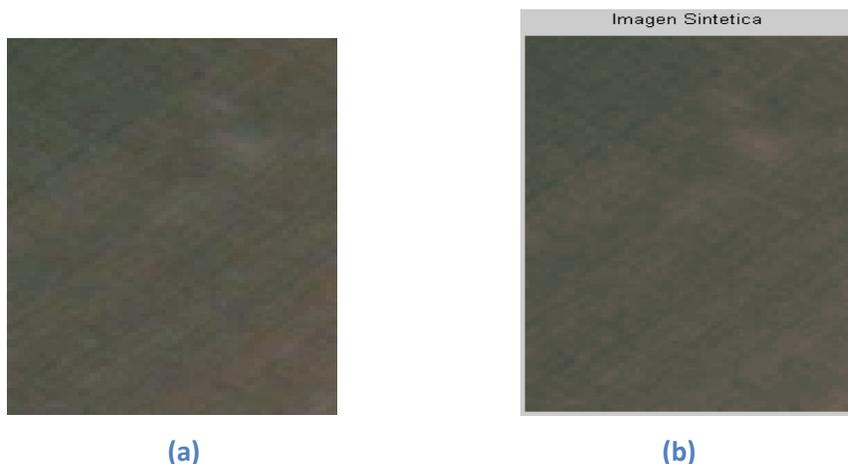
$$\mathbf{M} = \begin{bmatrix} \mu_{11} & \mu_{12} & \dots & \mu_{1c} \\ \mu_{21} & \mu_{22} & \dots & \mu_{2c} \\ \vdots & \vdots & \ddots & \vdots \\ \mu_{b1} & \mu_{b2} & \dots & \mu_{bc} \end{bmatrix} \quad (4.2)$$

$$\mathbf{f} = (f_1, f_2, \dots, f_c)^T = \begin{pmatrix} f_1 \\ f_2 \\ \vdots \\ f_c \end{pmatrix} \quad (4.3)$$

Donde el vector  $\mathbf{f}$  de tamaño  $(c \times 1)$ , representa las proporciones de coberturas de suelo de las  $c$  clases presentes en un píxel. Cada elemento de la matriz  $\mathbf{M}$  de tamaño  $(b \times c)$ , representa la media (descriptor) de cada tipo de cobertura (columna) para cada banda espectral  $\mathbf{b}$  (fila).  $\mu = \mu_{b1}, \mu_{b2}, \dots, \mu_{bc}$  representa la media de los NDs de cada cobertura de suelo  $c$  para una determinada banda  $\mathbf{b}$ . El **PPM** será utilizado para la construcción de la **Ventana Sintética Suave**.

**Ventana Satelital Base (VSB) y Ventana Sintética Suave (VSS).** En este apartado se describe la contribución en este trabajo para la construcción de las imágenes satelitales sintéticas. La ventana sintética suave (VSS) es una subimagen RGB que estará compuesta únicamente por píxeles mezclados construidos a partir del PPM y principalmente de la ventana satelital base

(VSB). La VSB es una subimagen satelital real que servirá para extraerles sus características de niveles de gris que formarán a la VSS. La diferencia entre la VSB y la VSS radica en que en la VSB no se conoce como se encuentra compuesto cada píxel mezclado con respecto a las coberturas de suelo presentes en el píxel mezclado. La figura 4.4 muestra ambas ventanas.



**Figura 4.4. (a) Ventana satelital base, (b) Ventana sintética suave.**

De esta manera, a partir de la subimagen VSB de la figura 4.4.a se construye la VSS, de la cual se heredarán características como tamaño, niveles de gris y relación espacial entre sus píxeles.

Los pasos para construir la VSS se describen a continuación:

1. Se selecciona una subimagen satelital real constituida por las tres primeras bandas espectrales que forman la composición en verdadero color RGB. Esta subimagen (VSB) contiene únicamente píxeles mezclados de las coberturas de suelo de las que se analizarán.
2. Dada la ventana VSB de tamaño  $m \times n$  (compuesta por sus tres respectivas bandas espectrales), la idea principal es que cada píxel de la ventana VSS deberá ser construido usando el PPM.
3. Para construir el píxel mezclado de la posición  $(i,j)$  de la ventana VSS, se toma el nivel de gris de cada banda en la ventana VSB del píxel correspondiente a esa misma posición. Por

ejemplo, digamos que el nivel de gris en la banda 1 es de 150, en la banda 2 es de 110 y en la banda 3 es de 80.

4. Esta terna de valores es buscada en el patrón PPM, y la terna que tenga una mayor similitud con esta primera, será la que corresponde a los niveles de gris para el píxel mezclado de la ventana VSS. En el ejemplo dado, digamos que encontramos para la banda 1: 151, para la banda 2: 109 y para la banda 3: 81. La figura 4.4b muestra un ejemplo de una VSS.

Las ventajas de construir la imagen sintética son:

- 1) Hasta hoy en día en la literatura no existe la construcción de este tipo de VSS. Con este método propuesto se conoce la composición de cada píxel mezclado respecto a cada cobertura homogénea presente.
- 2) La diferencia principal con otros trabajos reportados en el estado del arte es que este método propuesto mantiene las relaciones espaciales entre píxeles muy similares con respecto la ventana VSB. De esta manera, se hace posible la extracción de características de textura en la imagen sintética debido a que estas características miden la relación que existe entre el píxel y su vecindad.

## **4.2 Obtención de las regiones de transición**

En una imagen satelital, el paso de una cobertura homogénea a otra, se presenta de manera gradual. Este cambio gradual se muestra como una degradación de una cobertura de suelo a medida que nos alejamos de la misma, lo cual genera regiones de transición (RsT). Por ejemplo, si pasamos de una zona de bosque hacia una zona de vegetación, se realiza de manera gradual y no de forma abrupta. Estas regiones de transición están formadas por una diversidad de píxeles mezclados, los cuales se encuentran combinados espectralmente por las coberturas homogéneas que las generan.

Una parte importante en el desarrollo de esta investigación es la obtención de los píxeles mezclados generados por una región de transición. Para localizar estos píxeles mezclados, se propone delimitarlos mediante la ubicación de las regiones de transición. El segundo método propuesto llamado *TreDet* (*Transition Regions Determination*) permite determinar las Regiones de transición, el cual inicia con la obtención de las coberturas homogéneas de la zona bajo estudio. Al obtener las coberturas homogéneas se aíslan los píxeles mezclados, los cuales serán analizados posteriormente usando una clasificación suave. En la figura 4.5 se muestran los bloques principales del método propuesto.

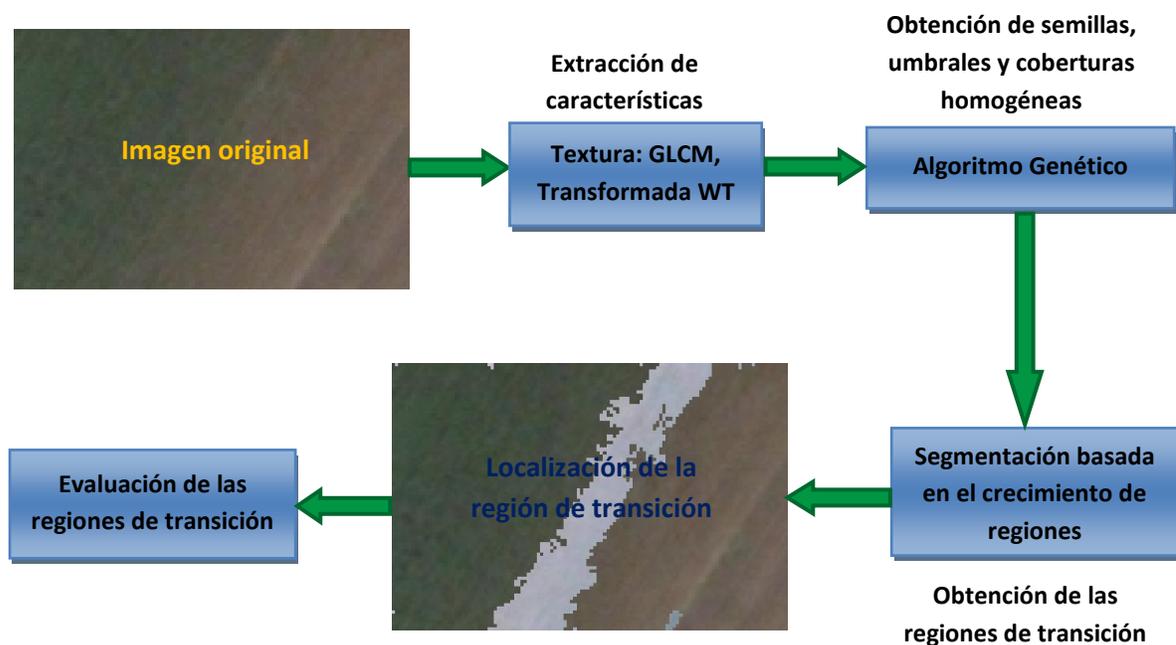


Figura 4.5. Método *TreDet* propuesto para la obtención de regiones de transición basado en el crecimiento de regiones.

#### 4.2.1 Extracción de características

La extracción de características en imágenes satelitales puede realizarse principalmente en dos niveles (Pawley, 2006):

- a) Nivel región. Consiste en calcular distintas propiedades a partir de un conjunto de píxeles (región). Cada propiedad indica una medida cuantitativa calculada para cada región.
- b) Nivel píxel. Consiste en obtener diversas propiedades a partir de un solo píxel. El píxel es tomado como una sola entidad.

En este trabajo de tesis se realiza la extracción de características combinando los dos niveles anteriores. Primeramente, para cada píxel de la imagen satelital se extraen ventanas que contiene a la vecindad de píxeles donde se encuentra al píxel en turno. A partir de esta ventana se extraen un conjunto de características de textura que describen las propiedades del píxel en relación a sus vecinos. Esta extracción de características permite obtener las relaciones espaciales de cada píxel que cambia de una cobertura de suelo a otra.

Existen distintos tipos de características (Clausi, 2002), (Qazi, 2011), entre ellas se tienen las de textura. Este tipo de características permiten medir las relaciones espaciales entre el píxel en turno y su vecindad. De esta manera es posible medir la influencia que presentan los píxeles vecinos hacia el píxel central. En este trabajo se extrajeron el siguiente conjunto de características:

1. Diez características extraídas usando la transformada wavelet.
2. Cuatro características extraídas usando GLCM (Matriz de Co-ocurrencia de los niveles de gris).
3. Los tres niveles de gris de cada banda espectral de la imagen satelital.

Estas características fueron seleccionadas de manera experimental guiadas por los trabajos reportados en la literatura relacionada con la clasificación de imágenes satelitales. La razón de utilizar este conjunto de características es con el fin de combinar las características a nivel región (textura) con características a nivel píxel, lo cual mejoró los resultados experimentales de los métodos propuestos.

La transformada wavelet (*Wavelet Transform, WT*) proporciona una estructura precisa y unificada para el análisis y caracterización de una señal a diferentes escalas (Unser, 1995), (Meher, 2007). En este trabajo se toma la WT para calcular la relación espacial del píxel con su vecindad en una ventana de 16x16 píxeles. Esta ventana, se filtra usando WT (*Low Pass, LP*: filtro pasa bajas, *High Pass, HP*: filtro pasa altas) en tres niveles para descomponer la ventana (subimagen) a diferentes escalas. Finalmente, se extrae la energía de cada subimagen que se toma como una característica de cada píxel. En total se obtienen 10 características de textura usando wavelets:  $e_{LL-1}$ ,  $e_{LH-1}$ ,  $e_{HL-1}$ ,  $e_{HH-1}$ ,  $e_{LL-2}$ ,  $e_{LH-2}$ ,  $e_{HL-2}$ ,  $e_{HH-2}$ ,  $e_{LL-3}$ ,  $e_{LH-3}$ ,  $e_{HL-3}$ ,  $e_{HH-3}$ . Donde  $e$  representa la energía de toda la ventana, las letras del subíndice el filtro usado y el número en el subíndice indica el nivel en que se encuentra la salida. Ver figura 4.6.

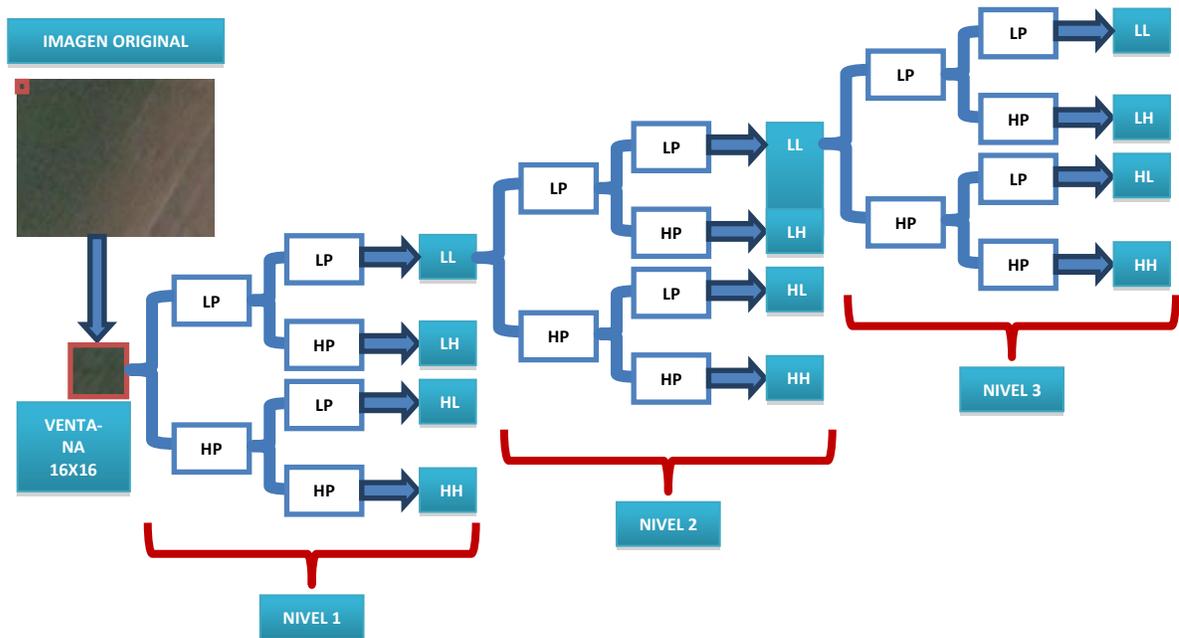


Figura 4.6. Estructura de tres niveles de filtros pasa bajas y pasa altas de la familia wavelet usada para la extracción de 10 características de textura, (Meher, 2007).

Se utilizaron los niveles de gris de cada píxel dentro de cada una de las tres bandas que componen la imagen satelital. Para complementar las características extraídas por el filtrado wavelet, se extraen cuatro características mediante la matriz de co-ocurrencia de niveles de gris

(Clausi, 2002). Estas características son: correlación, energía, entropía y homogeneidad. En las ecuaciones 4.4-4.8 se describen la forma de calcular estas cuatro características:

$$\text{Correlación} = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} \frac{(i-\mu_i)(j-\mu_j)C_{ij}}{\sigma_i\sigma_j} \quad (4.4)$$

$$\text{Energía} = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} p(i,j)^2 \quad (4.5)$$

$$\text{Entropía} = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} C_{ij} \log C_{ij} \quad (4.6)$$

$$\text{Homogeneidad} = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} \frac{p(i,j)}{1+|i-j|} \quad (4.7)$$

$$C_{ij} = \frac{p(i,j)}{\sum_{i=1}^{Ng} \sum_{j=1}^{Ng} p(i,j)} \quad (4.8)$$

Donde:

$\mu_i$  = Media de los niveles gris de  $i$ .

$\mu_j$  = Media de los niveles gris de  $j$ .

$\sigma_i$  = Desviación estándar de los niveles de gris de  $i$ .

$\sigma_j$  = Desviación estándar de los niveles de gris de  $j$ .

$p(i,j)$  = Número de ocurrencias de los niveles de gris  $i$  y  $j$  dentro de la ventana dada.

$Ng$  = Número cuantizado de niveles de gris de la matriz de co-ocurrencia.

#### 4.2.2 Obtención de semillas, umbrales de crecimiento y coberturas homogéneas

Se ha seleccionado una segmentación por crecimiento de regiones debido a que nos permite:

- ✓ Determinar las coberturas homogéneas (formadas únicamente por píxeles puros) presentes en las imágenes satelitales. Una vez obtenidas las coberturas homogéneas, se obtienen los píxeles mezclados generados por las regiones de transición.
- ✓ Controlar el grado de homogeneidad de la cobertura homogénea durante el crecimiento de las regiones.

Existen dos condiciones principales que afectan el rendimiento del segmentador seleccionado. El primero de ellos es la selección del o los píxeles semillas que servirán como puntos iniciales para el crecimiento de las regiones. Estos píxeles deberán ser representativos de cada cobertura homogénea, por tal motivo su elección tiene gran repercusión en la calidad de la segmentación. El segundo de los problemas es la obtención de los umbrales que marcan los límites del crecimiento de cada región. Estos umbrales deberán elegirse de manera que las regiones obtenidas contengan únicamente píxeles puros. Para sobrellevar estos problemas se ha seleccionado un método de optimización que nos permite obtener valores muy precisos para cada uno de estos parámetros. Este método se basa en algoritmos genéticos (GAs). Los GAs son una técnica de optimización que imita la evolución de las especies (Seo, 2007). Los GAs operan sobre un conjunto de individuos virtuales, los cuales representan las posibles soluciones del problema. Estos individuos se optimizan a través de un cierto número de iteraciones (generaciones) que convergen a la solución buscada. La figura 4.7 muestra el método utilizado que se explica a detalle a continuación:

***Extracción de características de textura a nivel píxel.*** Extraer información a nivel píxel (nivel de gris) resulta bastante simple y sencillo de utilizar. La limitante principal es la incapacidad de tomar en cuenta la relación espacial que tiene el píxel con sus vecinos. Para sobrellevar esta limitante existen técnicas que permiten medir esta relación espacial usando características de textura. La extracción de características ha sido descrita en la sección 4.2.1.

***Pre-segmentación inicial “watershed”.*** En esta etapa se realiza una pre-segmentación de la imagen satelital original. Cada región debería ser homogénea en el espacio de características

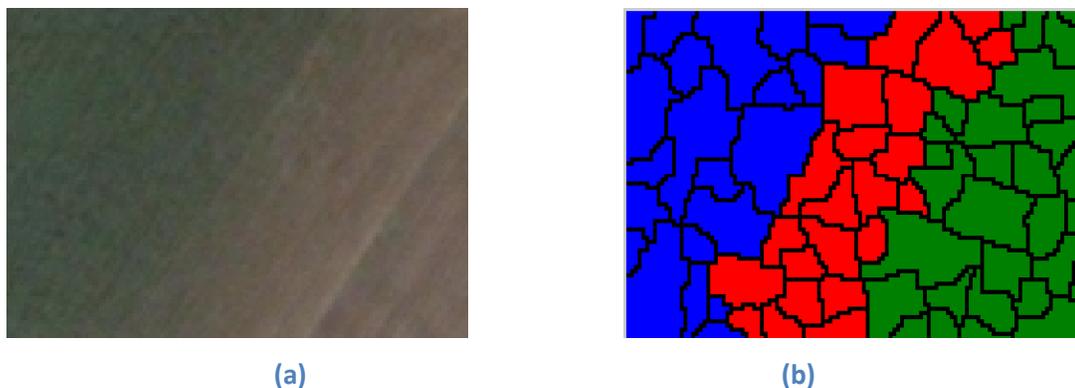
mientras que regiones vecinas deberían poseer diferentes características. Para obtener esta pre-segmentación se ha utilizado la técnica *watershed* con cálculo de gradiente debido a que obtiene una mejor segmentación inicial que el *watershed* simple, (Haris, 1998). En esta etapa se obtiene una imagen pre-segmentada en regiones iniciales, los cuales serán agrupados mediante un algoritmo genético. El propósito de crear estas regiones iniciales es para que el algoritmo genético no trabaje a nivel píxel en el agrupamiento sino usando estas regiones iniciales.



Figura 4.7. Selección de semillas usando algoritmos genéticos.

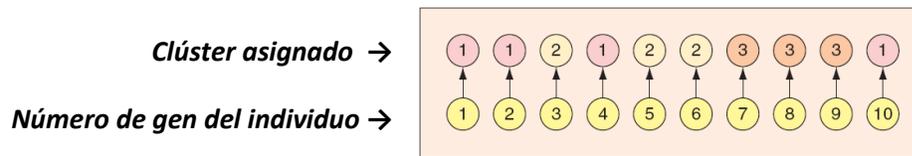
**Optimización por clúster usando GAs.** En el uso de los algoritmos genéticos generalmente se inicia con la codificación de los individuos virtuales de la población inicial. Partiendo de una imagen satelital pre-segmentada por la técnica *watershed* donde se obtienen distintas regiones

iniciales (ver figura 4.8). En este caso, el objetivo del algoritmo genético consiste en agrupar estas regiones iniciales en un cierto número de “clusters”. Además, cada cluster representa ya sea una cobertura homogénea o una región de transición. Por lo tanto, un individuo virtual representa a todas las regiones iniciales (genes del cromosoma) agrupadas en  $n$  clusters de manera aleatoria.



**Figura 4.8. (a) Imagen original, (b) Obtención de las regiones iniciales a partir de una imagen satelital presegmentada por la técnica watershed.**

La codificación de un individuo se realiza asignando cada región (gen) como un clúster inicial de manera aleatoria, tal como se muestra en la figura 4.9 (Jiao, 2010). El número de clúster se determina por el número de coberturas homogéneas y mezcladas (regiones de transición) presentes en la zona de estudio. El número de genes (longitud del individuo virtual) equivale al número de regiones iniciales encontradas en la pre-segmentación watershed. En el ejemplo de la figura 4.8, la técnica *watershed* determinó 10 regiones iniciales dentro de la imagen satelital, las cuales representan a los 10 genes del individuo virtual. Además, suponiendo que se tienen 3 clústers en la imagen satelital, se asigna cada región inicial a uno de los clústers (figura 4.9a). Finalmente, se obtiene el individuo codificado tal como se muestra en la figura 4.9b. El orden de las regiones en el individuo codificado corresponde al número de la región asignada durante la pre-segmentación inicial.



(a)



(b)

Figura 4.9. Asignación de cada región (gen) a un clúster determinado, (b) Individuo codificado (Jiao, 2010).

La función de aptitud permite medir la capacidad que tiene cada individuo virtual (posible solución) para obtener el mejor agrupamiento de regiones iniciales. Para obtener la función de aptitud se utiliza la distancia euclidiana la cual es calculada desde el centro del clúster hacia cada uno de los píxeles. Posteriormente, se suman todas estas distancias para ser dividida entre la unidad. Esta función de aptitud, propuesta por (Jiao, 2010), mide la fuerza de atracción entre los elementos de cada clúster y su centroide en el espacio de características, lo cual se optimiza con el GA.

$$aptitud = \frac{1}{\sum_{i=1}^{NC} \sum_{j=1}^{NR_i} \sum_{k=1}^{NP_j} dis(p_{ijk}, m_i)} \quad (4.9)$$

Donde:

$NC$  indica el número de clústers.

$NR_i$  representa al número de regiones en el  $i$ -ésimo clúster.

$NP_j$  representa al número de píxeles en la  $j$ -ésima región.

$p_{ijk}$  es el  $k$ -ésimo píxel en la  $j$ -ésima región.

$m_i$  es el centroide de todos los píxeles del  $i$ -ésimo clúster en el espacio de característica.

$dis()$  representa la distancia euclidiana entre  $p_{ijk}$  y  $m_i$ .

El algoritmo genético selecciona a los individuos que formarán parte de la siguiente generación de dos maneras: se selecciona un porcentaje de ellos de manera elitista y el resto por medio de la técnica de torneo.

La cruce y mutación complementan el proceso de optimización del algoritmo genético para dar una mayor combinación entre los individuos (Koppen, 2006). En el proceso de cruce se toma a dos individuos padres donde se selecciona un punto de cruce a partir del cual serán cortados e intercambiados sus cadenas (genes) para formar a los nuevos individuos. Para el caso del agrupamiento de regiones surge un inconveniente, que resulta cuando una región pueda pertenecer a más de un clúster. Para evitar esto en (Jiao, 2010) propusieron una técnica de cruce entre regiones.

La figura 4.10 muestra un ejemplo de la cruce de dos individuos que contienen tres clústeres cada uno. El padre A con sus clústers 1 {1, 3, 7, 5, 10}, 2 {2, 4}, y 3 {6, 8, 9}, respectivamente. Por otra parte, el padre B se encuentra distribuido de la siguiente manera: 1 {1, 4, 5, 7}, 2 {2, 3, 6} y 3 {8, 9, 10}. Como se muestra en la figura 4.10a, para cada clúster del padre A se han seleccionado algunas regiones (encerradas por líneas punteadas). Lo que se pretende es que estas regiones seleccionadas sean introducidas al clúster correspondiente del padre B. Por ejemplo, para las 3 regiones seleccionadas del clúster 1 del padre A (1, 3 y 7), observando el clúster 1 del padre B, notamos que ya se encuentran las regiones 1 y 7, pero la región 3 se encuentra en el clúster 2. Por lo tanto, se mueve la región 3 del cluster 2 al cluster 1 para generar el clúster 1 del nuevo individuo, ver figura 4.10c. De la misma forma se sigue para los siguientes dos clústers de los padres A y B.

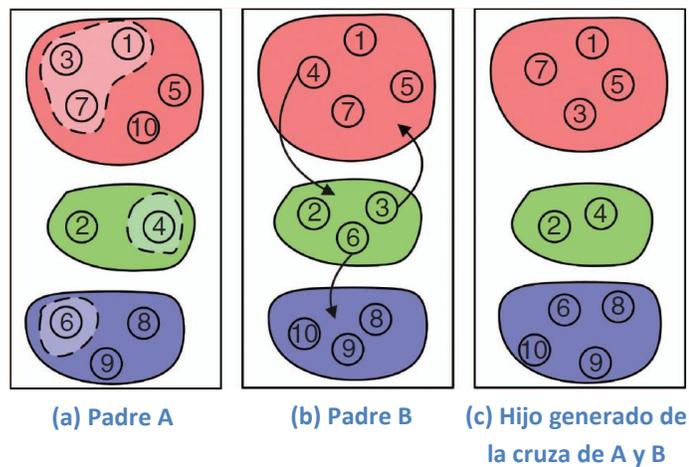


Figura 4. 10. Operación de cruce entre dos individuos virtuales. Figura traducida de (Jiao, 2010).

En la mutación, si resulta que un gen debe ser mutado de acuerdo al porcentaje de probabilidad (parámetro de ajuste del GAs), será cambiado a otro clúster de forma aleatoria. Esto significa que la región correspondiente será reasignada a otro clúster.

La condición de paro se basa en el número de generaciones (este número de generaciones se obtuvo de manera experimental). Al finalizar la ejecución del GA, se toma al mejor individuo de la población final. Este individuo optimizado consiste en una imagen que contiene las regiones iniciales (regiones que pre-segmentadas por la técnica watershed) agrupadas en  $n$  clústers definidos por el usuario. El número de clústers corresponde a la suma del número de coberturas homogéneas y del número de coberturas mezcladas presentes en la imagen original. De esta manera, la solución obtenida es una imagen satelital segmentada en coberturas homogéneas y mezcladas.

**Obtención de semillas para cada clúster.** Una vez obtenidos los grupos de la imagen, se calculan sus respectivos centroides en el espacio de características. A partir de estos centroides se obtiene la distancia entre el respectivo centroide y cada píxel perteneciente al clúster. Posteriormente se ordenan las distancias calculadas de menor a mayor. Finalmente se seleccionan los “ $k$ ” píxeles con las distancias mínimas como semillas. La finalidad de seleccionar

estas “k” semillas es para resolver el problema cuando se tienen dos regiones de un mismo tipo de cobertura separadas por otra cobertura distinta. De esta manera es posible “sembrar” una semilla en cada región que pertenezca al mismo tipo de cobertura.

**Obtención de las coberturas homogéneas.** Se calcula la varianza de cada clúster, y se ordenan en forma ascendente. La varianza es una medida estadística que mide la variación entre los datos y su media. Se asume que las coberturas homogéneas tienen una varianza menor que las regiones de transición. Se toman como coberturas homogéneas aquellos clústers cuyas varianzas sean las menores de acuerdo al número de coberturas homogéneas seleccionadas en la imagen satelital. Por otra parte, derivado de la naturaleza de las características extraídas, es muy difícil obtener varianzas iguales debido a la homogeneidad que muestra cada tipo de cobertura de suelo. En caso de que existiera empate, se realizan corridas extras donde se extrae el promedio de las varianzas para obtener al menor.

**Obtención de los umbrales.** En relación con la distribución de los píxeles de cada cobertura homogénea, los píxeles se encuentran distribuidos bajo 3 desviaciones estándar según lo descrito en (Liu, 2009). Según Liu, al tomar en consideración únicamente a los datos distribuidos en la primera desviación estándar, se toman en cuenta solamente a los píxeles puros de cada cobertura homogénea.

#### 4.2.3 Segmentación basada en crecimiento de regiones

En esta etapa, se determinan las coberturas homogéneas identificadas como clases formadas por una sola cobertura de suelo. Los parámetros utilizados por el segmentador basado en el crecimiento de regiones se calculan como se describe en la sección 4.2.2. Ahora se utilizan para segmentar la imagen satelital y obtener las coberturas homogéneas que delimitarán las regiones de transición.

#### 4.2.4 Evaluación de las regiones de transición

Neubert y sus colegas (Neubert, 2008) realizaron un análisis para evaluar la calidad de la segmentación de imágenes. Su trabajo se dirige principalmente hacia imágenes sensadas remotamente. En su investigación describen un conjunto de programas comerciales enfocados a la detección de bordes. En nuestro trabajo, utilizamos algunos de ellos. También presentan un análisis de las métricas para evaluar la calidad de las regiones segmentadas, las cuales también han sido utilizadas en este trabajo con el fin de realizar una comparación cuantitativa entre herramientas comerciales y nuestro método. Las métricas usadas para evaluar la calidad de la segmentación se muestran en las ecuaciones 4.10 - 4.13. Otra métrica usada es la calidad visual, la cual mide de manera cualitativa la calidad de la segmentación mediante la ayuda del experto en el dominio.

1. **% Diferencia de área:** cuantifica el porcentaje de diferencia de áreas entre el objeto de referencia y el objeto segmentado. Está definida por la siguiente ecuación.

$$\% DA = \frac{A_{\text{objeto de referencia}} - A_{\text{objeto segmentado}}}{A_{\text{objeto de referencia}}} \quad (4.10)$$

2. **% Diferencia de perímetro:** cuantifica el porcentaje de diferencia de los perímetros entre el objeto de referencia y el objeto segmentado. Está definida por la siguiente ecuación.

$$\% PD = \frac{P_{\text{objeto de referencia}} - P_{\text{objeto segmentado}}}{P_{\text{objeto de referencia}}} \quad (4.11)$$

3. **% Índice de forma:** cuantifica el porcentaje de índice de forma que presenta el objeto de segmentado y con respecto al objeto de referencia. Está definida por la siguiente ecuación.

$$SI = \frac{P_{\text{object}}}{4\sqrt{A_{\text{object}}}} \quad (4.12)$$

$$\% SI = \frac{SI_{\text{objeto de referencia}} - SI_{\text{objeto segmentado}}}{SI_{\text{objeto de referencia}}} \quad (4.13)$$

### 4.3 Fuzzy C-Means-Modificado para la clasificación de píxeles mezclados

La figura 4.11 muestra los bloques principales que describen el método propuesto para la clasificación de píxeles mezclados generados por las regiones de transición. Los píxeles mezclados se obtienen con el segmentador basado en crecimiento de regiones descrito en la sección 4.2.3. Los bloques restantes serán descritos en las secciones siguientes.

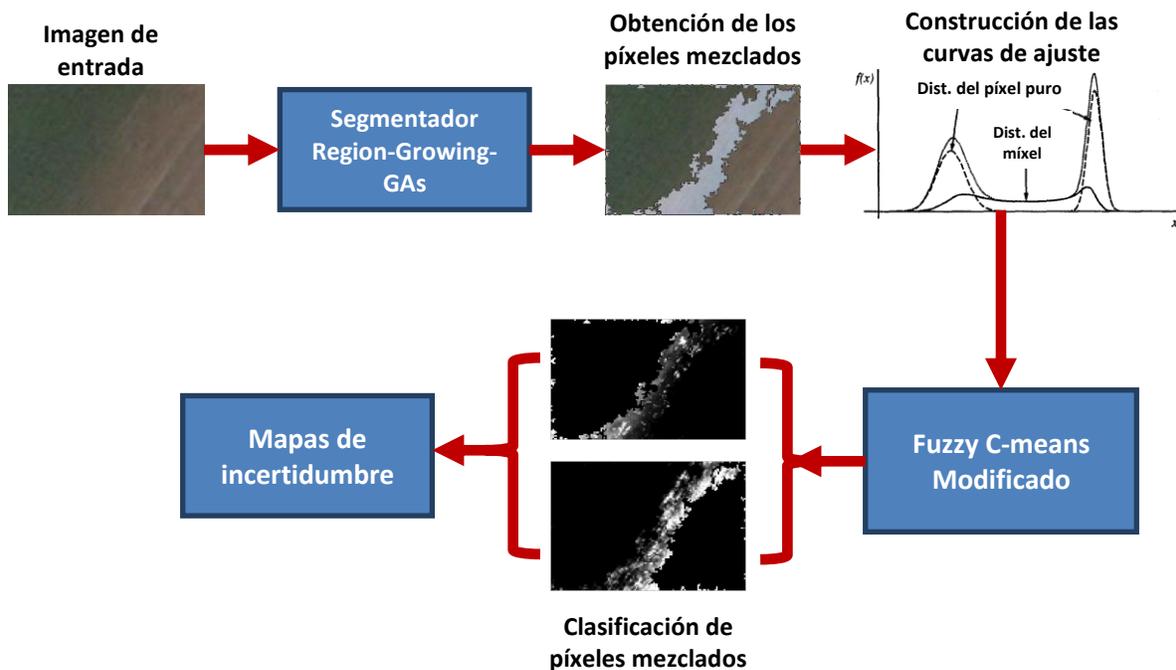


Figura 4.11. Método FCM-Modificado agregando información de las curvas de ajuste, integrando los métodos propuestos en las secciones anteriores y la construcción de mapas de incertidumbre.

#### 4.3.1 Construcción de las curvas de ajuste

Una función de pertenencia de un conjunto difuso  $A$  sobre un universo de discurso  $X$  es de la forma  $\mu_A: X \rightarrow [0,1]$ , donde a cada elemento de  $X$  le corresponde un valor entre 0 y 1. Este valor, llamado valor de pertenencia o grado de pertenencia, representa el grado en el que el elemento de  $X$  pertenece al conjunto difuso  $A$ . Normalmente, las funciones de pertenencia nos permiten representar gráficamente un conjunto difuso. En el eje " $x$ " (abscisas) se representa el universo

de discurso, mientras que en el eje “y” (ordenadas) se sitúan los grados de pertenencia en el intervalo [0,1].

Una curva de ajuste es una función de pertenencia especializada que se construye a partir de una región de transición de una cobertura de suelo de una imagen satelital real. Según se describió en la sección 2.2.2, cada entidad geográfica (cobertura de suelo) presenta una zona de transición donde los píxeles que se encuentran en la zona más externa al objeto muestran una pertenencia al objeto en menor grado.

La idea principal de una curva de ajuste es la de transformar la información proporcionada por el comportamiento natural de los píxeles mezclados en una función de pertenencia (curva de ajuste) tal como se muestra en la figura 4.12. En la figura se muestra en el eje horizontal la amplitud de la región de transición de la cobertura de suelo en cuestión. Esta amplitud es calculada usando los histogramas de niveles de gris de los píxeles mezclados localizados en la región de transición. La pertenencia es tomada de acuerdo a la frecuencia de los píxeles localizados en la región de transición. Finalmente podemos mencionar que, cada curva de ajuste representa la forma en que se encuentran localizados los píxeles mezclados en la región de transición dada una cobertura de suelo. Por lo tanto, el objetivo es construir una curva de ajuste específica para cada tipo de cobertura suelo que nos proporcione el grado de pertenencia a esa entidad geográfica.

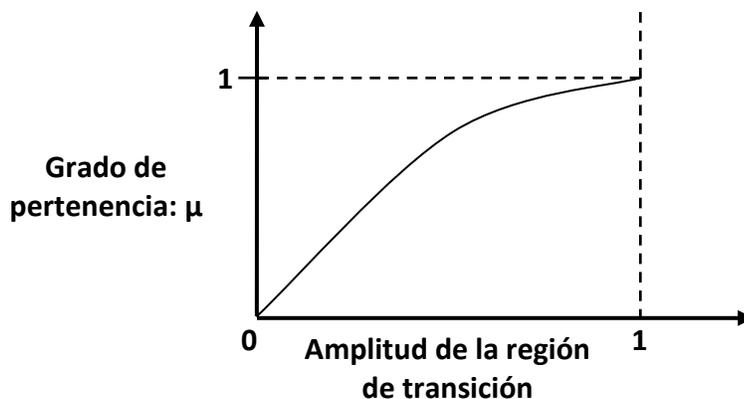


Figura 4.12. La curva de ajuste definida como una función de pertenencia.

Estas curvas de ajuste son utilizadas en la clasificación Fuzzy C-Means Modificado para obtener la pertenencia de los píxeles mezclados a la cobertura de suelo correspondiente.

La figura 4.13 ilustra la manera en que dos coberturas homogéneas contribuyen a la generación de píxeles mezclados en una región de transición. Así por ejemplo, si tomamos las distribuciones de los píxeles puros de dos coberturas homogéneas y agregamos los píxeles mezclados de la región de transición, se tiene como resultado una distribución compuesta por dos distribuciones homogéneas más una zona mezclada de estas dos distribuciones. En consecuencia, *el problema radica en determinar la contribución de cada una de las coberturas homogéneas para la generación de la distribución de píxeles mezclados*.

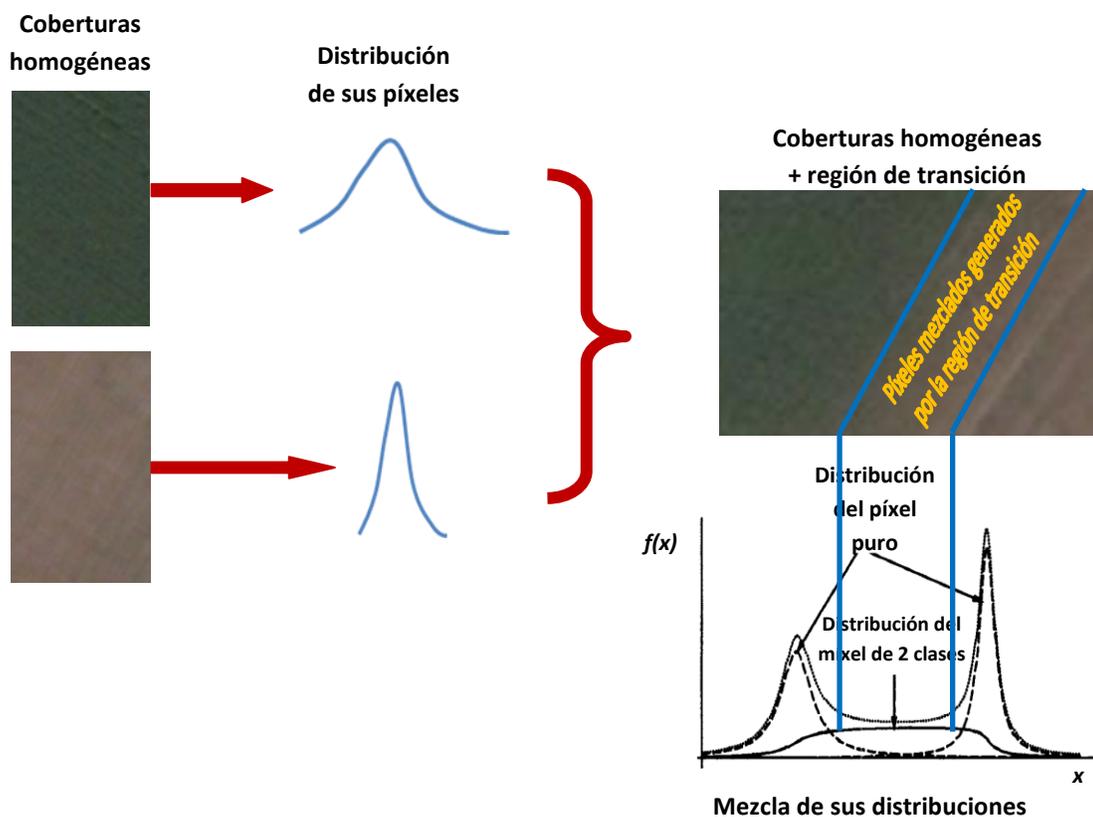


Figura 4.13. Ejemplo de la distribución de píxeles mezclados y puros en una región de transición.

Para resolver este problema se construye la curva de ajuste para los píxeles mezclados con respecto a cada cobertura homogénea. La finalidad de llevar a cabo las siguientes acciones es para localizar mediante un histograma a los píxeles mezclados de una cobertura de suelo. Este histograma se convertirá en su curva de ajuste correspondiente. A continuación se describen los pasos:

- i. Seleccionar una imagen satelital que contenga dos coberturas homogéneas y una región de transición.
- ii. Segmentar por crecimiento de regiones únicamente a los píxeles puros de una cobertura homogénea a la vez. En este caso no se toma en cuenta la región de transición donde se encuentran los píxeles mezclados correspondientes a esta cobertura.
- iii. Construir el histograma de esta región segmentada para cada una de las tres bandas que componen la imagen.
- iv. Segmentar por crecimiento de regiones a los píxeles puros y mezclados de la misma cobertura homogénea. Ahora se agregaron a los píxeles de la región de transición (zona difusa del objeto).
- v. Construir el histograma de esta región segmentada para cada una de las tres bandas que componen la imagen.
- vi. Finalmente, para obtener únicamente el histograma de los píxeles mezclados, se realiza una diferencia de los histogramas de los pasos tres y cinco. La figura 4.14 muestra las curvas de ajuste construidas para cada cobertura de cada banda de la imagen satelital del ejemplo de la figura 4.13.

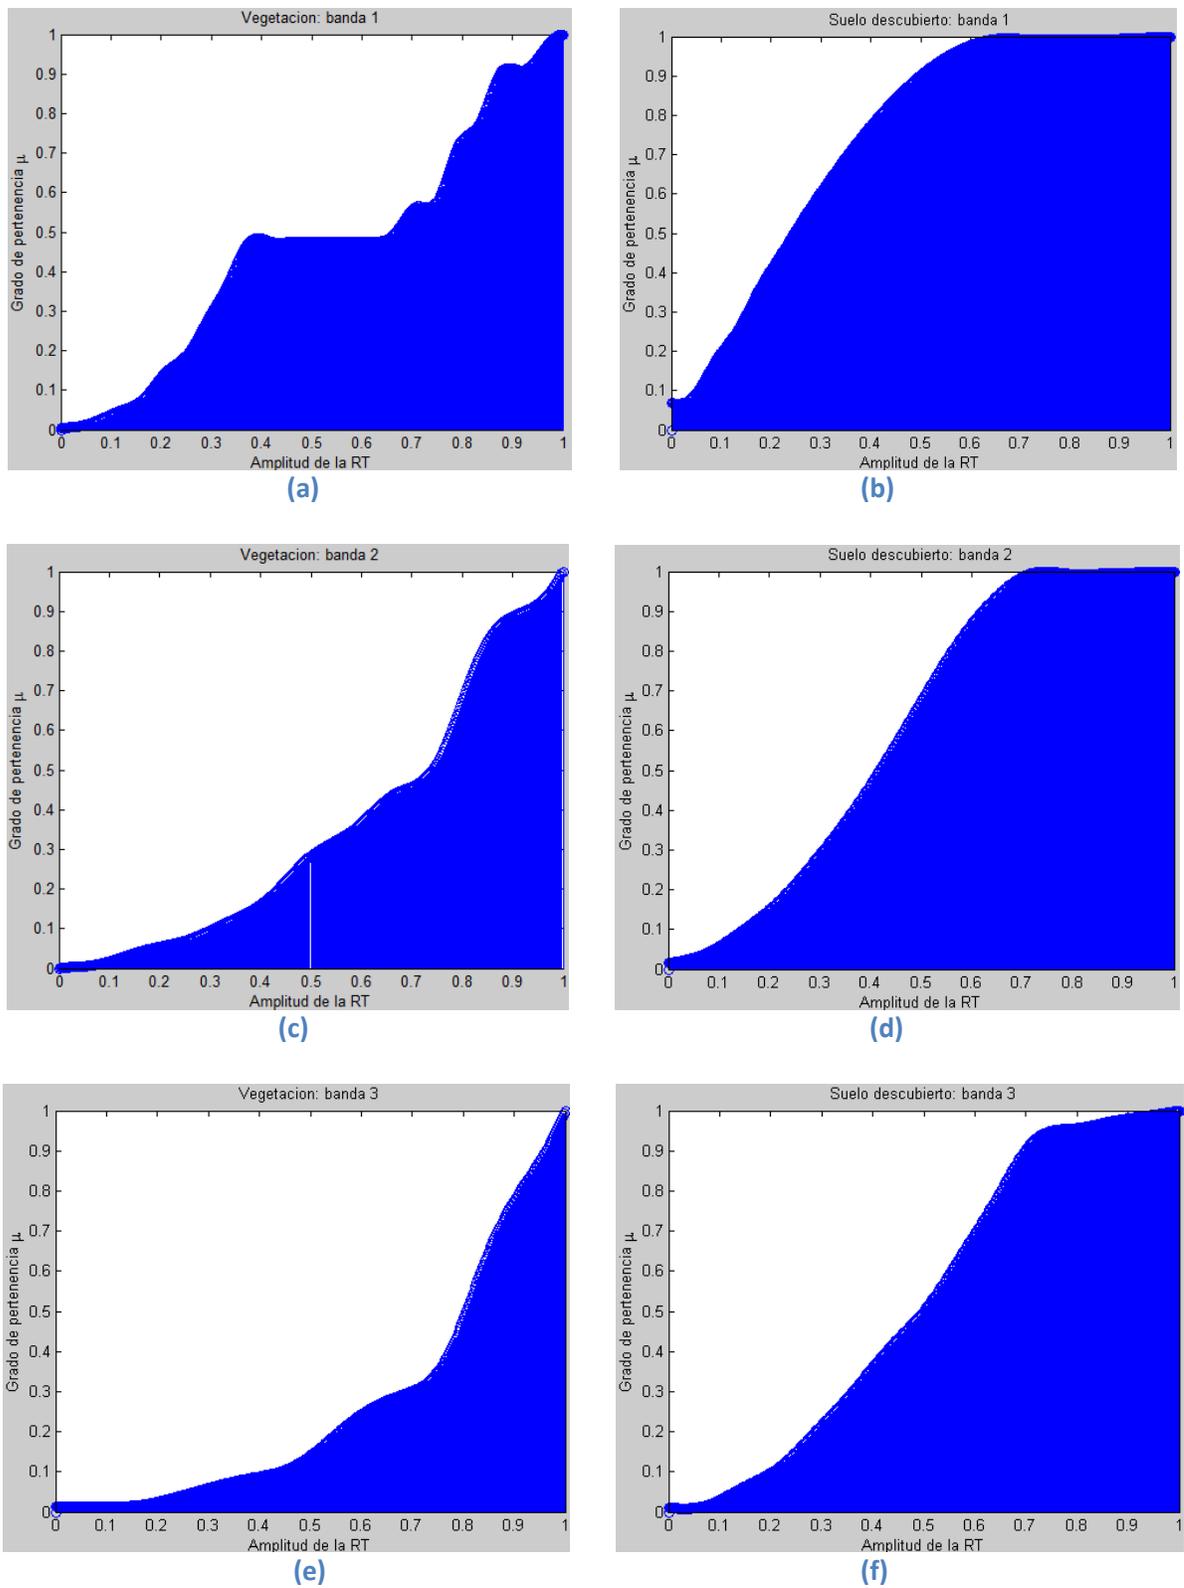


Figura 4.14. Curvas de ajuste para dos coberturas de suelo en sus tres bandas espectrales.

### 4.3.2 Clasificador FCM-Modificado (FCMM)

En general, un píxel corresponde a un área del espacio de suelo, el cual puede no necesariamente pertenecer a un solo tipo de cobertura de suelo. Esto indica que los píxeles en una imagen satelital pueden ser asociados con una gran cantidad de imprecisión e incertidumbre. Por lo tanto, la aplicación de los principios de la teoría difusa aparece de una manera natural y apropiada para ser aplicada a tales dominios, (Maulik, 2009). En este mismo sentido, el algoritmo Fuzzy C-Means (FCM), como parte de la teoría difusa es utilizado para mejorar la compactés de las regiones debido a su capacidad de agrupar y simplicidad para su implementación, (Siang, 2011). FCM permite clasificar (descomponer en sus partes proporcionales) de manera suave a los elementos (píxeles) de un grupo determinado con respecto a todos los grupos formados por FCM. El concepto de clasificación suave se le da a los clasificadores que otorgan un grado de pertenencia en el intervalo [0 1] a un elemento (píxel) con respecto a un grupo (cobertura de suelo).

Así mismo, en la clasificación FCM, es importante que los elementos de una partición difusa  $U$ , representen el grado de pertenencia de un píxel a una clase. Estos valores de pertenencia deberán satisfacer:

$$\mu_{ik} \in [0,1] \quad (4.14)$$

$$\sum_{k=1}^n \mu_{ik} > 0, i = 1, \dots, c \quad (4.15)$$

$$\sum_{i=1}^c \mu_{ik} = 1, k = 1, \dots, n \quad (4.16)$$

Los valores de pertenencia se calculan a través de la siguiente ecuación:

$$\mu_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}}\right)^{\frac{2}{m-1}}} \quad (4.17)$$

Donde:

$i$  =  $i$ -ésimo clúster

$j$  =  $j$ -ésimo clúster

$k$  =  $k$ -ésimo píxel

$c$  = número de clústers de la imagen

$m$  = factor de difusión

$d_{ik}$  = distancia entre el píxel  $k$  y el clúster  $i$

En este trabajo de investigación se ha tomado como base el algoritmo de clasificación FCM para realizar la clasificación suave de los píxeles mezclados. Las modificaciones realizadas en la clasificación FCM se describen a continuación:

- El FCM-Modificado toma los centroides fijos de cada clúster que son representados por los píxeles semillas calculados en el proceso de segmentación por crecimiento de regiones. De esta manera no recalcula dichos centroides en cada iteración, modificando así al FCM tradicional como si fuera un FCM supervisado.
- FCM-Modificado es utilizado únicamente para calcular los grados de pertenencias de los píxeles mezclados, no realiza el agrupamiento de los píxeles.
- Los grados de pertenencia obtenidos por el FCM son promediados con los grados de pertenencia calculados usando las curvas de ajuste. Estas curvas de ajuste contienen información del comportamiento natural de los píxeles generados por la región de transición.

El método propuesto FCM-Modificado para clasificar píxeles mezclados se describe en los siguientes pasos:

**Paso 1:** Extraer los niveles de gris en las tres bandas de los píxeles mezclados de la imagen satelital para construir la matriz de datos.

**Paso 2:** Asignar los píxeles semilla como centroide de cada clúster (cobertura de suelo).

**Paso 3:** Realizar la clasificación de los píxeles mezclados usando el algoritmo Fuzzy C-Means tradicional.

**Paso 4:** Realizar el ajuste de la pertenencia para cada píxel de la siguiente manera:

- i. Dada la matriz de pertenencias  $U$  del clasificador FCM tradicional, extraer el grado de pertenencia  $\mu_{ik}$  del  $k$ -ésimo píxel con respecto al  $i$ -ésimo clúster.
- ii. Tomar la curva de ajuste correspondiente al clúster (cobertura de suelo) a la que se desea ajustar.

- iii. Buscar el grado de pertenencia  $\mu_{ik}$  dado por el clasificador FCM en el eje horizontal de la curva de ajuste (amplitud de la región de transición). En la misma curva de ajuste, buscar en el eje vertical su grado de pertenencia  $\mu_{ik}'$  correspondiente.
- iv. Promediar los dos grados de pertenencia ( $\mu_{ik}$  y  $\mu_{ik}'$ ) para calcular el nuevo grado de pertenencia.
- v. Realizar este proceso para cada píxel y para cada clúster.

**Paso 5.** Repetir los pasos 3 y 4 durante cinco iteraciones. Se ha revisado experimentalmente, que este número de iteraciones es suficiente para que el algoritmo FCM-Modificado converja a una solución.

El método FCM-Modificado descrito anteriormente se utiliza en la sección 5.3 para la clasificación de los píxeles mezclados generados por regiones de transición en imágenes satelitales.

#### 4.3.3 Construcción de Mapas de incertidumbre

Un mapa de incertidumbre es una imagen que sirve para mostrar la incertidumbre que obtuvo un clasificador para una clase dada (cobertura de suelo). En un mapa de incertidumbres cada píxel de la imagen es representado mediante un color que va desde el blanco (0 % incertidumbre) hasta el negro (100 % de incertidumbre). En otras palabras, mientras más blancos se encuentren pintados los píxeles mezclados, la certeza del clasificador será mayor.

En el proceso de clasificación de imágenes satelitales es necesario cuantificar la exactitud alcanzada por el clasificador en cuestión (Congalton, 2008). Para realizar la evaluación de los resultados de la clasificación de píxeles mezclados se utiliza la medida de certeza difusa basada en clases (CFCM) propuesta por Schiewe y Kinkeldey (Schiewe, 2009b). Esta medida fue seleccionada porque permite evaluar la clasificación suave de los píxeles mezclados presentes en imágenes satelitales. Esta métrica fue desarrollada tomando en cuenta las incertidumbres generadas en las zonas indeterminadas de las coberturas de suelo (regiones de transición). Esta métrica mide la certeza que obtiene un clasificador suave para clasificar los píxeles mezclados

tomando en cuenta para su validación a los datos de referencia también clasificados de manera suave. La ecuación 4.18 presenta la forma de calcular esta métrica.

$$CFCM(c) = 1 - \frac{1}{n} \sum_{i=1}^n |\mu_{i,REF}(c) - \mu_{i,CLASS}(c)| \quad (4.18)$$

$$\forall i | \mu_{i,REF} > 0 \vee \mu_{i,CLASS} > 0$$

donde:

$\mu_{REF}(c)$ : Corresponde al valor de pertenencia de un píxel/área para una clase  $c$  en los datos de referencia.

$\mu_{CLASS}(c)$ : Corresponde al valor de pertenencia de un píxel/área para una clase  $c$  en los datos de la clasificación.

$N$ : Corresponde al número de píxeles/áreas bajo prueba.

$C$ : Clase (cobertura de suelo).

La ecuación 4.18 puede ser aplicada para realizar una evaluación a nivel píxel o a nivel región. Si es calculada a nivel región, CFCM representa la certeza promedio que obtuvo el clasificador suave para esa cobertura de suelo. Sin embargo, si se calcula a nivel píxel, es posible construir mapas de incertidumbre para cada tipo de cobertura de suelo.

## Resumen

En este capítulo se describieron los tres métodos propuestos para alcanzar los objetivos planteados en el desarrollo de este trabajo de investigación. a) El primer método construye las imágenes satelitales sintéticas, b) El segundo método obtiene la localización espacial de las regiones de transición usando el método de segmentación por crecimiento de regiones y algoritmos genéticos, y c) el tercer método FCM-Modificado realiza la clasificación de los píxeles mezclados generados por las regiones de transición. En el siguiente capítulo se muestran los experimentos que validan el planteamiento de los métodos propuestos, así como la comparación frente a otras propuestas donde se alcanzan mejores resultados en los propuestos.

## V. Experimentos y resultados obtenidos

El objetivo general de este trabajo de investigación se encuentra dividido en dos partes principales: 1) obtener los píxeles mezclados generados en las regiones de transición en imágenes satelitales y 2) realizar la clasificación suave para obtener la pertenencia de cada píxel mezclado con respecto a cada cobertura de suelo que presente. Los métodos propuestos para cumplir el objetivo general son descritos en las secciones 4.2 y 4.3 del capítulo 4. En este capítulo se propone comprobar la efectividad de los métodos propuestos mediante una serie de experimentos utilizando imágenes satelitales reales y sintéticas.

Para realizar los experimentos de este trabajo de investigación se utilizaron dos conjuntos de imágenes satelitales, los cuales son:

- **Imágenes satelitales reales (ISR).** Conjunto de sub-imágenes que contienen coberturas homogéneas y regiones de transición seleccionadas de imágenes satelitales reales para su estudio. Las imágenes satelitales deben de ser de alta resolución tal como Quick Bird. La imagen utilizada de tipo Quick Bird corresponde a la región de Puebla. Está compuesta por las tres primeras bandas espectrales. También se han seleccionado imágenes de tipo Spot 7 disponibles en la red mediante la aplicación de *Google Earth* disponible en la página web: <http://www.google.es/intl/es/earth/index.html>.
- **Imágenes satelitales sintéticas (ISS).** Son construidas a partir de imágenes satelitales reales. En una imagen ISS se conoce la composición de cada píxel mezclado de la región de transición. Para más detalle ver la sección 4.1.2.

## 5.1 Metodología usada para realizar los experimentos

La metodología utilizada para realizar los experimentos se divide en dos etapas. La primera consiste en la obtención de los píxeles mezclados generados por una región de transición en una imagen satelital. La segunda etapa detalla la experimentación realizada para la descomposición de los píxeles mezclados que se encuentran en las regiones de transición. Los pasos que se siguen en el desarrollo de cada etapa se describen a continuación:

### **Etapas I: Obtención de los píxeles mezclados generados por una región de transición.**

**Paso 1.** Selección del área de estudio. Ésta debe contener coberturas homogéneas y región(es) de transición con una alta resolución espacial con el propósito de observar de manera visual los píxeles mezclados.

**Paso 2.** Extraer las características de la imagen satelital. Las características son extraídas a nivel píxel tomando en cuenta la vecindad de cada píxel para extraer su información de textura. Los detalles se describen en la sección 4.2.1.

**Paso 3.** Obtener los elementos necesarios para realizar la segmentación basada en el crecimiento de regiones, estos elementos son: semilla(s) y umbral(es) de crecimiento para cada cobertura homogénea presente en la imagen satelital. Para determinar estos valores se utiliza el método descrito en la sección 4.2.2. Además, con este método es posible determinar que regiones son homogéneas.

**Paso 4.** Determinar las regiones de transición en las que se encuentran los píxeles mezclados de la imagen satelital. Para obtener las regiones de transición, se utiliza la segmentación basada en el crecimiento de regiones descrita en la sección 4.2.3. Esta segmentación determina las coberturas homogéneas que delimitan las regiones de transición.

**Paso 5.** Finalmente, es necesario validar la calidad de la localización de las regiones de transición. Para realizar esto se utilizan las métricas descritas en la sección 4.2.4. La evaluación se realiza utilizando softwares comerciales tales como eCognition, EDISON, Idrisi TAIGA y Matlab.

## **Etapas II: Clasificación de los píxeles mezclados generados por una región de transición.**

**Paso 6.** Construcción de las curvas de ajuste utilizando el método descrito en la sección 4.3.1. Las curvas de ajuste preservan la información extraída de las regiones de transición pertenecientes a cada cobertura homogénea bajo estudio. Estas curvas ayudan a ajustar el valor de la pertenencia de un determinado píxel con respecto a una cobertura homogénea dada.

**Paso 7.** Realizar la clasificación suave de los píxeles mezclados usando el método FCM-Modificado descrito en la sección 4.3.2. El método propuesto obtiene la descomposición de cada píxel mezclado obteniendo la pertenencia de cada píxel con respecto a cada cobertura presente en él.

**Paso 8.** Evaluar la clasificación de los píxeles mezclados usando el método descrito en la sección 4.3.3. Para realizar la evaluación de los resultados de la clasificación de píxeles mezclados se ha utilizado la medida de certeza difusa basada en clases (CFCM).

## **5.2 Experimentos utilizando imágenes satelitales sintéticas**

Con el propósito de realizar una evaluación cuantitativa de los métodos propuestos en este trabajo de investigación, se construyeron imágenes satelitales sintéticas (ver la sección 4.1). Las imágenes satelitales sintéticas contienen los valores conocidos (verdaderos) que permiten realizar una validación cuantitativa de los métodos propuestos. El experimento consta de tres partes principales: a) descripción del experimento, b) obtención de la región de transición, c)

clasificación de los píxeles mezclados usando FCM y FCM-Modificado comparados con otras propuestas y d) mapas de incertidumbres.

## 5.2.1 Experimento 1

### 5.2.1.1 Descripción del experimento

**Área de estudio.** La imagen satelital sintética está compuesta por las tres bandas que forma el RGB verdadero color. Su tamaño es de 100 x 150 píxeles.

**Tipos de coberturas.** Las coberturas analizadas son vegetación y suelo descubierto. Además de una región de transición formada por estas coberturas.

**Métodos usados.** Los métodos usados son: obtención de las regiones de transición (descrito en la sección 4.2) y clasificación suave de píxeles mezclados (descrito en la sección 4.3). Además, programas comerciales para su comparación.

### 5.2.1.2 Obtención de la región de transición

En esta sección se evalúan cuantitativamente los límites de la región de transición obtenidos por el método de segmentación por crecimiento de regiones. Estas imágenes se construyeron con el método descrito en la sección 4.1. La localización de las regiones de transición también se realizó utilizando herramientas comerciales que han sido desarrolladas utilizando técnicas de detección de bordes (Neubert, 2008). Estos softwares fueron obtenidos mediante licencia temporales solicitadas a los autores correspondientes. A continuación se describen brevemente estas herramientas:

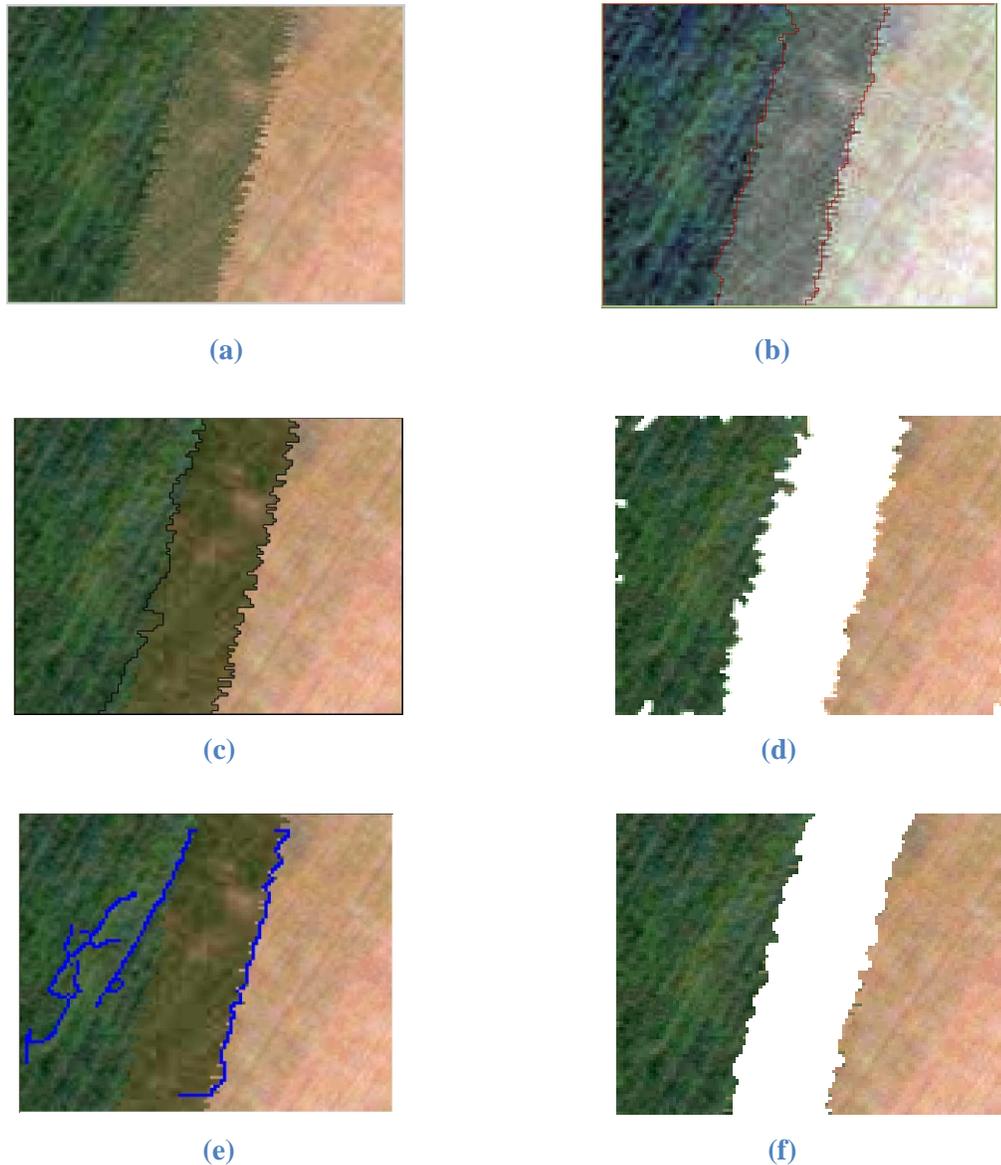
- **Idrisi Taiga.** Este software utiliza un enfoque de segmentación *watershed* que particiona la imagen de entrada en función de su varianza (Eastman, 2012).

- **eCognition.** Utiliza un algoritmo de segmentación para crear objetos de la imagen. El algoritmo de segmentación multi-resolución fusiona recursivamente píxeles u objetos existentes de la imagen. Se trata de una segmentación *bottom-up* basada en la técnica de fusión de región por emparejamiento (Baatz, 2001).
  
- **EDISON.** Este sistema implementa el algoritmo de detección de bordes basado en el espacio de gradiente de intervalo de confianza descrito en (Meer, 2001).
  
- **CANNY (Método de filtrado de matlab).** Se utilizó la función **edge** de Matlab para la detección de bordes. La función **edge** utiliza el método “*canny*”. El método *canny* localiza los bordes que se encuentran en la imagen mediante la búsqueda de máximos locales con un gradiente de la imagen de entrada. El gradiente se calcula utilizando la derivada del filtro Gaussiano. Este método utiliza dos umbrales para la detección de bordes fuertes y débiles respectivamente. Incluye los bordes débiles en la salida solamente si están conectados a los bordes fuertes. Debido a esto, el método *canny* tiene menos probabilidad (que otros) de agregar ruido al resultado, y es más probable que detecte bordes débiles verdaderos (Guide, 1998).

La figura 5.1 muestra los resultados de la localización de las regiones de transición utilizando las herramientas descritas anteriormente y el método propuesto. Para el caso de las herramientas comerciales, la detección de los bordes ha sido realizada con la ayuda del experto en el dominio que indica la mejor ubicación de los límites entre las coberturas de suelo.

Observando los límites trazados por cada uno de los métodos de la figura 5.1, se puede observar que el método propuesto obtiene la región de transición con mayor precisión para las coberturas de suelo analizadas. Por ejemplo, podemos ver que el límite entre la cobertura de vegetación y la región de transición se aprecia mejor en la imagen resultante de nuestro método (véase la figura 5.1d) con respecto a los resultados obtenidos con los otros métodos

debido a que no agrega píxeles mezclados de la zona de transición. El método propuesto localiza a los píxeles mezclados, es decir, no agrega a los píxeles puros a la región de transición.



**Figura 5. 1. Resultados de la localización de las regiones de transición entre las coberturas de suelo de vegetación y suelo descubierto utilizando diferentes herramientas comerciales de software especializado. (a) imagen sintética, (b) resultados obtenidos con Idrisi Taiga, (c) resultados obtenidos con eCognition, (d) resultados obtenidos con el Método propuesto, (e) resultados obtenidos con EDISON, y (f) resultados obtenidos con Canny.**

Neubert y sus colegas (Neubert, 2008) crearon un método para evaluar la calidad de la segmentación de imágenes. Las métricas utilizadas son: *Porcentaje de diferencia de área*,

*Porcentaje de diferencia de perímetro e Índice de forma* descritos en la sección 4.2.3. Para validar las regiones de transición encontradas, se realizaron diez experimentos utilizando imágenes sintéticas con coberturas de suelo de vegetación y suelo descubierto. Los resultados presentados se generaron a partir del promedio de los valores obtenidos para las tres coberturas de suelo. La tabla 5.1 muestra los resultados promediados de este análisis. Además, se hizo una evaluación cualitativa (con la ayuda del experto en el dominio) de la *Calidad visual* de la segmentación de las imágenes satelitales de la figura 5.12.

**Tabla 5.1. Resultados de la evaluación de la calidad en la detección de las regiones de transición.**

Métrica	Programa de Segmentación				
	Idrisi Taiga	eCognition	EDISON	Matlab	TreDet
% Diferencia de área	12.97	2.3	20.5	1.3	<b>0.94</b>
% Diferencia de perímetro	18.53	11.8	35.8	24.6	<b>9.45</b>
% Índice de forma	1.3246	1.854	2.225	<b>0.5</b>	1.4376
Calidad visual	1.0	1.2	0.7	1.2	<b>1.3</b>

A partir de la tabla 5.1 podemos notar que el método propuesto (TreDet) obtiene mejores resultados en las métricas de % diferencia de área, % diferencia de perímetro, y calidad visual (0: pobre, 1: medio, 2: bueno). Estas métricas no tienen unidades debido a que son calculadas mediante relaciones entre la imagen segmentada y la imagen original (datos reales). Matlab obtiene mejor resultado para el índice de forma. En este caso se debió a que el experto en el dominio le proporcionó ayuda para obtener la región de transición. Una contribución importante del trabajo de investigación es que el método propuesto obtiene de manera automática la localización de la región de transición, mientras que los otros algoritmos necesitan del conocimiento de un experto en el dominio para poder obtener una mejor ubicación de los límites indefinidos de la región de transición.

### 5.2.1.3 Clasificación de los píxeles mezclados usando FCM-Modificado y otros métodos

Se realizó la clasificación de píxeles mezclados usando el método propuesto FCM modificado, además se realizaron otras clasificaciones para comparar de forma cuantitativa los resultados de los distintos clasificadores. Los clasificadores usados son de: a) usando Matlab (FCM) y b) IDRISI TAIGA (Difuso, Bayesiano, k-nn-suave y red neuronal SOM). Para ver los detalles de la clasificación realizada en IDRISI TAIGA ver el apéndice A.1.

Las figuras 5.2 – 5.7 muestran los resultados de la clasificación suave de los distintos clasificadores en el siguiente orden: FCM, FCM-Modificado, Difuso, Bayesiano, k-nn-suave y red neuronal SOM. Los resultados de la clasificación suave se presentan en imágenes separadas: la columna de la izquierda muestra el porcentaje de pertenencia de los píxeles mezclados con respecto a la cobertura vegetación y la columna de la derecha el porcentaje de pertenencia de los píxeles mezclados con respecto a la cobertura suelo descubierto. La pertenencia de cada píxel se muestra de acuerdo al tono de gris que va desde el color blanco (pertenencia del 100 %) al color negro (pertenencia del 0 %).

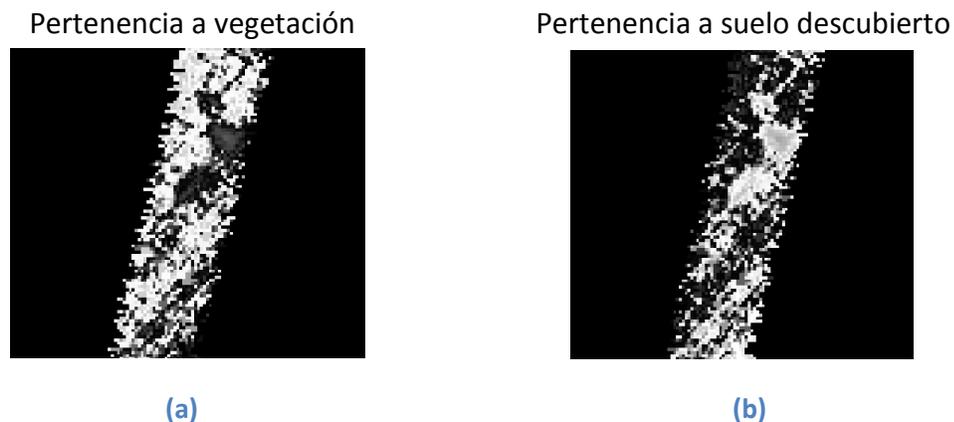
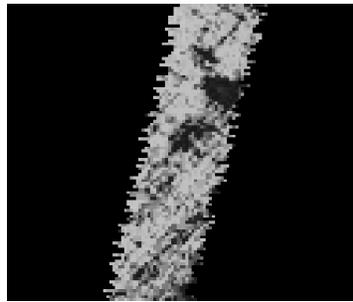
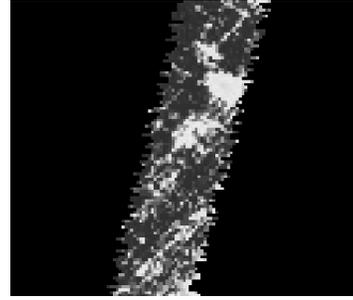


Figura 5.2. Clasificación de píxeles mezclados usando el método FCM, (a) Pertenencia a la clase vegetación, (b) Pertenencia a la clase suelo descubierto. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %).

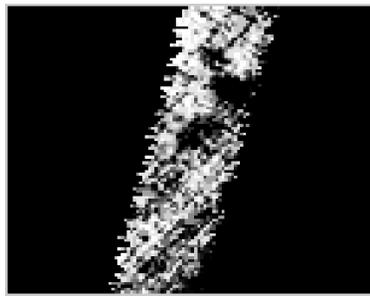


(a)

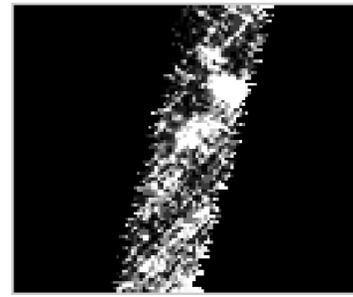


(b)

Figura 5.3. Clasificación de píxeles mezclados usando el método FCM-Modificado, (a) Pertenencia a la clase vegetación, (b) Pertenencia a la clase suelo descubierto. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %).

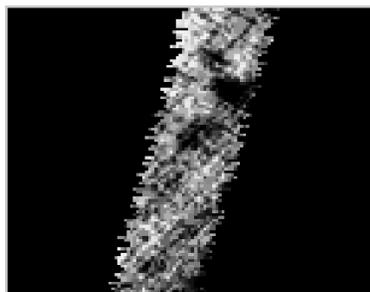


(a)

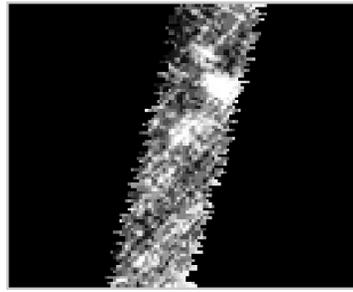


(b)

Figura 5.4. Clasificación de píxeles mezclados usando el método difuso, (a) Pertenencia a la clase vegetación, (b) Pertenencia a la clase suelo descubierto. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %).

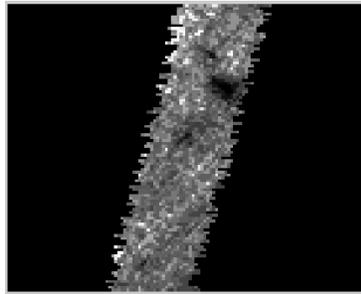


(a)

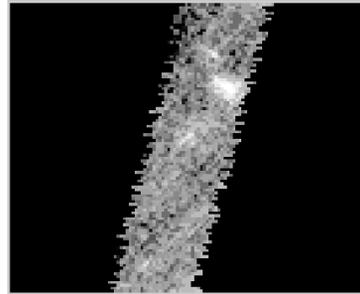


(b)

Figura 5.5. Clasificación de píxeles mezclados usando el método de una red bayesiana, (a) Pertenencia a la clase vegetación, (b) Pertenencia a la clase suelo descubierto. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %).

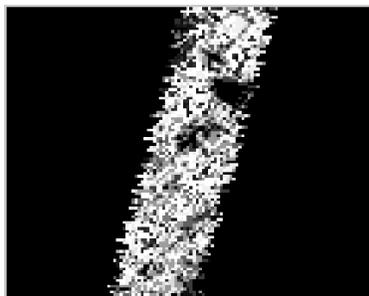


(a)

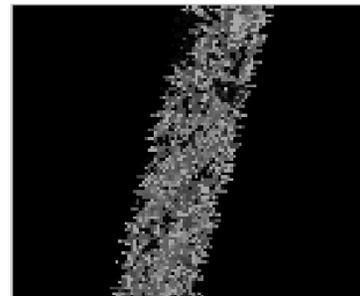


(b)

Figura 5.6. Clasificación de píxeles mezclados usando el método k-nn-suave, (a) Pertenencia a la clase vegetación, (b) Pertenencia a la clase suelo descubierto. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %).



(a)



(b)

Figura 5.7. Clasificación de píxeles mezclados usando una red neuronal SOM, (a) Pertenencia a la clase vegetación, (b) Pertenencia a la clase suelo descubierto. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %).

Los resultados de la clasificación suave mostrados en las figuras 5.2 – 5.7 por sí solos no determinan cual clasificador obtuvo mejores resultados. Para analizar los resultados cuantitativos se recurre a la construcción de mapas de incertidumbre que se describe en la siguiente sección.

#### 5.2.1.4 Mapas de Incertidumbre

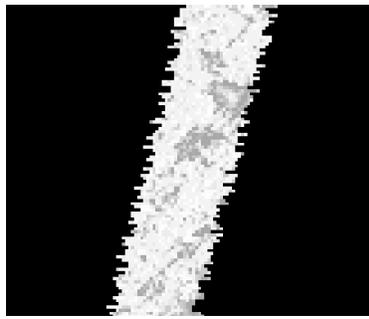
Con la finalidad de realizar la evaluación de la clasificación de los píxeles mezclados se construyeron los mapas de incertidumbre descritos en (Schiewe, 2009b). Estos mapas se construyen para medir la certeza (exactitud) que obtuvo la clasificación suave a nivel píxel

representada en forma de imágenes. La certeza se calcula para cada píxel y para cada clase utilizando la ecuación 17 descrita en la sección 4.3.3. De esta manera, el mapa de incertidumbre muestra la certeza de cada píxel que se obtuvo a partir del clasificador en turno. Por ejemplo, si el píxel es de color blanco, significa que el clasificador obtuvo el 100 % de certeza para determinar la pertenencia con respecto a esa cobertura de suelo. Sin embargo, si el píxel es de color negro, el clasificador obtuvo 0 % de certeza para determinar la composición de dicho píxel.

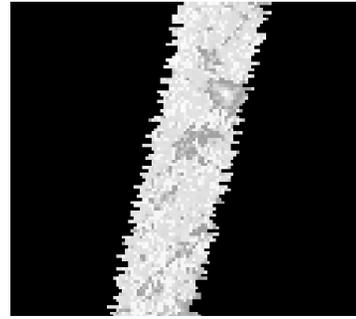
Las figuras 5.8 – 5.13 muestran los mapas de incertidumbre de la región de transición en el siguiente orden: clasificador FCM, clasificador FCM-Modificado, clasificador Difuso, clasificador Bayesiano, clasificador k-nn-suave y clasificador red neuronal SOM. Los resultados los mapas de incertidumbre se presentan en imágenes separadas: La columna de la izquierda muestra los mapas de incertidumbre de los píxeles mezclados con respecto a la cobertura vegetación y la columna de la derecha muestra los mapas de incertidumbre de los píxeles mezclados con respecto a la cobertura suelo descubierto. Cada mapa de incertidumbre se lee de la siguiente manera: La certeza de cada píxel se muestra de acuerdo al tono de gris que va desde el color blanco (certeza del 100 %) al color negro (certeza del 0 %).



**Figura 5.8. Construcción de mapas de incertidumbre usando el clasificador FCM: (a) para vegetación, (b) para suelo descubierto.**

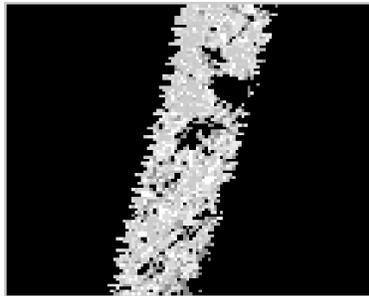


(a)

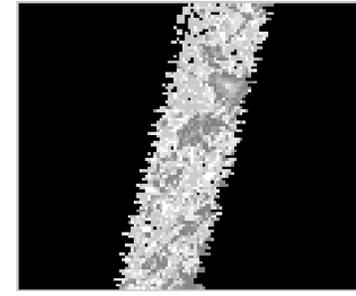


(b)

Figura 5.9. Construcción de mapas de incertidumbre usando el clasificador FCM-Modificado: (a) para vegetación, (b) para suelo descubierto.

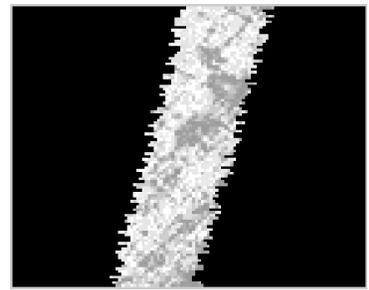


(a)

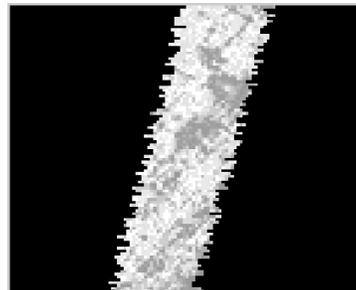


(b)

Figura 5.10. Construcción de mapas de incertidumbre usando el clasificador difuso: (a) para vegetación, (b) para suelo descubierto.

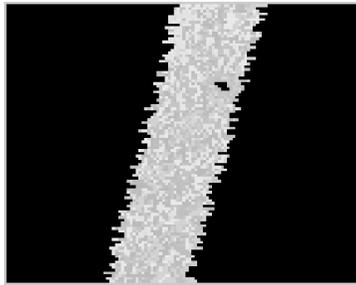


(a)

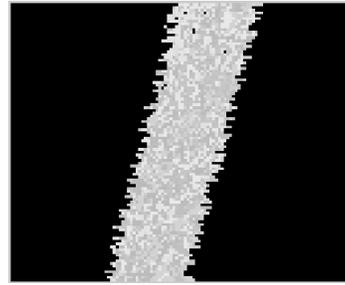


(b)

Figura 5.11. Construcción de mapas de incertidumbre usando el clasificador bayesiano: (a) para vegetación, (b) para suelo descubierto.

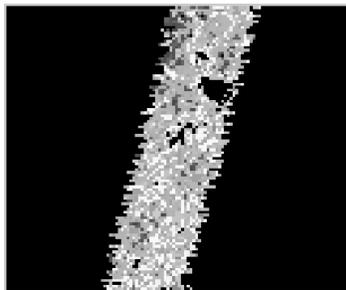


(a)

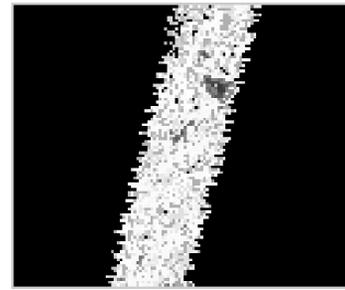


(b)

**Figura 5.12. Construcción de mapas de incertidumbre usando el clasificador k-nn-suave: (a) para vegetación, (b) para suelo descubierto.**



(a)



(b)

**Figura 5.13. Construcción de mapas de incertidumbre usando el clasificador red neuronal SOM: (a) para vegetación, (b) para suelo descubierto.**

Realizando una comparación visual entre las imágenes de la figura 5.8 – 5.13, es posible notar que los mapas de incertidumbre de la figura 5.9 correspondiente al clasificador FCM-Modificado y el de la figura 5.11 para el clasificador Bayesiano muestran una mayor intensidad de color claro. Esto se debe a que sus resultados de la clasificación obtuvieron mayor certeza difusa. Para verificar los resultados de manera cuantitativa se utilizó la medida de certeza difusa por clase descrita en la sección 4.3.3. La tabla 5.2 muestra los resultados de la CFCM para los clasificadores implementados.

Tabla 5.2. CFCM para los clasificadores suave.

Cobertura de suelo	CFCM para Vegetación	CFCM para Suelo descubierto	CFCM total
FCM	71.71	71.71	71.71
<b>FCM-Modificado</b>	<b>89.70</b>	<b>86.31</b>	<b>88.01</b>
Difuso	80.59	77.41	79.00
Bayesiano	83.59	83.59	83.59
k-nn-suave	81.37	81.33	81.35
Red Neuronal SOM	73.12	86.14	79.63

De acuerdo a los resultados obtenidos en las tablas 5.2 y 5.3, se puede notar que el clasificador FCM-Modificado (el método propuesto) obtiene una mejor certeza CFCM en la clasificación de los píxeles mezclados generados en la región de transición. Los resultados demuestran que el método propuesto tiene mejor rendimiento debido a los siguientes puntos:

- La clasificación suave se realiza únicamente a los píxeles mezclados de la región de transición. Esto permite que en la clasificación no se agreguen píxeles puros que puedan ser tomados como suaves como lo toman los demás clasificadores.
- Se le instruye al clasificador FCM-Modificado información de acerca de la distribución de los píxeles mezclados en una región de transición de una imagen satelital real. Esta información es proporcionada a través de la curva de ajuste.
- Se toman como centroides fijos del FCM-Modificado a los píxeles semillas de las coberturas homogéneas que fueron calculado mediante la segmentación basada en el crecimiento de regiones.

## 5.2.2 Experimento 2

### 5.2.2.1 Descripción del experimento

**Área de estudio.** La imagen satelital sintética está compuesta por las tres bandas que forma el RGB verdadero color. Su tamaño es de 100 x 150 píxeles.

**Tipos de coberturas.** Las coberturas analizadas son: selva, bosque, matorrales, playa y suelo descubierto. Además de una región de transición formada por estas coberturas.

**Métodos usados.** Los métodos usados son: obtención de las regiones de transición (descrito en la sección 4.2) y clasificación suave de píxeles mezclados (descrito en la sección 4.3). Además, programas comerciales para su comparación.

### 5.2.2.2 Análisis de los resultados obtenidos

La tabla 5.3 muestra los resultados obtenidos de la evaluación de las medidas de similitud entre las ventanas satelital real y las ventanas sintéticas suave. Para más detalle de la construcción de las imágenes satelitales sintéticas se muestran en el Apéndice A.2.

**Tabla 5.3. Medidas de similitud entre las imágenes reales y sintéticas.**

Figura	FSIM	FSIMc
A.2.1	0.9948	0.9915
A.2.2	0.9638	0.9621
A.2.3	0.9698	0.9638
A.2.4	0.978	0.9749
A.2.5	0.9842	0.9839
<b>Promedio</b>	<b>0.97812</b>	<b>0.97524</b>

El intervalo de los valores de las medidas FSIM y FSIMc comprende desde -1 (imágenes antisimétricas en sus valores de píxeles) hasta 1 (imágenes idénticas). Como puede observarse en los resultados de la tabla 5.3, existe una alta similitud entre las ventanas sintéticas y reales.

Los resultados obtenidos validan la eficiencia del método para la construcción de las imágenes sintéticas. Por lo tanto, estas imágenes satelitales sintéticas pueden ser usadas para la obtención y clasificación de los píxeles mezclados debido a que mantienen las características a nivel píxel y a nivel región de cada píxel de la imagen original. Además que permiten realizar la evaluación de la clasificación suave de los píxeles mezclados.

La tabla 5.4. muestra los resultados de la evaluación cuantitativa de la localización de las regiones de transición para las figuras A.2.7 – A.2.11 mostradas en el apéndice A.2.

**Tabla 5.4. Evaluación cuantitativa de la localización de las regiones de transición para las figuras A.2.7 – A.2.11 mostradas en el apéndice A.2.**

Métrica	Programa de Segmentación			
	Idrisi Taiga	eCognition	EDISON	TreDet
% Diferencia de área	16.34	13.78	5.5	<b>2.72</b>
% Diferencia de perímetro	22.58	18.32	10.76	<b>9.62</b>
% Índice de forma	2.474	2.21	<b>1.312</b>	1.33
Calidad visual	0.86	0.84	1.36	<b>1.5</b>

A partir de la tabla 5.4 podemos notar que el método propuesto (TreDet) obtiene mejores resultados en las métricas: % diferencia de área, % diferencia de perímetro, calidad visual (0: pobre, 1: medio, 2: bueno); EDISON obtiene ligeramente mejor resultado que el método propuesto en la métrica de índice de forma. Estas métricas no tienen unidades debido a que son calculadas mediante relaciones entre la imagen segmentada y la imagen original (datos reales). Es conveniente resaltar que la diferencia entre los software comerciales y el método propuesto, radica en que los software comerciales determinan las regiones de transición de manera supervisada, es decir, necesitan la ayuda del experto en el dominio para ajustar los parámetros necesarios en cada programa comercial. En este segundo método propuesto, además se determinan los centros de clústers de cada cobertura homogénea los cuales son utilizados en la clasificación FCM-Modificado.

La tabla 5.5 muestra los resultados de la evaluación cuantitativa de la clasificación suave de los píxeles mezclados usando las imágenes sintéticas de la figura A.2.6 mostradas en el apéndice A.2. La métrica utilizada es la medida de certeza difusa por clase (CFCM).

**Tabla 5.5. CFCM para la clasificación de las imágenes sintéticas de la figura A.2.6.**

Cobertura de suelo	CFCM para la cobertura de suelo 1	CFCM para la cobertura de suelo 2	CFCM total
FCM	75.44	75.44	75.44
<b>FCM-Modificado</b>	<b>86.40</b>	<b>85.65</b>	<b>86.02</b>
Difuso	81.45	82.61	82.03
Bayesiano	83.32	81.16	82.24
k-nn-suave	79.24	80.12	79.68
Red Neuronal SOM	77.35	74.27	75.81

Los resultados de la tabla 5.5 muestran que el método propuesto para la clasificación de píxeles mezclados obtiene una mejor clasificación suave. Este mejoramiento demuestra que utilizar información basada en regiones de transición de imágenes satelitales reales ayudan al clasificador FCM-Modificado para tomar su decisión en la descomposición de los píxeles mezclados. Además de que los clústers encontrados en el método de segmentación ayudan a que no se recalculen los centroides del FCM tradicional, esto ayuda al método propuesto para converger en la solución de la clasificación suave usando un menor número de iteraciones.

Para este experimento 2 se realizó un análisis de significancia estadística para los resultados de la clasificación suave usando los métodos de la tabla 5.5. Se utilizó el método de significancia estadística Wilcoxon (Demsar, 2006). Este método toma como hipótesis nula los resultados contra los cuales deseamos probar (en nuestro caso se realizó contra los métodos de la tabla 5.5). Entonces se realizaron 10 corridas para cada clasificador. Se calcularon los promedios de la medida de certeza difusa CFCM correspondiente a dos tipos de coberturas de suelo clasificados. Los resultados se muestran en la table 5.6. Se midió el nivel de significancia estadística a un 99.05 % de confianza. Los resultados demuestran que las diferencias entre los métodos son significativos.

Tabla 5.6. Prueba de significancia estadística usando el método Wilcoxon para los métodos de clasificación de la tabla 5.5.

CFCM-FCM	CFCM-Mod	CFCM-Difuso	CFCM-Bayesiano	CFCM-Knn-Suave	CFCM-Red Neuronal SOM
75	86	82	82	80	76
75	86	82	82	80	76
75	86	82	82	80	76
75	86	82	82	80	76
75	86	82	82	80	76
75	86	82	82	80	76
75	86	82	82	80	76
75	86	82	82	80	76
75	86	82	82	80	76
75	86	82	82	80	76

### 5.3 Experimentos utilizando imágenes satelitales reales

En esta sección se presentan los resultados experimentales de los dos métodos propuestos utilizando imágenes satelitales reales. Los resultados de la obtención de las regiones de transición son evaluados de forma cualitativa debido a que no se tienen imágenes reales como datos de referencia para realizar una validación cuantitativa. El experimento consta de tres partes principales: a) descripción del experimento, b) obtención de la región de transición y c) clasificación de los píxeles mezclados usando FCM-Modificado.

#### 5.3.1 Experimento 1

##### 5.3.1.1 Descripción del experimento

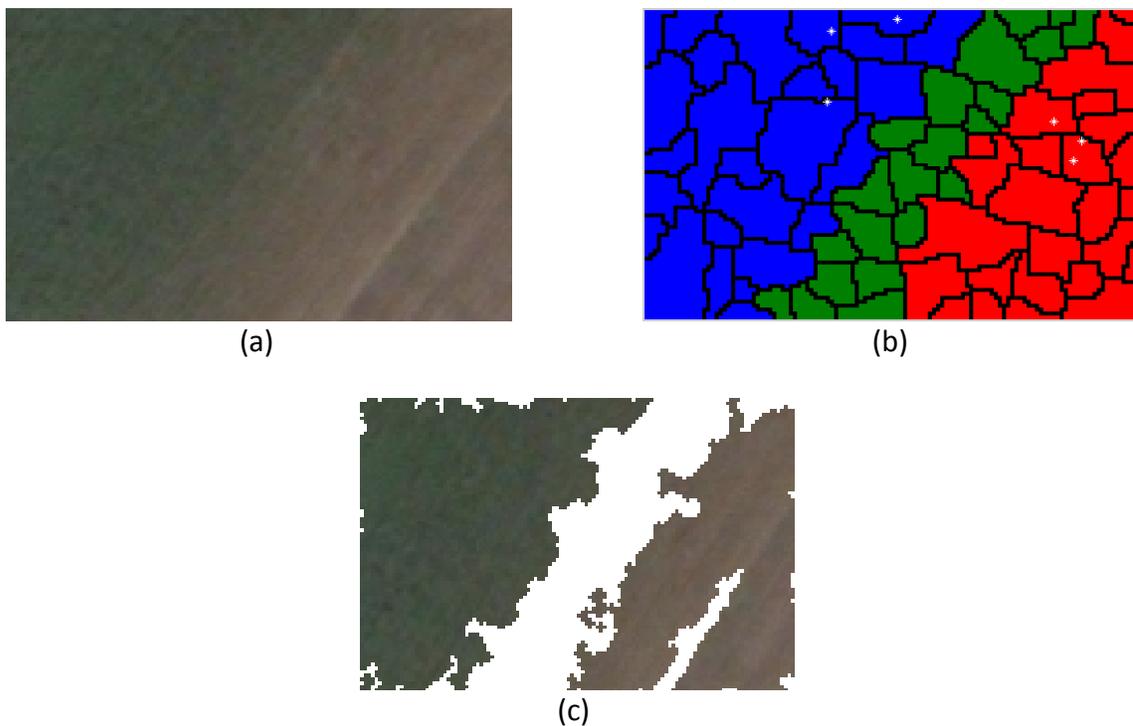
**Área de estudio.** La imagen satelital sensada por el satélite *Quick Bird* con una resolución de 60 cm correspondiente a la zona de Puebla, México. A partir de esta imagen satelital se extraen 3 subimágenes.

**Tipos de coberturas.** Las coberturas analizadas son vegetación y suelo descubierto. Además de una región de transición formada por estas coberturas.

**Métodos usados.** Los métodos usados son: Obtención de las regiones de transición (descrito en la sección 4.2) y Clasificación suave de píxeles mezclados (descrito en la sección 4.3).

### 5.3.1.2 Obtención de la región de transición

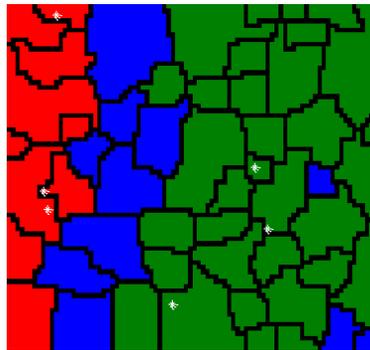
Las figuras 5.14 – 5.16 muestran las imágenes resultantes del proceso de obtención de las regiones de transición. Las figuras 5.14 – 5.16 (a) muestran las imágenes originales con coberturas de vegetación y suelo descubierto. Las figuras 5.14 – 5.16 (b) presentan la localización de las semillas marcadas por puntos de color blanco (tres por cada cobertura homogénea). Las figuras 5.14 – 5.16 (c) muestran las coberturas homogéneas que delimitan los píxeles mezclados generados por las regiones de transición.



**Figura 5.14. Resultados de la obtención de las regiones de transición: (a) Imagen original, (b) Localización de las semillas en las coerturas de suelo vegetación (azul) y suelo descubierto (rojo) y (c) Coberturas homogéneas que delimitan los píxeles mezclados.**



(a)



(b)

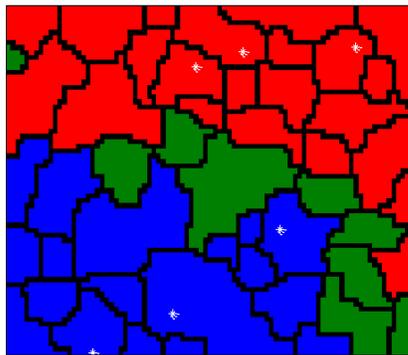


(c)

Figura 5.15. Resultados de la obtención de las regiones de transición: (a) Imagen original, (b) Localización de las semillas en las coerturas de suelo vegetación (rojo) y suelo descubierto (verde) y (c) Coberturas homogéneas que delimitan los píxeles mezclados.



(a)



(b)



(c)

**Figura 5.16. Resultados de la obtención de las regiones de transición: (a) Imagen original, (b) Localización de las semillas en las coerturas de suelo vegetación (rojo) y suelo descubierto (azul) y (c) Coberturas homogéneas que delimitan los píxeles mezclados.**

En las imágenes de la figura 5.14 – 5.16 (c) se muestra la obtención de las regiones de transición. Estas regiones son delimitadas por las coberturas homogéneas de tipo vegetación y suelo descubierto. La importancia de esta segmentación basada en el crecimiento de regiones,

radica en no agregar a los píxeles píxeles mezclados. De esta manera se puede apreciar de forma visual que las coberturas segmentadas contienen en su gran mayoría únicamente a los píxeles homogéneos (un solo tipo de cobertura).

#### *5.3.1.3 Clasificación de los píxeles mezclados usando FCM-Modificado*

La figura 5.17 muestra los resultados de clasificación de los píxeles mezclados generados por regiones de transición de las imágenes mostradas en las figuras 5.14 - 5.16. Las figuras 5.17 (a-c) muestran las imágenes originales con coberturas de vegetación y suelo descubierto. Las figuras 5.17 (d-i) presentan los resultados de la clasificación suave usando el clasificador FCM-Modificado de los píxeles mezclados. La clasificación se muestra en imágenes separadas: las figuras 5.17 (d-f) muestran la composición de los píxeles mezclados con respecto a la cobertura vegetación, y las figuras 5.17 (g-i) muestran la composición con respecto a la cobertura suelo descubierto. La pertenencia de cada píxel se muestra de acuerdo al tono de gris que va desde el color blanco (pertenencia del 100 %) al color negro (pertenencia del 0 %).

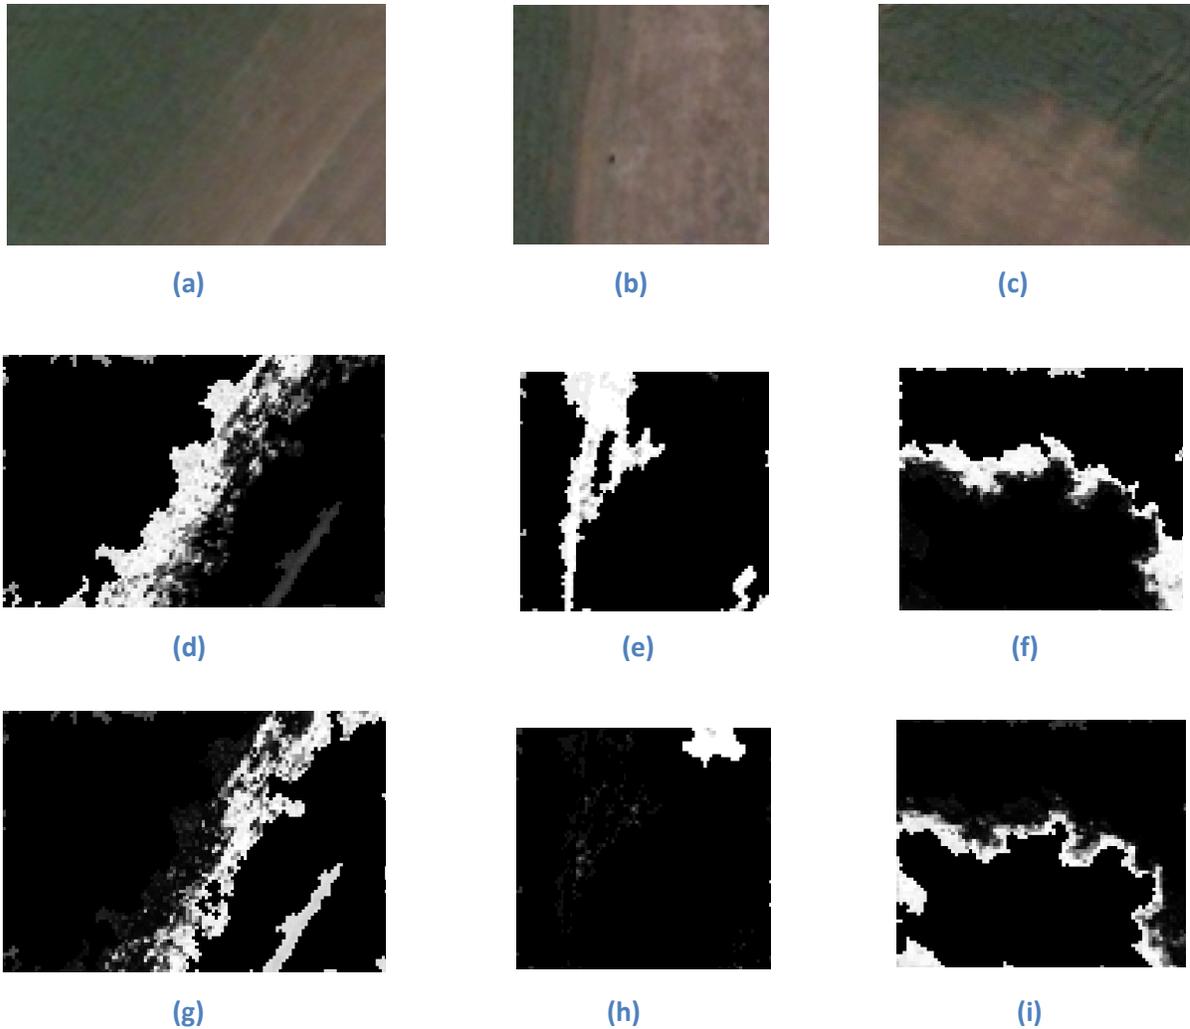


Figura 5.17. Resultados de la obtención de las regiones de transición: (a-c) Imágenes originales, (d-f) Pertenencia de los píxeles mezclados con respecto a la cobertura vegetación y (g-i) Pertenencia de los píxeles mezclados con respecto a la cobertura suelo descubierto.

## 5.3.2 Experimento 2

### 5.3.2.1 Descripción del experimento

**Área de estudio.** Se seleccionaron imágenes satelitales que contienen distintas coberturas de suelo. Las imágenes corresponden a la región sureste de la República Mexicana.

**Tipos de coberturas.** Las coberturas analizadas: tales como: matorrales, pastizal, construcciones (carreteras), playa, bosque y selva. Además de una región de transición formada por cada par de estas coberturas.

**Métodos usados:** obtención de las regiones de transición (descrito en la sección 4.2).

### 5.3.2.2 Obtención de la región de transición

Las figuras 5.18 – 5.24 muestran las imágenes resultantes del proceso de obtención de las regiones de transición usando el método propuesto basado en el crecimiento de regiones.

#### Imagen satelital original



Figura 5.18. (a) Imagen satelital original con coberturas de suelo: bosque y matorrales, (b) Localización espacial de la región de transición (color café claro).

#### Imagen satelital original



Figura 5.19. (a) Imagen satelital original con coberturas de suelo: bosque y carretera, (b) Localización espacial de la región de transición (color café claro).

**Imagen satelital original**



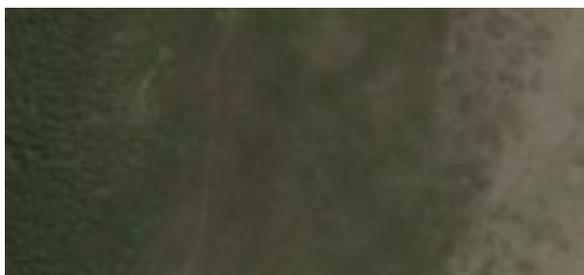
(a)



(b)

Figura 5.20. (a) Imagen satelital original con coberturas de suelo: selva y carretera, (b) Localización espacial de la región de transición (color café claro).

**Imagen satelital original**



(a)



(b)

Figura 5.21. (a) Imagen satelital original con coberturas de suelo: selva y playa, (b) Localización espacial de la región de transición (color gris).

**Imagen satelital original**



Selva

Playa

(a)



Región de  
transición

(b)

Figura 5.22. (a) Imagen satelital original con coberturas de suelo: selva y playa, (b) Localización espacial de la región de transición (color café claro).

**Imagen satelital original**



Bosque

Pastizal

(a)



Región de  
transición

(b)

Figura 5.23. (a) Imagen satelital original con coberturas de suelo: bosque y pastizal, (b) Localización espacial de la región de transición (color café claro).

**Imagen satelital original**



Bosque

Pastizal

(a)



Región de  
transición

(b)

Figura 5.24. (a) Imagen satelital original con coberturas de suelo: bosque y pastizal, (b) Localización espacial de la región de transición (color café claro).

Es posible notar que las imágenes de las figuras 5.18(b), 5.19(b), 5.20(b), 5.22(b), 5.23(b) y 5.24 se aprecian de manera clara la ubicación de las coberturas homogéneas que delimitan a las regiones de transición. Para la imagen de la figura 5.21(b) en la cobertura de selva se nota la presencia de una combinación de dos coberturas de suelo en la misma región. Esto se debe a que en la imagen original existen estas 3 coberturas de suelo en vez de 2. Sin embargo, en todas las imágenes es posible apreciar las regiones de transición generadas por cada par de cobertura de suelo.

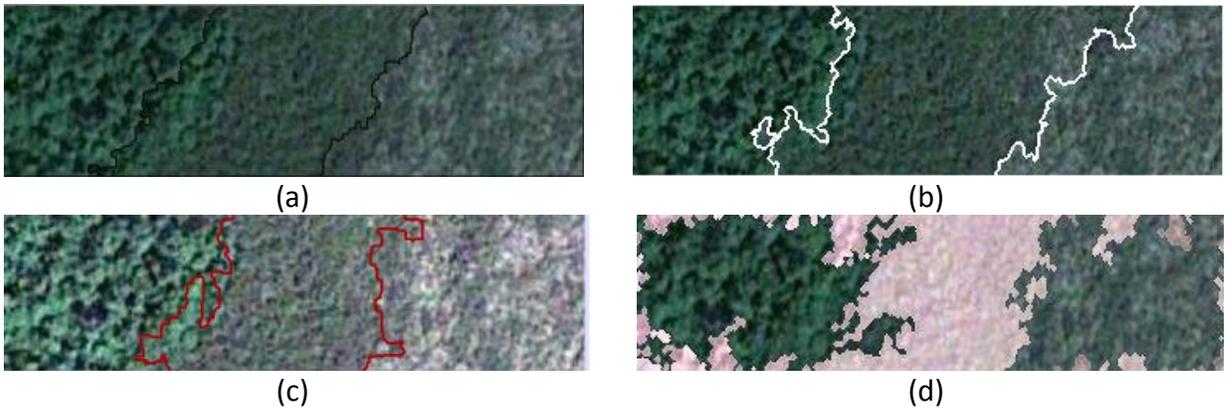
### **5.3.3 Validación de las regiones de transición a través del experto en el dominio**

Los expertos del dominio que nos apoyaron para la evaluación de los resultados de este trabajo son personas con experiencia en el área de Percepción Remota y coberturas de suelo. Los expertos en el dominio en su mayoría han sido colaboradores muy cercanos de la especialidad de Percepción Remota impartida por el CRECTEALC.

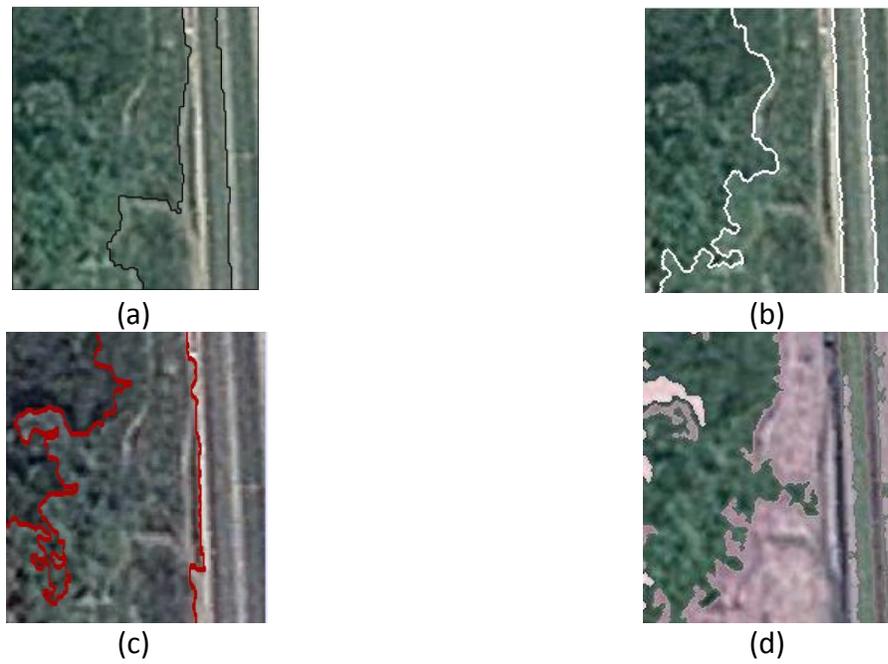
Cabe mencionar que el grado de dificultad para la evaluación de imágenes satelitales por un experto en el dominio se dificulta conforme a los siguientes aspectos:

1. Baja la resolución de las imágenes satelitales.
2. Incertidumbre asociada a toda imagen satelital.
3. Subjetividad agregada por cada experto en el dominio para la evaluación.

Tomando en cuenta los aspectos anteriores, se les solicitó a los expertos en el dominio que evaluaran las imágenes satelitales mostradas en las figuras 5.25 – 5.31.



**Figura 5.25. Localización de las regiones de transición: (a) eCognition, (b) EDISON, (c) Idrisi TAIGA y (d) Método Propuesto.**



**Figura 5.26. Localización de las regiones de transición: (a) eCognition, (b) EDISON, (c) Idrisi TAIGA y (d) Método Propuesto.**

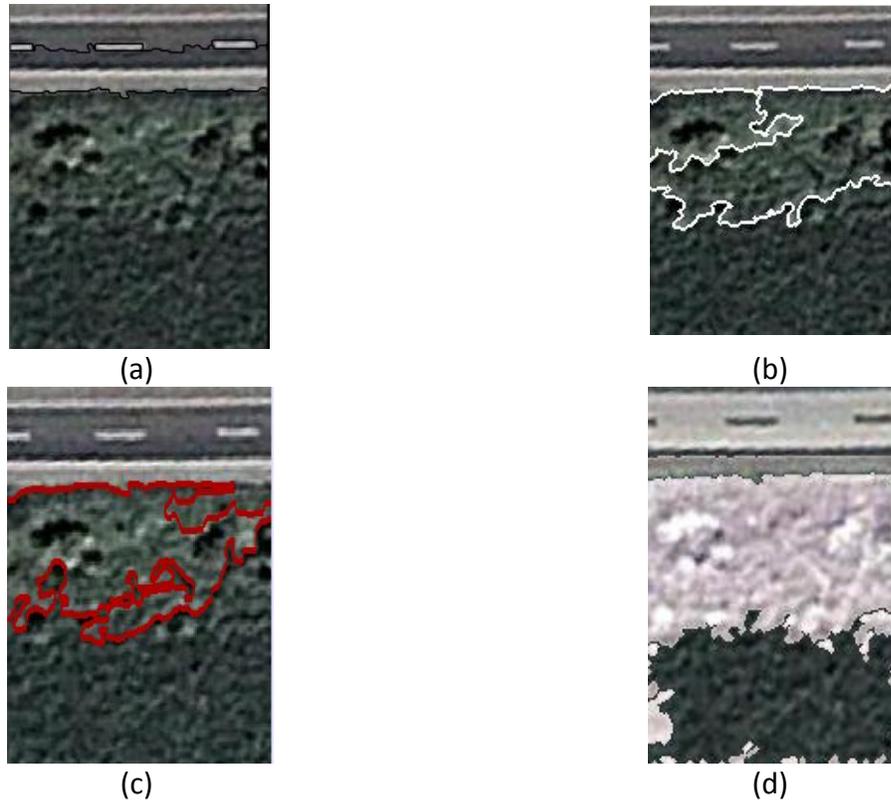


Figura 5.27. Localización de las regiones de transición: (a) eCognition, (b) EDISON, (c) Idrisi TAIGA y (d) Método Propuesto.

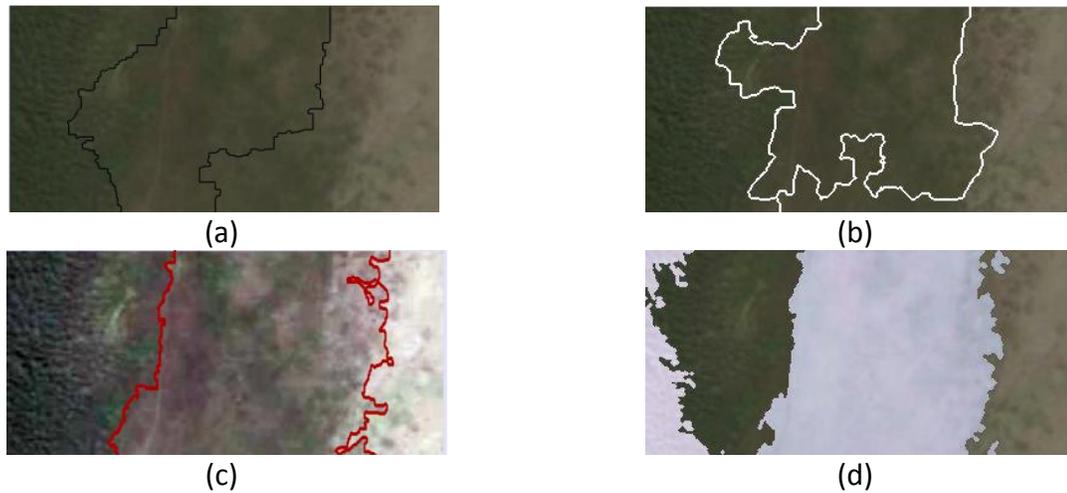


Figura 5.28. Localización de las regiones de transición: (a) eCognition, (b) EDISON, (c) Idrisi TAIGA y (d) Método Propuesto.

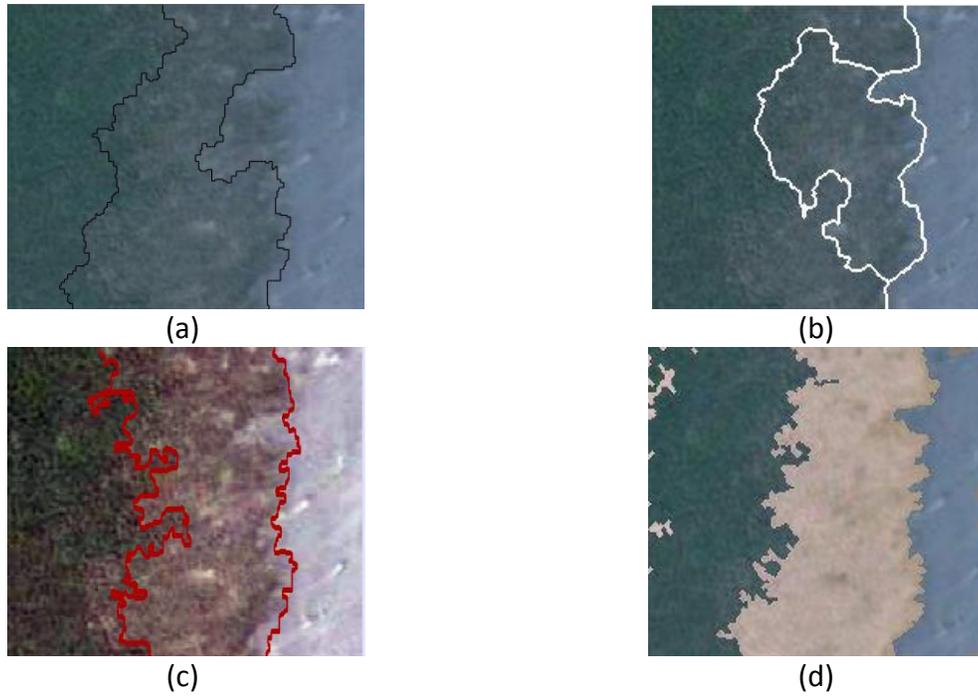


Figura 5.29. Localización de las regiones de transición: (a) eCognition, (b) EDISON, (c) Idrisi TAIGA y (d) Método Propuesto.

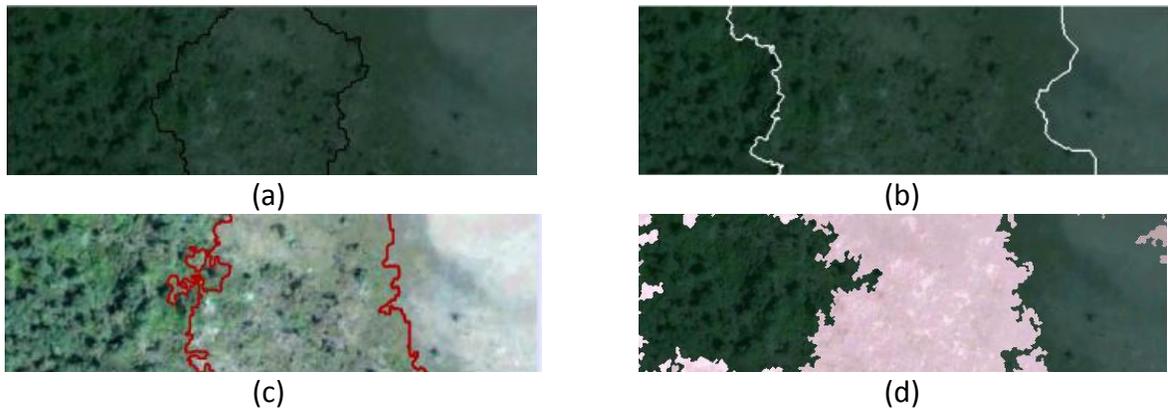
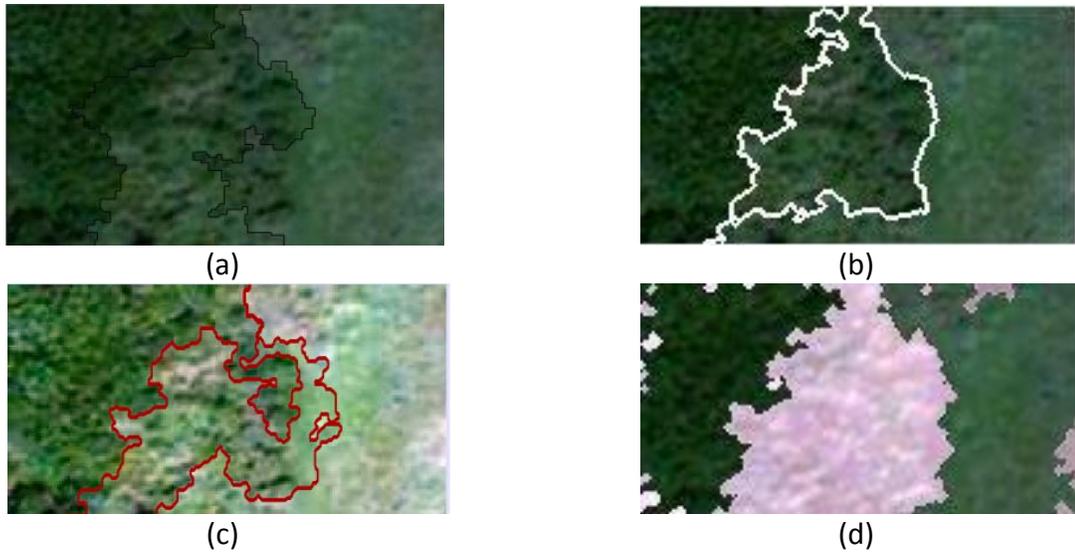


Figura 5.30. Localización de las regiones de transición: (a) eCognition, (b) EDISON, (c) Idrisi TAIGA y (d) Método Propuesto.



**Figura 5.31. Localización de las regiones de transición: (a) eCognition, (b) EDISON, (c) Idrisi TAIGA y (d) Método Propuesto.**

Observando las figuras 5.25 – 5.31 es posible notar que el método propuesto (TreDet) obtiene buenos resultados en las imágenes satelitales de las figuras 5.27 – 5.31. La idea principal de esta segmentación es obtener coberturas homogéneas que no contengan píxeles mezclados. Por esta razón lo importante es agrupar los píxeles puros dejando en la zona de transición a los píxeles mezclados. El método TreDet no alcanza buenos resultados para las imágenes satelitales de las figuras 5.25 y 5.26, esto se debe a que en las coberturas seleccionadas como homogéneas existen pequeños objetos que modifican la varianza de estas regiones lo cual afecta el segmentador basado en el crecimiento de regiones.

La tabla 5.3 muestra los resultados de la evaluación realizada por los expertos en el dominio. En la tabla se muestran los promedios obtenidos de todos los expertos en el dominio para las imágenes de las figuras 5.25 – 5.31. Los criterios solicitados en la evaluación son: capacidad para determinar las regiones de transición, capacidad para obtener la cobertura homogénea 1 (lado izquierdo o parte superior de la imagen), capacidad para obtener la cobertura homogénea 2 (lado derecho o parte inferior de la imagen). La calificación otorgada en cada aspecto se encuentra en el intervalo de 0 a 10. Se excluyó el filtrado *canny* de matlab debido a que no obtuvo resultados satisfactorios en este experimento.

**Tabla 5.6. Resultados de la evaluación por los expertos en el dominio.**

Promedios	eCognition	EDISON	Idrisi TAIGA	TreDet
Obtención RsT	7.6	7.14	7.43	<b>8.14</b>
Obtención cob. hom. 1	7.86	8.21	7.77	<b>8.35</b>
Obtención cob. hom. 2	7.07	7.14	<b>8.43</b>	8.36

Los resultados mostrados en la tabla 5.6 no dejan de tener una alta subjetividad correspondiente a cada experto en el dominio. La evaluación fue realizada de acuerdo a sus conocimientos relacionados con imágenes satelitales respecto a su formación profesional. Los valores obtenidos son muy similares, alcanzando mejores resultados el método propuesto.

#### 5.4 Análisis de eficiencia

En el análisis de la eficiencia de los métodos de segmentación y clasificación se tomaron en cuenta los tiempos de respuesta que tomaban los cálculos para ser mostrados por el método en particular. El tiempo está dado en segundos. Las imágenes usadas en la medición de eficiencia son de tamaño 100x120 píxeles. La tabla 5.4 muestra el rendimiento del tiempo que le toma cada método de segmentación en alcanzar sus resultados. Para el caso del método propuesto que se basa en la segmentación por crecimiento de regiones, no se contempla el cálculo de las semillas mediante el algoritmo genético. Para este experimento, el tiempo utilizado para que el algoritmo genético determine el agrupamiento de las coberturas de la imagen satelital es de 2 horas, con un número de generaciones igual a 1500. Por tanto el tiempo de ejecución global del método TreDet es mayor que los métodos comerciales.

**Tabla 5.7. Cálculo de la eficiencia de los métodos de segmentación (segundos).**

Promedios	eCognition	EDISON	Idrisi TAIGA	Canny	TreDet
Tiempo de respuesta	4	5	35	5	6

Los tiempos de respuesta mostrados de la tabla 5.4 indican que hay mucha similitud en el procesamiento de las imágenes satelitales debido a que en todas se utilizan las tres bandas. El método propuesto solo tarda menos que el método IDRISI TAIGA debido a que utiliza

características de textura calculadas como paso preliminar del algoritmo genético. Sin embargo, la extracción de las características para una imagen satelital en particular solo es realizada una vez y almacenada en un archivo.

La tabla 5.5 muestra el rendimiento del tiempo que le toma cada método de clasificación suave en alcanzar sus resultados.

**Tabla 5.8. Cálculo de la eficiencia de los métodos de clasificación suave (segundos).**

Promedios	FCM	FCM-Mod	Difuso	Bayesiano	Knn-suave	Red Neuronal SOM
<b>Tiempo de respuesta</b>	350	3	5	7	15	70

Los tiempos de respuesta mostrados en la tabla 5.5 indican que el método propuesto FCM-Modificado mejora el tiempo utilizado por el FCM tradicional, además que obtiene una convergencia a la solución en un menor número de iteraciones debido a que no recalcula los centroides de cada clúster (cobertura homogénea).

## 5.5 Análisis de los métodos propuestos

Los resultados obtenidos mediante los tres métodos propuestos mejoran la clasificación de los píxeles mezclados debido a los siguientes aspectos:

Las imágenes satelitales sintéticas permiten mantener las relaciones espaciales entre la vecindad de los píxeles de la imagen satelital real. Esta propiedad hace posible que se extraigan características de textura similares a las que presenta una imagen satelital real. La capacidad del método para construir las imágenes sintéticas radica principalmente en la construcción del Patrón de Píxeles Mezclados que permite ubicar un píxel mezclado dentro de la imagen real. El inconveniente que se tiene es la disponibilidad de imágenes satelitales en la red de la internet con buena resolución espacial para observar a simple vista las regiones de transición. Esto conlleva a que se seleccionen aquellas coberturas que representan una gran extensión espacial en la imagen satelital, excluyendo aquellas coberturas que a simple vista no contienen o contienen una región de transición muy estrecha. Una limitante es que las coberturas homogéneas de la imagen satelital deben mostrar una alta homogeneidad (que no contengan algún otro objeto) debido a que el método está basado en el procesamiento de las coberturas homogéneas. Debido a esto, se utilizaron principalmente coberturas de suelo de vegetación como: bosque, selva, matorrales, pastizales y suelo descubierto como: zona de playa y zona agrícola.

La segmentación basada en el crecimiento de regiones obtiene buenos resultados comparados con métodos implementados en software comerciales. Mejora la localización de las regiones de transición mediante la obtención de las coberturas homogéneas. El rendimiento de este método propuesto se ve disminuido cuando en la imagen satelital aparece una cobertura homogénea que presenta errores originados por la captura de la imagen, tales como: nubes o sombras en la imagen. Este problema se tuvo debido a que no se realiza una corrección radiométrica y/o espectral de la imagen satelital original.

Una limitante para el método es la aparición de pequeños objetos dentro de las coberturas homogéneas que modifican la varianza de dicha cobertura. Esta alteración de la varianza afecta al método propuesto debido a que es un parámetro estadístico usado para determinar las regiones que son las coberturas homogéneas. Otra limitante es que las coberturas de suelo presenten respuesta espectral muy similares, lo que se traduce en una diferencia de varianzas mínimas entre estas coberturas de suelo.

Finalmente, el clasificador FCM-Modificado contiene las ventajas obtenidas por el segmentador basado en el crecimiento de regiones tales como: (1) cálculo de las regiones de transición formado por los píxeles mezclados que permiten la construcción de las curvas de ajuste. Estas curvas de ajuste refuerzan la decisión final del clasificador para determinar las proporciones de las coberturas presentes en un píxel mezclado; (2) cálculo de los semillas para cada cobertura homogénea las cuales son tomadas como centroides fijos para el clasificador FCM-Modificado. De esta manera ya no se calcula iterativamente los centroides de cada clúster (cobertura homogénea) reduciendo en gran medida el tiempo de ejecución en el método propuesto. (3) Clasificar únicamente a los píxeles mezclados contenidos en la región de transición. Esto reduce el tiempo de ejecución del método propuesto frente a las herramientas comerciales.

Como se mencionó anteriormente el inconveniente de tener varianzas similares, también reduce el rendimiento de todo método de clasificación suave debido la presencia de clases espectralmente muy similares. Esto reduce la eficiencia del método propuesto. Un punto importante para el funcionamiento del método FCM-Modificado es la obtención de las semillas que realmente describan a las coberturas homogéneas (clusters). Finalmente, es conveniente que exista una alta homogeneidad de las coberturas homogéneas utilizadas para obtener mejores resultados en la clasificación suave.

## Resumen

En este capítulo se presentaron los experimentos implementados para sustentar los tres métodos propuestos en esta investigación. Primeramente se describió la metodología donde se

muestra la serie de pasos que deben tomarse en cuenta en construcción de todos los experimentos. Los experimentos han sido divididos en dos secciones: utilizando imágenes satelitales reales (ISR) y utilizando imágenes satelitales sintéticas (ISS). Los resultados de cada experimento usando ISS fueron validado cuantitativamente utilizando métricas adecuadas al experimento. En la evaluación de la clasificación suave, se utilizó la métrica de certeza difusa (CFCM) donde nuestro método propuesto FCM-Modificado mejoró el rendimiento del clasificador FCM tradicional en un 17 % de exactitud.

## VI. Conclusiones, Aportaciones y Trabajo futuro

La presencia de píxeles mezclados en imágenes sensadas remotamente resulta de gran relevancia en el proceso de clasificación suave debido a que influyen en el resultado de la clasificación de la imagen satelital. De esta manera, es indispensable conocer distintos aspectos de los píxeles mezclados tales como: fuentes que lo generan, proporción que guardan dentro de la imagen bajo análisis y la ubicación de cada uno de ellos para ser analizados de acuerdo a sus características.

El presente trabajo de investigación se basó en dos etapas fundamentales: 1) Localización de los píxeles mezclados generados por las regiones de transición entre dos o más coberturas de suelo y 2) Clasificación suave de estos píxeles mezclados. Para desarrollar estas dos etapas, se utilizaron métodos ya propuestos y en ambos casos, se propusieron dos nuevos métodos para el análisis de los píxeles mezclados.

A continuación se describen las conclusiones, aportaciones y trabajo futuro relacionados con el trabajo de investigación doctoral.

### 6.1 Conclusiones

Durante el desarrollo del presente trabajo se obtuvieron distintos resultados que nos ayudan a hacer las siguientes conclusiones:

- Resulta de gran ayuda para la clasificación suave la localización espacial de los píxeles mezclados para que sean clasificados tomando en cuenta su incertidumbre asociada y con esto evitar el problema de clasificar de forma dura a un píxel suave.
- El método propuesto 2, para la localización espacial de las regiones de transición, mejora los resultados de otros métodos comerciales, además que lo encuentra de manera

automática, sin la dependencia del experto en el dominio para determinar las semillas y umbrales para la segmentación por crecimiento de regiones.

- El método propuesto 3, el clasificador FCM-Modificado, mejora el rendimiento del clasificador FCM tradicional al agregar información de imágenes satelitales reales. Aumenta la convergencia del algoritmo FCM tradicional en la búsqueda de una mejor clasificación, disminuyendo el número de iteraciones necesarias para la convergencia del resultado. Esto se comprobó usando la medida de certeza difusa CFCM. La exactitud es mejorada hasta en un 18 % entre un FCM tradicional y el FCM-Modificado.
- Se desarrolló un método para construir imágenes satelitales sintéticas que mantienen las propiedades originales de una imagen satelital real. Esto permite extraer características de textura para aplicar los métodos propuestos tanto a imágenes reales como sintéticas. También permite evitar la ayuda del experto en el dominio para la validación de los resultados de la clasificación.

## 6.2 Aportaciones

Las principales aportaciones de este trabajo de tesis son las siguientes:

- Un método para la localización de píxeles mezclados generados por las regiones de transición. La ubicación espacial de los píxeles mezclados es muy importante porque determina las fronteras que delimitan a las regiones de transición influye positivamente en la clasificación de los píxeles mezclados.
- Un método para la clasificación de los píxeles mezclados usando FCM-Modificado. El método propuesto agrega información real de las coberturas de suelo asociadas a la región de transición.

- Construcción de Imágenes Satelitales Sintéticas para validar los dos métodos propuestos mencionados anteriormente. Se construyeron las imágenes sintéticas suave debido a que no se cuenta con un banco de imágenes satelitales estandarizadas que ya hayan sido clasificadas en forma suave.

### 6.3 Trabajo futuro

A partir del trabajo desarrollado es posible describir los siguientes trabajos futuros:

- Construir un banco de imágenes satelitales sintéticas que pueda ser consultado por otras instituciones de investigación para realizar la validación de sus clasificadores propuestos.
- Realizar un análisis general del comportamiento de los píxeles mezclados generados por las cuatro fuentes de píxeles mezclados: (a) mezcla causada por la presencia de pequeños objetos (subpíxel) dentro del área del píxel, (b) mezcla como consecuencia de píxeles que contienen límites discretos de clases temáticas, (c) mezcla debido a la transición gradual observada entre las clases temáticas continuas y mezcla debido a la contribución de un objeto exterior al área representada por un píxel pero influenciado por su punto de función de dispersión
- Realizar la clasificación de píxeles mezclados por más de dos coberturas de suelo. Resulta difícil encontrar este tipo de píxeles en imágenes satelitales disponibles en la red.

## VII. Referencias

- (Altman, 1994) Altman, D. (1994). Research Article. Fuzzy set theoretic approaches for handling imprecision in spatial analysis. *International Journal of Geographical Information Systems*, 8(3), 271-289.
- (Baatz, 2001) Baatz, M., Benz, U., Dehghani, S., Heynen, M., Höltje, A., Hofmann, P., ... & Willhauck, G. (2001). eCognition user guide. *Definiens Imaging GmbH*.
- (Boateng, 2012) Boateng, I. (2012). An assessment of the physical impacts of sea-level rise and coastal adaptation: a case study of the eastern coast of Ghana. *Climatic change*, 1-21.
- (Brown, 1998) Brown, D.G. (1998). Classification and boundary vagueness in mapping presettlement forest types. *International Journal of Geographical Information Science*, 12(2), 105-129.
- (Cheng, 2002) Cheng, T. (2002). Fuzzy objects: their changes and uncertainties. *Photogrammetric engineering and remote sensing*, 68(1), 41-49.
- (Cheng, 2001) Cheng, T., Molenaar, M., & Lin, H. (2001). Formalizing fuzzy objects from uncertain classification results. *International Journal of Geographical Information Science*, 15(1), 27-42.
- (Christman, 1982) Christman, N. R., (1982). A Theory of Cartographic Error and its Measurement in Digital Databases, *Autocarto*, (5), 159-168.
- (Clarendon, 1993) *Oxford English Dictionary*. Clarendon, 1993.
- (Clausi, 2002) Clausi, D. A. (2002). An analysis of co-occurrence texture statistics as a function of grey level quantization. *Canadian Journal of remote sensing*, 28(1), 45-62.
- (Congalton, 2008) Congalton, R. G., & Green, K. (2008). *Assessing the accuracy of remotely sensed data: principles and practices*. CRC.
- (Cornelius, 1991) Cornelius, J. M., & Reynolds, J. F. (1991). On determining the statistical significance of discontinuous within ordered ecological data. *Ecology* 72,

- 2057–2070.
- (DeFries, 1995) DeFries, R., Hansen, M., & Townshend, J. (1995). Global discrimination of land cover types from metrics derived from AVHRR Pathfinder data. *Remote Sensing of Environment*, 54(3), 209-222.
- (De Jong, 2005) De Jong, S. M., & Van Der Meer, F. D. (2005). *Remote Sensing Image Analysis: Including the Spatial Domain*. Springer Science + Business Media, Inc.
- (Demsar, 2006) DEMSAR, J., 2006, Statistical Comparisons of Classifiers over Multiple Data Sets. *The Journal of Machine Learning Research*, 7, 1-30.
- (Dey, 2009) Dey, Ch., Jia, X., & Fraser, D. (2009). Mixed Pixel Analysis for Flood Mapping Using Extended Support Vector Machine, *Digital Image Computing: Techniques and Applications*.
- (Dijkmeijer, 1996) Dijkmeijer, J., & De Hoop, S. (1996). Topologic relationships between fuzzy area objects. *Advances in GIS Researches II, Proceedings of 7th Spatial Data Handling, London: Taylor & Francis*, 377-394.
- (Edwards, 1996) Edwards, G., & Lowell, K. E. (1996). Modeling uncertainty in photointerpreted boundaries. *Photogrammetric Engineering and Remote Sensing*, 62(4), 377-390.
- (Eastman, 2012) Eastman, J. R. (2012). *Idrisi Selva: Guía para SIG y procesamiento de imágenes*, Manual Versión 17, IDRISI Production, Clark University.
- (Foody, 2000) Foody, G. M. (2000). Mapping land cover from remotely sensed data with a softened feedforward neural network classification. *Journal of Intelligent & Robotic Systems*, 29(4), 433-449.
- (Foody, 2002) Foody, G. M., & Atkinson, P. M. (Eds.). (2002). *Uncertainty in remote sensing and GIS*. J. Wiley.
- (Fortin, 2000) Fortin, M. J., Olson, R. J., Ferson, S., Iverson, L., Hunsaker, C., Edwards, G., ... & Klemas, V. (2000). Issues related to the detection of boundaries. *Landscape Ecology*, 15(5), 453-466.
- (Gahegan, 2000) Gahegan, M., & Ehlers, M. (2000). A framework for the modelling of

- uncertainty between remote sensing and geographic information systems. *ISPRS Journal of Photogrammetry and Remote Sensing*, 55(3), 176-188.
- (Galton, 2005) Galton, A., & Hood, J. (2005). Anchoring: A new approach to handling indeterminate location in GIS. *Spatial Information Theory*, 1-13.
- (Ghosh, 2009) Ghosh, A., Uma Shankar, B., & Meher, S. K. (2009). A novel approach to neuro-fuzzy classification. *Neural Networks*, 22(1), 100-109.
- (Guesgen, 2005) Guesgen, H. W. (2005). Fuzzy reasoning about geographic regions. *Fuzzy Modeling with Spatial Information for Geographic Problems*, Petry FE, Robinson VB, and Cobb MA (Eds.), Springer, Berlin, Germany, 1-14.
- (Guide, 1998) Guide, M. U. S. (1998). The mathworks. *Inc., Natick, MA*, 5.
- (Gutierrez, 2005) Gutiérrez, J., & Jegat, H. (2005). Uso de la teoría de lógica difusa en la clasificación de imágenes satelitales con coberturas mixtas: El caso urbano e Mérida, Venezuela. *Interciencia*, 30(5), 261-266.
- (Haris, 1998) Haris, K., Efstratiadis, S. N., Maglaveras, N., & Katsaggelos, A. K. (1998). Hybrid image segmentation using watersheds and fast region merging. *Image Processing, IEEE Transactions on*, 7(12), 1684-1699.
- (He, 2008) He, M., & Mei, S. (2008). Fully constrained oblique projection approach to mixed pixel linear unmixing. In *Proc. ISPRS*, (pp. 661-666).
- (Huguenin, 1997) Huguenin, R. L., Karaska, M. A., Van Blaricom, D., & Jensen, J. R. (1997). Subpixel classification of bald cypress and tupelo gum trees in Thematic Mapper imagery. *Photogrammetric Engineering and Remote Sensing*, 63(6), 717-724.
- (Jalas, 1955) Jalas, J. (1955). Hemerobe und hemerochore Pflanzenarten. *Ein terminologischer Reformversuch. Acta Soc. Flora Fauna Fennica*, 72, 1-15.
- (Jiao, 2010) Jiao, L., Gong, M., Wang, S., Hou, B., Zheng, Z., & Wu, Q. (2010). Natural and remote sensing image segmentation using memetic computing. *Computational Intelligence Magazine, IEEE*, 5(2), 78-91.
- (Johnston, 1992) Johnston, C. A., Pastor, J., & Pinay, G. (1992). Quantitative methods for studying landscape boundaries. *Ecological studies: analysis and synthesis*,

92.

- (Kaftandjian , 2002) Kaftandjian, V., Dupuis, O., Babot, D., & Min Zhu, Y. (2003). Uncertainty modelling using Dempster–Shafer theory for improving detection of weld defects. *Pattern recognition letters*, 24(1), 547-564.
- (Koppen, 2006) Koppen, M., Franke, K., & Vicente-Garcia, R. (2006). Tiny GAs for image processing applications. *Computational Intelligence Magazine, IEEE*, 1(2), 17-26.
- (Lesparre, 2003) Lesparre, J., & Gorte, B. G. H. (2003). Using mixed pixels for the training of a maximum likelihood classification, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, (34).
- (Liaoying, 2009) Liaoying, Z., Yali, L., Kai, Z., & Xiaorun, L. (2009, November). A New Scheme for Decomposition of Mixed Pixels Based on Modified Nonnegative Matrix Factorization and Genetic-Algorithm. In *Artificial Intelligence and Computational Intelligence, 2009. AICI'09. International Conference on* (Vol. 3, pp. 457-461). IEEE.
- (Lillesand, 2008) Lillesand, T. M. (2008), *Remote sensing and image interpretation*, Jhon Wiley & Sons Inc., 6<sup>th</sup> Edition.
- (Liu, 2009) Liu, L., Wang, B., & Zhang, L. (2009). Decomposition of mixed pixels based on bayesian self-organizing map and Gaussian mixture model. *Pattern Recognition Letters*, 30(9), 820-826.
- (Liu, 2010a) Liu, X., Li, X., & Zhang, X. (2010). Determining class proportions within a pixel using a new mixed-label analysis method. *Geoscience and Remote Sensing, IEEE Transactions on*, 48(4), 1882-1891.
- (Liu, 2010b) Liu, L., Wang, B., & Zhang, L. (2010). An approach based on self-organizing map and fuzzy membership for decomposition of mixed pixels in hyperspectral imagery. *Pattern Recognition Letters*, 31(11), 1388-1395.
- (Lowell, 1994) Lowell, K. E. (1994). Probabilistic temporal GIS modelling involving more than two map classes. *International Journal of Geographical Information Systems*, 8(1), 73-93.

- (Lu, 2003) Lu, D., Moran, E., & Batistella, M. (2003). Linear mixture model applied to Amazonian vegetation classification. *Remote Sensing of Environment*, 87(4), 456-469.
- (Malanson, 2006) Malanson, G. P., Zeng, Y., & Walsh, S. J. (2006). Landscape frontiers, geography frontiers: lessons to be learned. *The Professional Geographer*, 58(4), 383-396.
- (Maulik, 2009) Maulik, U., & Saha, I. (2009). Modified differential evolution based fuzzy clustering for pixel classification in remote sensing imagery. *Pattern Recognition*, 42(9), 2135-2149.
- (Meer, 2001) Meer, P., & Georgescu, B. (2001). Edge detection with embedded confidence. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 23(12), 1351-1365.
- (Meher, 2007) Meher, S., Shankar, B., & Ghosh, A. (2007). Multispectral remote sensing image classification using wavelet based features. *Soft Computing in Image Processing*, 3-34.
- (Morales, 2014) Morales, J., Gonzalez, J. A., Reyes-Garcia, C. A., and Altamirano, L., (2014). Transition regions detection from satellite images based on evolutionary region growing segmentation. *Intelligent Data Analysis – An International Journal*, 18(2).
- (Nascimento, 2009) Nascimento, J. M., & Dias, J. B. (2005). Vertex component analysis: A fast algorithm to unmix hyperspectral data. *Geoscience and Remote Sensing, IEEE Transactions on*, 43(4), 898-910.
- (Navulur, 2006) Navulur, K. (2006). *Multispectral image analysis using the object-oriented paradigm*. CRC.
- (Neubert, 2008) Neubert, M., Herold, H., & Meinel, G. (2008). Assessing image segmentation quality—concepts, methods and application. *Object-based image analysis*, 769-784.
- (Pawley, 2006) Pawley, J. B. (2006). Points, pixels, and gray levels: digitizing image data. In *Handbook of biological confocal microscopy* (pp. 59-79). Springer US.

- (Penaloza , 1996) Penaloza, M. A., & Welch, R. M. (1996). Feature selection for classification of polar regions using a fuzzy expert system. *Remote sensing of environment*, 58(1), 81-100.
- (Pitas, 2000) Pitas, I. (2000). *Digital image processing algorithms and applications*. Wiley-interscience.
- (Plaza , 2009) Plaza, J., Plaza, A., Perez, R., & Martinez, P. (2009). On the use of small training sets for neural network-based characterization of mixed pixels in remotely sensed hyperspectral images. *Pattern Recognition*, 42(11), 3032-3045.
- (Pu, 2008) Pu, R., Gong, P., Michishita, R., & Sasagawa, T. (2008). Spectral mixture analysis for mapping abundance of urban surface components from the Terra/ASTER data. *Remote Sensing of Environment*, 112(3), 939-954.
- (Qazi, 2011) Qazi, I. U. H., Alata, O., Burie, J. C., Moussa, A., & Fernandez-Maloigne, C. (2011). Choice of a pertinent color space for color texture characterization using parametric spectral analysis. *Pattern Recognition*, 44(1), 16-31.
- (Ramirez-Ortegón, 2010) Ramírez-Ortegón, M. A., Tapiá, E., Ramírez-Ramírez, L. L., Rojas, R., & Cuevas, E. (2010). Transition pixel: A concept for binarization based on edge detection and gray-intensity histograms. *Pattern Recognition*, 43(4), 1233-1243.
- (Reddy, 2008) Reddy, M. A. (2008). *Textbook of Remote Sensing and Geographical Information Systems*. BS publications.
- (Robles, 2007) Robles, J. F. (2007). *Extracción de Mapas Temáticos a partir de la Clasificación en Imágenes Satelitales*, Instituto Nacional de Astrofísica, Óptica y Electrónica.
- (Schiewe , 2008) Schiewe, J., & Gähler, M. (2008). Modelling uncertainty in high resolution remotely sensed scenes using a fuzzy logic approach. *Object-Based Image Analysis*, 755-768.
- (Schiewe , 2009a) Schiewe, J., Ehlers, M., Kinkeldey, C., & Tomowski, D. (2009). Implementation of Indeterminate Transition Zones for Uncertainty

- Modeling in Classified Remotely Sensed Scenes. In *International Conference on Geographic Information Science*.
- (Schiewe, 2009b) Schiewe, J., & Kinkeldey, C. Development of an Advanced Uncertainty Measure for Classified Remotely Sensed Scenes. *Proceedings for ISPRS WG II/2, 3(4)*.
- (Seo, 2007) Seo, K. K. (2007). A GA-Based Feature Subset Selection and Parameter Optimization of Support Vector Machine for Content-Based Image Retrieval. In *Advanced Data Mining and Applications* (pp. 594-604). Springer Berlin Heidelberg.
- (Shalan, 2003) Shalan, M. A., Arora, M. K., & Ghosh, S. K. (2003). An evaluation of fuzzy classifications from IRS 1C LISS III imagery: a case study. *International Journal of Remote Sensing, 24(15)*, 3179-3186.
- (Shi, 2010) Shi, W. (2009). *Principles of modeling uncertainties in spatial data and spatial analyses*. CRC.
- (Siang, 2012) Siang Tan, K., & Mat Isa, N. A. (2011). Color image segmentation using histogram thresholding-Fuzzy C-means hybrid approach. *Pattern Recognition, 44(1)*, 1-15.
- (Singh, 2008) Singh, A., Jaikumar, P., & Mitra, S. K. (2008, December). A Bayesian Learning Based Approach for Clustering of Satellite Images. In *Computer Vision, Graphics & Image Processing, 2008. ICVGIP'08. Sixth Indian Conference on* (pp. 187-192). IEEE.
- (Sukopp, 1972) Sukopp, H. (1972). Wandel von Flora und Vegetation in Mitteleuropa unter dem Einfluß des Menschen. *Ber. Landwirt, 50(1)*, 112-139.
- (Thomas, 1996) Thomas, G., Hobbs, S. E., & Dufour, M. (1996). Woodland area estimation by spectral mixing: applying a goodness-of-fit solution method. *International Journal of Remote Sensing, 17(2)*, 291-301.
- (Tiwari, 1999) Tiwari, R. S., Arora, M. K., & Kailash, T. (1999). Soft classification for sub-pixel land cover extraction. *Journal of the Indian Society of Remote Sensing, 27(4)*, 225-234.

- (Trabucchi, 2012) Trabucchi, M., Puente, C., Comin, F. A., Olague, G., & Smith, S. V. (2012). Mapping erosion risk at the basin scale in a Mediterranean environment with opencast coal mines to target restoration actions. *Regional Environmental Change*, 1-13.
- (Unser, 1995) Unser, M. (1995). Texture classification and segmentation using wavelet frames. *Image Processing, IEEE Transactions on*, 4(11), 1549-1560.
- (Users, 1996) Users, E.L. (1996). A conceptual framework and fuzzy set implementation for geographic feature, *Geographic Objects with Indeterminate Boundaries*, Taylor & Francis, pp. 71-85.
- (Wang, 1996) Wang, F., & Hall, G. B. (1996). Fuzzy representation of geographical boundaries in GIS. *International Journal of Geographical Information Systems*, 10(5), 573-590.
- (Wang, 2007) Wang, Z., Hu, G., & Yao, S. (2007). Decomposition mixed pixel of remote sensing image based on tray neural network model. *Advances in Computation and Intelligence*, 305-309.
- (Weng, 2009) Weng, Q. (2009). *Remote sensing and GIS integration: Theories, methods, and applications*. McGraw-Hill Professional.
- (Wiens, 1985) Wiens, J. A., Crawford, C. S., & Gosz, J. R. (1985). Boundary dynamics: a conceptual framework for studying landscape ecosystems. *Oikos*, 421-427.
- (Zadeh, 1966) Zadeh, L. A. (1966). Shadows of fuzzy sets. *Problemy Peredachi Informatsii*, 2(1), 37-44.
- (Zhang, 2001) Zhang, J., & Foody, G. M. (2001). Fully-fuzzy supervised classification of sub-urban land cover from remotely sensed imagery: statistical and artificial neural network approaches. *International journal of remote sensing*, 22(4), 615-628.
- (Zhou, 2005) Zhou, H., Wang, B., & Zhang, L. (2005). A new scheme for blind decomposition of mixed pixels based on non-negative matrix factorization. *Advances in Neural Networks–ISNN 2005*, 814-814.



## Apéndice

### A.1 Clasificación usando clasificadores de IDRISI TAIGA

IDRISI TAIGA es un software comercial destinado a la construcción de mapas temáticos y Sistemas de Información Geográfica. Dentro de sus potencialidades se encuentran implementados diversos clasificadores suaves (Eastman, 2012). Estos clasificadores suaves fueron utilizados para realizar la comparación cuantitativa con los resultados obtenidos por el método FCM-Modificado.

A continuación se muestra la serie de pasos necesarios para realizar una clasificación supervisada usando los clasificadores suaves de IDRISI TAIGA:

1. Seleccionar manualmente las regiones de entrenamiento para cada una de las clases (coberturas de suelo) de la imagen satelital, figura A.1.1. Cada región debe contener tanto píxeles puros como mezclados para indicarle a cada clasificador el conjunto de píxeles que le ayudará a realizar la clasificación. Para realizar la digitalización de las regiones de entrenamiento se utiliza el módulo “Digitize” asignando los valores indicados en la figura A.1.2.

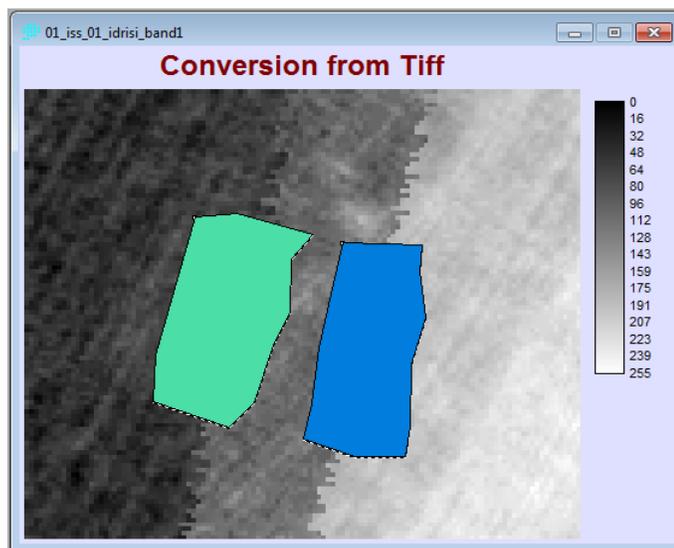
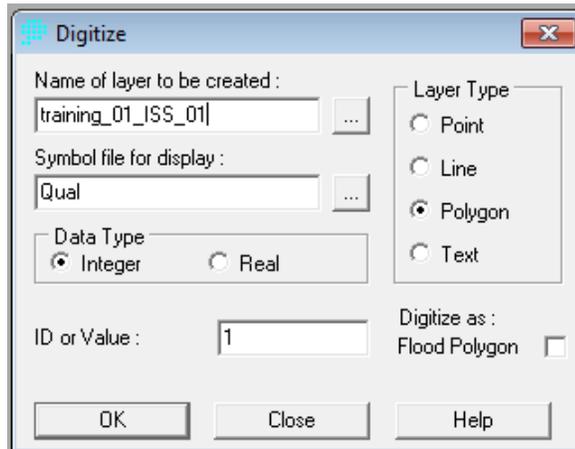


Figura A.1.1. Selección de las regiones de entrenamiento.



**Figura A.1.2. Digitalización de las regiones de entrenamiento.**

2. Construir la firma espectral de cada una de las clases usando el módulo MAKESIG. La firma espectral representa la respuesta espectral de cada clase para cada una de las bandas disponibles (en este caso, composición RGB en verdadero color). La figura A.1.3 muestra la asignación de los parámetros que necesita dicho módulo. Se debe especificar el archivo que contiene los sitios de entrenamiento para cada una de las clases utilizadas. Se asigna el número de bandas espectrales disponibles para la imagen satelital. Es posible seleccionar el número de píxeles que se desea tomar como entrenamiento para cada clase. Por último, se realiza la asignación de los nombres usados para cada cobertura mostrada en la figura A.1.4.

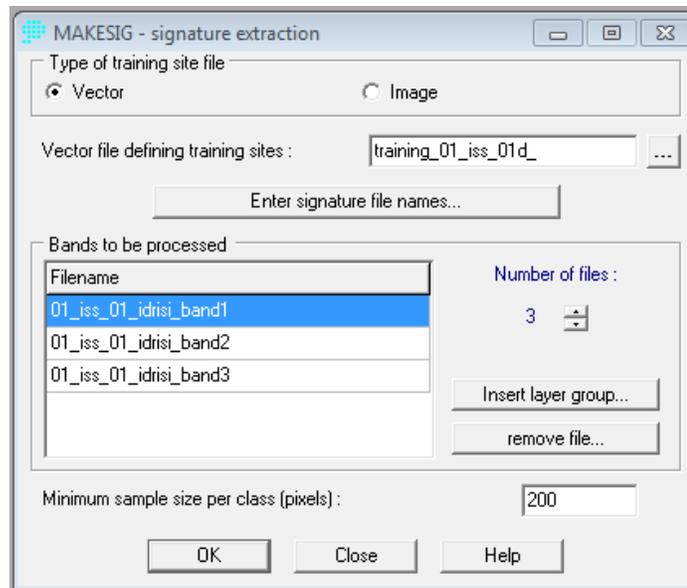


Figura A.1.3. Módulo para construcción de las firmas espectrales de cada clase.

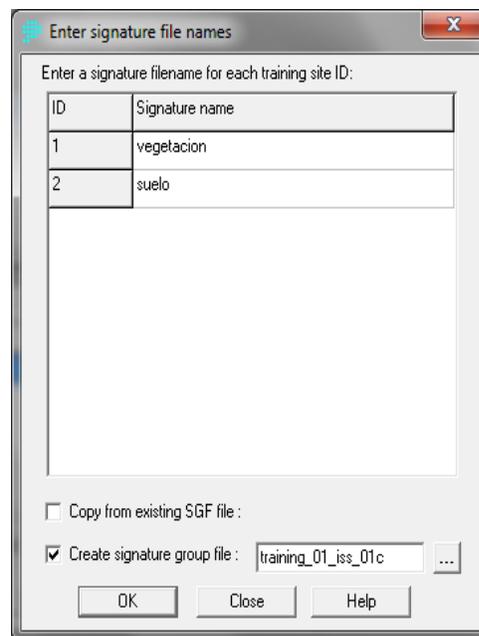


Figura A.1.4. Asignación de los nombres para cada clase de la firma espectral.

3. Finalmente, se aplica el módulo del clasificador suave que se desea utilizar. Se asignan los parámetros necesarios y se escribe el prefijo que se desea para los nombres de las imágenes resultantes. Las figuras A.1.5-A.1.7 muestran los módulos de IDRISI TAIGA.

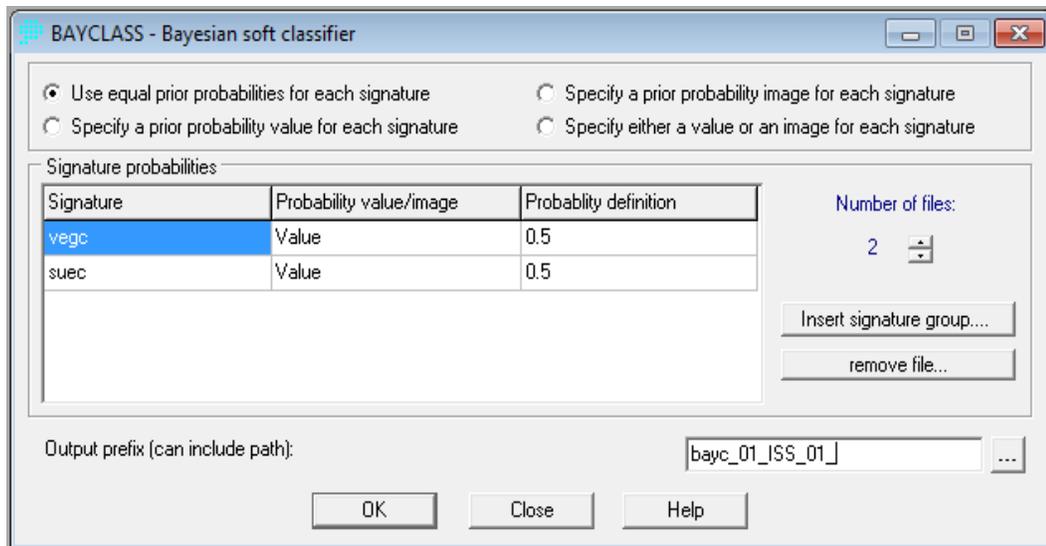


Figura A.1.5. Módulo para la realizar la clasificación Bayesiana.

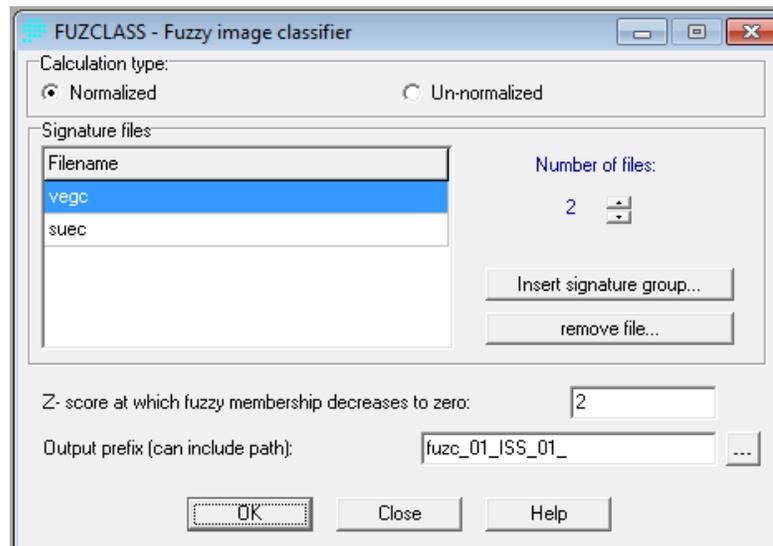


Figura A.1.6. Módulo para la realizar la clasificación Fuzzy.

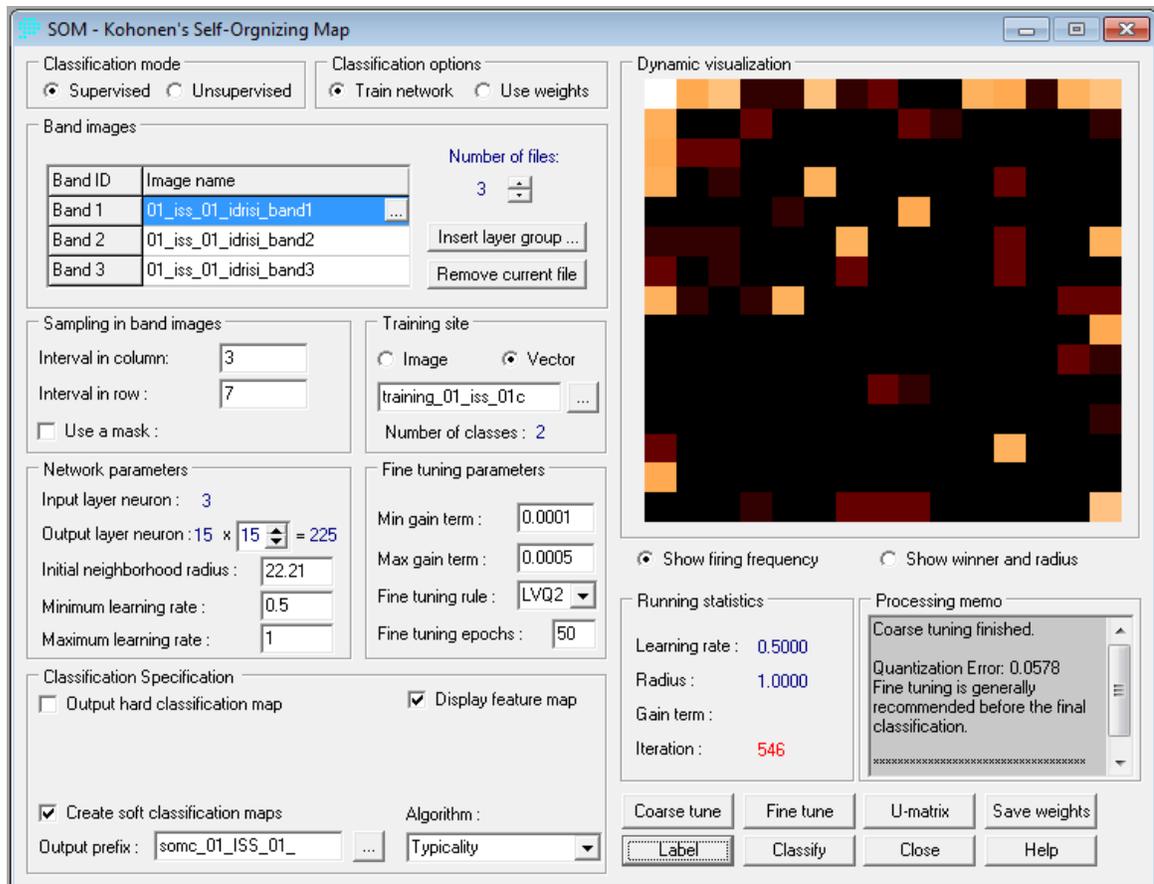


Figura A.1.7. Módulo para realizar la clasificación SOM.

## A.2 Experimentos usando imágenes sintéticas

### A.2.1 Descripción del experimento

**Área de estudio.** La imagen satelital sintética está compuesta por las tres bandas que forma el RGB verdadero color. Su tamaño es de 100 x 150 píxeles. Las imágenes satelitales base fueron adquiridas desde la plataforma de Google earth.

**Tipos de coberturas.** Las coberturas analizadas son: bosque, selva, playa, suelo descubierto y matorrales. Además de una región de transición formada por cada par de estas coberturas.

**Métodos usados.** Los métodos usados son: obtención de las regiones de transición (descrito en la sección 4.2) y clasificación suave de píxeles mezclados (descrito en la sección 4.3). Además, programas comerciales para su comparación.

### A.2.2 Construcción de las imágenes sintéticas

Para construir las imágenes sintéticas se utilizó el método propuesto en la sección 4.1.2. En las figuras A.2.1a – A.2.5a se muestran las sub-imágenes reales tomadas como base para la construcción de las ventanas sintéticas suave (figuras A.2.1b – A.2.5b). Estas ventanas sintéticas contienen los píxeles mezclados de dos tipos de coberturas de suelo.

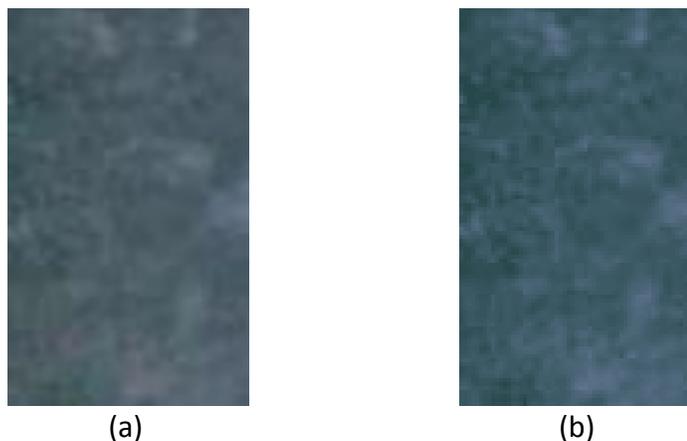


Figura A.2.1. (a) Ventana satelital real formada por las coberturas selva y playa, (b) Ventana sintética suave construida a partir de la imagen satelital real.



(a)



(b)

**Figura A.2.2. (a) Ventana satelital real formada por las coberturas bosque y matorrales, (b) Ventana sintética suave construida a partir de la imagen satelital real.**

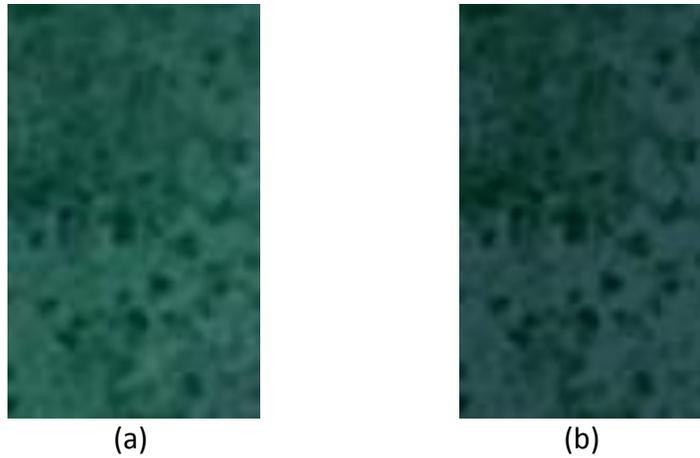


(a)

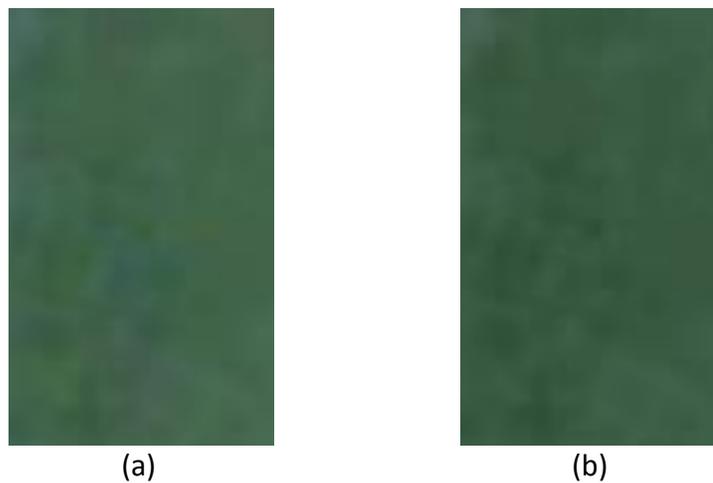


(b)

**Figura A.2. 3. (a) Ventana satelital real formada por las coberturas bosque y suelo descubierto, (b) Ventana sintética suave construida a partir de la imagen satelital real.**



**Figura A.2.4. (a) Ventana satelital real formada por las coberturas bosque y matorrales, (b) Ventana sintética suave construida a partir de la imagen satelital real.**



**Figura A.2.5. (a) Ventana satelital real formada por las coberturas bosque y matorrales, (b) Ventana sintética suave construida a partir de la imagen satelital real.**

Para realizar la validación de la similitud entre las imágenes reales y sintéticas de las figuras A.2.1 – A.2.5, se calcularon los índices de similitud de la calidad propuesto por Zhang y sus colegas en (Zhang, 2011). El primer índice corresponde al índice de similitud característico (*FSIM*), mientras que el segundo índice corresponde al índice de similitud característico con congruencia de fase. La figura A.2.6 muestra las imágenes sintéticas construidas usando las

imágenes de la figura A.2.1 – A.2.5, además de las coberturas homogéneas que generan a estas regiones de transición.



(a)



(b)



(c)



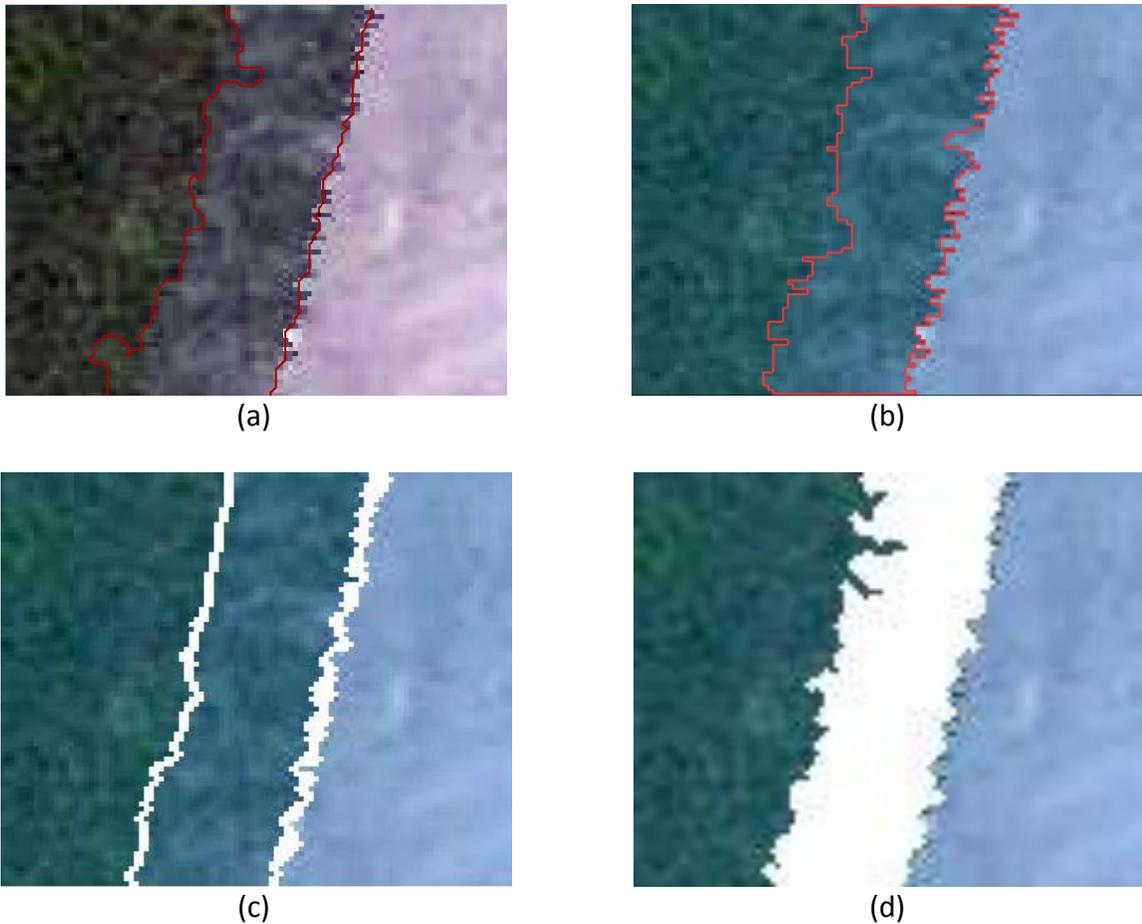
(d)



(e)

Figura A.2.6. Imágenes sintéticas construidas.

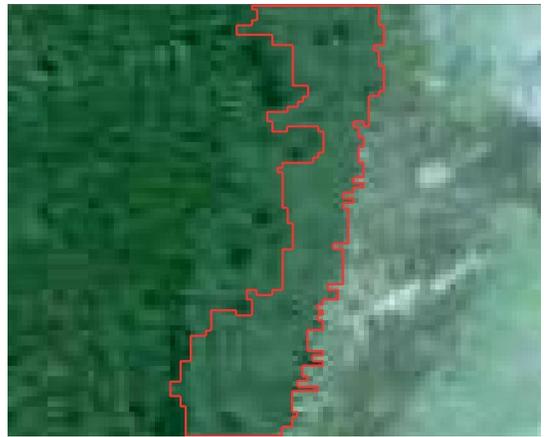
Las figuras A.2.7 – A.2.11 muestran los resultados de la localización de las regiones de transición de las imágenes de la figura A.2.6 usando el método propuesto en la sección 4.2, además de los programas comerciales mencionados en la sección 5.2.1.2. Los resultados usando el filtrado *canny* de matlab no localizaron correctamente las regiones de transición por tal motivo no se muestra en estas figuras.



**Figura A.2.7. Localización de las regiones de transición de la imagen A.2.6(a) usando: (a) Idrisi Taiga, (b) eCognition, (c) EDISON y (d) TreDet.**



(a)



(b)

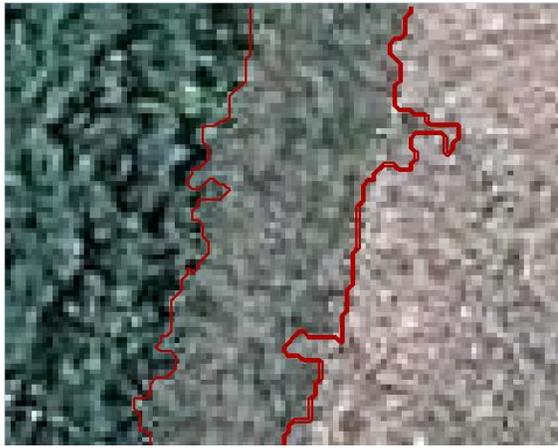


(c)

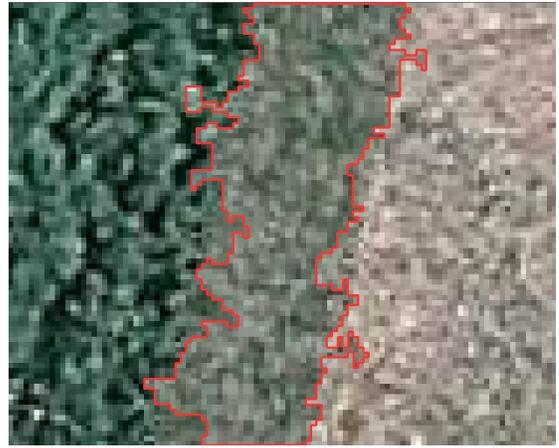


(d)

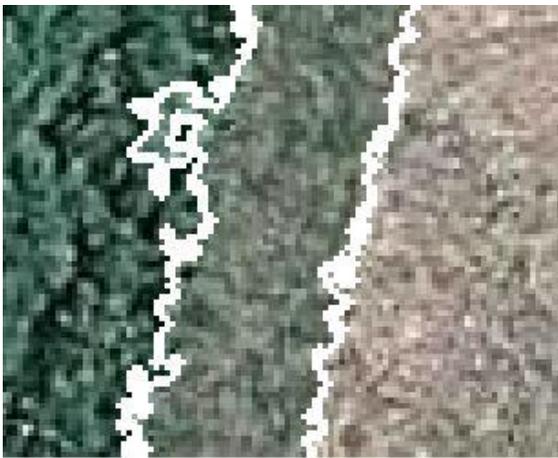
Figura A.2.8. Localización de las regiones de transición de la imagen A.2.6(b) usando: (a) Idrisi Taiga, (b) eCognition, (c) EDISON y (d) TreDet.



(a)



(b)

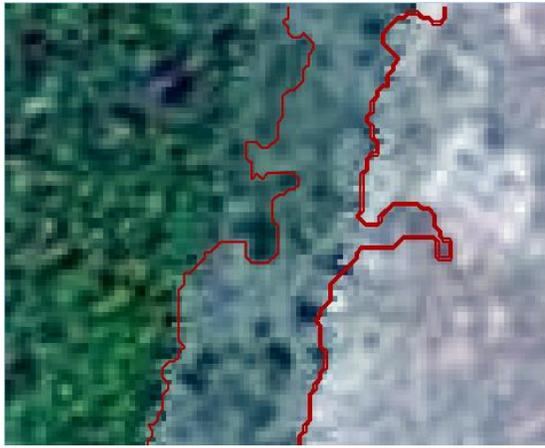


(c)

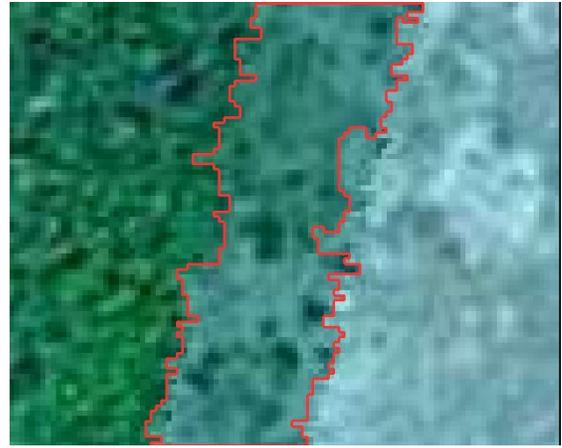


(d)

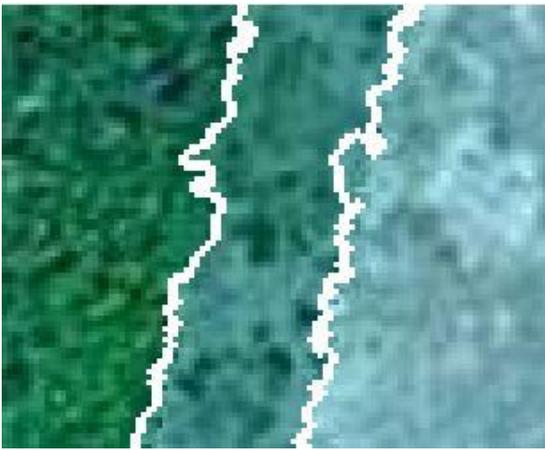
Figura A.2.9. Localización de las regiones de transición de la imagen A.2.6(c) usando: (a) Idrisi Taiga, (b) eCognition, (c) EDISON y (d) TreDet.



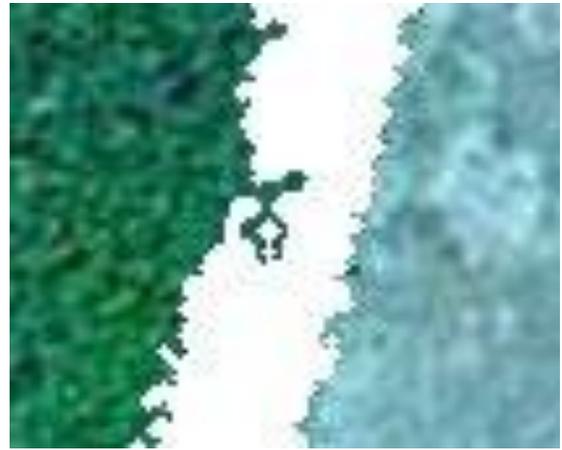
(a)



(b)

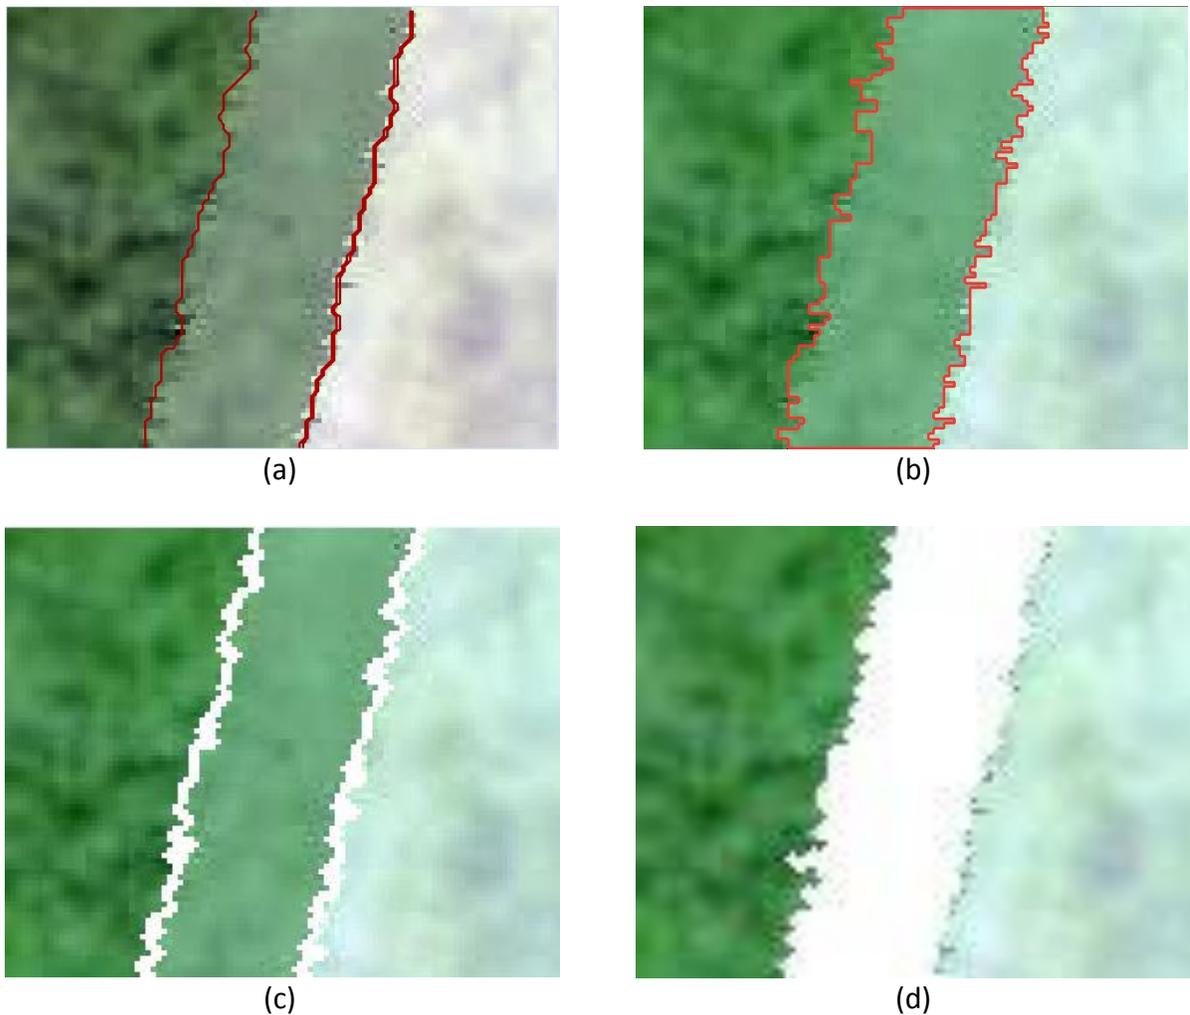


(c)



(d)

Figura A.2.10. Localización de las regiones de transición de la imagen A.2.6(d) usando: (a) Idrisi Taiga, (b) eCognition, (c) EDISON y (d) TreDet.



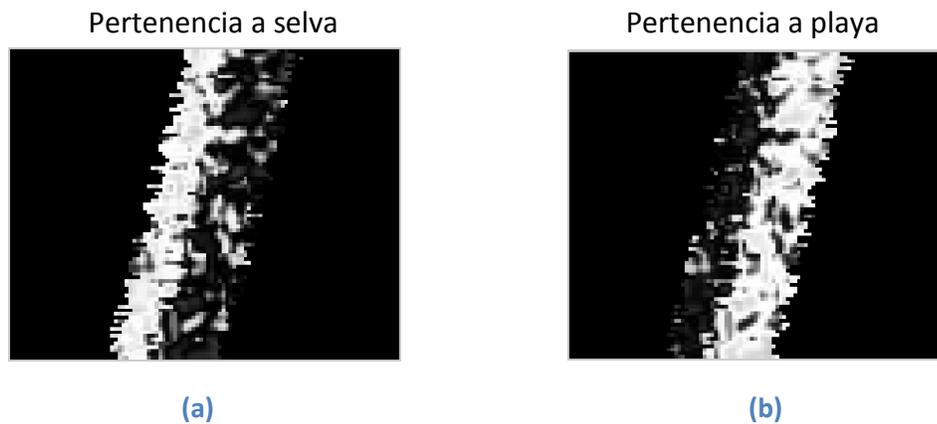
**Figura A.2.11. Localización de las regiones de transición de la imagen A.2.6(e) usando: (a) Idrisi Taiga, (b) eCognition, (c) EDISON y (d) TreDet.**

### **A.2.3 Clasificación de los píxeles mezclados usando FCM-Modificado y otros métodos**

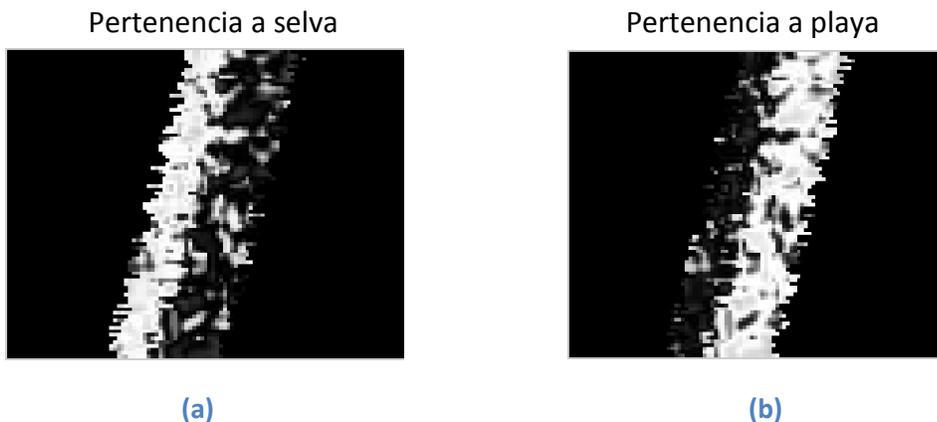
En este experimento, se realizó la clasificación de píxeles mezclados usando el método propuesto FCM modificado, además se realizaron otras clasificaciones para comparar de forma cuantitativa los resultados de los distintos clasificadores. Los clasificadores usados son de: a) usando Matlab (FCM) y b) IDRISI TAIGA (Difuso, Bayesiano, k-nn-suave y red neuronal SOM).

Las figuras A.2.12 – A.2.17 muestran los resultados de la clasificación suave únicamente de la imagen A.2.6a usando distintos clasificadores en el siguiente orden: FCM, FCM-Modificado,

Difuso, Bayesiano, k-nn-suave y red neuronal SOM. Los resultados de la clasificación suave se presentan en imágenes separadas: la columna de la izquierda muestra el porcentaje de pertenencia de los píxeles mezclados con respecto a la cobertura selva y la columna de la derecha el porcentaje de pertenencia de los píxeles mezclados con respecto a la cobertura playa. La pertenencia de cada píxel se muestra de acuerdo al tono de gris que va desde el color blanco (pertenencia del 100 %) al color negro (pertenencia del 0 %).



**Figura A.2.12. Clasificación de píxeles mezclados usando el clasificador FCM, (a) Pertenencia a la clase selva, (b) Pertenencia a la clase playa. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %).**



**Figura A.2.13. Clasificación de píxeles mezclados usando el clasificador FCM-Modificado, (a) Pertenencia a la clase selva, (b) Pertenencia a la clase playa. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %).**

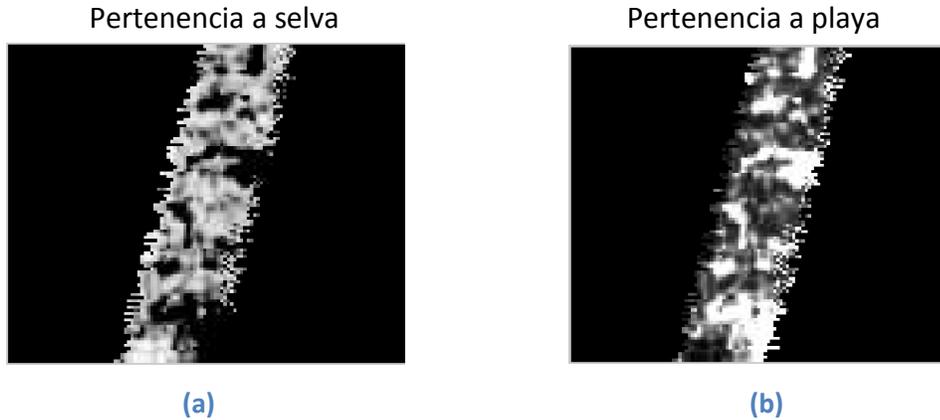


Figura A.2.14. Clasificación de píxeles mezclados usando el clasificador difuso, (a) Pertenenencia a la clase selva, (b) Pertenenencia a la clase playa. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %).

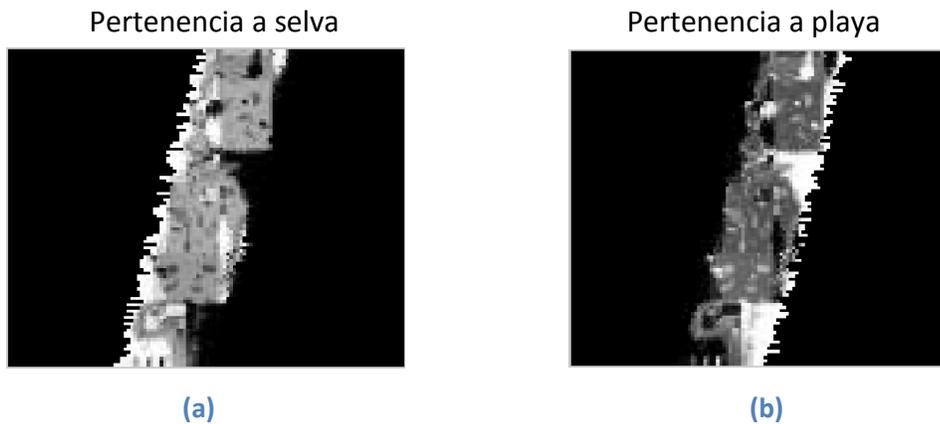


Figura A.2.15. Clasificación de píxeles mezclados usando el clasificador bayesiano, (a) Pertenenencia a la clase selva, (b) Pertenenencia a la clase playa. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %).

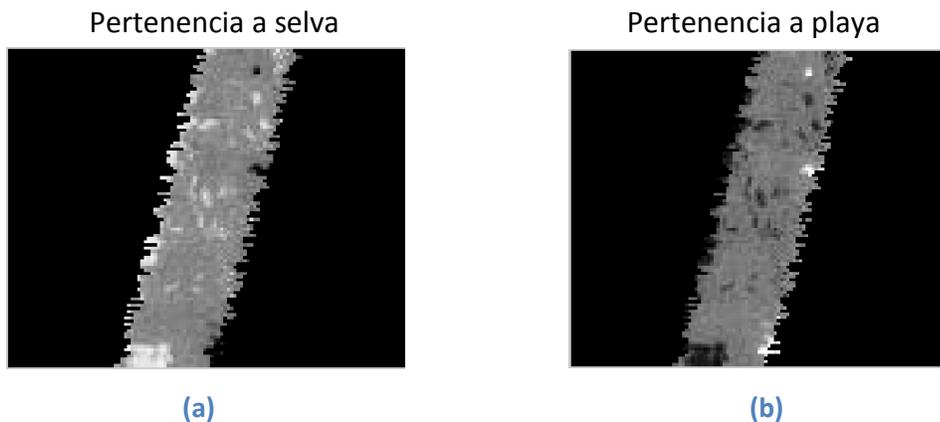
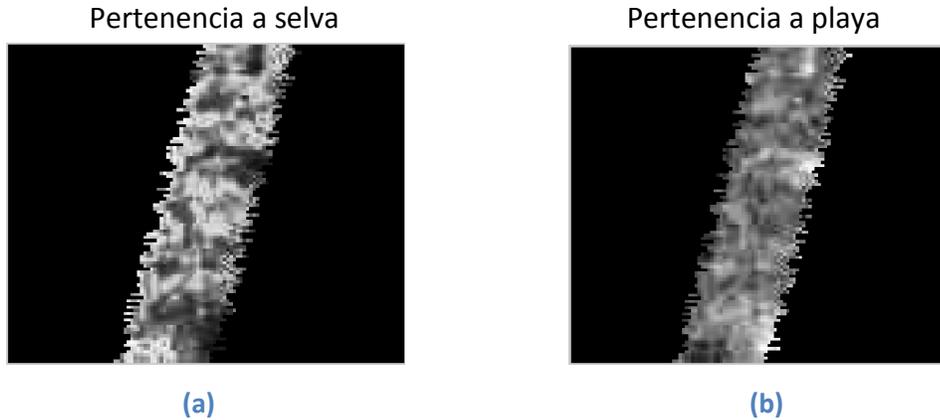


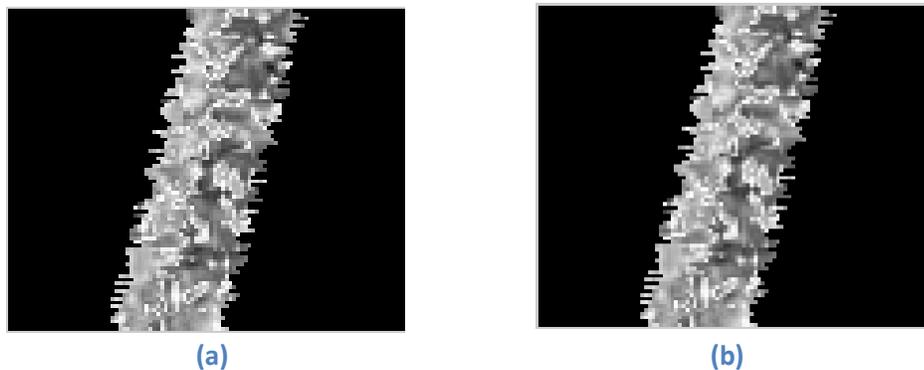
Figura A.2.16. Clasificación de píxeles mezclados usando el clasificador k-nn-suave, (a) Pertenenencia a la clase selva, (b) Pertenenencia a la clase playa. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %).



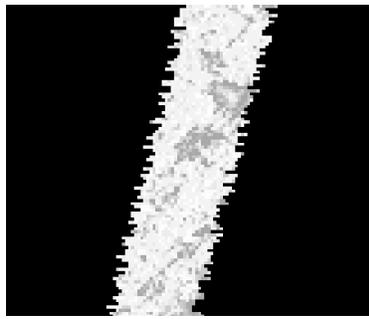
**Figura A.2.17. Clasificación de píxeles mezclados usando el clasificador red neuronal SOM, (a) Pertenenencia a la clase selva, (b) Pertenenencia a la clase playa. El intervalo de valores comprende desde un píxel en color blanco (pertenencia del 100 %) hasta píxel en color negro (pertenencia del 0 %).**

#### A.2.4 Mapas de incertidumbres

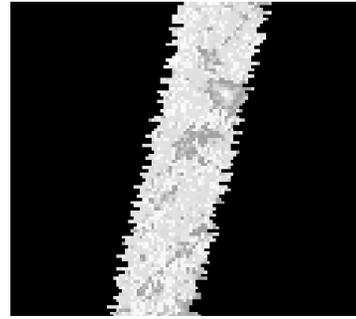
Las figuras A.2.18 – A.2.23 muestran los mapas de incertidumbre de la región de transición únicamente para la imagen A.2.6a en el siguiente orden: clasificador FCM, clasificador FCM-Modificado, clasificador Difuso, clasificador Bayesiano, clasificador k-nn-suave y clasificador red neuronal SOM. Los resultados de los mapas de incertidumbre se presentan en imágenes separadas: La columna de la izquierda muestra los mapas de incertidumbre de los píxeles mezclados con respecto a la cobertura selva y la columna de la derecha muestra los mapas de incertidumbre de los píxeles mezclados con respecto a la cobertura playa. Cada mapa de incertidumbre se lee de la siguiente manera: La certeza de cada píxel se muestra de acuerdo al tono de gris que va desde el color blanco (certeza del 100 %) al color negro (certeza del 0 %).



**Figura A.2.18. Construcción de mapas de incertidumbre usando el clasificador FCM: (a) para selva, (b) para playa.**

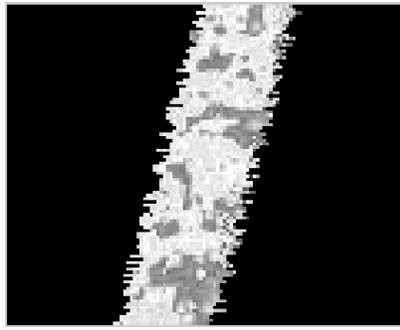


(a)

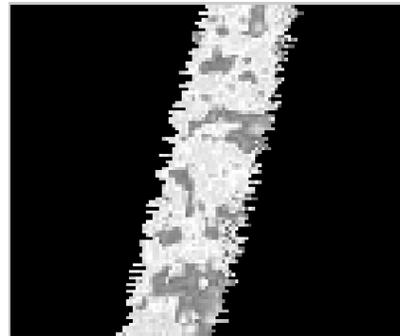


(b)

Figura A.2.19. Construcción de mapas de incertidumbre usando el clasificador FCM-Modificado: (a) para vegetación, (b) para suelo descubierto.

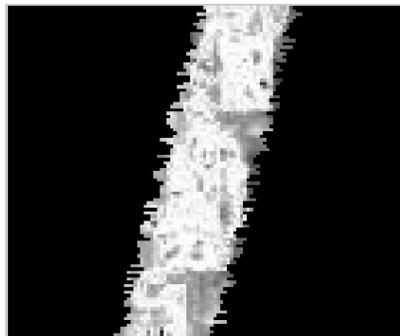


(a)

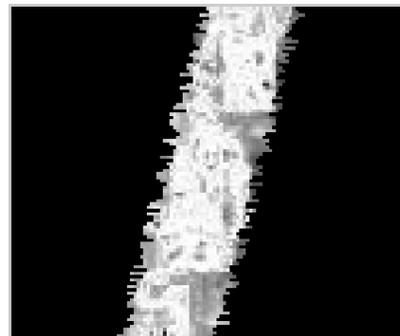


(b)

Figura A.2.20. Construcción de mapas de incertidumbre usando el clasificador difuso: (a) para selva, (b) para playa.

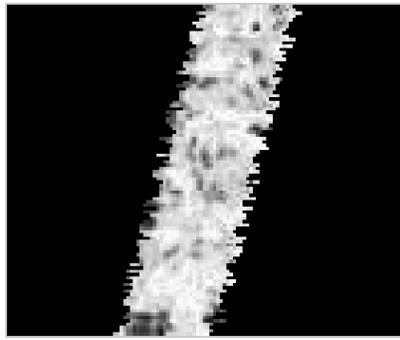


(a)

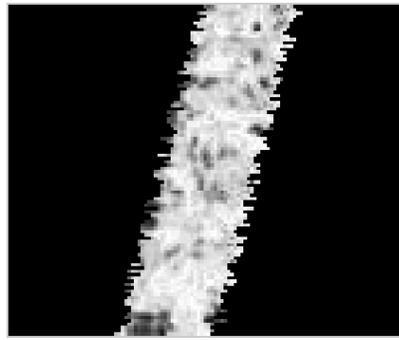


(b)

Figura A.2.21. Construcción de mapas de incertidumbre usando el clasificador bayesiano: (a) para selva, (b) para playa.

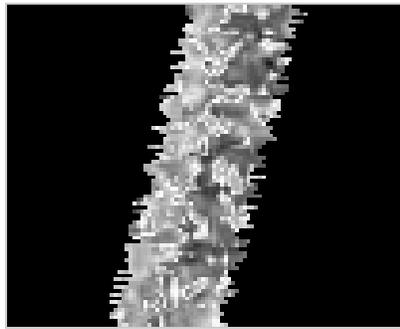


(a)

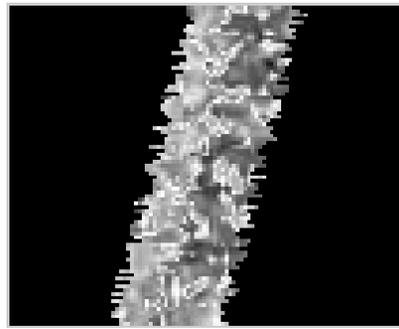


(b)

Figura A.2.22. Construcción de mapas de incertidumbre usando el clasificador k-nn-suave: (a) para selva, (b) para playa.



(a)



(b)

Figura A.2.23. Construcción de mapas de incertidumbre usando el clasificador red neuronal SOM: (a) para selva, (b) para playa.

## A.3 Publicaciones

### A.3.1 Artículos publicados

Morales, J., Gonzalez, J. A., Reyes-Garcia, C. A., & Altamirano, L. (2010). A soft computing approach for obtaining transition regions in satellite images. In *Advanced Intelligent Computing Theories and Applications* (pp. 150-157). Springer Berlin Heidelberg.

Morales, J., Gonzalez, J. A., Reyes-Garcia, C. A., and Altamirano, L., (2014). "Transition regions detection from satellite images based on evolutionary region growing segmentation", *Intelligent Data Analysis – An International Journal*, Volume 18(2).

### A.3.2 Artículos sometidos

Morales, J., Gonzalez, J. A., Reyes-Garcia, C. A., and Altamirano, L., "Linear Mixture Modeling to Generate Synthetic Satellite Images". En desarrollo por los comentarios dados en *IEEE Geoscience and Remote Sensing Letters (GRSL)*.