



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

POSGRADO EN CIENCIAS DE LA TIERRA

INSTITUTO DE GEOFÍSICA

**“CLASIFICACIÓN MULTIVARIADA DE MÉTRICAS DEL PAISAJE EN
IMÁGENES MULTIESPECTRALES Y DE RADAR”**

T E S I S

QUE PARA OPTAR POR EL GRADO DE:

MAESTRA EN CIENCIAS DE LA TIERRA

P R E S E N T A:

SARA NOHEMÍ MORALES CARRERA

TUTOR:

DR. JORGE ARTURO LIRA CHÁVEZ (Instituto de Geofísica, UNAM)

MIEMBROS DEL COMITÉ TUTOR

DR. ISMAEL HERRERA REVILLA (Instituto de Geofísica, UNAM)

DR. RAMIRO RODRÍGUEZ CASTILLO (Instituto de Geofísica, UNAM)

DR. MIGUEL MOCTEZUMA FLORES (Instituto de Ingeniería, UNAM)

DR. JOSÉ LUIS BRAVO CABRERA (Centro de Ciencias de la Atmósfera, UNAM)

MÉXICO, D.F. DICIEMBRE 2015



Universidad Nacional
Autónoma de México



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

Agradecimientos

En primer lugar agradezco a quien me ha permitido estar en este mundo tan maravilloso y llegar a este punto, al Creador de todo, ¡Gracias!.

A la Universidad Nacional Autónoma de México, al Instituto de Geofísica y al CONACYT por darme la oportunidad de estudiar una maestría apoyándome en lo intelectual como en lo económico.

A mi director de tesis el Dr. Jorge Lira Chávez por su amistad, apoyo, y conocimientos compartidos en este tiempo de trabajo; a mis sinodales el Dr. José Luis Bravo, Dr. Miguel Moctezuma, Dr. Ismael Herrera y Dr. Ramiro Ramírez[†] por sus aportaciones y correcciones a mi tesis. A mi compañero y amigo el M.I. Erick Marín por su paciencia y ayuda durante la realización de esta tesis.

A mi hermosa madre por haberme apoyado en todo momento, por sus consejos, valores y motivación constante que me ha permitido salir a delante, y sobre todo por su amor incondicional.

A mi padre por sus ejemplos de perseverancia y constancia, por su valor que me ha mostrado al nunca rendirse, por sus consejos y valores que me ha infundado siempre, y por su amor total.

A mi hermana Karina por ser un ejemplo de lucha y esfuerzo, y por todas las sonrisas y locuras que vivo con ella; a ti Rafael gracias por tomar siempre tu papel de hermano mayor cuidándonos y apoyándonos en todo momento; a mi tío Fray Isaías por su ejemplo de amor y por sus oraciones; a toda mi familia a quienes no acabaría de nombrar y agradecerles su apoyo.

A todos mis amigos y amigas fuera y dentro del Instituto de Geofísica quienes han hecho más liviano este camino. Finalmente agradezco a Ángel Ventura quien ha sido mi soporte y motivación en este trayecto, a ti adeudo la ternura, las palabras de aliento y el abrazo que me hace continuar.

ÍNDICE GENERAL

RESUMEN	i
1. INTRODUCCIÓN	1
1.1 Objetivos	3
1.1.1 Objetivo General	3
1.1.2 Objetivos Específicos.....	3
1.2 Estado del Arte	3
1.3 Resumen por capítulos	8
2. MARCO TEÓRICO	9
2.1 Percepción Remota	10
2.1.1 Definición y Aspectos generales	10
2.1.2 Elementos de la Percepción Remota.....	12
2.2 Imagen Multiespectral y de Radar.....	19
2.2.1 Conceptos y aspectos generales	19
2.2.2 Espectro Electromagnético	21
2.2.3 Generación de una imagen multiespectral	23
2.2.4 Generalidades del sistema Radar	25
2.3 Reconocimiento de patrones	28
2.3.1 Técnicas de segmentación.....	29
2.3.2 Descriptores morfológicos	33
2.3.2.1 Conceptos	35
2.3.2.2 Área	36
2.3.2.3 Perímetro	37
2.3.2.4 Razón Perímetro/Área.....	38
2.3.2.5 Índice de Forma.....	38
2.3.2.6 Índice de Dimensión Fractal.....	39
2.3.2.7 Relación de Círculo Circunscrito	40
2.3.2.8 Índice de Contigüidad	41
2.3.3 Clasificación.....	43
2.3.3.1 Clasificación espectral	43

2.3.3.2 Clasificación basada en objetos	47
3. MÉTODOS Y MATERIALES	49
3.1 Descripción de los casos de estudio	50
3.1.1 Caso 1: Ciudad de México	51
3.1.2 Caso 2: Campos de Cultivo Irapuato	54
3.1.3 Caso 3: Cuerpos de agua de Tabasco	57
3.1.4 Caso 4: Inundación de Tabasco	59
3.2 Proceso de segmentación	62
3.2.1 Imágenes Landsat TM y SPOT 5 - Ciudad de México	62
3.2.2 Imagen Terra/Aster - Campos de Cultivo Irapuato	64
3.2.3 Imagen Terra/Aster - Cuerpos de agua de Tabasco	65
3.2.4 Imagen de Radar TerraSar X - Inundación de Tabasco	67
3.3 Normalización de variables	69
3.4 Correlación de las métricas del paisaje.	72
3.4 Clasificación Multivariada	75
4. RESULTADOS Y DISCUSIÓN	79
4.1 Calidad de resultados	80
4.2 Resultados de la Ciudad de México.....	82
4.2.1 Imagen Landsat TM – Ciudad de México 1989	83
4.2.2 Imagen Landsat TM – Ciudad de México 2001	85
4.2.3 Imagen SPOT 5 – Ciudad de México	88
4.3 Resultados Imagen Terra/Aster - Campos Cultivo	90
4.4 Resultados Imagen Terra/Aster - Cuerpos de agua de Tabasco	95
4.5 Resultado Imagen Radar - Inundación de Tabasco	99
4.6 Resultados de la imagen sintética	106
4.7 Discusión y limitaciones	109
5. CONCLUSIONES	112
5.1 Conclusiones generales	112
5.2 Trabajo futuro	114
REFERENCIAS BIBLIOGRÁFICAS	115

ÍNDICE DE FIGURAS

2.1. Elementos de la Percepción Remota.....	12
2.2. Espectro Electromagnético	21
2.3. Generación de una imagen digital multiespectral	24
2.4. Parámetros correspondientes a la formación de un imagen Radar	26
2.5. Principio del Radar de Apertura Sintética	28
2.6. Procedimiento para el reconocimiento de patrones espaciales o espectrales	29
2.7. a) Código de Freeman. b) Representación de coordenadas de pixels en una imagen. .	36
2.8. Imagen que muestra en grises los pixels de un objeto segmentado	37
2.9. Ventana que convoluciona a la imagen digital, para medir el valor de Contigüidad	42
2.10 Agrupación de datos (<i>clustering</i>).....	44
3.1. Zona Metropolitana del Valle de México y Distrito Federal	52
3.2. Composición de falso color de la imagen Landsat, Ciudad de México.....	54
3.3. Localización del cuarto caso de estudio: Campos de Cultivo, Irapuato	55
3.4. Composición de falso color de la imagen Aster/Terra, Campos Cultivo	56
3.5. Subregiones de Tabasco	58
3.6. Localización del segundo caso de estudio: Cuerpos de agua de Tabasco	59
3.7. Localización del tercer caso de estudio: Inundación de Tabasco 2007	61
3.8. Segmentación de la ciudad de México, imagen Landsat TM 1989	63
3.9. Segmentación de la ciudad de México, imagen Landsat TM 2001	63
3.10. Segmentación de la ciudad de México, imagen SPOT 5 2003	64
3.11. Imagen segmentada de los campos de cultivo del municipio de Irapuato	65
3.12. Segmentación de la imagen Cuerpos de agua de Tabasco.....	66
3.13. Segmentación de la imagen Inundación de Tabasco	68
3.14. Distribución de las métricas AREA y RCC sin transformación	70
3.15. Distribución de las métricas AREA y RCC con transformación logarítmica.....	70
3.16. Histograma del índice de Contigüidad, sin aplicar transformación	71
3.17. Histograma del índice de Contigüidad, después de aplicar una transformación	71
3.18. Baja correlación entre las métricas de FRAC y CONTIG	74

3.19. Alta correlación entre las métricas de AREA y PERIM	74
3.20. Nube de datos de las métricas: PERIM-RCC-CONTIG	77
3.21. Dendograma generado por la función de agrupación	77
3.22. Formación de <i>clusters</i> para el conjunto de métricas: PERIM-RCC-CONTIG	78
4.1. Dendograma de la imagen Ciudad de México 1989	84
4.2. Resultado de la clasificación para la imagen Ciudad de México 1989	85
4.3. Dendograma de la imagen Ciudad de México 2001	86
4.4. Resultado de la clasificación para la imagen Ciudad de México 2001	87
4.5. Resultado de la clasificación para la Imagen Ciudad de México SPOT 5	89
4.6. Dendograma de la imagen Campos Cultivos con el uso de las métricas PERIM-PARA-FRAC-RCC	91
4.7. Resultado de la clasificación con las métricas PERIM – PARA – FRAC - RCC en la imagen Campos Cultivos	92
4.8. Dendograma de la imagen Campos Cultivos con el uso de las métricas FRAC-RCC	93
4.9. Resultado de la clasificación con las métricas FRAC - RCC en la imagen Campos Cultivos.....	94
4.10. Dendograma de la imagen Cuerpos de agua de Tabasco con el uso de las métricas FORMA - RCC	96
4.11. Resultado de la clasificación con las métricas FORMA - RCC en la imagen Cuerpos de agua de Tabasco	97
4.12. Dendograma de la imagen Cuerpos de agua de Tabasco con el uso de las métricas PERIM - RCC - CONTIG	98
4.13. Resultado de la clasificación con las métricas PERIM – RCC – CONITG en la imagen Cuerpos de agua de Tabasco.....	99
4.14. Dendograma de la imagen Inundación de Tabasco con el uso de las métrica FRAC - RCC	101
4.15. Resultado de la clasificación con las métricas FRAC – RCC en la imagen Inundación de Tabasco	102
4.16. Dendograma de la imagen Inundación de Tabasco con el uso de las métricas RCC - CONTIG	103

4.17. Resultado de la clasificación con las métricas RCC – CONTIG en la imagen Inundación de Tabasco	104
4.18. Dendograma de la imagen Inundación de Tabasco con el uso de las métricas PERIM - RCC - CONTIG	105
4.19. Resultado de la clasificación con las métricas PERIM – RCC – CONTIG en la imagen Inundación de Tabasco.....	106
4.20. Dendogramas para diferentes combinaciones de métricas en la imagen sintética	107
4.21. Resultados para diferentes combinaciones de métricas en la imagen sintética	109

ÍNDICE DE TABLAS

2.1. Principales plataformas satelitales en percepción remota.....	15
2.2. Rangos del espectro electromagnético	22
2.3. Nomenclatura de bandas para la región espectral de microondas	25
2.4. Aplicaciones de descriptores morfológicos en diferentes disciplinas	34
3.1 Información Técnica de las imágenes empleadas en el proyecto de investigación	50
3.2. Correlación de las métricas de la imagen Ciudad de México 1989.....	72
3.3. Correlación de las métricas de la imagen Ciudad de México 2001	72
3.4. Correlación de las métricas de la imagen Cuerpos de agua de Tabasco.....	73
3.5. Correlación de las métricas de la imagen Inundación de Tabasco	73
3.6. Correlación de las métricas de la imagen Campos de Cultivo	73
4.1. Análisis de la separabilidad entre las clases formadas por la combinación de las métricas: RCC – CONTIG, en la imagen Ciudad de México 1989.....	84
4.2. Análisis de la separabilidad entre las clases formadas por la combinación de las métricas: RCC – CONTIG, en la imagen Ciudad de México 2001.	87
4.3. Análisis de la separabilidad entre las clases formadas por la combinación de las métricas: RCC – CONTIG, en la imagen Ciudad de México SPOT-5.....	89
4.4. Análisis de la separabilidad entre las clases formadas por la combinación de las métricas PERIM-PARA-FRAC-RCC, en la imagen Campos Cultivo	92
4.5. Análisis de la separabilidad entre las clases formadas por la combinación de las métricas FRAC-RCC, en la imagen Campos Cultivo.....	93
4.6. Análisis de la separabilidad entre las clases formadas por la combinación de las métricas FORMA – RCC, imagen Cuerpos de agua de Tabasco	96
4.7. Análisis de la separabilidad entre las clases formadas por la combinación de las métricas PERIM - RCC - CONTIG, imagen Cuerpos de agua de Tabasco	98
4.8. Análisis de la separabilidad entre las clases formadas por la combinación de las métricas FRAC – RCC, imagen Inundación de Tabasco.....	101
4.9. Análisis de la separabilidad entre las clases formadas por la combinación de las métricas RCC - CONTIG., imagen Inundación de Tabasco	103
4.10. Análisis de la separabilidad entre las clases formadas por la combinación de las métricas PERIM - RCC - CONTIG, imagen Inundación de Tabasco	105
4.11. Análisis de la separabilidad entre las clases formadas por distintas combinaciones de métricas, imágenes sintéticas	108

RESUMEN

En el trabajo de tesis se propone implementar una clasificación multivariada de descriptores morfológicos para cuantificar y describir la estructura de las clases que forman parte de una escena. El análisis y clasificación de patrones espaciales es un elemento importante para entender el comportamiento de una escena por medio de sus imágenes. Para el comportamiento morfológico parche-clase, los descriptores morfológicos son llamados “métricas del paisaje”. Las métricas del paisaje son modelos matemáticos que describen la estructura que compone a una escena. Empleamos métricas tales como: área, perímetro, compacidad, forma, dimensión fractal, y contigüidad, para la descripción de los patrones o parches. Los parches se encuentran definidos como áreas espacialmente constantes con característica temáticas similares, son la entidad básica homogénea que describen y/o representan una escena

En esta investigación obtuvimos el valor de una serie de métricas morfológicas de patrones en imágenes de los sensores Landsat TM, SPOT 5, Terra/Aster y TerraSar X, correspondientes a la Ciudad de México, Cuerpos de agua de Tabasco, Campos de cultivo en Irapuato e Inundación de Tabasco del 2007. La gama de métricas fue normalizada y se aplicó una clasificación multivariada utilizando un algoritmo de *clustering* jerárquico, teniendo como ejes vectoriales a las métricas menos correlacionadas.

La clasificación multivariada se evaluó para cada grupo de métricas del paisaje en los casos de estudio. Se produjeron una serie de clasificaciones utilizando diferentes grupos de descriptores y el uso de tres a cinco clases. La clasificación multivariada de las métricas originó un elemento de cuantificación de la morfología y estructura de los parches de en cada caso de estudio. Algunos de los parches presentaron una estructura morfológica muy compleja con un perímetro áspero, agujeros internos y una forma irregular. Otros parches mostraron una morfología simple. Esta técnica puede ser empleada para cuantifica la morfología de un objetivo en particular, dentro de una imagen, así como, modelar los cambios temporales y espaciales de los patrones que forman la cobertura terrestre.

Capítulo 1

Introducción



Vista nocturna del planeta Tierra desde la Estación Espacial Internacional (ISS).

La evolución del entorno de nuestro planeta, debido a la dinámica de los ecosistemas, a los fenómenos naturales y las actividades antropogénicas; ha sido objeto de enorme interés, debido a ello se ha incrementado la demanda por la información de la cobertura terrestre. La percepción remota y el tratamiento digital de imágenes, en conjunto con el avance computacional hacen posible proporcionar información oportuna y precisa sobre los cambios de la superficie del planeta. Esta información tienen una aplicación práctica e inmediata para monitorear las tendencias en el cambio climático, la agricultura, los

movimientos de agua, hielo y vegetación, la actividad geológica e incluso la actividad humana (Clark y Rilee, 2010).

Los cambios de cobertura debido a los fenómenos naturales o crecimientos urbanos no regulados, poseen una estructura, en su mayoría, compleja, difícil de cuantificar y describir. Para el estudio de los cambios en la superficie (por ejemplo: cuerpos de agua, campos de cultivo, área urbana) es indispensable la evaluación de los patrones que los conforman. En esta tesis se presenta una nueva metodología para extraer información de carácter morfológico de los patrones que forman parte de una escena a partir de imágenes multiespectrales (Landsat TM 4, Terra/Aster) y de radar (TerraSar X), empleando métricas del paisaje.

Las denominadas métricas son una herramienta de popularidad e interés desarrolladas en el ámbito de la Ecología del Paisaje (McGarigal *et al.*, 2002). Esta disciplina aporta un marco contextual adecuado para el estudio de las alteraciones en las estructuras espaciales de los paisajes consecuencia de los procesos territoriales (Forman, 1995; Turner, 2005).

La cantidad disponible de métricas resulta ingente (Uuemaa *et al.*, 2009), lo que dificulta la selección de aquellas más adecuados para la identificación de ciertos procesos espaciales (Cushman *et al.*, 2008). Más aún si se considera que, en ocasiones, estas métricas se encuentran altamente correlacionadas entre sí (Tischendorf, 2001; Botequilha-Leitão, 2001). Por ello no existe aún un grupo completamente establecido de métricas adecuadas para el estudio de las características espaciales del paisaje.

El método propuesto tiene como propósito implementar una clasificación multivariada de las métricas del paisaje con una baja y media correlación entre ellas. Con el fin de describir y cuantificar la complejidad morfológica de los patrones o parches. Los parches se definen como entidades espacialmente constantes con atributos similares y representan rasgos característicos de la escena, permitiendo de esta manera un análisis y descripción del comportamiento de la escena o clase en cuestión.

La clasificación morfológica puede tener aplicaciones en urbanismo, inundaciones u otros fenómenos naturales. Éste método puede ser empleado en cualquier imagen digital

donde exista el interés de información morfológica de los patrones que componen a una imagen como por ejemplo, en imágenes médicas (para describir tumores) o en imágenes microscópicas (para conocer el comportamiento de sus partículas).

Con éstas técnicas, no sólo se clasifica y cuantifica una estructura, sino también se modelan los cambios temporales y espaciales de los patrones que forman la cobertura terrestre, por lo que es factible cuantificar la evolución de los patrones en una imagen.

1.1 Objetivos

1.1.1 Objetivo general

Realizar una clasificación no supervisada mediante métricas del paisaje, para cuantificar y describir la estructura morfológica de los parches que forman parte de una escena, a partir de imágenes de sensores remotos.

1.1.2 Objetivos específicos

- Seleccionar las técnicas más precisas para segmentar una imagen multiespectral, con el fin de tener los patrones de interés a clasificar.
- Seleccionar el método *clustering* adecuado para realizar la clasificación no supervisada.

1.2 Estado del Arte.

El análisis y la clasificación de patrones espaciales es tal vez, la tarea más importante de la percepción remota, ya que nos ayuda a entender el comportamiento de una zona en estudio. Las características principales de un patrón para ser reconocido, son su respuesta espectral y sus descriptores morfológicos. Entre los descriptores morfológicos encontramos a la textura y las métricas del paisaje. Las métricas del paisaje son medidas cuantitativas que describen a los parches que conforman las estructuras espaciales de una escena. Los parches son definidos como entidades homogéneas con atributos similares. El uso de las métricas del paisaje para caracterizar el comportamiento morfológico de un paisaje o escena se ha extendido en los últimos años.

Muchos investigadores han implementado distintos métodos para precisar la clasificación de patrones espaciales que describen la cobertura del suelo. Entre las investigaciones que emplean descriptores morfológicos encontramos a: De Cola (1989) así como Lam (1990), quienes caracterizaron zonas urbanas por su alta complejidad estructural y fragmentación en contraste con las áreas de vegetación; Mesev *et al.* (1995) por medio de imágenes satelitales obtuvieron el índice fractal de un área urbana, al utilizar un clasificador de máxima-probabilidad demostraron el incremento de la capacidad para describir la estructura y cambios en la morfología urbana.

McGarigal y Marks (1994) así como O'Neill *et al.* (1988), definen a las métricas del paisaje como índices cuantitativos que describen la estructura y los patrones de una escena. En Herold *et al.* (2002), aplican seis métricas a tres áreas de prueba, es decir, área de centros comerciales e industrias, área residencial con alta densidad de construcciones y área residencial de baja densidad de construcción. Esto con el fin de describir la estructura del de suelo y los cambios en la cobertura resultantes del crecimiento urbano. Las métricas aplicadas fueron:

Métricas	Descripción
Porcentaje de área del paisaje	Relación de áreas de vegetación y áreas construidas
Densidad de parches	Información sobre la densidad de áreas construidas
Desviación estándar del tamaño del parche	Aporta información del tamaño de las áreas construidas
Área ponderada de la media de la dimensión fractal del parche	Favorece la medición de dimensiones de las estructuras urbanas
Índice de contagio	Describe la fragmentación del paisaje
Densidad de borde	Facilita las comparaciones entre los paisajes de diferentes tamaños.

Con ese trabajo Herold *et al.* (2002), demostraron la gran utilidad de las métricas del paisaje para el análisis de ambientes urbanos. Y de acuerdo con Peng *et al.* (2007), la categorización del uso de suelos tiene un impacto sobre un entorno urbano y debería ser tomado en cuenta en estudios de análisis de patrones del paisaje.

De manera similar Greenhiil *et al.* (2003), caracterizaron zonas suburbanas en relación a los espacios de vegetación. Las imágenes de prueba que utilizaron fueron dos imágenes multiespectrales Ikonos. Los indicadores que ellos emplearon fueron: la media ponderada del tamaño del parche y la lacunaridad, los cuales dan una idea del paisaje urbano.

Malinverni, Tasseti. y Bernardini (2010) lograron describir de manera óptima el paisaje urbano, al utilizar una clasificación híbrida, aplicando métricas de los parches para el análisis de fragmentación en áreas construidas. Estos autores utilizaron las siguientes métricas:

Métricas	Descripción
Índice de forma	Mide la complejidad de la forma del parche comparado con una forma circular estándar
Razón perímetro-área	Describe la forma de un parche
Dimensión fractal	Caracteriza el grado de complejidad de un polígono
Densidad de parches	Mide la densidad de áreas construidas

Por otro lado, se han realizado trabajos enfocados en métodos que sólo aplican la métrica de dimensión fractal. Sun, Xu, Gong, y Liang, (2006) mencionaron cuatro principales aplicaciones que emplean el cálculo de la dimensión fractal (FRAC):

- a) Caracterizar la complejidad espacial de una imagen.
- b) Realizar la clasificación de una imagen mediante su información textural.
- c) Describir la complejidad geométrica de la forma de las clases de rasgos en una imagen clasificada.
- b) Examinar el comportamiento de la escala de un fenómeno ambiental.

A continuación, se detallan las investigaciones de las cuatro aplicaciones mencionadas, según el orden aludido:

a) Sin duda el mayor uso de la dimensión fractal es para caracterizar la complejidad textural de imágenes satelitales, en estas aplicaciones sólo es necesario el cálculo de un solo valor de FRAC para la imagen entera. Lam (1990) y Qiu *et al.* (1999) trabajaron en la caracterización de la complejidad textural en imágenes multiespectrales e hiperespectrales, ambos encontraron que la textura de un tipo de la cobertura de suelo puede ser mejor caracterizada por ciertas bandas que otras y que el valor más alto para FRAC corresponde a zonas urbanas. Por otro lado, Weng (2003) aplicó la dimensión fractal para analizar la variabilidad espacial de la temperatura de la superficie a lo largo de tres perfiles construidos por imágenes Landsat TM. Sus resultados mostraron que la variación de los valores de FRAC a lo largo de un perfil se pueden ligar a tipos de cobertura del suelo, además, observó que los cambios de FRAC durante cierto periodo de tiempo pueden ser utilizados para entender el incremento de la complejidad textural de las superficies térmicas.

b) Pentland (1984) así como Keller *et al.* (1987) sugirieron que la variación local en el cálculo de FRAC puede ser usada como una técnica en la medida de textura para segmentar imágenes, en razón que diferentes tipos de cobertura tienen características de textura y rugosidad propias, las cuales pueden ser descritas por los diferentes valores de FRAC (Sun, *et al.*, 2006).

c) De Cola (1989) mostró que es posible asociar tipos de cobertura de suelo con valores de FRAC. Por ejemplo, los bosques examinados en su estudio se caracterizaron por altos valores de FRAC y largas regiones, mientras que en zonas de agricultura tuvieron largas regiones con un FRAC inversamente relacionado a la intensidad del cultivo, sin embargo parte de las zonas urbanas produjeron pequeñas regiones con altos valores de FRAC.

d) Se debe tener en cuenta que las imágenes captadas por sensores remotos, bajo ciertas aplicaciones no son precisamente fractales, ya que no cumplen con la consideración de autosimilitud y autorreferencia de un modelo fractal. Estas consideraciones suponen que el cálculo de FRAC debe ser constante en todas las escalas, ubicaciones y direcciones. Sin embargo, las imágenes digitales, pueden comportarse estadísticamente autosimilares sobre un limitado intervalo de tamaños de pixels. (Lam, 1990; Emerson *et al.*, 1999; De Jong y Burrough, 1995; Sun *et al.*, 2006).

Al considerar que las imágenes satelitales no son verdaderos fractales, el comportamiento de FRAC puede ser usado para estudiar los efectos de los cambios de escala en una imagen. Emerson *et al.* (1999) al examinar los efectos de cambio del tamaño del pixel en el cálculo de los valores de FRAC en imágenes, señalaron que la información sobre el comportamiento de la escala de fenómenos ambientales puede ser valiosa para la selección de una resolución óptima en la caracterización de un fenómeno bajo investigación.

Por otro lado, la precisión semántica se ha explorado utilizando la complejidad de las métricas. La precisión semántica relaciona fragmentos sobre una imagen segmentada a objetos en una escena. De esta manera Stein y Beurs (2005) utilizaron indicadores semánticos como índice de agregación, índice de fragmentación, índice de borde, índice de contagio y el tamaño del parche para el cálculo de la precisión semántica de imágenes multiespectrales de satélite. De esta manera justificaron que la complejidad está relacionada al número, tamaño y estructura de los parches de las clases.

Autores como Borak, *et al.* (2000) y Paudel y Yuan (2012) han empleado las métricas del paisaje para predecir cambios espaciales y temporales de patrones del paisaje. En el trabajo de Paudel y Yuan (2012) agruparon las métricas dentro de dos categorías: índices no espaciales e índices espaciales. Los índices no espaciales fueron: el área, número de parches y el tamaño medio del parche. Los índices espaciales fueron: la media ponderada del área, índice de forma y la densidad de bordes. Los índices no espaciales e índices espaciales se utilizaron en el módulo GEOMOD de IDRISIS para pronosticar la pérdida forestal y agrícola.

Los cambios espaciales de hábitat de fauna pueden ser modelados también con grupos de métricas del paisaje como lo hicieron en la publicación de Oyana *et al.* (2014). Un punto de importancia mencionado en Oyana *et al.* (2014) es que una alta resolución espacial de imágenes es adecuada para el análisis del cambio de la estructura del paisaje y que se han desarrollado series (o números) de funciones de escala, como las leyes de potencias, para predecir el valor de las métricas del paisaje a diferentes escalas. Este es un tema importante, ya que los procesos naturales y antropogénicos a menudo se desarrollan en diferentes escalas.

1.4 Resumen por capítulos

El presente trabajo se encuentra dividido en 5 capítulos, los cuales se resumen a continuación:

Capítulo 1 Introducción: Este capítulo proporciona, la motivación del trabajo, la plantación de los objetivos y una breve reseña de los trabajos que han empleado a los descriptores morfológicos de manera general.

Capítulo 2 Marco Teórico: Esta sección se encarga de introducir al lector en los conceptos teóricos principales de la percepción remota y el análisis de imágenes digitales con enfoque al reconocimiento de patrones presentes en un paisaje o escena.

Capítulo 3 Métodos y Materiales: En este capítulo se describen las zonas y las imágenes de los casos de estudio y el proceso metodológico específico para lograr los objetivos planteados.

Capítulo 4 Resultados y Discusión: En este apartado se resaltan las imágenes más representativas obtenidas por la metodología planteada y se discuten los resultados alcanzados.

Capítulo 5 Conclusiones: Este capítulo presenta las conclusiones generales del presente proyecto de tesis, así como los trabajos que se pretenden seguir a futuro.

Capítulo 2

Marco Teórico



“La percepción remota nos brinda la capacidad de ver literalmente lo invisible”

(Lillesand, T. 1987)

Este capítulo proporciona los temas relacionados con el desarrollo del proyecto de tesis. Se define a la percepción remota, sus elementos y aplicaciones. Del mismo modo, se explica la generación de una imagen multispectral y de radar. Además, se hace un enfoque en los procesos de reconocimiento de patrones.

2.1 Percepción Remota

La percepción remota, también conocida como teledetección, no es una técnica nueva. Por muchas décadas el hombre se ha estado elevando por encima de la tierra con el fin de observarla desde la distancia y así aprender más acerca de su condición (Philip *et al.*, 1978). Las primeras imágenes de la Tierra a ciertas alturas se lograron debido a la invención de la cámara portátil y al advenimiento de los globos aerostáticos durante el siglo XIX, con la limitación de observación en el espectro visible. Fue hasta principios de los años 60's, que comienza a escribirse la historia de la percepción remota.

2.1.1 Definición y aspectos generales

La guerra ha estimulado las innovaciones científicas y tecnológicas. Con el desarrollo de la aviación durante la primera guerra mundial, se dieron como resultado las primeras imágenes aéreas de humanos y paisajes naturales. La década de 1930 vió el desarrollo de la fotografía a color, así como dos tipos de instrumentos capaces de detectar y determinar la distancia a objetivos remotos, el RADAR en la tierra y el sonar bajo el agua (Coe, 1978). La interpretación de las fotografías aéreas llegó a ser muy importante durante la Segunda Guerra Mundial. La era espacial se pone en marcha con el lanzamiento de los satélites *Sputnik* en 1957 (U.S.S.R.), el *Explorer 1* en 1958 (EE.UU.), y con la colección de fotografías del programa secreto de satélites espías *CORONA* iniciado en 1960 (Jensen, 2000).

En la actualidad existen distintas plataformas satelitales con sensores capaces de captar longitudes de onda del espectro electromagnético que van del intervalo de la luz visible a las longitudes de microondas. En la sección 2.2.2 se detalla el espectro electromagnético.

Para definir a la percepción remota fue necesario adoptar dos conceptos fundamentales en esta ciencia: *interpretación fotográfica* y *sensores remotos*. Colwell (1960) definió a la *interpretación fotográfica*, como: el acto de examinar imágenes fotográficas con el propósito de identificar objetos y juzgar su importancia.

Los *sensores remotos* formalmente se definieron por *American Society for Photogrammetry and Remote Sensing (ASPRS)* como: La medición o adquisición de

información de algunas propiedades de un objeto o fenómeno, por un dispositivo de grabación que no está en contacto físico o íntimo con el objeto o fenómeno bajo estudio (Colwell, 1983).

Fue en 1988 que *ASPRS*, adoptó las definiciones de la interpretación fotográfica y la de sensores remotos, para dar una definición de percepción remota como: el arte, la ciencia y la tecnología de obtener información confiable sobre los objetos físicos y del medio ambiente, a través del proceso de grabar, medir e interpretar imágenes y representaciones digitales de patrones de energía derivados de sistemas de sensores con los que no se tiene contacto (Colwell, 1997)

Como otras definiciones de la percepción remota, tenemos a las siguientes:

“Es el registro, sin contacto, de información del ultravioleta, visible, infrarrojo y región del microondas del espectro electromagnético por medio de instrumentos tales como cámaras, escáneres, láser, matrices lineales y/o matrices de área ubicados en plataformas, como aviones o naves espaciales, y el análisis de la información obtenida a través de procesamiento digital y visual de imágenes” (John, 2000)

“La obtención de información acerca de una escena, empleando radiación electromagnética en la región óptica y de microondas, por medio del análisis automatizado de datos obtenidos a distancia por un sistema formado por un grupo de sensores remotos” (Lira, 2010).

Clark y Lee (2010) describen a la percepción remota como un esfuerzo multifacético y multidisciplinario para adquirir información de objetos a distancia, involucrando los siguientes objetivos:

- El desarrollo de una misión y el diseño de una nave espacial y/o instrumentos para caracterizar un objetivo lejano desde el investigador en el contexto de su entorno.
- Uso de instrumentos para detectar, adquirir, y calibrar datos en las regiones seleccionadas del espectro electromagnético producido por el objetivo.
- Transmisión de datos recogidos y codificados en una señal portadora electromagnética, en seguida, recibir y decodificar la señal en la ubicación del

investigador, lo que requiere el conocimiento de la posición de la nave espacial y el instrumento de orientación relativa al objetivo.

- El análisis e interpretación de los datos implica un análisis estadístico, la cartografía y el trabajo de campo.
- El archivo y la gestión de los datos obtenidos para uso científico y público.

2.1.2 Elementos de la percepción Remota

De las definiciones mencionadas podemos destacar los siguientes elementos de la percepción remota (véase Figura 2.1):

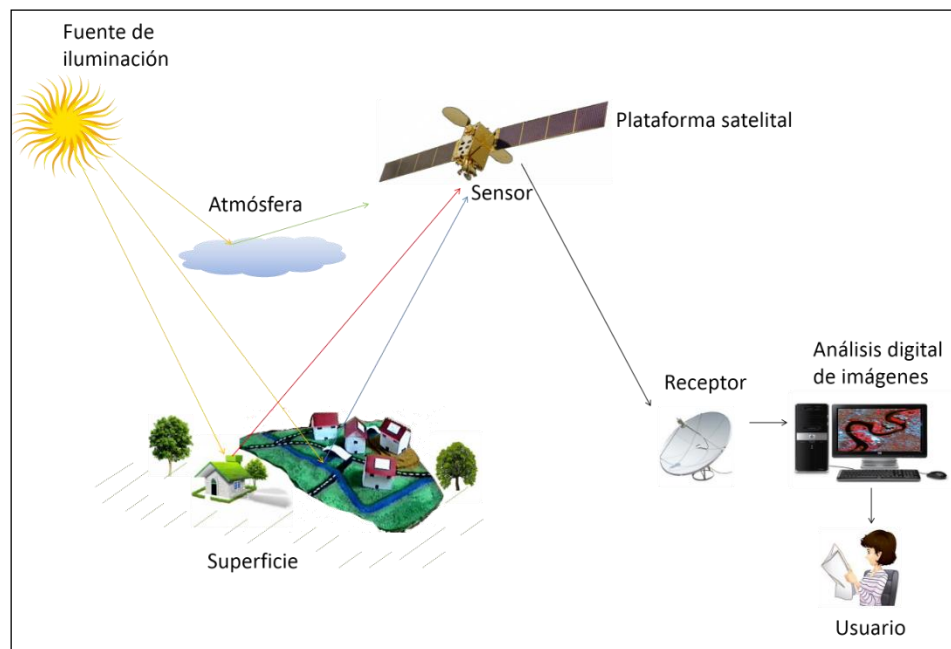


Figura 2.1. Elementos de la Percepción Remota

Fuente de iluminación

Los sistemas de percepción remota colectan datos empleando ya sea un sensor *pasivo* o *activo*. La energía procedente de una fuente incide e interactúa sobre un objetivo, y la energía resultante depende del espectro de energía de la fuente, así como de la naturaleza y composición física del objetivo.

Los sistemas *pasivos* utilizan una fuente de iluminación externa, sobre la cual no se puede tener control (Lira, 1995) como lo es el Sol. Los sensores *pasivos* registran la radiación electromagnética de origen natural que es reflejada o emitida de la escena. Por otro lado, los sistemas *activos* son aquellos que utilizan su propia fuente de iluminación. En los sensores *activos* su fuente de iluminación puede ser la luz ultravioleta o infrarroja, los rayos X o rayos gamma, microondas como las que emplean los sistemas de RADAR (*Radio Detection And Ranging*) y LIDAR (*Ligh Detection And Ranging*). Los sistemas activos barren el paisaje con energía electromagnética controlada por el hombre y registran la cantidad de flujo radiante dispersa vuelta hacia el sistema del sensor (Jensen, 2000).

Paisaje y Escena

El paisaje se puede entender como el objeto global de estudio, es el elemento de la percepción remota que más retos da al investigador (Lira, 1995) ya que el ser humano no tiene control sobre él. El paisaje llega a ser sumamente complejo donde intervienen una serie de factores inconvenientes a la finalidad de la investigación. La escena se puede entender como una sección contenida en el paisaje que comprende un conjunto de objetos presentes en un área definida. Para entenderlo tomaremos un ejemplo de Lira (1995) referentes a una radiografía. Cuando un radiólogo enfoca el aparato de rayos X sobre una sección del sistema óseo lo que está haciendo es seleccionar una escena del "paisaje", que en este caso es el cuerpo humano. La superficie que constituye la escena es en este ejemplo el plano sobre el que se enfoca el aparato de rayos X y los objetos son los huesos que se encuentran enfocados; la radiografía resultante es la representación visual de los huesos y su estructura.

Detección de datos (sensores)

Los detectores o sensores operan en diferentes regiones de la energía electromagnética. Los detectores separan y miden la intensidad de componentes, de ahí se derivan los sistemas de dispersión físicos o espectrales.

La parte visible del espectro electromagnético es muy pequeña, y la mayoría de los sistemas de satélite han sido diseñados para ser sensible a otras porciones del espectro, esta característica permite a los analistas ver porciones del espectro que el ojo humano no puede

detectar, mejorando así la capacidad para identificar diferentes materiales de superficie. Las resoluciones de un sensor son las siguientes:

Espacial: es la capacidad de un sensor para distinguir objetos de cierto tamaño.

Spectral: se refiere al número de bandas espectrales que puede discriminar el sensor y el ancho que éstas poseen.

Radiométrica: es la sensibilidad que tiene el sensor para detectar variaciones de la radiancia que recibe. En fotografías, el número de grises y en sensores óptico-electrónicos, la cantidad de valores digitales

Temporal: se refiere a la frecuencia de cobertura de una misma porción de la superficie terrestre.

La colección de datos en percepción remota puede llevarse por medio de sensores:

In situ o manuales: Este tipo de sensores son particularmente ocupados en agronomía, por ejemplo al medir el índice de área foliar. Los datos tomados directamente en campo sirven para calibrar los datos del sensor satelital o aéreo.

Aéreos: Los sensores aéreos se encuentran montados en aviones, drones o cualquier tipo de transporte aéreo.

Satelitales: En esta modalidad los sensores se encuentran ensamblados en vehículos espaciales. Los vehículos o escenarios donde se encuentran montados los sensores son llamados Plataformas (véase Tabla 2.1)

Los satélites pueden ser colocados en una órbita polar o ecuatorial (Lira, 2010). Los satélites de órbita polar se encuentran más cerca de la Tierra, hacen observaciones a una frecuencia baja y generalmente son utilizados para observaciones de la superficie de la Tierra y oceanográficas (Richards, 2013). Los satélites colocados en orbitas ecuatoriales son llamados satélites geoestacionarios ya que la velocidad angular de su rotación es similar a la de la Tierra por lo que aparentan estar fijos en el firmamentos (Lira, 2010). Estos últimos satélites se encuentran a una altura mayor que los de órbita polar y son empleados para estudios meteorológicos. La tabla 2.1 muestra las principales plataformas satelitales.

Dato Plataforma	Fecha de lanzamiento	Altura Promedio	Periodo de Orbita	Periodo de Cobertura	Resolución Espacial	Bandas Espectrales (μm)
Landsat 7 ETM	Abril, 1999	705 km	99 minutos	16 días	bandas 1-5 y 7: 30 m banda 6: 60 m banda 8: 15 m	1) 0.45-0.52 2) 0.53-0.60 3) 0.63-0.69 4) 0.78-0.90 5) 1.55-1.75 6) 10.4-12.5 7) 2.09-2.35 8) 0.52-0.90
Aster	Diciembre, 1999	717 km	99 minutos	16 días	bandas 1-3: 15 m bandas 4-9: 30 m banda 10-14: 90 m	1) 0.52-0.60 2) 0.63-0.69 3) 0.76-0.86 4) 1.60-1.70 5) 2.145-2.185 6) 2.185-2.225 7) 2.235-2.285 8) 2.295-2.365 9) 2.360-2.430 10) 8.125-8.475 11) 8.475-8.825 12) 8.925-9.275 13) 10.25-10.95
QuickBird 2	Octubre, 2001	450 km	93 minutos	3.5 días	pancromático: 0.61 m multiespectral: 2.44 m	1) 0.45-0.52 2) 0.52-0.60 3) 0.63-0.69 4) 0.76-0.90 5) 0.45-0.90
Spot 5	Mayo, 2002	832 km	101 minutos	26 días	pancromático: 2.5 m multiespectral: 10 m	1) 0.50-0.59 2) 0.61-0.68 3) 0.79-0.89 4) 1.58-1.75
OrbView 3	Junio, 2003	470 km	92 minutos	3 días	bandas 1-4: 4 m banda 5: 1 m	1) 0.450-0.520 2) 0.520-0.600 3) 0.625-0.695 4) 0.760-0.900 5) 0.450-0.900
GeoEye 1	Septiembre, 2008	770 km	98 minutos	2.6 días	pancromático: 0.46 m multiespectral: 1.84 m	1) 0.450-0.510 2) 0.510-0.580 3) 0.655-0.690 4) 0.780-0.920 5) 0.450-0.800
WorldView 2	Octubre, 2009	770 km	100 minutos	3.7 días	pancromático: 0.46 m multiespectral: 1.85 m	1) 0.400-0.450 2) 0.450-0.510 3) 0.510-0.580 4) 0.585-0.625 5) 0.630-0.690 6) 0.705-0.745 7) 0.770-0.895 8) 0.860-1.040

Tabla 2.1. Principales plataformas satelitales en percepción remota.

Pleiades 1A	Diciembre, 2011	694 km	99 minutos	1 día	pancromático: 0.5 m multiespectral: 2.0 m	1) 0.430-0.550 2) 0.500-0.620 3) 0.590-0.710 4) 0.740-0.940 5) 0.480-0.830
Spot 6	Septiembre, 2012	695 km	99 minutos	1 a 5 días	pancromático: 1.5 m multiespectral: 6.0 m	1) 0.455-0.525 2) 0.530-0.590 3) 0.625-0.695 4) 0.760-0.890 5) 0.455-0.745
Sentinel-2	Junio, 2015	786 km	100.6 minutos	10 días	bandas 2, 3, 4 y 8: 10 m bandas 5, 6, 7, 8a, 11 y 12: 20 m bandas 1, 9 y 10: 60 m	1) 0.443 2) 0.490 3) 0.560 4) 0.665 5) 0.705 6) 0.740 7) 0.783 8) 0.842 8a) 0.865 9) 0.945 10) 1.375 11) 1.610 12) 2.190

Sistema Radar

	Fecha de Lanzamiento	Altura Promedio	Periodo de Orbita	Periodo de cobertura	Resolución Espacial	Bandas Espectrales	Polarización Looks
Ers 2	Abril, 1995	784 km	100 minutos	35 días	26 x 30 m ²	5.6 cm (banda C)	VV 6
Radarsat 2	Diciembre, 2007	798 km	101 minutos	24 días	desde 3 x 3 m ² hasta 100 x 100 m ²	5.6 cm (banda C)	HH, HV, VH, VV 1-4
Envisat (Asar)	Marzo, 2002	796 km	100 minutos	35 días	25 x 25 m ² ó 150 x 150 m ²	5.6 cm (banda C)	VV, HH, HV 4
TerraSar	Junio, 2007	514 km	95 minutos	11 días	desde 1 x 0.65 m ² hasta 16 x 16 m ²	3.1 cm (banda X)	VV, HH, HV 1-11
Sentinel-1	Abril, 2014	693 km	98 minutos	12 días	5 x 5 m ²	5.6 cm (banda C)	VV, HH, HV 1

Tabla 2.1. Continuación de las Principales plataformas satelitales en percepción remota.

Análisis de Datos

El análisis de datos, así como, su interpretación implica un análisis estadístico, un procesamiento de datos y el trabajo de campo, para finalmente presentar la información lograda y de esa manera tomar las decisiones adecuadas según el objeto de estudio.

El rápido progreso de la tecnología, el avance computacional y la generación de técnicas de procesamiento de imágenes facilitan la extracción de información temática para la elaboración de políticas de apoyo. El software y hardware multimedia se está convirtiendo en estándar para la manipulación de imágenes, secuencias de imágenes, e incluso visualización 3-D. Los métodos de procesamiento de imágenes se aplican ahora a prácticamente todas las ciencias naturales y disciplinas técnicas (Jähne, 2005).

Hay dos grandes claves para la interpretación de las imágenes. Uno consiste en los métodos computacionales para el análisis, en el cual varios algoritmos son empleados para automatizar lo que de otro modo sería una tarea imposiblemente asistida. La otra consiste enteramente de habilidades de analista responsable (Richards, 2013).

Los Sistemas de Información Geográfica (SIG) y la Percepción Remota juegan un papel importante en todos los aspectos geográficos. Los SIG se utilizan para manipular y analizar datos espaciales y propiedades de los datos procedentes de distintas fuentes. También se utilizan para producir reportes en formato de mapas, bases de datos y textos que faciliten los procesos de toma de decisiones. Esta técnica se ha desarrollado rápidamente en las últimas dos décadas, y es ahora aceptada como una herramienta esencial para el uso efectivo de la información geográfica (Lozano, 2007).

La **aplicación** de la percepción remota es bastante amplia. A continuación se mencionan algunos ejemplos de los usos de percepción remota en diferentes campos y disciplinas:

- Agricultura: para examinar la situación de los cultivos, asegurar el control de las superficies cultivadas, predicción de la producción y rendimientos, y efectuar el seguimiento de las medidas agroambientales (ERMEX).
- Exploración de recursos naturales como son: minerales, gas natural, campos geotérmicos, recursos hídricos.

- Monitoreo y valoración ambiental: caracterización de zonas urbanas y suburbanas, monitoreo del crecimiento urbano, medida de la contaminación del aire deforestación, derrames de petróleo, calentamiento global.
- Monitoreo de áreas de desastre o zonas de riesgo: sequías, incendios, inundaciones, estimación del deshielo de los glaciares y zonas polares, suministro de información post-desastre de Tsunamis y Terremotos, monitoreo de volcanes activos.
- Meteorología: Dinámica atmosférica, predicción de estados del tiempo.
- Reconocimiento y vigilancia militar: Políticas estratégicas y valoración táctica.
- Investigación Oceanográfica y desarrollo portuario.
- Astronomía: estudio objetos gaseosos y sólidos del espacio. Muchas de las contribuciones más significativas al campo de la percepción remota fueron producto de los programas espaciales (Clark y Rilee, 2010).

2.2 Imagen digital Multiespectral y de Radar

La cantidad de información adquirida en una imagen es inestimable, y no sólo en el ámbito de la percepción remota, sino también, en toda disciplina que emplee datos e información extraídos de imágenes o fotografías. Por ello, es de vital importancia conocer las características y elementos que conforman una imagen, así como también, conocer los procesamiento y técnicas de análisis, permitiendo de esta manera, la interpretación y aprovechamiento óptimo de la información obtenida.

2.2.1 Conceptos y aspectos generales

La energía es la habilidad de realizar un trabajo. En el proceso para realizar un trabajo, la energía se transfiere de un cuerpo a otro o de un lugar a otro. Existen tres maneras básicas en que la energía se puede transmitir ya sea por conducción, convección o radiación. La transferencia de energía por radiación electromagnética es de primordial interés en la ciencia de la percepción remota, ya que de esa manera, la energía transferida puede tomar lugar en un espacio vacío, tal como la región entre el Sol y la Tierra (Jensen, 2000). Para entender el comportamiento de la radiación electromagnética se han utilizados dos modelos, el *ondulatorio* y el *corpúscular* (Englert *et al.*, 1994).

El modelo de onda adaptado por James Clerk Maxwell quién conceptualizó la radiación electromagnética como una onda electromagnética que viaja a través del espacio a la velocidad de la luz ($c = 2.99793 \times 10^8 \text{ m/s}$), que a su vez contiene dos campos de fuerzas ortogonales entre sí: eléctrico y magnético. Las ondas electromagnéticas pueden ser descritas en términos de la longitud de onda λ (distancia de cualquier punto de un ciclo u onda a la misma posición sobre el siguiente ciclo u onda) y la frecuencia ν (número de ciclos por unidad de tiempo)

La teoría de *partícula* o *corpúscular* considera a la energía electromagnética como un flujo de partículas fotones. Los fotones son paquetes discretos de energía que viajan a la velocidad de la luz c y transportan energía de acuerdo con la ecuación (2.1)

$$e_f = h\nu = \frac{c}{\lambda} \quad (2.1)$$

donde e_f es la energía radiante de un fotón, $h = 6.626 \times 10^{-34} \text{ Js}$ es la constante de Plank. Esta cantidad de energía radiante es cuantizada y sólo puede ser múltiplo de $h\nu$ para una cierta frecuencia. Una vez conocida la energía de cada fotón, que generalmente se expresa en *electrón voltio* ($eV = 1.602 \times 10^{-19} \text{ J}$), la energía total de la radiación está dada por el número de fotones (Jähne y HauBecker, 2000).

Ambas teorías se complementan, ya que el concepto de onda explica cómo la energía electromagnética se propaga, sin embargo, esta energía sólo puede ser detectada cuando interactúa con la materia. En la interacción, la energía electromagnética se comporta de forma corpuscular. A medida que la luz se propaga a través de un medio de diferentes densidades ópticas, se refracta, adquiriendo un comportamiento asociado a las ondas. Cuando un sensor mide la intensidad de la luz, la interacción de los fotones con la materia fotosensible del fotodetector, produce una señal eléctrica cuya magnitud varía en forma directamente proporcional con el número de fotones que sobre él inciden.

Podemos entender como *radiación incidente* al proceso de interacción de la energía electromagnética y la materia. Cuando existe esta interacción, la materia puede modificar la intensidad, la dirección, la longitud de onda, la polarización y la fase de la radiación incidente. Son estos cambios los que la ciencia de la percepción remota recaba para determinar las características de la materia. La radiación incidente puede ser:

Transmitida, cuando se transmite la energía a través de medios de diferentes densidades, por ejemplo del aire al agua, esto ocasiona un cambio en la velocidad de la radiación electromagnética.

Absorbida, cuando la energía entra en la materia provocando un aumento en la temperatura en ella.

Emitida por la materia, esto en función de su estructura y temperatura, generalmente ocurre en longitud de ondas grandes.

Dispersada, cuando es redirigida en todas las direcciones. Las superficies con una rugosidad de tamaño comparable con la longitud de onda producen dispersión.

Reflejada, cuando retorna de la superficie del material con un ángulo de reflexión igual y opuesto al ángulo de incidencia. La reflexión es provocada por superficies que son

relativamente suaves a la longitud de onda de la energía incidente. La polarización, que es la dirección de vibración de las ondas reflejadas, puede diferir con respecto a la onda incidente.

2.2.2 Espectro electromagnético

Tomando en cuenta los conceptos descritos, podemos definir al **espectro electromagnético** como toda la gama de energías que se pueden producir como resultado de las interacciones entre la materia y la radiación electromagnética. El nivel de energía o región dentro del espectro se puede expresar en longitud de onda (por ejemplo cm, μm , nm), frecuencias (Hz) o electrón-voltios (eV). (Clark y Rilee, 2010). El intervalo de longitudes de onda (o frecuencias) dentro del espectro electromagnético es comúnmente llamado canal, región o banda (Jensen, 2000). La Figura 2.2 muestra una clasificación del espectro electromagnético en escala de longitud de onda y frecuencia. La tabla 2.2 describe las regiones del espectro electromagnético.

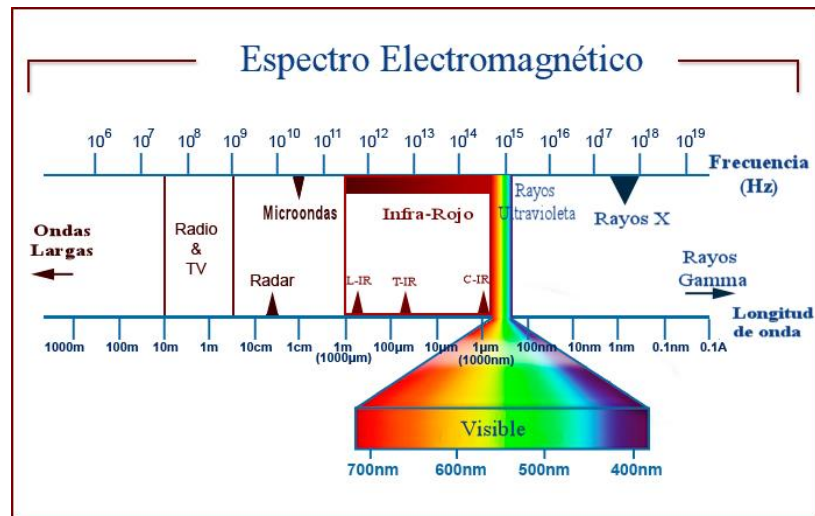


Figura 2.2. Espectro Electromagnético (adaptado de Hayness, CRHfoto)

Región	Longitud de Onda	Descripción
Rayos gamma	<0.03 nm	La radiación entrante es completamente absorbida por la ionosfera y no está disponible para la percepción remota.
Rayos X	0.03 a 30 nm	Completamente absorbida por la atmósfera. No se emplea en percepción remota.
Región ultravioleta	0.03 a 0.4 μm	La radiación ultravioleta tiene una longitud de onda más corta que la luz visible azul o violeta. La capa de ozono en la estratosfera filtra la mayor parte de la radiación ultravioleta.
Banda fotográfica UV	0.3 a 0.4 μm	Transmitida a través de la atmósfera. Detectable con películas fotográficas y fotodetectores, sin embargo la atenuación en la atmósfera es severa.
Visible	0.4 a 0.7 μm	Es percibida por nuestros ojos. Suele distinguirse tres bandas elementales: azul (0.492-0.455 μm), verde (0.577-0.492 μm) y rojo (0.770-0.622 μm)
Infrarrojo Cercano	0.70 a 3.0 μm	Es de suma importancia por su capacidad para discriminar masas vegetales y concentraciones de humedad.
Infrarrojo medio	3 a 30 μm	Se entremezclan los procesos de reflexión de la luz solar y de emisión de la superficie terrestre. Idóneo para estimar el contenido de humedad en la vegetación y para la detección de focos de alta temperatura.
Infrarrojo lejano	30 a 100 μm	Incluye la porción emisiva del espectro terrestre, en donde se detecta el calor proveniente de la mayor de las cubiertas terrestres.
Microondas	0.1 a 100 cm	Tiene una mayor capacidad para la penetración nube, así como para la caracterización de vapor de agua y oxígeno a través de sus bandas de absorción de microondas. Ideal para la caracterización de cuerpos de agua y atmósfera.
Radio	> 100 cm	Región del espectro electromagnético con mayor longitud de onda. Las principales aplicaciones están en la medicina y la astronomía.

Tabla 2.2. Rangos del espectro electromagnético (adaptado de Rodríguez, 2008; González y Woods, 2008;)

2.2.3 Generación de una imagen multiespectral

Se debe tener en cuenta que existen dos maneras fundamentales en que los sensores remotos son capaces de producir imágenes, una es en formato analógico (primeras fotografías) y la otra en formato digital.

Las imágenes digitales están compuestas de elementos lógicos de la escena o pixels (picture element). Para obtener una imagen digital multiespectral se requiere de una fuente de iluminación como se mencionó en la sección 2.1.2, la radiación emitida, reflejada o transmitida por el elemento físico de la escena, el cual se conoce como: Campo Instantáneo de Vista (CIV), es captada por un sistema óptico, el cual posee un subsistema de enfoque y conducción de radiación. Entonces, la radiación es conducida a filtros de radiación o un espectroradiómetro, cuya función es seleccionar un intervalo de energía o longitudes de onda. Para cada intervalo de energía los sensores miden la cantidad de radiación por unidad de ángulo sólido, por unidad de tiempo (mW/msterad/s).

La señal captada es introducida en un convertidor analógico-digital, el cual a cada píxel le asigna un valor de tono (negro, blanco, matices de gris o color), de las intensidades de energías captadas, el cual está representado en un código binario (ceros y unos), la escala que usualmente se usa es de 0 a 255 (256 niveles), con la ventaja que este valor es almacenable en un byte (8 bits de un computador). Este proceso se conoce como cuantización y está en relación con la resolución radiométrica.

Los valores cuantizados se almacenan en una matriz bidimensional en posición correspondiente al CIV. La matriz bidimensional es lo que se conoce como banda, y los valores que contiene, corresponden a un intervalo de energía del espectro electromagnético captado por el sensor. Por lo tanto, si existen γ sensores y cada uno registra una región del espectro, habrá γ bandas espectrales (Marín, 2014).

La Figura 2.3 muestra algunos de los elementos que intervienen en la formación de una imagen digital multiespectral.

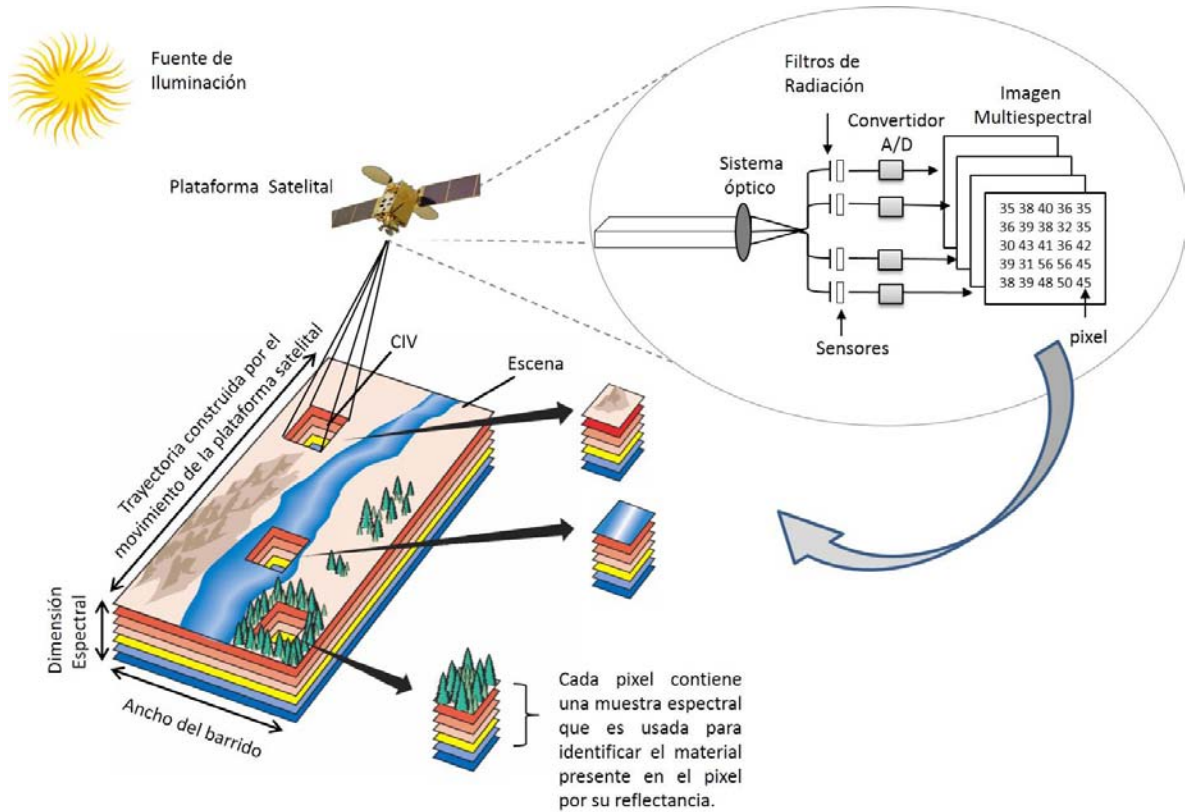


Figura 2.3. Generación de una imagen digital multiespectral.

Por lo tanto, podemos definir a una *imagen digital multiespectral* como el conjunto de bandas espectrales para una escena dada, la cual caracteriza la distribución espacial y espectral de la radiación proveniente de ésta.

Para cada CIV, se producen γ números de pixels (p_{mn}) que conjuntamente describen su respuesta espectral, los que arreglados vectorialmente se describen como:

$$p_{mn} = \{b_1, b_2, \dots, b_\gamma\}_{mn} \quad (2.2)$$

Donde b_i es el valor numérico obtenido para el intervalo de energía o longitud de onda de la radiación empleada. Los índices (m, n) representan las coordenadas del píxel en su posición dentro de la imagen digital (Lira, 2010).

2.2.4 Generalidades del Sistema Radar

Los sensores de RADAR (*Radio Detection And Ranging*) pueden ser pasivos o activos. Los sensores pasivos de radar responden a niveles muy bajos de energía, en la región de microondas, emitida o reflejada por la materia, este tipo de radares no son empleados en percepción remota. Por el contrario, un sistema de radar activo emite un haz energético de microondas y registra la energía reflejada luego de interactuar con la superficie u objetos. El tipo de energía que emplean los sistemas de radar es coherente, es decir, que los paquetes de ondas que forman el haz de iluminación tienen la misma longitud de onda y la misma fase (Lira, 2002). La ventaja de un sistema activo es el control que se tiene sobre su fuente de iluminación.

La transmitancia atmosférica, la cual tiene un efecto significativo en el comportamiento de la radiación solar al llegar a la superficie, es muy alta para la longitud de onda en la que opera el radar. La región de microondas (Tabla 2.3) de la radiación solar, atraviesa la atmósfera sin ninguna distorsión, por lo que el radar puede operar en cualquier condición atmosférica, esto implica una considerable ventaja respecto a sensores ópticos.

Banda	Longitud de onda (cm)	Frecuencia [MHz (10^6 c/s)]
K_a	0.75 - 1.1	40 000 - 26 500
K	1.1 - 1.67	26 500 - 18 000
K_u	1.67 - 2.4	18 000 - 12 500
X	2.4 - 3.75	12 500 - 8 000
C	3.75 - 7.5	8 000 - 4 000
S	7.5 - 15	4 000 - 2 000
L	15 - 30	2 000 - 1 000
P	30 - 100	1 000 - 300

Tabla 2.3. Nomenclatura de bandas para la región espectral de microondas. (Adaptado de Lillesand y Kiefer, 2001)

El principio básico de un sistema de radar consiste en medir el tiempo de retorno de la señal emitida y la intensidad de la misma con el fin de determinar la distancia de la antena al objeto detectado y así cuantificar las características físicas del mismo, como su tamaño y

sus características texturales a una antena de radar emite un haz conformado por un tren de pulsos de corta duración $\Delta\tau$ y con una alta frecuencia de repetición (Lira, 2010). Este sistema mide de manera lateral, como se muestra en la Figura 2.4.




Figura 2.4. Parámetros correspondientes a la formación de una imagen Radar

De la Figura 2.4 podemos observar los siguientes parámetros:

y , corresponde a la dirección del desplazamiento de la antena, también conocida como dirección de Azimut.

x , dirección perpendicular al azimut, conocida como dirección de rango.

η , ángulo de *squint*, el cual es formado por la dirección de desplazamiento y el rango.

R , rango, distancia que existe entre la antena de radar y la zona iluminada en el terreno.

h , altura de la antena sobre la superficie.

$\Delta\eta$, apertura del haz en la dirección de azimut.

$\Delta\beta$, apertura del haz en la dirección de rango.

β , ángulo de depresión, es la inclinación hacia el terreno del haz de iluminación.

La resolución en un sistema de radar es controlada por la longitud del pulso de la señal y el ancho del haz proveniente de la antena. La longitud del pulso determina la resolución en la dirección de propagación de la energía (dirección de rango o alcance). Pulsos más cortos dan lugar a una alta resolución en el alcance.

De acuerdo con el tamaño de la antena, los radares en percepción remota se pueden dividir en dos grupos: Radar de Apertura Real (**RAR**, por sus siglas en inglés) y Radar de Apertura Sintética (**SAR**, por sus siglas en inglés).

1. La ventaja de los sistemas **RAR**, está en su diseño simple y en el procesamiento de los datos. No obstante, la resolución de la imagen es pobre y varía en función directa de la distancia de la plataforma al terreno y del tamaño de la antena radar. El uso de estos datos está limitado y es difícil aplicarlos a estudios atmosféricos o de dispersión, ya que las misiones vuelan a baja altitud y su cobertura es pequeña.

2. A causa del problema de dependencia que tiene el sistema RAR surge un nuevo diseño llamado **Radar de Apertura Sintética (SAR)**. Una apertura sintética o antena virtual, consiste en un extenso arreglo de sucesivas y coherentes señales de radar que son transmitidas y recibidas por una pequeña antena que se mueve a lo largo de un determinado recorrido de vuelo u órbita. Con base en el desplazamiento relativo entre la antena y un punto dado en la escena (véase Figura 2.5), se mide la variación de rango y el corrimiento doppler para un intervalo acotado de la dirección y . Durante un cierto intervalo de tiempo y debido al ancho finito del haz y al movimiento relativo entre la escena y la antena, se produce una variación del rango y del corrimiento doppler para cada punto de la escena. Esta historia de rangos y corrimientos doppler es medida y registrada por el sistema radar durante el proceso de generación de una imagen (Lira, 2010).




Figura 2.5. Principio del Radar de Apertura Sintética.

Todas las imágenes obtenidas a partir de cualquier sistema que utilice radiación coherente, como por ejemplo los sistemas SAR, laser, y los empleados para la generación de imágenes de rayos x, ultrasonidos, y tomografías, se caracterizan por el contenido de *speckle*. El *speckle*, es producido por la interacción de la escena con los pulsos de energía coherente. La interacción coherente puede ser constructiva o destructiva, dependiendo del cambio de fase de la radiación. El *speckle* se encuentra aleatoriamente distribuido en una imagen con apariencia visual al ruido y aunque no es precisamente un ruido tienen propiedades estadísticas definidas por lo cual puede reducirse por medio de métodos físicos o digitales.

2.3 Reconocimiento de Patrones

El objetivo de cualquier análisis de imágenes es el reconocimiento de patrones presentes en ellas, es decir, cuantificar y clasificar las propiedades de los objetos contenidos en una escena.

Como seres humanos estamos expuestos constantemente a reconocer objetos, esto se logra con base en las propiedades morfológicas y espectrales de los mismos. Los elementos que conllevan al reconocimiento de un objeto son: 1) las propiedades que lo distinguen, 2) la etiqueta o nombre asociado y 3) la identificación de su función (opcional).

Por ejemplo, inmediatamente al visualizar una naranja, sabemos que es una naranja por su forma redondeada, color anaranjado y su textura rugosa. Esto es posible porque nuestro cerebro tiene almacenado una base de datos de las características y propiedades de bastantes objetos, que nos ayudan a identificar y etiquetar los objetos del mundo circundante. El reconocimiento de patrones, en imágenes de sensores remotos, conserva un razonamiento similar. Primeramente, para reconocer un objeto o patrón, es necesario extraer sus propiedades fundamentales, en seguida, modelar matemáticamente estas propiedades y medir a éstas de acuerdo con una métrica. A continuación se esquematiza el proceso del reconocimiento de patrones espaciales o espectrales en imágenes.

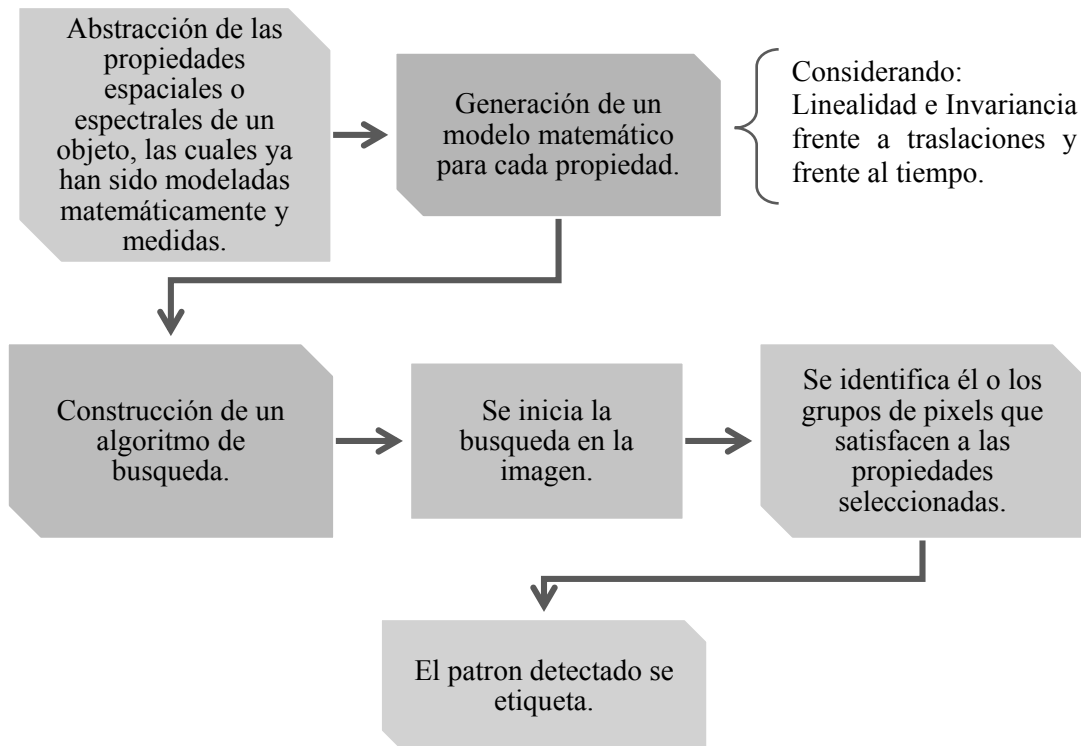


Figura 2.6. Procedimiento para el reconocimiento de patrones espaciales o espectrales.

2.3.1 Técnicas de Segmentación

El procedimiento de segmentación consiste en la partición de una imagen en regiones homogéneas que la constituyen. En general, la segmentación es una de las tareas más difíciles en el procesamiento digital de imágenes. Un buen método de segmentación, lleva

un largo proceso hacia la solución satisfactoria de los problemas. Por otro lado, los algoritmos de segmentación débiles o erráticos casi siempre garantizan un fallo eventual. En general, cuanto más precisa es la segmentación, es más probable tener éxito al momento del reconocimiento de patrones (Gonzalez y Woods, 2008).

En una imagen segmentada, los elementos básicos ya no son los píxeles individuales, sino conjuntos de píxeles pertenecientes a la misma región conectada. Una vez que la imagen ha sido segmentada, las mediciones se pueden realizar en cada región. Por lo tanto, la segmentación de imagen es un paso importante para la interpretación cuantitativa de los datos de imagen.

La resolución espacial de las imágenes de percepción remota ha cambiado considerablemente desde sus inicios, cada vez el tamaño de pixel es menor, lo que conlleva la generación de nuevos algoritmos de clasificación de alta y muy alta resolución de imágenes.

La segmentación de imágenes está presente en todo tipo de análisis de imagen. A continuación, se resumen brevemente las técnicas de segmentación de imágenes multiespectrales captadas por sensores remotos (Dey *et al.*, 2010). Es de importancia señalar, que las imágenes de radar tienen un horizonte distinto en el proceso de segmentación.

- a) **Técnica umbrales del histograma.** Es una técnica primitiva para la segmentación de imágenes. Se basan en la suposición que hay un fondo uniforme en la imagen y los objetos se colocan de forma irregular en este fondo (Rosenfield y Davis, 1979). Se fundamenta principalmente en las propiedades espectrales. La variación espectral está representada por el histograma.
- b) **Modelos de campo aleatorio Markov.** Estas técnicas tienen en cuenta la relación de vecindad entre pixels, que los hace atractivos para el modelado contextual y de textura en las imágenes. Estos modelos han tomado mucha importancia en cuestión de la segmentación de imágenes, por ello ha crecido ampliamente la investigación sobre ellos. Esto es debido a su capacidad de integrar propiedades espectrales, espaciales, texturales y contextuales de la imagen. Sin embargo, sus desventajas son la

formulación matemática y alta complejidad computacional. (Los detalles del modelo se encuentran en Li, 2009)

- c) **Técnica de lógica difusa.** A partir de este tipo de segmentación se deriva la metodología de *clustering*. El algoritmo difuso de c-medias es un método de agrupamiento de pixels o datos en *clusters* (cúmulos) en el cual, la nube de datos en espacio espectral es agrupada en C cúmulos, donde cada pixel pertenece a cada cúmulo con cierto grado de membresía.
- d) **Método de redes neuronales.** Está basado en la emulación de las neuronas del cerebro humano. La base de la red neuronal se encuentra en el entrenamiento de la red neuronal. El objetivo del entrenamiento es modelar el proceso de generación de los datos de manera que puede predecir la salida para los datos imprevistos. La formación se asocia generalmente con la metodología supervisada. Sin embargo, la red sin supervisión también se puede formular. Visa *et al.* (1991) fueron pioneros en aplicar redes neuronales para segmentación de imágenes. Ellos utilizaron la matriz de co-ocurrencia basada en vectores característicos de la textura, como entrada al mapa de auto-organización de redes neuronales.
- e) **Modelo multi-resolución.** La escala de un objeto se establece como el nivel de agregación y abstracción en el que un objeto puede ser descrito (Benz *et al.*, 2004). Un objeto que es menor a la resolución espacial de la imagen no puede ser identificado. Basado en esto, dos problemas se pueden indicar. En primer lugar, si el tamaño del objeto es grande, la alta resolución de un sensor espacial fragmenta al objeto y en segundo lugar, si el tamaño del objeto es pequeño, entonces la baja resolución espacial puede que ni siquiera lo reconozca. Con la disponibilidad de imágenes satelitales de alta resolución el segundo problema se elimina. El primer problema se puede resolver con el modelo multi-resolución/multiescala. La segmentación multi-escala puede ir en ambos sentidos de baja resolución a alta resolución y viceversa (Zhong *et al.*, 2005).
- f) **Modelo de Cuenca.** Está basado en la morfología matemática y deriva su analogía al contexto de una inundación real (Beucher, 1992). Transforma la imagen en un gradiente, entonces, la imagen se aprecia como una superficie topográfica donde los

valores de grises se consideran como la elevación de la superficie en ese punto. El proceso de inundación se inicia cuando el agua fluye del valor mínimo de la escala de grises. Este método es esencialmente una técnica basada en bordes (Carleer *et al.*, 2005). La aplicación del algoritmo de cuencas en imágenes de sensores remotos es relativamente reciente en comparación con otros modelos y se ha estado modificando, ya que dicho algoritmo produce una sobre-segmentación por el ruido o los patrones de textura.

Es importante hacer mención de las medidas de homogeneidad que caracterizan a la imagen, estas medidas son empeladas en el proceso de segmentación. Las posibles medidas se basan en las propiedades espectrales, de textura, del tamaño, de forma, y temporales de los patrones de la imagen. También se requiere de alguna otra información semántica de previo conocimiento así como el contexto y la conectividad (Wang y Terman, 1997). El siguiente listado categoriza a las medidas de homogeneidad.

- a) **Características espectrales y de textura.** La característica primordial de un objeto es sin duda su respuesta espectral, la cual se aprecia en los valores del pixel en una imagen. Si bien, desde hace tiempo se demostró que utilizando sólo los rasgos espectrales no es factible obtener una buena segmentación de patrones, pero aun así se practicaba debido a la facilidad de incorporarlos en formato digital (Kettig y Landgrebe, 1976). Con el fin de mejorar la segmentación en imágenes surge incorporar las propiedades espectrales y espaciales, como la textura. A este proceso se le conoce como *segmentación contextual*. El método espectral-textura, es el de uso más común en percepción remota. No obstante, cuantificar las características de textura no es simple (Richards y Jia, 2006). Debido a este hecho, la segmentación de textura se ha estudiado de manera amplia, generalmente en combinación con otras características, hasta hoy en día (Dey *et al.*, 2010).

- b) **Características de Forma y Tamaño.** La importancia de la forma y medida del tamaño, puede entenderse cuando un objeto natural debe ser identificado en las imágenes satelitales. Por ejemplo, un río y un estanque pueden tener la misma respuesta espectral, textura, pero difieren en su forma y tamaño. Las medidas de forma y tamaño se utilizan sobre todo como complementarias entre sí y son alusivas a la

segmentación de imágenes multi-escala/multi-resolución. La forma y el tamaño son métricas especialmente útiles cuando se detallan objetos de gran complejidad en imágenes.

- c) **Contexto.** Generalmente se refiere al contexto espacial, es decir, la relación de pixels con su vecindad (Thakur y Dikshit, 1997). El Contexto ayuda a evitar la fragmentación o la fusión de un segmento. El contexto es especialmente útil cuando la segmentación requiere identificar grandes extensiones de área como un solo segmento, por ejemplo, en la clasificación del uso de suelo. Los modelos de Campo Aleatorio Markov son actualmente los que mayormente implementan a las medidas contextuales.
- d) **Temporal:** la medida temporal concierne a la medición de las características de la misma área o escena de una imagen en tiempos diferentes. La medida temporal no se utiliza directamente en el proceso de segmentación, más bien, se aprovecha como una aplicación de la imagen segmentada. Por ejemplo, las aplicaciones de la característica temporal, las podemos encontrar en el monitoreo de cambios de uso de suelo, flujos de tráfico, crecimiento de ciudades, cartografía de cultivos o de desastres naturales, entre otros (Campbell, 2007). Su aplicación se observa principalmente en la detección de cambios en áreas grandes, y no tanto en áreas pequeñas. Por lo tanto, las imágenes más empleadas para detección de cambios, son de baja resolución espacial.

2.3.2 Descriptores morfológicos

El ser humano está expuesto a infinidad de objetos físicos, los cuales poseen una forma geométrica o irregular. Al considerar la forma de un objeto interviene la psicovisión humana, que es la encargada de estimar de manera general la apariencia y figura de objetos geoméricamente regulares. Sin embargo, cuando se trata de figuras irregulares, la psicovisión humana se ve limitada al momento de discernir entre dos formas que difieran relativamente poco entre sí; más aún sin poder cuantificarlas, su valoración no pasa de ser subjetiva en el mejor de los casos (Lira, 2010).

Como se mencionó en el capítulo 1, el análisis y clasificación de patrones espaciales es un elemento importante para entender el comportamiento de un objetivo por medio de sus

imágenes. La morfología de los objetos o patrones tiene una especial relevancia, sobre todo cuando se quiere describirlos o identificarlos (Costa y Marcondes, 2001). Los descriptores morfológicos son métricas que describen las propiedades espaciales de un segmento o patrón. En algunos casos, la descripción de un objeto puede ser simple, por ejemplo, los campos de cultivo detectados por plataformas satelitales, se pueden describir empleado métricas como son el área y el perímetro. Por el contrario, cuando los objetos son de forma compleja, se requiere de la textura y de otros descriptores de forma, un ejemplo sería al intentar caracterizar algún tumor captado a través de una imagen de tomografía computada. La Tabla 2.4 muestra ejemplos de las aplicaciones de los descriptores morfológicos.

Campo de Investigación	Ejemplos de Aplicaciones
Neurociencias	Taxonomía de células neuronales, investigaciones sobre la relación entre la forma y la función y simulación de estructuras neuronales.
Análisis de Documentos	Reconocimiento Óptico de caracteres, base de datos multimedia y documentos históricos.
Artes Visuales	Efectos especiales, gráficos por computadora, visualizaciones e imágenes sintéticas.
Medicina	Reconocimiento de tumores, cuantificación de cambios y/o deformaciones de estructuras anatómicas, análisis numérico de cromosomas, identificación de patologías genéticas y estudios genéticos de morfología dentofacial.
Biología	Taxonomía, relación entre la forma y la función, anatomía comparativa, citología, identificación y conteo de células, caracterización de células y formas nucleares y microscopía.
Física	Análisis de trayectorias de partículas, caracterización de agrupación de estrellas en astronomía y crecimiento de cristales.
Ingeniería	Semiconductores, control de calidad, detección de peligros, robótica, percepción remota.
Seguridad	Detección de huellas dactilares de rostros e iris, biometría y verificación de firmas.
Agricultura	Control de cosechas, conteo de semillas y control de calidad, identificación de especies y análisis de maduración de frutos.

Tabla 2.4. Aplicaciones de descriptores morfológicos en diferentes disciplinas (adaptado de Costa y Marcondes, 2001).

2.3.2.1 Conceptos

Los descriptores morfológicos, como lo son el área, perímetro, la forma, la excentricidad y la contigüidad son llamados métricas del paisaje, para describirlos utilizaremos el concepto de parche. Cabe recordar que los parches están definidos como entidades espacialmente constantes con atributos similares. Los parches muestran formas pocas veces geométricas y en su mayoría se muestran de forma irregular.

La complejidad de los parches recae en su geometría, ya que tiende a ser simple y compacta o irregular y compleja. La forma es un atributo difícil de estimar con tan sólo un parámetro o métrica ya que existen infinitas formas complejas en las que se puede encontrar un parche (McGarigal, 2014). Por lo tanto, existen métricas o descriptores morfológicos que asignan un valor numérico a la complejidad de un parche.

La forma o geometría de un objeto o parche, se puede formalizar en conceptos matemáticos de conectividad. Es decir, el término *forma* es cualquier conjunto de puntos conectados. (Costa y Marcondes, 2001).

La conectividad entre pixels es un concepto utilizado para establecer los límites en objetos y regiones que componen una imagen. El concepto de conectividad constituye una relación de vecindad espacial entre un pixel y sus próximos vecinos. La estructura de una imagen digital hace que las direcciones en ésta estén discretizadas, es decir, únicamente ciertas de ellas son dadas de acuerdo con el arreglo matricial de los pixels (Lira, 2010), véase Figura 2.7.

La Figura 2.7a muestra las direcciones principales que relacionan de manera directa a un pixel con sus vecinos próximos. Esta roseta se conoce como el **código de Freeman**, la cual representa las ocho principales direcciones de conectividad entre pixels. Una dirección principal pasa por el centro de un conjunto de pixels alineados, de lo contrario, se considera una dirección secundaria, la cual no es especificada en el código de Freeman.




Figura 2.7. a) Código de Freeman. b) Representación de coordenadas de pixels en una imagen.

Para distinguir la conectividad - 4 de una conectividad - 8, veamos al pixel p en sus coordenadas (i,j) como se muestra en la Figura 2.7 b)

Denotemos como G_4 al grupo de pixels que se encuentran en las direcciones horizontales y verticales, las cuales corresponden por las direcciones 0, 2, 4, 6 por el código de Freeman. Los próximos vecinos de p que se encuentran localizados en las diagonales principales, especificadas por las direcciones 1, 3, 5, 7 del código de Freeman, los denotaremos como el grupo de pixeles G_8 . La unión de los grupos G_4 y G_8 conforman los ocho primeros vecinos de p , a los cuales los designaremos como el grupo G_8 , es decir $G_8 = G_4 \cup G_8$. Con base en estas definiciones, se establece lo siguiente: Sea p el pixel de referencia de coordenadas (i,j) y q un pixel próximo a él. Se dice que p y q están bajo **Conectividad - 4**, cuando q pertenece al grupo G_4 . Se dice que p y q están bajo **Conectividad - 8**, cuando q pertenece al grupo G_8 .

2.3.2.2 Área.

El área de cada parche, seguramente es el más sencillo, importante y útil fragmento de información. El área es la base de muchas métricas del paisaje. La cual se encuentra expresada en metros cuadrados. Se debe tener en cuenta que ésta métrica varía según el tipo de conectividad, ya sea 4 u 8, seleccionada entre sus pixels vecinos.

Lira (2010) define el **área** de un objeto como el número de pixels que forman a dicho objeto multiplicado por la escala a la cual se le observa, es decir, el tamaño asociado al pixel. Lira (2010) menciona la importancia de anotar que en conectividad 8 se pueden presentar ambigüedades que hacen que la evaluación del área presente inconsistencias en el estudio de patrones. La Figura 2.8 ejemplifica un parche cuya área es de 15 suponiendo una escala de 1.




Figura 2.8. Imagen que muestra en grises los pixels de un objeto segmentado (parche).

Es importante mencionar que las métricas de área tienen limitaciones impuestas por la escala de investigación. El tamaño mínimo del parche y la extensión del paisaje establece los límites superior e inferior de esas métricas de área respectivamente. Estos son los límites críticos para reconocer, porque establecen el límite inferior y superior de resolución para el análisis de la composición y configuración del paisaje (McGarigal, 2014).

2.3.2.3 Perímetro.

El perímetro al igual que el área es una pieza fundamental que provee información acerca del paisaje o imagen en análisis. El perímetro en un parche, es tratado como un borde. Junto con el área, el perímetro del parche es la base para la mayoría de las métricas del paisaje.

Para poder evaluar el perímetro es necesario en primera instancia, establecer la conectividad que guardan los pixels que lo componen. En conectividad 4 se cuenta el número de lados que tienen los pixels del borde del objeto, mientras que en conectividad 8

se calcula la distancia entre los centros de tales pixels. De tal modo, un objeto formado por un solo pixel tendría un perímetro de 4 bajo conectividad 4 y de cero bajo conectividad 8; por lo tanto, se adopta la convención que para un único pixel el perímetro es de $\sqrt{2}$ bajo conectividad 8. Los resultados de los cálculos deben ser multiplicados por la escala de observación (Lira, 2010). A diferencia del área, el perímetro es un rasgo sensible al ruido en la imagen, el contorno del objeto se vuelve más rugoso y/o más largo; esto implica tener cuidado cuando se realiza comparaciones de perímetros de objetos en distintas imágenes. El perímetro del objeto de la Figura 2.8 es de 24 suponiendo una escala de 1 y bajo una conectividad 4, sin embargo bajo una conectividad 8 el valor del perímetro sería de $4 + 8\sqrt{2} = 15.3137$.

2.3.2.4 Razón Perímetro-Área

El descriptor morfológico de la Razón Perímetro-Área (PARA) es una simple medida de la complejidad de forma, pero sin estandarización a una forma euclidiana. La ecuación de la Razón Perímetro-Área es el cociente del perímetro (P_{ij}) de un parche (i,j) sobre su área (a_{ij}), como se muestra a continuación.

$$\text{PARA} = \frac{P_{ij}}{a_{ij}} \quad (2.3)$$

La unidad de medida de PARA es 1/m y su intervalo de medida es mayor a cero sin límite alguno. Un problema con esta métrica del paisaje es que varía con el tamaño del parche, por ejemplo imaginemos un parche de forma constante, un incremento de su tamaño causará una disminución en el valor de la razón PARA.

2.3.2.5 Índice de Forma

La ecuación de la métrica Índice de Forma (FORMA) se establece como el cociente del perímetro (m) de un parche entre la raíz cuadrada del área (m^2) del parche:

$$\text{FORMA} = \frac{.25P_{ij}}{\sqrt{a_{ij}}} \quad (2.4)$$

Este descriptor morfológico se encuentra adaptado por una constante de ajuste que estandariza la forma geometría de un cuadrado. Es una métrica sin unidades de medida. El

rango de medición para el Índice de Forma es igual o mayor a uno. Cuando FORMA es igual a uno su forma geométrica corresponde a un cuadrado, al incrementar su valor la forma del parche se torna más irregular.

El índice de forma corrige el problema del tamaño del parche presente en la métrica del paisaje PARA, esto lo logra mediante el ajuste de la estandarización a un cuadrado, por consiguiente, se convierte en una de las métricas más simples, y a la vez de gran eficacia al dimensionar de manera directa la complejidad de la forma de un parche. Este índice de forma es ampliamente aplicable en la investigación ecológica del paisaje (Forman y Godron, 1986).

2.3.2.6 Índice de Dimensión Fractal

Uno de los modelos que ha sido utilizado para cuantificar la complejidad de la forma de cualquier objeto, que sin duda arroja excelentes resultados, es la Dimensión Fractal (FRAC).

Mandelbrot (1977-1982) introdujo el concepto de fractal, una forma geométrica que presenta la estructura en todas las escalas espaciales, y propuso un método perímetro-área para calcular la dimensión fractal de formas planas naturales. El método perímetro-área cuantifica el grado de complejidad de las formas planas. El grado de complejidad de un polígono se caracteriza por la dimensión fractal (D), de tal manera que el perímetro (P) de un parche está relacionada con el área (A) del mismo parche por $P \approx \sqrt{A^D}$ es decir, $[\log(P) \approx \frac{1}{2}D \log(A)]$. Para formas euclidianas simples (por ejemplo, círculos y rectángulos), $P \approx \sqrt{A}$ y $D = 1$ (la dimensión de una línea). Como los polígonos se hacen más complejos, el perímetro rellena cada vez más la superficie de un parche y $P \approx A$ con $D \rightarrow 2$. Utilizamos esta relación para calcular la dimensión fractal de cada parche por separado. Se debe tener en cuenta que el valor de la dimensión fractal calculado de esta manera depende de tamaño del parche y/o las unidades empleadas (Rogers, 1993). Por lo tanto, variando el tamaño de celda de la imagen de entrada afectará a la dimensión fractal del parche. Por esa razón, se debe tener precaución al utilizar este índice dimensión fractal como una medida de la complejidad forma de parche.

La ecuación de la métrica FRAC es el cociente de dos veces el logaritmo del perímetro del parche (m) entre logaritmo del área (m²) del parche. Una modificación a la expresión de dimensión fractal (Olsen *et al.*, 1993), adecuada a una imagen digital, se expresa en la siguiente ecuación:

$$\mathbf{FRAC} = \frac{2\ln(.25P_{ij})}{\ln(a_{ij})} \quad (2.5)$$

Al igual que la métrica PARA, la Dimensión Fractal tiene dimensiones 1/m, como ya se mencionó, depende de la escala de observación del objeto bajo estudio. Si el objeto de interés contiene un solo pixel, con unidad igual a uno, la ecuación 2.5 queda indefinida. Suponiendo que un pixel es el objeto espacial más simple que existe en una imagen, se admite como definición que FRAC es igual a uno para este caso (Lira, 2010).

El intervalo de los valores correspondientes a la dimensión fractal oscila entre 1 y un valor máximo. Los valores máximos del índice de dimensión fractal de un parche representan mayor complejidad en su forma, mientras que los valores cercanos a 1 indican la similitud de la forma geométrica de un cuadrado. Es importante señalar que el índice de dimensión fractal es muy sensible para distinguir formas irregulares y complejas que difieren muy poco entre sí (Lira,2010).

2.3.2.7 Relación Círculo Circunscrito

El índice de Relación Círculo Circunscrito (RCC) compara el área del parche con el área del círculo más pequeño que pueda circunscribir el parche (Baker y Cai, 1992). La métrica del paisaje RCC proporciona una medida de la elongación general de un parche. La ecuación para cada elemento está definida como 1 menos el área del parche (a_{ij}) dividido por el área del círculo circunscrito más pequeño (a_{ij}^s):

$$\mathbf{RCC} = 1 - \left[\frac{a_{ij}}{a_{ij}^s} \right] \quad (2.5)$$

El área del círculo circunscrito más pequeño (a_{ij}^s) se calcula matemáticamente con base en un verdadero círculo, a pesar del formato digital de la imagen. Para asegurar que el

valor mínimo sea siempre cero, el diámetro del círculo que circunscribe se calcula como la distancia máxima entre los pixels de la periferia basados en la distancia de borde-a-borde, a diferencia de la distancia de centro-a-centro del pixel, la cual se usa en todos los cálculos de vecinos más cercanos.

La Relación Círculo Circunscrito emplea el círculo circunscrito más pequeño en lugar del cuadrado circunscrito más pequeño, a pesar del formato de la imagen digital, esto se debe a que es más simple su implementación. El índice RCC proporciona una medida de la elongación o alargamiento general del parche.

El índice de RCC varía entre cero y uno. Un parche de forma muy compleja, pero estrecho, tendrá un valor del índice RCC cercano a cero, por el contrario, un parche alargado tendrá un valor cercano a uno. Este descriptor morfológico es de gran utilidad para discernir a los parches que son estrechos de los alargados; es una métrica del paisaje que no está influenciada por el tamaño del parche.

2.3.2.8 Índice de Contigüidad

Otro método de evaluación de la forma de un parche es el Índice de Contigüidad (CONTIG), el cual se basa en la conexión espacial o contigüidad. El índice CONTIG evalúa la conectividad espacial o contigüidad de los pixels dentro de un parche para proporcionar un valor de la configuración del contorno del parche y por consiguiente de la forma del parche.

Para el cálculo de CONTIG, es necesario primero obtener el valor de Contigüidad. Este se cuantifica mediante la convolución de una ventana cuadrada de 3 x 3 pixels con una imagen digital binaria, en la cual los pixels dentro del parche de interés se les asigna un valor de 1 y los pixels de fondo (todos los otros tipos de parches) se les da un valor de cero. En la ventana cuadrada (3x3) se designa un valor de 2 para cuantificar las relaciones de pixels horizontales y verticales (direcciones 0, 2, 4 y 6 del código de Freeman) dentro de la imagen y se asigna un valor de 1 para cuantificar las relaciones diagonales (direcciones 1, 3, 5, 7 del código de Freeman), véase Figura 2.9.

1	2	1
2	1	2
1	2	1

Figura 2.9. Ventana que convoluciona a la imagen digital, para medir el valor de Contigüidad.

Esta combinación de valores enteros hace que los pixels ortogonalmente contiguos tengan mayor peso que los pixels contiguos en diagonal. Al pixel central de la ventana se le asigna el valor de 1, esto para asegurar que el parche de un sólo pixel, tenga el valor de 1 en la imagen de salida y no de 0. El valor de cada pixel en la imagen de salida, se calcula cuando el centro de la ventana de corrimiento es una función del número y el lugar de pixels de la misma clase dentro de las nueve celdas de la imagen. Específicamente, el valor de contigüidad para un pixel, en la imagen de salida, es la suma de los productos de cada valor de la ventana y el valor del pixel de la imagen de entrada correspondiente, dentro de la vecindad de las nueve celdas de la ventana (LaGro, 1991).

El índice CONTIG es igual al valor medio de contigüidad de los pixels en un parche, es decir la suma de los valores de los pixels divididos por el número de pixels en el parche, menos 1, dividido por la suma de los valores de una ventana de corrimiento (13 en este caso) menos 1. El hecho de restar en el numerado y denominador 1, confina al rango del índice entre 0 y 1 (McGarigal, 2014).

$$\text{CONTIG} = \frac{\left[\sum_{r=1}^z c_{ijr} \right] - 1}{a_{ij}^* - 1} \quad (2.6)$$

donde:

c_{ijr} es el valor de la contigüidad para el pixel r en el parche (i,j)

v es la suma de los valores en una ventana de 3 x 3.

a_{ij}^* es el área del parche (i,j) en términos del número de pixels.

2.3.3 Clasificación

La clasificación de las características de la superficie terrestre, con imágenes satelitales es la aplicación más importante de la percepción remota. Realizar una clasificación manualmente, a menudo, resulta muy difícil, además de que tomaría demasiado tiempo. Es por ello, que muchos investigadores han recurrido a técnicas del campo estadístico y de *machine learning* para desarrollar clasificadores automatizados.

En imágenes digitales, la clasificación se puede definir como el proceso por el cual un conjunto de datos o pixels son identificados y etiquetados como pertenecientes a una clase de acuerdo a un criterio y una regla de decisión (Lira, 2010).

Los pixels son la unidad más pequeña y elemental de una imagen. Las clasificaciones *supervisada* y *no supervisada*, son las técnicas empleadas más comunes y están basadas en el valor espectral del pixel. Sin embargo, la clasificación basada en objetos ha surgido como una alternativa interesante. Esta técnica permite el trabajo de clasificación de la imagen a nivel objeto, lo cual amplía notablemente la cantidad de información que se puede extraer de la misma.

2.3.3.1 Clasificación espectral

La clasificación espectral se basa en la suposición de que cada objeto o materia presente en la escena está caracterizado por su respuesta espectral, llamada también firma espectral. Con base en la firma espectral un objeto puede ser asignado a una clase con características espectrales similares.

Existen dos amplios procedimientos en la clasificación espectral: *supervisado* y *no supervisado*, las cuales se explican a continuación.

Clasificación no supervisada

Este tipo de clasificación se lleva a cabo por medio de agrupamientos llamados *clusters* o cúmulos. La clasificación no supervisada tiene como finalidad encontrar grupos formados por pixels con valores espectrales similares. El procedimiento requiere dos parámetros de entrada, definidos por el usuario 1) las bandas espectrales a usar y 2) el número de cúmulos

o clases que se desean generar; con esta información, los algoritmos de *clustering* realizan la clasificación de la imagen. Además del problema de determinar de antemano el número de grupos a producir, muchos algoritmos también requieren el establecimiento de un valor umbral que determina los límites de las agrupaciones, es decir, que tan cerca, en el sentido de la medida de proximidad definida, dos puntos de datos necesitan estar con el fin de clasificarse en el mismo grupo. Los diferentes valores del umbral producirán diferentes agrupamientos. Por ejemplo, si la tarea es a agrupar pixels o datos en un plano, como los de la Figura 2.10, se debe determinar la distancia deseada por debajo de la cual, los puntos de datos están incluidos en el mismo grupo. El valor del umbral se puede establecer por una distancia absoluta o alguna medida relativa.

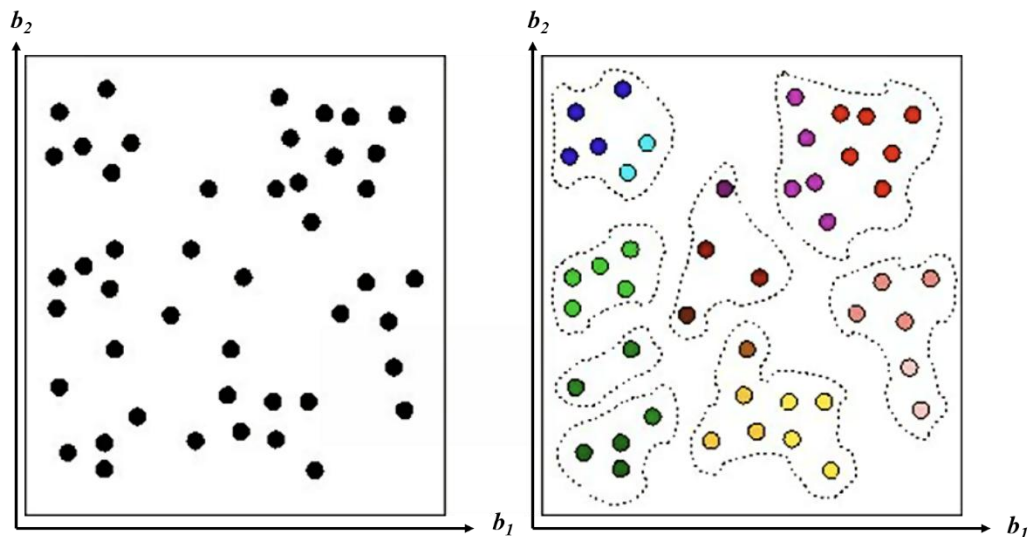


Figura 2.10. A la izquierda se muestra un conjunto o nube de pixels, los cuales pueden ser agrupados de varias maneras, dependiendo del objetivo de la función empleada. A la derecha se muestra un posible agrupamiento de los pixels. Los ejes b_1 y b_2 representan a las bandas espectrales.

Una imagen multiespectral de γ bandas se encuentra referida a un espacio de γ dimensiones cuyos ejes tienen un intervalo igual a los valores espectrales de las bandas, por lo tanto estos valores se convierten en las coordenadas de los pixels, los cuales, al graficarlos, forman una nube de puntos (véase Figura 2.10). Es esta nube de puntos, es la que se dividirá para formar clases.

Existen dos tipos de técnicas para realizar un análisis de cúmulos: método de optimización y método jerárquico.

Método de optimización. Este método consiste en producir un número fijo de cúmulos, digamos k . El número k puede estar preestablecido o puede ser obtenido como parte del proceso. En la mayoría de los casos el método inicia con una agrupación de pixels en cúmulos o una selección inicial de puntos semilla que forman el centroide de los cúmulos. Los algoritmos más comunes son: de k -medias, *Isodata* y *logica difusa c-medias*.

Método jerárquico: Este método tiene por objetivo agrupar *clusters* para formar uno nuevo o bien, separa alguno ya existente para dar origen a otros dos, de tal forma que, si sucesivamente se va efectuando este proceso de aglomeración o división, se minimiza alguna distancia o bien se maximiza alguna medida de similitud.

Los métodos jerárquicos se subdividen en aglomerativos y divisivos. Los métodos aglomerativos, comienzan el análisis con tantos grupos como pixels u objetos hayan. A partir de estas unidades iniciales se van formando grupos de forma ascendente, hasta que al final del proceso todos los casos tratados están englobados en un mismo *cluster*. Por el contrario, los métodos divisivos constituyen el proceso inverso al anterior. Comienzan con un conglomerado que engloba a todos los datos o pixels tratados y, a partir de este grupo inicial, a través de sucesivas divisiones, se van formando grupos cada vez más pequeños. Al final del proceso se tienen tantas agrupaciones como pixels u objetos han sido tratados.

Clasificación supervisada

La clasificación supervisada es similar al análisis de cúmulos o clasificación no supervisada en el sentido de que la nube de puntos es particionada en un cierto número de cúmulos o clases. La diferencia estriba en el uso de pixels prototipos de cada clase definida de antemano.

La esencia de la clasificación supervisada es que el analista adquiere previamente un conjunto de muestras representativas para cada una de las clases de interés en la imagen multiespectral. Estas áreas seleccionadas se denominan “campos de entrenamiento”. Los

datos de entrenamiento se utilizan para estimar a los parámetros u otras constantes requeridas para operar el algoritmo de clasificación supervisada elegido.

Elegir un clasificador o una regla de decisión depende de la naturaleza de los datos de entrada y de los datos de salida deseados. Los algoritmos de clasificación supervisada pueden ser paramétricos o no paramétricos. Los paramétricos suponen que los vectores de medida X_c obtenidos para cada clase en cada banda espectral, durante la fase de entrenamiento, son Gaussianos, es decir, están normalmente distribuidos. Los algoritmos no paramétricos no hacen tal suposición (Chandra y Ghosh, 2006).

Una vez que los parámetros o constantes apropiadas han sido estimados empleado los datos de entrenamiento, el algoritmo está listo para ser empleado en los pixels de prueba, a eso comúnmente se le llama que se está capacitando el algoritmo (Richards, 2013).

Los algoritmos de clasificación supervisada más usados son el del *paralelepido* y el de *máxima verosimilitud*. El paralelepido se basa en la lógica booleana simple “y/o”. La regla de decisión del algoritmo de máxima verosimilitud está basado en la probabilidad de ocurrencia de un pixel (Chandra y Ghosh, 2006).

La salida, desde en el contexto de una clasificación espectral, ya sea la supervisada o no supervisada, arroja un mapa temático de etiquetas de clase. Tal mapa temático es a menudo acompañado por una tabla de estimaciones de superficie y una matriz de error que indica, por clase, el error residual, o la precisión del producto final. Esto último es una manera de cuantificar la precisión de la partición de la imagen representada en el mapa temático. La matriz de error puede calcularse empleando una métrica de la distancia espectral entre las regiones, dicha métrica se establece a partir del mismo modelo de comportamiento espectral de las clases involucradas en la segmentación. Un modelo de segmentación espectral es mejor entre mayor separabilidad espectral genere. Inversamente, los parámetros involucrados en la segmentación pueden ser optimizados en función de tal separabilidad. Por otro lado, la separabilidad está relacionada con otros factores relativos a la imagen: la relación señal/ruido, la correlación que presentan entre sí las bandas, la resolución espacial y radiométrica y la definición o agudeza de los bordes (Lira, 2010).

2.3.3.2 Clasificación basada en objetos

La clasificación convencional de imágenes de satélite se basa en la asignación de los píxeles a determinadas clases temáticas. Este sistema, presenta un problema asociado a la resolución espacial de las imágenes. Los píxeles de borde o mixtos, representan mezclas de dos o más tipos de coberturas. Esto es motivo de las principales causas de error de asignación y, por consecuencia, de la pérdida de precisión en la cartografía temática generada. Una solución posible a este problema es la clasificación basada en objetos, que brinda una aproximación operativa aprovechando las características intrínsecas de los objetos presentes en la escena (Perea *et al.*, 2009).

En general, el proceso de clasificación orientado a objetos puede dividirse dentro de dos principales pasos, la segmentación multi-resolución (Benz *et al.*, 2004) y la clasificación basada en el conocimiento de los segmentos (Xiaoxia., *et al.*, 2005).

La clasificación orientada a objetos inicia con la segmentación de la imagen en objetos característicos. La segmentación debe realizarse buscando generar objetos que a diferentes escalas y en una misma estructura, permitan combinar sus resultados y modelar características y patrones de interés que representan información significativa de la escena. La segmentación en múltiples resoluciones, permite solventar este obstáculo y generar así diferentes niveles de segmentación que contienen objetos generados con diferentes parámetros de homogeneidad (Blaschke *et al.*, 2008)

Los objetos de una imagen presentan y albergan información de ellos mismos, es decir tienen características o atributos que definen su estado, cada objeto en la red posee atributos intrínsecos que definen características inherentes al objeto como su área y forma. También posee atributos semánticos que describen relaciones contextuales a otros objetos, tales como la existencia o no de un cierto tipo de objetos en un nivel determinado de la estructura. Y atributos topológicos, que describen relaciones geométricas y de ubicación del objeto con respecto a los demás objetos dentro de la red, tales como la distancia a un cierto objeto o la longitud del perímetro que se comparte con otro. Es a partir de este conjunto de atributos que se formulan las características de las clases temáticas de interés y que permiten llevar a cabo la clasificación de los objetos (Ardila, *et al.*, 2005)

La clasificación se torna entonces en un proceso en el que se busca uno o más atributos que permitan la discriminación de objetos que presentan un determinado comportamiento. Los objetos son asignados finalmente a las clases de interés de acuerdo con la evaluación de las reglas o restricciones basadas en atributos que se generan para cada clase de acuerdo con una lógica difusa o booleana.

Capítulo 3

Métodos y Materiales



Patrones de onda en el Lago Erie, 2012.

En este capítulo se describen las condiciones geográficas de los casos de estudio, donde se aplicó la clasificación multivariada. Asimismo, se detallan los aspectos técnicos de las imágenes empleadas. Además, se presentan las técnicas de segmentación y el proceso metodológico específico de cada imagen para lograr los objetivos planteados.

3.1 Descripción de los casos de estudio

El método propuesto en esta investigación fue aplicado a imágenes de diferentes sensores y resoluciones. Se emplearon las imágenes de los sensores: Landsat TM-4, Terra/Aster, SPOT-5 y TerraSar X. La información técnica de las imágenes mencionadas se encuentra en la Tabla 3.1

Imágenes Multiespectrales					
Imagen	Plataforma	Fecha de adquisición	Tamaño de Pixel	Bandas empleadas (µm)	Tamaño de la imagen (pixels)
Ciudad de México	Landsat TM 4	Abril 01 del 2001	28.5 x 28.5 m ²	1) [0.45-0.52] 2) [0.52-0.60] 3) [0.63-0.69] 4) [0.76-0.90] 5) [1.55-1.75] 7) [2.08-2.35]	Original: 6907x6299 Recorte: 2883x2964
Ciudad de México	Landsat TM 4	Marzo 07 de 1989	28.5 x 28.5 m ²	1) [0.45-0.52] 2) [0.52-0.60] 3) [0.63-0.69] 4) [0.76-0.90] 5) [1.55-1.75] 7) [2.08-2.35]	Original: 7784x7379 Recorte: 2883x2964
Ciudad de México	SPOT 5	Diciembre 11 del 2003	10 x 10 m ²	1) [0.50-0.59] 2) [0.61-0.68] 3) [0.79-0.89] 4) [1.58-1.75]	6000 x 6000
Campos de Cultivos	Terra/Aster	Febrero 18 del 2001	15 x 15 m ²	1) [0.52-0.60] 2) [0.63-0.69] 3) [0.76-0.86]	1300 x 1300
Cuerpos de agua de Tabasco	Terra/Aster	Marzo 13 del 2001	Bandas remuestreadas a 30 x 30 m ²	1) [0.52-0.60] 2) [0.63-0.69] 3) [0.76-0.86] 4) [1.60-1.70] 5) [2.145-2.185] 6) [2.185-2.225] 7) [2.235-2.285] 8) [2.295-2.365] 9) [2.360-2.430]	1544x2356
Imagen de Radar					
Imagen	Plataforma	Fecha de adquisición	Tamaño de Pixel	Banda Empleada Polarización No. de looks	Tamaño de la imagen
Inundación Tabasco	Terrasar	Noviembre 06 del 2007	Remuestreado a 25 x25 m ²	3.1 cm Banda x Polarización HH 1 look	Original: 33,600 x 50,800 Recorte 1680 x 2540

Tabla 3.1. Información Técnica de las imágenes empleadas en el proyecto de investigación.

Diferentes escenas, como las ciudades por su complejidad en su crecimiento, las zonas de humedales y los campos de cultivo, son ejemplos significativos para estudiar su estructura morfológica y aplicar una clasificación de acuerdo a las métricas que describen a los parches, quienes conforman dichas escenas. El primer ejemplo, donde se aplicó la clasificación multivariada propuesta, fue la Ciudad de México.

3.1.1 Caso 1: Ciudad de México

Geografía del Distrito Federal

La Ciudad de México, Distrito Federal, es sólo una parte de la **Zona Metropolitana del Valle de México (ZMVM)**, la cual cuenta con una población mayor a los 20 millones de habitantes e incluye a las 16 delegaciones del Distrito Federal, a 59 municipios aglomerados del Estado de México y a un municipio del Estado de Hidalgo, véase Figura 3.1. La Zona Metropolitana del Valle de México, se encuentra localizada desde el punto de vista geográfico en la Cuenca del Valle de México, ubicada en la parte sur de la Mesa Central entre los paralelos 19° 03' 53'' y 20° 11' 09'' de latitud norte y entre los meridianos 98° 11' 53'' y 99° 30' 24'' de longitud oeste, presenta valles intermontañosos, mesetas, y cañadas, así como terrenos semiplanos, en los que alguna vez fueron los lagos de Texcoco, Xochimilco y Chalco. La ZMVM es considerada una de las 10 metrópolis más grandes del mundo y la primera de Latinoamérica (Brinkhoff, 2015).

El Distrito Federal (D.F.) es la capital de los Estados Unidos Mexicanos y es el núcleo urbano más grande del país. Según el Instituto Nacional de Estadística y Geografía la población del D.F. en el año 2010 era de 8 851 080 habitantes. El D.F. se ubica entre las coordenadas 19° 25' 10'' de latitud norte y 99° 08' 44'' de longitud oeste, a una altura media de 2 240 msnm. La superficie territorial del Distrito Federal abarca 1 495 km², lo que equivale el 0.1 % del territorio nacional (INEGI).

El relieve se define principalmente por una sierra y un valle, la primera se localiza al oeste, extendiéndose del noroeste al sureste y la conforman rocas de origen ígneo extrusivo producto de la formación de volcanes como: Tláloc, Cuautzin, Pelado, Teuhtli, Chichinautzin y el de mayor altitud la Cruz de Márquez o Ajusco con 3 930 msnm. En el

centro-oeste, hay un lomerío que separa al valle que se extiende desde el centro hasta el este. La planicie del valle es interrumpida por el cerro de Chapultepec, cerro de la Estrella, volcán Guadalupe y cerro del Chiquihuite. Las principales corrientes de agua son, Ríos: Mixcoac (entubado), Churubusco (entubado), Los Remedios, La Piedad (entubado), Tacubaya y Becerra (INAFED).

En la mayor parte del territorio del Distrito Federal se presenta clima templado subhúmedo (87%), en el resto se encuentra clima seco y semiseco (7%) y templado húmedo (6 %). La temperatura media anual es de 16°C. Las lluvias se presentan en verano, la precipitación total anual es variable: en la región seca es de **600 mm** y en la parte templada húmeda (Ajusco) es de **1 200 mm** anuales (INEGI).

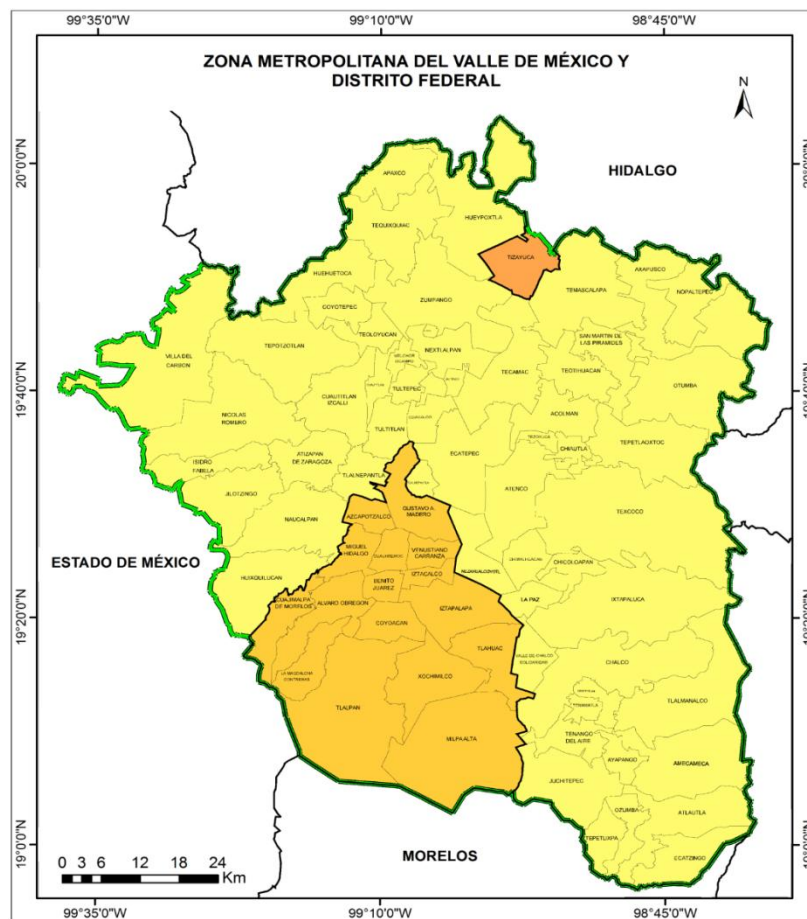


Figura 3.1. Zona Metropolitana del Valle de México y Distrito Federal. (Adaptado de FEESCM, 2000)

Descripción de las imágenes Landsat TM - Ciudad de México

El área seleccionada para el análisis de *la Ciudad de México* corresponde a dos subimágenes de 2 883 x 2 964 pixels, extraídas de imágenes multispectrales Landsat TM-4, las cuales cubren la zona urbana de la ciudad de México. La columna/renglón de las imágenes pertenecen al 26/47 y se encuentran georreferenciadas entre las coordenadas geográficas 19° 36' 25.09" N, 99° 26' 56.06" O (esquina noroeste) y 19° 04' 14.55" N, 98° 58' 34.14" O (esquina sureste). La fecha de adquisición de la primera imagen es del 7 de marzo de 1989 y de la segunda del 1 de Abril del 2001. La resolución espacial, la cual corresponde al tamaño de pixel, es de 28.5 m².

Por fines prácticos, en este trabajo se denomina como *Ciudad de México* y por lo tanto como área espacial de trabajo, a toda la mancha urbana continua, considerando al Distrito Federal y parte del área Metropolitana. La Figura 3.2 muestra la imagen Landsat TM-4 adquirida en el 2001. La imagen se visualiza en falso color, donde la composición RGB pertenece a las bandas 7, 4 y 2 respectivamente; en ella se aprecia la zona urbana, vegetación, suelo, cuerpos de agua y áreas de cultivo.

Descripción de la imagen *Ciudad de México – SPOT-5*

La imagen analizada SPOT-5 de la Ciudad de México corresponde a una imagen de 6 000 x 6 000 pixels, la cual cubre la zona urbana de la Ciudad de México. Se encuentra localizada de la siguiente manera:

Esquina	Latitud	Longitud	No. Pixel	No. Línea
1	19°50'54" N	99°18'8" O	1	1
2	19°42'36" N	98°42'7" O	6000	1
3	19°10'53" N	98°50'20" O	6000	6000
4	19°19'10" N	99°26'45" O	1	6000

La fecha de adquisición corresponde al 11 de Diciembre del 2003. Su resolución espacial es de 10 m. Esta imagen cuenta con cuatro bandas espectrales. El ángulo de orientación de la imagen es de 13.480537 grados y su ángulo de incidencia corresponde a 118.0554329 grados.




Figura 3.2. Composición de falso color RGB 742, de la imagen Landsat TM-4, 2001 perteneciente a la Ciudad de México.

3.1.2. Caso 2: Campos de Cultivo Irapuato.

El municipio de Irapuato se encuentra en la región suroeste de Guanajuato, teniendo como límites las coordenadas geográficas de $101^{\circ}08''$ y $101^{\circ}34'$ de longitud oeste y a las coordenadas $20^{\circ}30'$ y $20^{\circ}51'$ de latitud norte. Su extensión territorial es de 786.4 km^2 , que representa aproximadamente el 2.6% de la superficie total del Estado. El municipio de Irapuato colinda al norte con los municipios de Silao y Guanajuato al este con el municipio de Salamanca, al sur con los municipios de Pueblo Nuevo y Abasolo, y al oeste con los municipios de Abasolo y Romita. (INEGI, 2010). Véase Figura 3.3.

El municipio se distingue por tener un clima sub-húmedo, que hacia el poniente pasa a semi-cálido y hacia el norte a semi-seco. En las cumbres altas se dan climas semi-fríos sub-húmedos. En los extremos este y oeste de la sub-provincia se tienen condiciones cálidas subhúmedas en áreas reducidas. El mes más cálido se registra en mayo y el más frío en

enero (INEGI-INIDEG). El municipio de Irapuato está en la región hidrológica No. 12 Lerma-Chapala-Santiago; dicha región se divide en seis cuencas, y el municipio se localiza en la cuenca B río Lerma Salamanca, la cual drena una superficie de 10 391 665 km². Esta cuenca 12 B, tiene su origen en la presa Solís, por lo que el municipio de Irapuato está beneficiado por varios canales de riego. Se cuenta con la presa La Purísima. Asimismo, existen tres presas para el control de ríos: la Gavia, Chichimequillas y el Conejo II (INAFED-2).

El suelo de Irapuato está caracterizado por ser altamente propicio para la agricultura, pues su mayor parte tiene suelos profundos de más de 100 cm y sin pedregosidad; y aunque la precipitación es de 800 mm anuales, tiene sistemas de riego que permiten agricultura de este tipo y de temporal, así que desde el punto de vista agrícola es la más importante del Estado, debido a que en ella se encuentra la mayor superficie de agricultura de riego y está considerada como la de mayor producción en el ámbito nacional, ya que el uso que se le da a la producción es básicamente comercial. También, es una zona con condiciones climáticas buenas para el desarrollo de praderas cultivadas y vegetación de pastizal, por lo que tiene altas posibilidades de uso pecuario. Las posibilidades de aprovechamiento económico, definitivamente son agrícolas y pecuarias (INAFED-2).

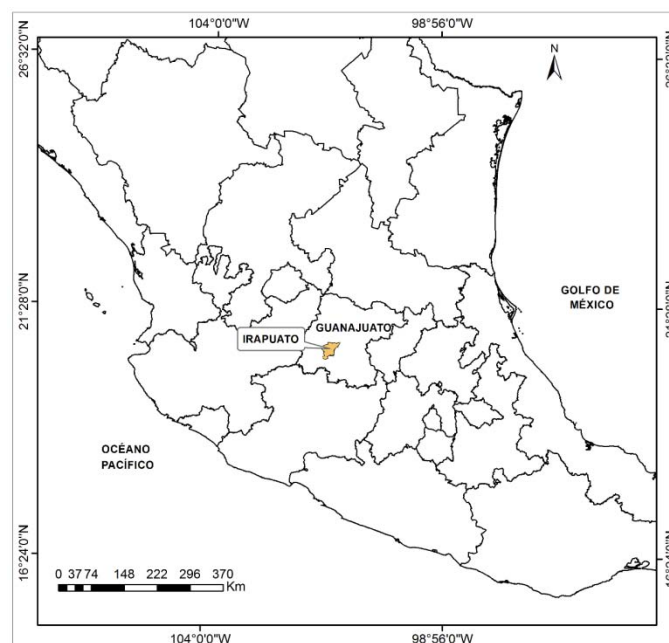


Figura 3.3. Localización del cuarto caso de estudio: Campos de Cultivo, Irapuato.

Descripción de la imagen Terra/Aster - Campos de Cultivo, Irapuato

Para el caso de los Campos de Cultivo, se consideró una imagen digital multiespectral Terra/Aster, con dimensión de 1 300 x 1 300 pixels. Las coordenadas geográficas de la imagen son 44' 38.04'' N, 101° 24' 32.23'' O (esquina noroeste) y 20° 35' 20.52'' N, 101° 17' 21.11'' O (esquina sureste). La imagen fue captada el 18 de febrero del 2001. Para este caso se emplearon sólo las tres primeras bandas de la imagen multiespectral, quienes tienen un tamaño de pixel de 15 x 15 m². La Figura 3.4 muestra una composición de falso color de la imagen multiespectral correspondiente a los campos de cultivo de Irapuato.




Figura 3.4. Composición de falso color de la imagen Aster/Terra. En rojo se muestran los campos agrícolas fuera de la ciudad.

3.1.3 Caso 3: Cuerpos de agua de Tabasco

Geografía de Tabasco

El Estado de Tabasco se localiza al sureste de la República Mexicana, sobre la llanura costera del Golfo de México, delimita geográficamente entre los 17°15' y 18°39' de latitud norte y los 91°00'-94°07' de longitud oeste. Tiene una extensión territorial de 24 661 km², representando el 1.3% del territorio nacional. Tabasco ocupa el decimosegundo lugar en superficie en la República, pero alberga en promedio el 23% de la biodiversidad nacional de vertebrados y el 53 % de los humedales de agua dulce de la nación (Barba *et al.*, 2006). Al norte limita con el Golfo de México y Campeche; al este con Campeche y la República de Guatemala; al sur con Chiapas y al oeste con Veracruz. Tabasco se encuentra dividido por sus características naturales en cinco subregiones, las cuales son: 1. Chontalpa, 2. Centro, 3. Sierra, 4. Pantanos y 5. Ríos (Barba *et al.*, 2006). En la Figura 3.5 se muestran las subregiones enumeradas en el orden aludido.

La subregión Chontalpa se ubica en la parte occidental del Estado, comprende una superficie de 746 289 ha, cuenta con una precipitación anual aproximada de 1 225 mm. La subregión Centro cubre una superficie de 259 380 ha; su precipitación anual es de 1 882 mm anuales y su vegetación original era de selva mediana perennifolia. La subregión Sierra, ubicada en la región centro-sur del Estado, abarca alrededor de 184 727 ha. En ella se encuentran elevaciones accidentadas menores de 1 000 m, su precipitación anual es de 3 711 mm en promedio y la vegetación predominante es la selva. La subregión Ríos es casi totalmente plana, con elevaciones menores a los 40 msnm, tiene una superficie de 603 408ha; y abarca la red hídrica influenciada por los ríos más largos de México el Grijalva y el Usumacinta; la precipitación anual es de 2 343. Se conservan zonas selváticas, aunque predominan sabanas y pastizales (INEGI-INIDEG-2). La subregión Pantanos suma una superficie de 663 568 ha, abarca ríos, manglares y arroyos; presenta una precipitación pluvial anual de 1 225 mm, dentro de esta subregión se encuentra la Reserva Biológica Pantanos de Centla declarada en 1992 (SERNAPAM).

La Reserva Biológica Pantanos de Centla, limita al norte con el Golfo de México en la desembocadura del río San Pedro y San Pablo y con la ciudad de Frontera; al este con el

Estado de Campeche; al sur con el río Los Bitzales hasta su unión con el río Grijalva; y al oeste con el arroyo Las Porfías y la carretera Villahermosa - Ciudad del Carmen. Su superficie es de 302 706 ha y ocupa los municipios de Centla (225 108 ha), Jonuta con (65 651 ha) y Macuspana (6 280 ha), lo que representa el 12.27% de la superficie total del estado Tabasco. Al centro, norte y este, la Reserva es drenada por distributarios del Usumacinta como son el Palizada, San Pedrito y San Pedro y San Pablo. Estas lagunas juegan un papel primordial en el ciclo de vida de muchas especies marinas y dulceacuícolas (Parks-Watch, 2003)



Figura 3.5. Subregiones de Tabasco

El segundo caso de estudio, donde se aplicó una clasificación multivariada de métricas del paisaje, lo denominamos "Cuerpos de agua de Tabasco". La zona abarca la subregión Centro y la subregión Pantanos, incluyendo una gran parte de la Reserva Biológica Pantanos de Centla, véase Figura 3.6.

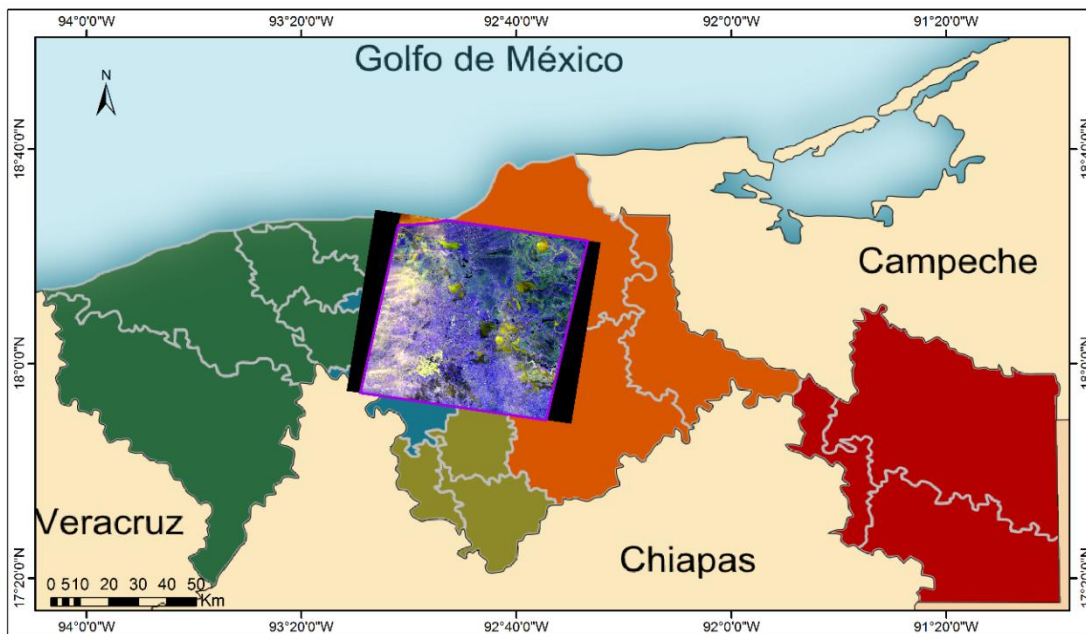


Figura 3.6. Localización del segundo caso de estudio: Cuerpos de agua de Tabasco

Descripción de la imagen Terra/Aster - Cuerpos de agua de Tabasco

La imagen que se empleó para realizar el análisis morfológico de los cuerpos de agua de Tabasco fue un recorte de dimensión 1 544 x 2 356 pixels de una imagen Terra/Aster. Sus coordenadas geográficas corresponden a 18° 27' 59.06'' N, 93° 01' 29.49'' O (esquina noroeste) y 17° 49' 37.55'' N, 92° 35' 15.55'' O (esquina sureste). La fecha de adquisición de la imagen fue el 13 de marzo de 2001.

La Tabla 2.1 del capítulo 2, muestra la resolución espacial de las plataformas Aster, la cual es de 15 m para las bandas 1-3, de 30 m para las bandas 4-9 y para las bandas 10-14 es de 90 m. Las bandas empleadas fueron del 1-9, por tal motivo los pixels de las bandas 1,2 y 3 se remuestrearon a un tamaño de 30 x 30 m². Las bandas 10-14 no fueron utilizadas. La imagen se geocodificó a una proyección UTM.

3.1.4 Caso 4: Inundación de Tabasco

La planicie central del Estado de Tabasco se encuentra bañada por dos importantes cuencas bajas de los ríos Grijalva y Usumacinta, los más caudalosos del país, con sus escurrimientos medios anuales de 58 900 y 46 300 millones de metros cúbicos, aportan

cerca del 33% de los recursos hidrológicos del país. (INEGI). La entidad es prácticamente una llanura húmeda aluvial terminante de una pendiente que emana en Centroamérica predisponiendo las tierras bajas a grandes precipitaciones pluviales y a escurrimientos serranos (West *et al.*, 1985). Esta condición predispone a la capital Villahermosa, y a zonas circundantes, a severas inundaciones extraordinarias. Esto se ha reflejado en las crecidas de proporciones desastrosas, las más recientes y de mayor impacto en 1980, 1999 y 2007.

La inundación en octubre del 2007 en el Estado de Tabasco, con cerca del 62% del territorio cubierto de agua y hasta el 75% de población damnificada en 679 localidades de 17 municipios del Estado, tuvo un grave impacto socioeconómico a nivel estatal, relacionado con las pérdidas y daños en la infraestructura (caminos y puentes), en sectores productivos (actividad agrícola, industria, entre otros), social (vivienda, salud, educación) y en términos ambientales; sin embargo, según la información oficial, no hubo decesos en vidas humanas. La cifra total de daños y pérdidas llegó a más de 3 billones de dólares americanos (33 215.8 millones de pesos, de acuerdo a ese año), con mayor impacto en el sector productivo (31.77%) en la agricultura (26.85%) y menor en el medio ambiente, con un 0.49% (Perevochtchikova y Lezama, 2010).

Entre las causas de esta devastadora inundación se discutieron aspectos naturales y otros, influenciados por la actividad humana (Perevochtchikova y Lezama, 2010):

- i) En primera instancia, las condiciones climáticas naturales de octubre-noviembre de 2007, con una lámina de la precipitación extrema asociada a los frentes fríos 2 y 4 en las cuencas alta y media del Río Grijalva-Usumacinta y que provocó la sucesión de avenidas en los ríos.
- ii) Características Geográficas. La mayor parte de la superficie de Estado de Tabasco tiene una altitud próxima al nivel del mar y está cubierta por material aluvial. La llanura costera, por su parte, es conformada por depósitos aluviales de carácter deltáico; que en la medida que avance y crece hacia el mar, pierde el gradiente (inclinación del terreno) y la capacidad de carga de las corrientes fluviales. Debido a esto, el flujo superficial se deshabilita en las crecidas, ocasionando desbordes y cambios de trayectoria de la red hidrográfica (Ortiz y Silke 2005).

- iii) Las condiciones específicas del subsuelo que dificultan la rápida infiltración del agua, induciendo el escurrimiento superficial de la mayor parte del volumen del agua en la planicie tabasqueña.
- iv) Los cambios en el uso del suelo y las condiciones morfológicas del terreno a nivel de toda la cuenca relacionados con la deforestación de selva tropical con fines de uso ganadero, industrial, actividad petrolera y expansión urbana.

El tercer caso de estudio corresponde a la inundación de Tabasco en el 2007, esta zona abarca la subregión Centro, parte de la subregión Sierra de Tabasco y una pequeña parte de Chiapas. La Figura 3.7 muestra la ubicación de la imagen de Radar empleada para este caso.



Figura 3.7. Localización del tercer caso de estudio: Inundación de Tabasco 2007

Descripción de la imagen Radar TerraSar X - Inundación de Tabasco

El análisis de la imagen de Inundación de Tabasco corresponde a una imagen de Radar de Apertura Sintética TerraSar X. Sus coordenadas geográficas son 18° 10' 10.49'' N, 93° 12' 16.55'' O (esquina noroeste) y 17° 43' 35.57'' N, 92° 49' 41.17'' O (esquina sureste). Su

fecha de adquisición corresponde al 6 de noviembre de 2007. El número de *looks* de la imagen es de 1 con una polarización HH (Horizontal-Horizontal). La imagen original contaba con una dimensión de 33 600 x 50 800 pixels y con un tamaño de pixel de 1.25 x 1.25 m². La imagen fue remuestreada a una dimensión de 680 x 2 540 pixels, con un tamaño de pixel de 20 x 20 m².

3.2 Proceso de segmentación

Como se mencionó en la sección 2.3.1, del capítulo 2, el procedimiento de segmentación consiste en la partición de una imagen en regiones homogéneas que la constituyen en una imagen segmentada. Los elementos esenciales de una imagen ya no son los píxeles individuales, sino conjuntos de píxeles conectados pertenecientes a la misma región.

El procedimiento de segmentación genera una imagen binaria con dos clases: los parches y el resto de la imagen. Los parches representan la estructura espacial de la clase que intervienen en cada caso de estudio. En esta sección, proporcionamos los detalles del procedimiento de segmentación que genera la imagen binaria conocida como *bitmap*.

3.2.1 Imágenes Landsat TM 4 y SPOT 5 - Ciudad de México

La segmentación de una ciudad resulta muy complicada debido a la variabilidad espectral dentro de ella. Para lograr la segmentación de la Ciudad de México se realizó una expansión canónica de las imágenes multispectrales Landsat TM y SPOT 5 en término de tres variables, las cuales fueron: intensidad, índice de vegetación de diferencia normalizada (NDVI) y textura. La intensidad se obtuvo por medio de una descomposición en componentes principales, siendo la intensidad la primera componente principal. El NDVI se obtuvo con las medidas de reflexión espectral adquiridas en la región del rojo e infrarrojo cercano. La textura de la ciudad se obtuvo por medio del operador divergencia (Lira y Rodríguez, 2008). Estas tres variables se usaron en un algoritmo *clustering* de lógica borrosa. Los *clusters* resultantes se agruparon hasta generar una imagen binaria, la cual contiene a los parches correspondientes a la zona urbana. La Figura 3.8, la Figura 3.9 y la Figura 3.10 muestran el resultado de la segmentación de la Ciudad de México en las imágenes Landsat TM y SPOT 5.




Figura 3.8. Segmentación de la ciudad de México, imagen Landsat TM 1989.




Figura 3.9. Segmentación de la ciudad de México, imagen Landsat TM 2001.




Figura 3.10. Segmentación de la ciudad de México, imagen SPOT 5 2003.

3.2.2 Imagen Terra/Aster - Campos de Cultivo Irapuato

El proceso de segmentación para los campos de cultivo de Irapuato fue posible ocupando solamente las primeras tres bandas de la imagen multiespectral Terra/Aster. Las bandas 1-3 se introdujeron en un algoritmo de agrupamiento de lógica borrosa para obtener la imagen binaria, la cual contiene los parches correspondientes a los campos agrícolas. La Figura 3.11 muestra el resultado de la imagen segmentada.




Figura 3.11. Imagen segmentada de los campos de cultivo del municipio de Irapuato.

3.2.3 Imagen Terra/Aster – Cuerpos de agua de Tabasco

Los cuerpos de agua abiertos que forman parte del Estado de Tabasco fueron segmentados utilizando una variante del análisis de componentes principales (Lira, 2006). El procedimiento fue el siguiente:

1. Se identificó en la imagen multispectral un conjunto de pixels pertenecientes a un cuerpo de agua.
2. Del conjunto seleccionado se generó la matriz de covarianza (K_w).
3. El kernel A_w generado de los eigenvectores de la matriz de covarianza K_w , se aplicó a toda la imagen:

$$\mathbf{g}_w(\mathbf{r}) = \mathbf{A}_w \mathbf{f}(\mathbf{r}) \quad (3.1)$$

donde $\mathbf{f}(\mathbf{r})$ es la imagen multispectral y $\mathbf{gw}(\mathbf{r})$ es la imagen resultante, en la cual los cuerpos de agua se resaltan.

4. Las primeras dos componentes principales resultantes de la ecuación 3.1 fueron utilizadas en un algoritmo de agrupamiento de lógica difusa. Los *clusters* o cúmulos resultantes se agruparon hasta obtener la imagen binaria. Esta imagen de salida contiene los parches relacionados a los cuerpos de agua. La imagen 3.12 muestra el resultado de la segmentación de los Cuerpos de agua de Tabasco.




Figura 3.12. Segmentación de la imagen Cuerpos de agua de Tabasco.

3.2.4 Imagen de Radar TerraSar X - Inundación de Tabasco

El proceso de segmentación para la imagen de Radar de apertura sintética, TerraSar, se describe a continuación:

1. Como primer paso se redujo el *speckle* de la imagen de radar aplicando el filtro geométrico (Lira y Frulla, 1998).

En un filtro geométrico el elemento estructural se concibe como una sonda que altera o cuantifica la estructura del objeto para un análisis, está basado en una operación interseca o no interseca aplicada a los perfiles de la imagen. Produce buenos resultados en imágenes con ruido de tipo *speckle*.

2. Se generó una imagen de texturas aplicando la matriz de co-ocurrencia a toda la imagen original. La matriz de co-ocurrencia trabajó con una ventana de 17x17, utilizando un descriptor de entropía. El descriptor de entropía tiene como función evaluar el contenido de información de textura en una imagen mono-espectral.

3. A la imagen resultante se le aplicó un umbral al histograma para obtener la imagen binaria de los cuerpos inundados y el resto de la imagen.

El umbral se refiere a un parámetro de uniformidad y es empleado para cuantificar la variación de los valores de las propiedades (espaciales y espectrales) caracterizadas por el criterio de uniformidad (Lira, 2010).

La imagen 3.13 muestra el resultado del proceso de segmentación para la imagen de radar correspondiente a la inundación de Tabasco en el 2007.




Figura 3.13. Imagen segmentada. Muestra los cuerpos de agua debidos a la inundación de Tabasco en al año 2007.

3.3 Normalización de variables

Las métricas del paisaje descritas en la sección 2.3.2 del capítulo 2, se utilizaron en combinación para realizar una clasificación multivariada. Las métricas cuentan con unidades e intervalos de medida diferentes. La tipificación o normalización de las variables resulta muy útil para eliminar su dependencia respecto a las unidades de medida empleadas. La normalización corresponde a una transformación lineal. La variable tipificada o normalizada expresa el número de desviaciones típicas que dista de la media de cada observación. Por ello, se puede comparar la posición relativa de los datos de diferentes distribuciones.

Cuando existen distribuciones asimétricas se deben emplear transformaciones no lineales. El objetivo de una transformación es generar una distribución de los valores de una métrica a una distribución aproximada a la normal. Entre las transformaciones no lineales más comunes se encuentran la exponencial, raíz cuadrada, logarítmica e inversa.

La normalización es necesaria para efectos de la clasificación. Si no se normaliza, la clasificación multivariada puede estar sesgada por la métrica con el intervalo más grande (véase Figura 3.14). La normalización evita el predominio de alguna de las métricas en el procedimiento de la agrupación (véase Figura 3.15). Las métricas se normalizaron a un intervalo de $[0, 10]$, ya que la gama de los valores métricos varían ampliamente.

El histograma de los valores de las métricas indica el tipo de transformación necesaria para normalizar la distribución de valores. La Figura 3.16 muestra un ejemplo del histograma de los valores de contigüidad para los campos de la agricultura de Irapuato, sin transformación alguna. Mientras que, la Figura 3.17 muestra el histograma de los valores de contigüidad con una transformación de tipo exponencial.




Figura 3.14. Ejemplo de la distribución de los valores de las métricas de área (AREA) y relación índice circunscrito (RCC) sin la aplicación de alguna transformación. Los datos corresponden a los parches que conforman al *bitmap* de los Campos de Cultivo.




Figura 3.15. Ejemplo de la distribución de los valores de las métricas de área (AREA) y relación índice circunscrito (RCC) aplicando una transformación logarítmica a la métrica AREA. Los datos corresponden a los parches que conforman al *bitmap* de los Campos de Cultivo. Se puede observar la importancia de realizar un análisis estadístico a los datos empleados.




Figura 3.16. Histograma del índice de Contigüidad, sin aplicar transformación alguna. Esta métrica del paisaje corresponde a los parches de la imagen Campos de Cultivo.




Figura 3.17. Histograma del índice de Contigüidad, después de aplicar una transformación exponencial. Esta métrica del paisaje corresponde a los parches de la imagen Campos de Cultivo.

3.4 Correlación de las métricas del paisaje.

La correlación estadística determina la relación o dependencia que existe entre las dos variables que intervienen en una distribución. Se calculó la matriz de correlación de las métricas del paisaje para cada caso de estudio descritos con anterioridad. La mayoría de las métricas se encuentran por debajo del 60% en grado de correlación. Se seleccionaron los grupos de métricas con menor a media correlación entre ellas, para llevar a cabo una clasificación multivariada. En seguida se muestran las tablas de correlación de las métricas del paisaje pertenecientes a los parches que componen cada caso de estudio.

	AREA	PERIM	PARA	FORMA	FRAC	RCC	CONTIG
AREA	1						
PERIM	0.9718	1					
PARA	0.6738	0.4879	1				
FORMA	0.8418	0.9435	0.1933	1			
FRAC	0.6848	0.8313	0.0320	0.9547	1		
RCC	0.2808	0.4219	0.2517	0.5796	0.6949	1	
CONTIG	0.7257	0.5513	0.9860	0.2674	0.0505	0.2250	1

Tabla 3.2. Correlación de las métricas de la imagen Ciudad de México 1989. Los valores sombreados representan las correlaciones más altas y en negritas los valores más bajos de correlación.

	AREA	PERIM	PARA	FORMA	FRAC	RCC	CONTIG
AREA	1						
PERIM	0.9757	1					
PARA	0.4687	0.2676	1				
FORMA	0.8947	0.9689	0.0416	1			
FRAC	0.7707	0.8854	0.1627	0.9601	1		
RCC	0.3260	0.4266	0.2610	0.5136	0.5955	1	
CONTIG	0.5683	0.3817	0.9626	0.1653	0.0285	0.2530	1

Tabla 3.3. Correlación de las métricas de la imagen Ciudad de México 2001.

	AREA	PERIM	PARA	FORMA	FRAC	RCC	CONTIG
AREA	1						
PERIM	0.9595	1					
PARA	0.7569	0.5689	1				
FORMA	0.6984	0.8708	0.1322	1			
FRAC	0.5050	0.7214	0.1054	0.9536	1		
RCC	0.1788	0.3793	0.3012	0.6504	0.7616	1	
CONTIG	0.7706	0.5861	0.9952	0.1525	0.0820	0.3012	1

Tabla 3.4. Correlación de las métricas de la imagen Cuerpos de agua de Tabasco.

	AREA	PERIM	PARA	FORMA	FRAC	RCC	CONTIG
AREA	1						
PERIM	0.9732	1					
PARA	0.7714	0.6046	1				
FORMA	0.8403	0.9419	0.3044	1			
FRAC	0.7092	0.8471	0.1128	0.9659	1		
RCC	0.2546	0.3794	0.1682	0.5235	0.6095	1	
CONTIG	0.7460	0.5778	0.9860	0.2788	0.0911	0.2043	1

Tabla 3.5. Correlación de las métricas de la imagen Inundación de Tabasco

	AREA	PERIM	PARA	FORMA	FRAC	RCC	CONTIG
AREA	1						
PERIM	0.9444	1					
PARA	0.8806	0.6859	1				
FORMA	0.4139	0.6891	0.0370	1			
FRAC	0.0938	0.4114	0.3635	0.9311	1		
RCC	0.2290	0.0110	0.4904	0.4719	0.6380	1	
CONTIG	0.8832	0.6974	0.9943	0.0102	0.3349	0.4997	1

Tabla 3.6. Correlación de las métricas de la imagen Campos de Cultivo.

Para visualizar la correlación entre las métricas, la Figura 3.18 muestra un ejemplo de dos métricas con baja correlación, que corresponden a la Dimensión Fractal (FRAC) e índice de Contigüidad (CONTIG), para 255 parches que conforman a la imagen Cuerpos de agua de Tabasco. En la Figura 3.19 se puede ver una distribución de las métricas Área (AREA) y Perímetro (PERIM) las cuales tienen una alta correlación entre sí.

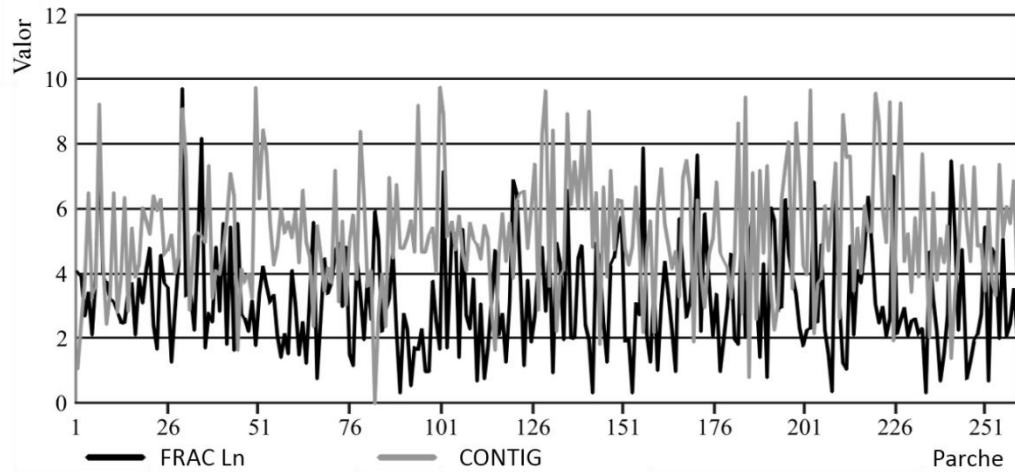


Figura 3.18. Baja correlación entre las métricas de Dimensión Fractal y Contigüidad, pertenecientes a la imagen Cuerpos de agua de Tabasco. Los valores de la métrica Dimensión Fractal tuvieron una transformación logarítmica previa.




Figura 3.19. Alta correlación de las métricas del paisaje Área y Perímetro pertenecientes a la imagen Cuerpos de agua de Tabasco. Los valores de ambas métricas se transformaron de manera logarítmica.

3.4 Clasificación Multivariada

El análisis multivariado, es un conjunto de métodos estadísticos que tienen por objeto el estudio de las relaciones existentes entre varias variables dependientes o independientes, que han sido medidas sobre los mismo objetos o individuos (Dagnelie, 1977).

La clasificación multivariada, empleada en esta investigación, es una clasificación de tipo no supervisada. Como se explicó en el capítulo 2, una clasificación no supervisada tiene como objetivo identificar grupos de objetos, en este caso parches, con características comunes, a partir de la observación de varias variables en cada uno de ellos. Las métricas del paisaje definidas en capítulo 2, secciones 2.3.2.2 - 2.3.2.8, se ocuparon para generar una clasificación multivariada, a partir de grupos de 2, 3 y hasta 4 métricas.

El grupo de métricas del paisaje seleccionadas se modelaron como un espacio vectorial de tantas dimensiones como el número de métricas de los parches que forman la imagen, cuyos ejes tienen una longitud igual al número de parches presentes en la imagen. De aquí que, el valor que tiene un parche según su métrica se convierte en su coordenada, véase Figura 3.20.

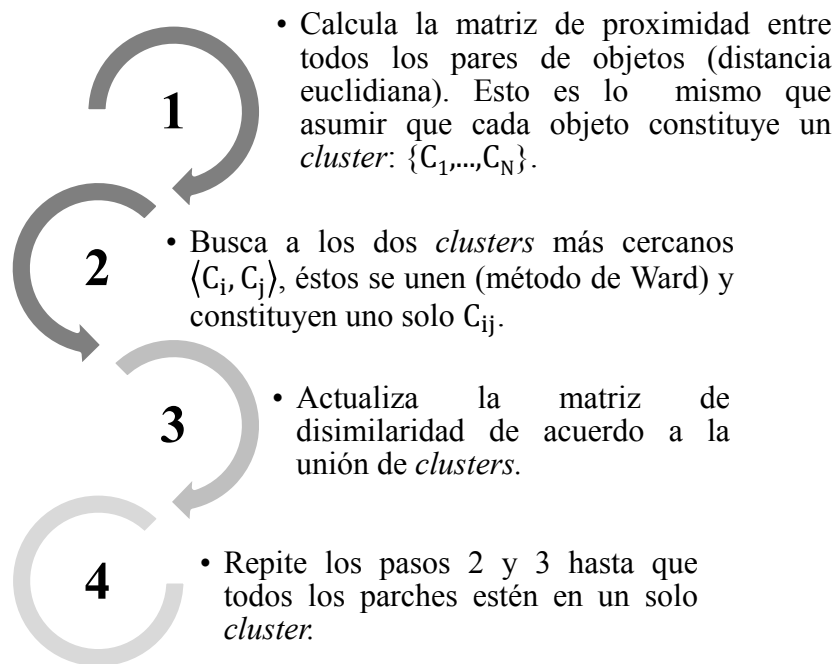
Después de generar pruebas con diferentes métodos de agrupación, un algoritmo de *clustering* jerárquico aglomerativo, se usó al realizar la clasificación multivariada, debido a que fue el que mejor resultados mostró para nuestro objetivo planteado.

Siendo \mathbf{A} una matriz $m \times n$ de los valores de los grupos de métricas ocupadas en la clasificación, para cada caso de estudio. La matriz \mathbf{A} esta formada por m -filas de vectores de n dimensión: $a_1(n), a_2(n), \dots, a_m(n)$, donde a_i es un vector de los valores de las i -métricas. Para medir la distancia entre los pares de métricas de la matriz \mathbf{A} , y así obtener la matriz de disimilaridad o proximidad necesaria en el algoritmo *clustering*, se empleó una distancia euclidiana. El agrupamiento de datos se llevó a cabo por medio del método de Ward (Ward, 1963; Cany, 2007).

Ward (1963), propuso que la pérdida de información que se produce al integrar los distintos objetos en *clusters* puede medirse a través de la suma total de los cuadrados de las desviaciones entre cada objeto (parche) y la media del *cluster* en el que se integra. Para que

el proceso *clustering* resulte óptimo, en el sentido de que los grupos formados no distorsionen los datos originales, propuso que en cada paso del análisis, se consideré la posibilidad de la unión de cada par de grupos y optar por la fusión de aquellos dos grupos que menos incrementen la suma de los cuadrados de las desviaciones al unirse. Por lo tanto el método de Ward, en cada etapa intenta agrupar elementos de modo que se minimice una determinada función objetivo. La función objetivo, persigue la minimización de la varianza intra-grupal del *cluster* formado. Este método también se conoce como un algoritmo que minimiza la varianza.

El método de *clustering* jerárquico aglomerativo se resume de la siguiente manera:



Los métodos jerárquicos construyen dendogramas como el que se muestra en la Figura 3.21. El dendograma, representa la estructura jerárquica de la formación de los cúmulos o *clusters*. Así, a partir de los K elementos observados podemos identificar desde 1 hasta K *clusters*, según el número de grupo que queramos obtener, sin más que realizar la partición horizontal adecuada. La Figura 3.22 muestra el resultado de un agrupamiento de datos por medio del algoritmo *clustering* jerárquico aglomerativo.




Figura 3.20. Ejemplificación de la nube de datos de las métricas: PERIM-RCC-CONTIG, pertenecientes a los parches que conforman el bitmap de la Inundación de Tabasco.




Figura 3.21. Dendrograma generado por la función de agrupación. El eje horizontal representa a los parches del conjunto de datos originales. Las barras representan la unión entre los parches. La altura de las barras indica la distancia de vinculación entre los parches o grupos de parches. La línea punteada corta 4 líneas del dendrograma, esas 4 líneas parten a los parches dentro de 4 clusters. Este ejemplo pertenece a las métricas PERIM-RCC-CONTIG, del *bitmap* de la Inundación de Tabasco.




Figura 3.22. Se muestra la formación de 4 *clusters* para el conjunto de métricas: PERIM-RCC-CONTIG, pertenecientes a los parches que conforman el *bitmap* de la Inundación de Tabasco

Varias clasificaciones se llevaron a cabo con varios grupos de métricas con correlaciones de bajas a medias. Un grupo de 2, 3 o 4 métricas (mt) forman un vector definido como:

$$p_{ij} = \{mt_i, mt_j\}; p_{ijk} = \{mt_i, mt_j, mt_k\}; o p_{ijkl} = \{mt_i, mt_j, mt_k, mt_l\}$$

Los vectores p_{ij} , p_{ijk} y p_{ijkl} se utiliza en la clasificación multivariada. El número de *clusters* se determinó por la inspección del dendograma. Cada *cluster* de salida está asociado a una clase que satisface los criterios morfológicos definidos por cada grupo de métricas. El capítulo siguiente muestra los resultados obtenidos.

Capítulo 4

Resultados y Discusión



Isla de Barbuda, imagen del satélite SPOT 5

En este apartado se hace un análisis de los resultados más representativos derivados de la clasificación multivariada de las métricas del paisaje, aplicada en imágenes ópticas (Landsat TM 4, Spot 5, Terra/Aster) y de radar (TerraSar X).

Los efectos de la clasificación multivariada de las métricas del paisaje son desconocidos debido a que no existen trabajos previos sobre el tema. Los ejemplos propuestos en el capítulo 3 se emplearon para demostrar la capacidad de la clasificación multivariada de las métricas del paisaje. Con base en ello, se elaboraron mapas temáticos que muestran el comportamiento morfológico de los parches, fundamentales para el análisis morfológico de una imagen. En las secciones siguientes se discuten los resultados obtenidos de las clasificaciones más significativas.

4.1 Calidad de resultados

La calidad de los resultados fue evaluada tomando en cuenta una imagen sintética (véase sección 4.5), la cual es de vital importancia para inspeccionar la discriminación de los parches de diferente forma, perímetro, área y complejidad. En ella, la forma y complejidad de sus parches es bien conocida permitiendo la verificación de la clasificación multivariada de las métricas del paisaje.

Como se mencionó en el capítulo 3 el método de la clasificación multivariada que utilizamos es una clasificación no supervisada. Una manera de cuantificar la calidad de la partición en la clasificación no supervisada es medir la distancia entre las regiones o clases generadas usando una métrica que se establece a partir del mismo modelo de comportamiento morfológico de las clases involucradas en la clasificación.

La distancia de las clases en un espacio morfológico puede ser cuantificada por la divergencia transformada o la distancia de Jeffries-Matusita (Richards y Jia, 1999), las cuales miden la separación espectral (en un principio), pero, en este caso se mide la separación morfológica que hay entre una colección de grupos de parches con características similares entre ellos. Esta separación es necesaria para validar la calidad de una segmentación hecha con base en las propiedades morfológicas de los parches del paisaje.

La Divergencia Transformada (Swain y Davis, 1978) es un método numérico de evaluación estadística, parte del supuesto de que los valores de las métricas del paisaje de los parches siguen una distribución normal, suponiéndose la separabilidad como una

medida de solape entre las categorías vecinas. En la Divergencia Transformada los resultados están acotados entre 0 y 2, donde 0 indica un solape absoluto entre las signaturas de dos clases y 2 una separación completa entre éstas (Molina y Chuvieco, 1996).

La distribución normal o gaussiana, en un espacio γ -dimensional, está caracterizada por la ecuación (Lira, 2010):

$$p(\mathbf{r}|\omega_i) = \frac{1}{(2\pi)^{\gamma/2}} |\mathbf{K}_i|^{-1/2} \exp\left\{-\frac{1}{2}(\mathbf{r} - \boldsymbol{\mu}_i)^t \mathbf{K}_i^{-1}(\mathbf{r} - \boldsymbol{\mu}_i)\right\} \quad (4.1)$$

Donde $\boldsymbol{\mu}_i$ es el vector de media de los datos prototipo de la clase ω_i y \mathbf{K}_i es su matriz de covarianza; γ es el número de métricas del paisaje o la dimensionalidad del espacio de muestras.

La ecuación 4.1 al ser sustituida en la expresión de la divergencia de un par de clases (4.2)

$$\mathbf{d}_{ij} = \int [p(\mathbf{r}|\omega_i) - p(\mathbf{r}|\omega_j)] \ln \left[\frac{p(\mathbf{r}|\omega_i)}{p(\mathbf{r}|\omega_j)} \right] \mathbf{d}\mathbf{r} \quad (4.2)$$

proporciona el siguiente valor para la divergencia:

$$\mathbf{d}_{ij} = \frac{1}{2} \text{Tr}\{[\mathbf{K}_i - \mathbf{K}_j][\mathbf{K}_i^{-1} - \mathbf{K}_j^{-1}]\} + \frac{1}{2} \text{Tr}\{[\mathbf{K}_i^{-1} + \mathbf{K}_j^{-1}][\boldsymbol{\mu}_i - \boldsymbol{\mu}_j][\boldsymbol{\mu}_i - \boldsymbol{\mu}_j]^t\} \quad (4.3)$$

Donde Tr es la traza de la matriz correspondiente, \mathbf{K}_i y \mathbf{K}_j son las matrices de covarianza de las clases i y j respectivamente. Al realizarse el cálculo para todos los pares de clases, se obtiene una matriz, conocida como la matriz de divergencia

Es necesario modificar la divergencia para que tenga un comportamiento exponencial asintótico; a tal modificación se le conoce como la Divergencia Transformada, cuya forma es la siguiente:

$$\mathbf{d}_{ij}^T = 2[1 - e^{-\mathbf{d}_{ij}/8}] \quad (4.4)$$

Para obtener otra caracterización de la separabilidad entre clases se introduce la definición de la distancia de Jeffries-Matusita (JM), también llamada de Bhattacharrya, para un par de distribuciones de valores de los parches de dos clases morfológicas:

$$J_{ij} = \int \left(\sqrt{p(\mathbf{r}|\omega_i)} - \sqrt{p(\mathbf{r}|\omega_j)} \right)^2 d\mathbf{r} \quad (4.5)$$

La expresión 4.5 cuantifica la suma de las distancias al cuadrado entre pares de valores de las distribuciones de probabilidad para el par de clases ω_i , ω_j . Al sustituir en 4.5 la expresión para una distribución normal se obtiene el siguiente resultado:

$$J_{ij} = 2(1 - e^{-k}) \quad (4.6)$$

donde k es:

$$k = \frac{1}{8} (\mu_i - \mu_j)^t \left[\frac{K_i + K_j}{2} \right]^{-1} (\mu_i - \mu_j) + \frac{1}{2} \ln \left[\frac{\left| \frac{K_i + K_j}{2} \right|}{|K_i|^{1/2} |K_j|^{1/2}} \right] \quad (4.7)$$

El intervalo de validez de las expresiones 4.4 y 4.6 está entre cero y dos, siendo el dos el valor para la máxima separabilidad. Los valores superiores a 1.5 muestran muy buena separabilidad. Entre 1 y 1.5 la separabilidad se considera buena. Los valores por debajo de 1 indican una mala separabilidad.

4.2 Resultados de la Ciudad de México

En el caso de la Ciudad de México se emplearon dos imágenes Landsat TM 4 en diferente tiempo (1989 y 2001), así como una imagen SPOT-5. Esto con el fin de visualizar la evolución temporal de la complejidad de la ciudad y con la imagen SPOT 5 identificar la importancia del cambio de escala de las imágenes que sean empleadas. Los resultados de la clasificación se ejemplifican con la combinación de las métricas: Relación Círculo Circunscrito (RCC) y Contigüidad (CONTIG) ya que fue la combinación más representativa para las imágenes Landsat TM-4 de este caso.

4.2.1 Imagen Landsat TM - Ciudad de México 1989

En el Gráfico 4.1 visualizamos la correlación entre las métricas RCC - CONTIG la cual es de 0.2250 (véase Tabla 3.2). El resultado de la clasificación de las métricas del paisaje: RCC - CONTIG se aprecia en la Figura 4.2. El dendograma de esta combinación se muestra en la Figura 4.1, donde se puede observar la manera de fusionar las clases de los parches, denotando el uso de 4 clases.

La estimación cuantitativa de la separabilidad entre las clases mediante el análisis de la divergencia transformada y Jeffries Matusita se exhibe en la Tabla 4.1 donde se nota una separabilidad satisfactoria.

En la Figura 4.2 se muestra un gran parche en color amarillo a la que llamamos clase 1 (C1), la cual comprende la mayor parte de la zona urbana. La clase 2 (C2) comprende a las zonas periféricas y las carreteras secundarias con perímetros alargados y complejos, esta clase se identifica en azul. Los parches pequeños con perímetro complejo se ven en rojo y son los que forman a la clase 3 (C3). La clase 4 (C4) es la que comprende el menor número de parches; se distingue por sus parches pequeños con perímetro suave, se representan en color rosa.




Grafico 4.1. Correlación entre las métricas RCC-CONTIG para la Ciudad de México 1989




Figura 4.1. Dendrograma de la clasificación con las métricas RCC y CONTIG, para el bitmap de la Ciudad de México 1989. Véase Figura 3.21 del capítulo 3 para mayor explicación en el uso del dendrograma.

	C1	C2	C3	C4
C1	0.0000	1.7781	1.8527	1.9032
C2		0.0000	1.8601	1.9963
C3			0.0000	1.8948
C4				0.0000
Promedio = 1.8809				

a)

	C1	C2	C3	C4
C1	0.0000	1.4480	1.3850	1.4770
C2		0.0000	1.5443	1.9530
C3			0.0000	1.5181
C4				0.0000
Promedio = 1.5542				

b)

Tabla 4.1. Estimación cuantitativa de la separabilidad entre las clases mediante el análisis de la divergencia transformada a) y Jeffries Matusita b). Se puede notar que las separabilidades con la divergencia transformada son muy buenas, mientras que el análisis de separabilidad por medio de Jeffries Matusita resulta menor, aunque sigue en promedio siendo muy buena.




Figura 4.2. Resultado de la clasificación RCC - CONTIG para 4 clases en el bitmap de la Ciudad de México 1989.

4.2.2 Resultado Imagen Landsat TM - Ciudad de México 2001

Como ya se mencionó, la combinación de las métricas utilizadas en la clasificación en el caso de la Ciudad de México fue la misma, tanto en las imágenes Landsat TM 4 como en la imagen SPOT 5. El dendograma del bitmap de la Ciudad de México 2001 se muestra en la Figura 4.3, denotándose nuevamente el uso de 4 clases, la correlación entre las métricas en este caso es de 0.2530 y la vemos en el Gráfico 4.2.

En la Tabla 4.2 se visualiza la estimación cuantitativa de la separabilidad entre las clases mediante el análisis de la divergencia transformada y Jeffries Matusita, con base en el promedio podemos deducir una separabilidad muy buena entre las clases.

El cambio de la zona urbana en el lapso de 12 años (1989-2001) se puede apreciar en la Figura 4.4, donde observamos que algunos de los parches periféricos, anteriormente representados en azul (clase 2) de la Ciudad de México 1989, se integraron a la mayor parte de la zona urbana (clase 1). Asimismo, algunos pequeños parches de formas tanto complejas como suaves se integraron al gran parche de la zona urbana (clase 1). Podemos presumir que dicha integración se debe al crecimiento de la zona urbana.




Grafico 4.2. Correlación entre las métricas RCC - CONTIG para la Ciudad de México 2001, su valor numérico corresponde a 0.2530821




Figura 4.3. Dendrograma de la clasificación con las métricas RCC - CONTIG, para el bitmap de la Ciudad de México 2001

	C1	C2	C3	C4
C1	0.0000	1.6732	1.8810	1.9948
C2		0.0000	1.8397	1.6904
C3			0.0000	1.8995
C4				0.0000
Promedio = 1.8298				

a)

	C1	C2	C3	C4
C1	0.0000	1.2367	1.5323	1.9393
C2		0.0000	1.3873	1.3961
C3			0.0000	1.4116
C4				0.0000
Promedio = 1.4839				

b)

Tabla 4.2. Análisis de la separabilidad entre las clases resultantes mediante la divergencia transformada a) y Jeffries Matusita b), en la imagen Ciudad de México 2001.




Figura 4.4. Mapa temático de la clasificación RCC y CONTIG, para 4 clases en la imagen de la Ciudad de México 2001. En donde se aprecia el cambio de la zona urbana

4.2.3 Imagen SPOT 5 - Ciudad de México

Con el fin de resaltar la importancia que existe en la escala de la imagen que se va a emplear, utilizamos la imagen SPOT 5 del 2003. La diferencia de resolución espacial entre las bandas que ocupamos de las imágenes Landsat TM 4 y SPOT 5 es considerable. Para las bandas de la imagen Landsat TM 4 la resolución espacial es de 28.5 m^2 , mientras que para la imagen SPOT 5 es de 10 m^2 . La correlación de las métricas en este caso se visualiza en el gráfico 4.3, siendo de 0.3012.

Con base en la información recolectada de las imágenes de la Ciudad de México Landsat TM-4 de 1989 y 2001. Se realizó la clasificación con las dos variables antes aplicadas, seleccionado el mismo número de clases de los casos anteriores expuestos. En promedio la separabilidad entre las clases es buena a muy buena, véase Tabla 4.3.

La Figura 4.5 muestra el resultado de la clasificación de las métricas del paisaje RCC - CONTIG para la imagen SPOT-5 donde sin duda podemos observar mucho mayor detalle a comparación con las imágenes Landsat. El resultado en esta clasificación pone a la vista a la clase 1 como predominante, abarcando la mayor parte de la ciudad. Dicha clase está compuesta por los parches de complejidad mayor. Los parches angostos y alargados, tales como carreteras, que constituían parte de la clase 2 en las imágenes anteriores, se unen para formar parte de la clase 1. En la clase 2 se muestran los parches irregulares de tamaños medianos a pequeños, con agujeros en sus interiores. La clase 3 exhibe a los parches pequeños de forma más compacta acercándose a un círculo, mientras que la clase 4 guarda a los parches más pequeños que conforman a la ciudad.




Gráfico 4.3. Correlación de las métricas RCC – CONTIG para SPOT 5

	C1	C2	C3	C4
C1	0.0000	1.5469	1.8032	1.8079
C2		0.0000	1.8130	1.9906
C3			0.0000	1.8966
C4				0.0000
Promedio = 1.8097				

a)

	C1	C2	C3	C4
C1	0.0000	1.2696	1.3421	1.5440
C2		0.0000	1.3983	1.9307
C3			0.0000	1.2685
C4				0.0000
Promedio = 1.4589				

b)

Tabla 4.3. Estimación de la separabilidad entre las clases mediante la divergencia transformada a) y Jeffries Matusita b) en la clasificación de la imagen SPOT-5.




Figura 4.5. Resultado de la clasificación con las métricas del paisaje: RCC - CONTIG, con 4 clases para la imagen de la Ciudad de México SPOT 5. Se muestra a mayor detalle la Ciudad de México, debido a que la resolución espacial es más alta que en las imágenes Landsat TM. Esto con lleva a incrementar considerablemente el número de parches.

4.3 Resultados Imagen Terra/Aster - Campos Cultivo

Los campos de agricultura poseen una estructura morfológica simple. Todos los campos de cultivo son de forma rectangular o poligonal con un pequeño número de lados. Para este caso, las clasificaciones más representativas las encontramos con la combinación de la métricas: Perímetro (PERIM) - Relación Perímetro-Área (PARA) - Dimensión Fractal (FRAC) - Relación Circulo Circunscrito (RCC) y la composición simple de las métricas: Dimensión Fractal (FRAC) - Relación Circulo. Circunscrito (RCC).

La primera clasificación de composición PERIM-PARA-FRAC-RCC se muestra en la Figura 4.7 y su correlación en el gráfico 4.4. En la Figura 4.7 se visualizan 4 clases, las cuales fueron seleccionadas con ayuda del dendograma de la Figura 4.6. Mediante el análisis de la divergencia transformada y Jeffries Matusita se estimó la separabilidad entre las clases, la cual resulta máxima en la divergencia transformada, véase Tabla 4.4

En la Figura 4.7 se aprecia la clase 1 en color verde la cual indica a los campos grandes y de formas un tanto complejas con agujeros internos. Los campos con formas semi-rectangulares se muestran de color rojo en la clase 2. En amarillo aparecen los parches o campos pequeños de forma muy fina, alargados y estrechos, asignando a estos en la clase 3. La clase 4 se encuentra en azul abarcando a los campos más pequeños de formas simples alargados.

En la segunda clasificación con la combinación de las métricas: FRAC y RCC se aprecia una manera diferente de asignar las clases. La correlación entre ellas la podemos ver en el gráfico 4.5. La agrupación de las clases se presenta en el dendograma de la Figura 4.8. El grado de separabilidad entre las 4 clases es muy bueno, véase Tabla 4.5.

En tanto en la Figura 4.9 se observa que los campos agrícolas que componen a la clase 1 tiene una forma compleja a comparación de los otros campos, sus tamaños son diversos, pequeños, medianos y grandes, presentando en la mayoría orificios intrínsecos. En la clase 2, de tono azul, observamos a los campos de perímetro regular, alargados, con cierta relación entre el ancho y largo del parche. La clase 3, en rojo, abarca a los campos de diferentes tamaños, con una estructura más compacta acercándose a una forma geométrica

cuadrada, mientras que la clase 4, en amarillo presenta a los campos de forma un poco menos complejos que la clase 1 pero mayor que la clase 2 y 3 su estructura se asemeja a semi-rectángulos y formas triangulares.




Gráfico 4.4. Correlación entre las métricas PERIM-PARA-FRAC-RCC en los campos de cultivo.




Figura 4.6. Dendograma de la clasificación para el bitmap de la Campos de cultivo, Irapuato, con la combinación de las métricas PERIM-PARA-FRAC-RCC. La visualización del dendograma nos ayuda a discernir el uso de 4 clases.

	C1	C2	C3	C4
C1	0.0000	2.0000	2.0000	2.0000
C2		0.0000	2.0000	2.0000
C3			0.0000	2.0000
C4				0.0000
Promedio = 2.0000				

a)

	C1	C2	C3	C4
C1	0.0000	1.6477	1.8170	1.7742
C2		0.0000	1.7288	1.9807
C3			0.0000	1.6457
C4				0.0000
Promedio = 1.7657				

b)

Tabla 4.4. Análisis de separabilidad entre las clases por medio de la divergencia transformada a) y Jeffries Matusita b) por la combinación de las métricas PERIM-PARA-FRAC-RCC. Se muestra la máxima separabilidad entre todas las clases con la divergencia transformada, mientras que para Jeffries Matusita la separación es muy buena.




Figura 4.7. Mapa temático obtenido por la clasificación de las métricas del paisaje: PERIM-PARA-FRAC-RCC, con 4 clases en la imagen segmentada Terra/Aster de los Campos de Cultivo, Irapuato.




Gráfico 4.5. Correlación media de 0.6380 entre las métricas FRAC – RCC de los patrones de los Campos de Cultivo




Figura 4.8. Dendograma resultante en la clasificación de los parches del bitmap Campos de cultivo, Irapuato, empleando la composición de las métricas: FRAC y RCC.

	C1	C2	C3	C4
C1	0.0000	1.9529	1.9930	2.0000
C2		0.0000	1.7097	1.9997
C3			0.0000	1.9249
C4				0.0000
Promedio = 1.9300				

a)

	C1	C2	C3	C4
C1	0.0000	1.5718	1.6209	1.9856
C2		0.0000	1.4754	1.9683
C3			0.0000	1.4650
C4				0.0000
Promedio = 1.6812				

b)

Tabla 4.5. Análisis de la separabilidad entre las 4 clases formadas en la clasificación de los parches de la imagen Campos Cultivos por la combinación de las métricas FRAC-RCC. en promedio se tiene un muy buena separabilidad tanto con la divergencia transformada a) como en Jeffries Matusita b).




Figura 4.9. Mapa temático obtenido como resultado de la clasificación de los parches del bitmap Terra/Aster de los Campos de Cultivo, en la cual se han empleado las métricas del paisaje: FRAC-RCC. En este resultado se muestra la variación de asignación de las clases en comparación de la Figura 4. 7 debido a las métricas ocupadas en cada clasificación.

4.4 Resultados Imagen Terra/Aster – Cuerpos de agua de Tabasco

El conjunto de cuerpos de agua abiertos que forman parte del Estado de Tabasco son de forma muy compleja. En este caso, las clasificaciones de los cuerpos de agua más significativos se exponen en las Figuras 4.11 y 4.13 las cuales se produjeron mediante los siguientes conjuntos de métricas: 1) Índice de Forma (FORMA) - Relación Círculo Circunscrito (RCC). 2) Perímetro (PERIM)- Relación Círculo Circunscrito (RCC) - índice de Contigüidad (CONTIG). Las correlaciones de estos conjuntos se visualizan en los gráficos 4.6 y 4.7.

Para determinar el número de clases de cada combinación nos apoyamos de la gráfica de los dendogramas los cuales corresponden a las Figuras 4.10 y 4.12 referente al orden aludido de combinación de métricas, también se realizaron pruebas de cada imagen con diferente número de clases, con el fin de analizar cambios significativos respecto a las clases que son empleadas. Por otra parte, las Tablas 4.6 y 4.7 nos indican el grado de separabilidad entre las clases generadas en cada clasificación mencionada; en los dos casos nos revelan una separación entre las clases muy satisfactoria.

La clasificación de 4 clases con las métricas FORMA – RCC, véase Figura 4.11, muestra una segmentación de los cuerpos de agua en términos de la complejidad de su estructura. Los parches con muy largo y complejo perímetro se representan en rojo, clase 1. La clase 2 de color mostaza, muestra algunos cuerpos de agua con menor perímetro complejo y variantes de tamaño entre pequeños y medianos, en su mayoría con brechas en su interior. En verde se encuentra la clase 3 quien confina a los parches de menos perímetro complejo con estructura simple con mayor compactación que la clase 1 y 2. Los cuerpos de agua en azul conforman a la clase 4, estos parches se distinguen por su perímetro suave y su mayor compactación con una estructura semiredondeada.

La clasificación con el conjunto de métricas: PERIM – RCC – CONTIG, Figura 4.13 nos muestra 3 clases fundamentales. En la clase 1 se engloban todos aquellos parches con perímetros de complejidad mediana a complejos, la forma de los cuerpos de agua son de irregularidad mediana a fuerte. La clase 2 nos exhibe a los cuerpos alargados, estrechos, con perímetro simple a sinusoidal que no están conectados a otros cuerpos de agua o

irrigando alguna laguna. La clase 3 representa a los cuerpos más pequeños de agua de estructura simple.




Gráfico 4.6. Correlación entre las métricas FORMA - RCC




Figura 4.10. Dendograma resultante de la agrupación de *clusters*, en la clasificación de los parches que conforman a la imagen Cuerpos de agua de Tabasco, empleando la combinación de las métricas: FORMA - RCC.

	C1	C2	C3	C4
C1	0.0000	1.8925	2.0000	2.0000
C2		0.0000	2.0000	1.8305
C3			0.0000	1.9426
C4				0.0000
Promedio = 1.9443				

a)

	C1	C2	C3	C4
C1	0.0000	1.3185	1.9997	1.9266
C2		0.0000	1.9850	1.2608
C3			0.0000	1.5580
C4				0.0000
Promedio = 1.6747				

b)

Tabla 4.6. Análisis de separabilidad mediante la divergencia transformada a) y Jeffries Matusita b) entre las 4 clases formadas en la clasificación de la imagen Cuerpos de agua de Tabasco.




Figura 4.11. Mapa temático con 4 clases, obtenido por la clasificación de las métricas del paisaje: FORMA – RCC, en la imagen Terra/Aster - Cuerpos de agua de Tabasco.




Gráfico 4.7 Correlación entre las métricas PERIM - RCC – CONTIG




Figura 4.12. Agrupación jerárquica de los *clusters* a partir de la combinación de las métricas PERIM - RCC - CONTIG, en la imagen Cuerpos de agua de Tabasco.

	C1	C2	C3	C4
C1	0.0000	1.9996	1.9999	1.9999
C2		0.0000	1.9999	2.0000
C3			0.0000	1.9999
C4				0.0000
Promedio = 1.9999				

a)

	C1	C2	C3	C4
C1	0.0000	1.3999	1.7293	1.5421
C2		0.0000	1.4854	1.8911
C3			0.0000	1.6204
C4				0.0000
Promedio = 1.6114				

b)

Tabla 4.7. Resultado de la divergencia transformada a) y Jeffries Matusita b) donde se aprecia la separabilidad entre las 4 clases formadas en la clasificación de la imagen Cuerpos de agua de Tabasco por el conjunto de las métricas: PERIM - RCC - CONTIG.




Figura 4.13. Presentación de las 4 clases, formadas a partir de la clasificación con las métricas: PERIM - RCC - CONTIG, en la imagen Terra/Aster - Cuerpos de agua de Tabasco.

4.5 Resultado Imagen Radar - Inundación de Tabasco

Al igual que el caso anterior, los cuerpos de agua desarrollados durante la inundación de Tabasco del 2007 constituyen una estructura muy compleja con cuerpos de diversos tamaños. Los resultados más significativos al aplicar una clasificación multivariada de las métricas del paisaje se encuentran en las Figuras 4.15, 4.17 y 4.19. Las correlaciones entre el conjunto de métricas se observan en los gráficos 4.8, 4.9 y 4.10. Los dendogramas para

cada clasificación se muestran en las Figura 4.14, 4.16 y 4.18 Por otra parte, las Tablas 4.8, 4.9 y 4.10 nos indican el grado de separabilidad entre las clases generadas en cada clasificación mencionada; en los tres casos nos revelan una separación entre las clases satisfactoria.

La Figura 4.15 muestra el resultado de la clasificación con las métricas FRAC-RCC para 5 clases. En la clase 1 de color azul, engloba a los parches con perímetros extremadamente complejos y variados en su área. Los cuerpos de agua menos complejos con una serie de agujeros intrínsecos, de tamaño mediano y cierto grado de compacidad se muestran en la clase 2 de color verde. Los parches más pequeños se clasificaron dentro de tres grupos: 1) en la clase 3 de color rosa, se encuentran los cuerpos de agua pequeños a medianos con perímetro irregular y estructura elongada, 2) los parches en amarillo corresponden a la clase 4 de perímetro suave y forma semiredondeada, 3) La clase 5, en tono rojo corresponden a los cuerpos con formas intermedias entre la clase 4 y la clase 3.

Con la combinación de los descriptores morfológicos RCC-CONTIG se obtiene un resultado muy interesante el cual se exhibe en la Figura 4.17 notamos en la clase 1 a los cuerpos de agua más complejos de tamaños de pequeños a grandes con brechas en su interior. A su vez, la clase 2 abarca a los parches menos complejos de tamaño mediano y cierto grado de compacidad muy similar a la clase 2 de la Figura 4.15. En tanto que la clase 3 resalta a los cuerpos de agua alargados y estrechos los cuales forman parte del río Grijalva. Por último la clase 4 encierra a los cuerpos de agua pequeños de estructura simple.

Al agregar la métrica PERIM a la combinación de la clasificación de la Figura 4.17 se observa un cambio significativo, principalmente cuando el objetivo sea resaltar a los ríos del resto de los cuerpos de agua; véase Figura 4.19. La combinación PERIM-RCC-CONTIG se realizó para 3 clases, nótese dendograma en la Figura 4.18. Para comparar con la combinación RCC-CONTIG se generó una combinación de 4 clases así también para 5 clases, en donde las variaciones fueron insignificantes, optando por el uso de las 3 clases. En la Figura 4.19 claramente se ven resaltados los cuerpos alargados, estrechos, de estructura sinusoidal y compleja pertenecientes a la clase 1, mientras que la clase 2 recluye

a los parches irregulares pertenecientes a los cuerpos de agua formados durante la inundación.




Gráfico 4.8. Correlación entre las métricas FRAC - RCC




Figura 4.14. Dendrograma de la clasificación de los cuerpos de agua para el bitmap Inundación de Tabasco, realizada con el conjunto de las métricas: FRAC – RCC.

	C1	C2	C3	C4	C5		C1	C2	C3	C4	C5
C1	0.0000	1.7402	1.9999	1.9999	2.0000	C1	0.0000	1.3248	1.9929	1.9391	1.9976
C2		0.0000	1.9509	1.8798	1.9996	C2		0.0000	1.6943	1.4779	1.9504
C3			0.0000	1.8553	1.9295	C3			0.0000	1.5618	1.4867
C4				0.0000	1.8386	C4				0.0000	1.3577
C5					0.0000	C5					0.0000
	Promedio = 1.9194						Promedio = 1.6783				
	a)						b)				

Tabla 4.8 Análisis de la separabilidad entre clases mediante la divergencia transformada a) y Jeffries Matusita b) en la clasificación de la imagen Inundación de Tabasco por medio de la combinación de las métricas FRAC – RCC.




Figura 4.15. Mapa temático obtenido por la clasificación de las métricas del paisaje: FRAC - RCC, con 5 clases para los cuerpos de agua que conforman a la imagen Radar - Inundación de Tabasco.




Gráfico 4.9. Correlación entre las métricas RCC - CONTIG




Figura 4.16. Dendrograma de la clasificación de los cuerpos de agua para el bitmap de Inundación de Tabasco, realizada con el conjunto de las métricas: RCC - CONTIG.

	C1	C2	C3	C4
C1	0.0000	1.5559	1.9531	1.5390
C2		0.0000	1.9635	1.9824
C3			0.0000	1.9642
C4				0.0000
Promedio = 1.8263				

a)

	C1	C2	C3	C4
C1	0.0000	1.2064	1.5799	1.2738
C2		0.0000	1.5963	1.8987
C3			0.0000	1.5335
C4				0.0000
Promedio = 1.5147708				

b)

Tabla 4.9. Resultado de la divergencia transformada a) y Jeffries Matusita b) donde se aprecia la separabilidad entre las 4 clases formadas en la clasificación de la imagen Inundación de Tabasco por la combinación de las métricas RCC - CONTIG.

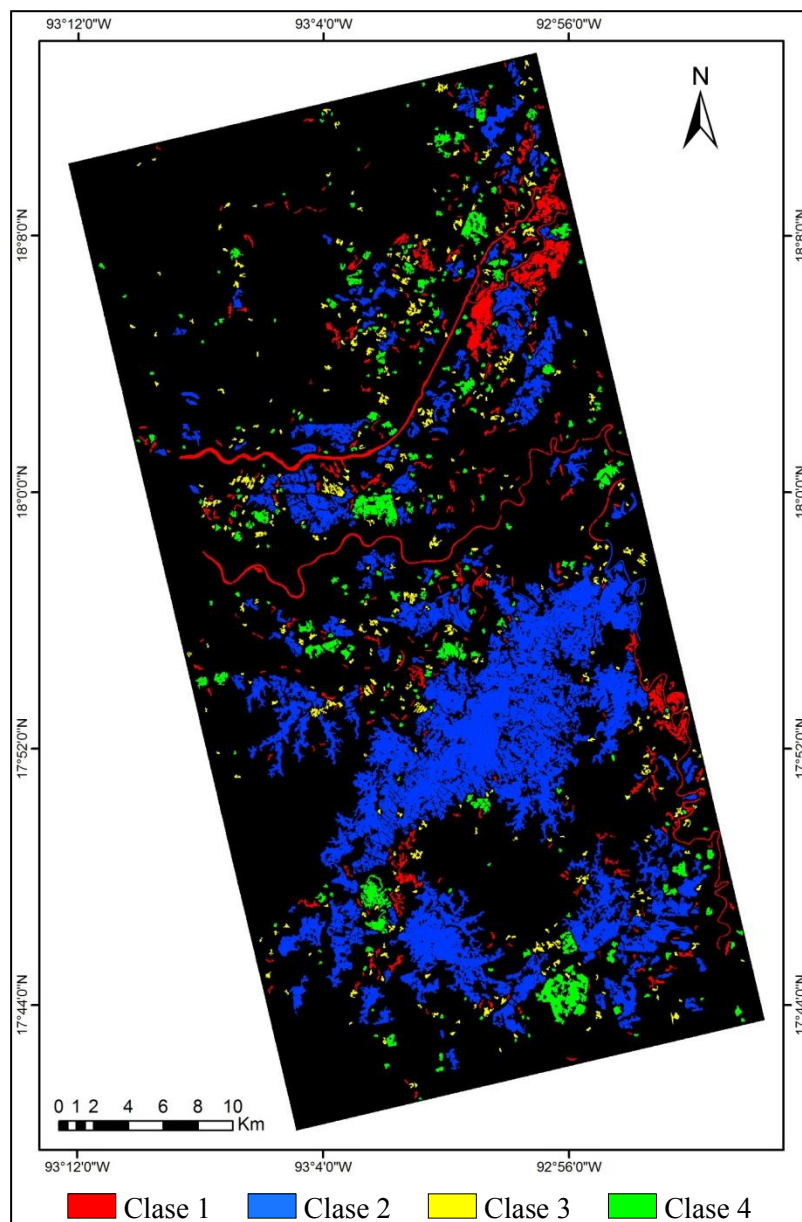


Figura 4.17. Resultado de las 4 clases formadas a partir de la clasificación con las métricas: RCC – CONTIG, en la imagen Radar - Inundación de Tabasco.




Gráfico 4.10 Correlación entre las métricas PERIM-RCC - CONTIG.




Figura 4.18. Agrupación jerárquica de los *clusters* a partir de la combinación de las métricas PERIM - RCC - CONTIG, en la imagen Inundación de Tabasco.

	C1	C2	C3
C1	0.0000	1.9993	1.9996
C2		0.0000	1.9951
C3			0.0000
Promedio = 1.9980			

a)

	C1	C2	C3
C1	0.0000	1.5373	1.6064
C2		0.0000	1.1787
C3			0.0000
Promedio = 1.4409			

b)

Tabla 4.10. Resultado de la divergencia transformada a) y Jeffries Matusita b) donde se aprecia la separabilidad entre las 3 clases formadas en la clasificación de la imagen Inundación de agua de Tabasco por el conjunto de las métricas: PERIM - RCC - CONTIG.

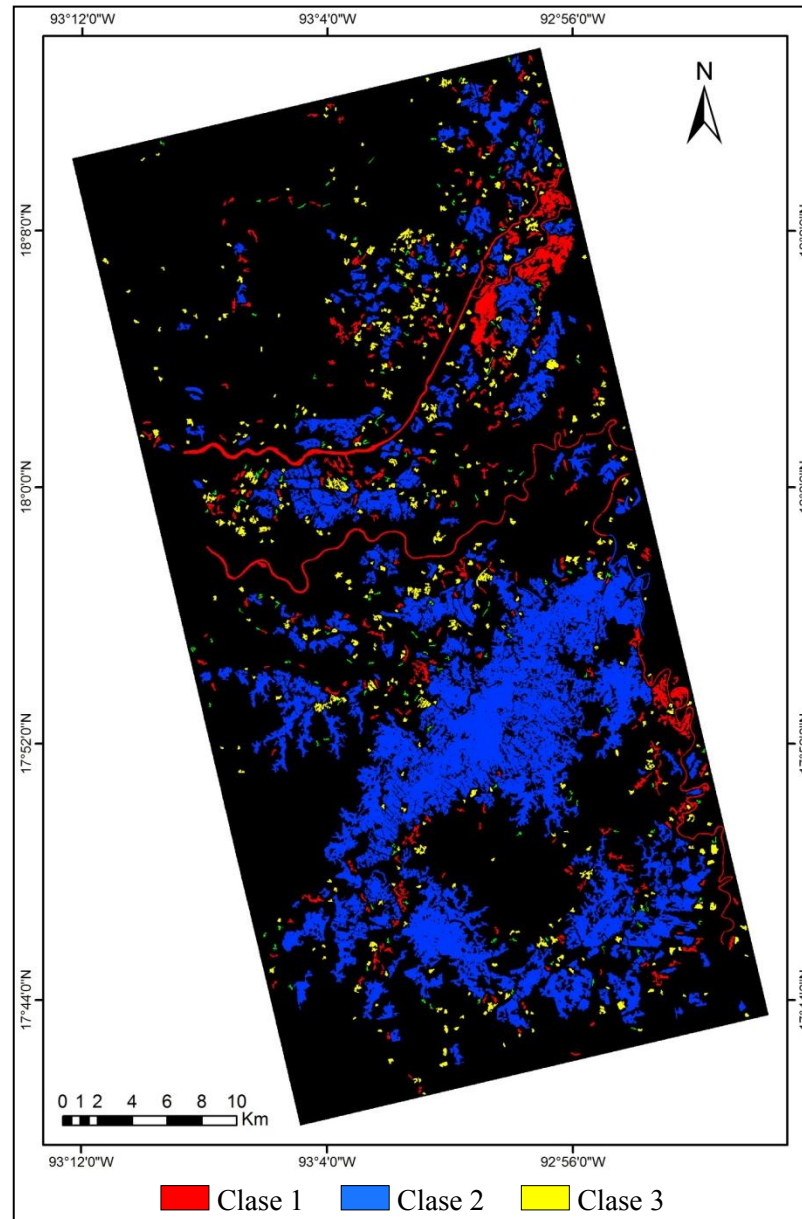


Figura 4.19. Mapa temático obtenido por la clasificación de las métricas del paisaje: PERIM – RCC - CONITG, con 3 clases para los cuerpos de agua que conforman a la imagen Radar - Inundación de Tabasco.

4.6 Resultados de la imagen sintética

Con el fin de probar la validez del método propuesto en esta investigación, se llevó a cabo una clasificación de una imagen sintética, donde los parches tienen formas y estructuras ideales bien conocidas. Esta imagen se utiliza para inspeccionar la discriminación de los

parches de forma diferente, perímetro, área y complejidad. La figura 4.20 muestra el dendograma de cada combinación generada. El resultado del análisis de separabilidad entre las clases, por medio de la divergencia transformada, es máxima para todo resultado de clasificación, existiendo variaciones cuando el análisis se realiza por Jeffries Matusita, (Tabla 4.11). La Figura 4.21 muestra cuatro clasificaciones de la imagen sintética con varios parches de diferente tamaño y forma. Una inspección visual muestra que las clasificaciones con distintas combinaciones de las métricas producen una buena discriminación de objetos con diferentes propiedades morfológicas. Tales propiedades se refieren a un examen conjunto de tamaño, forma y complejidad.

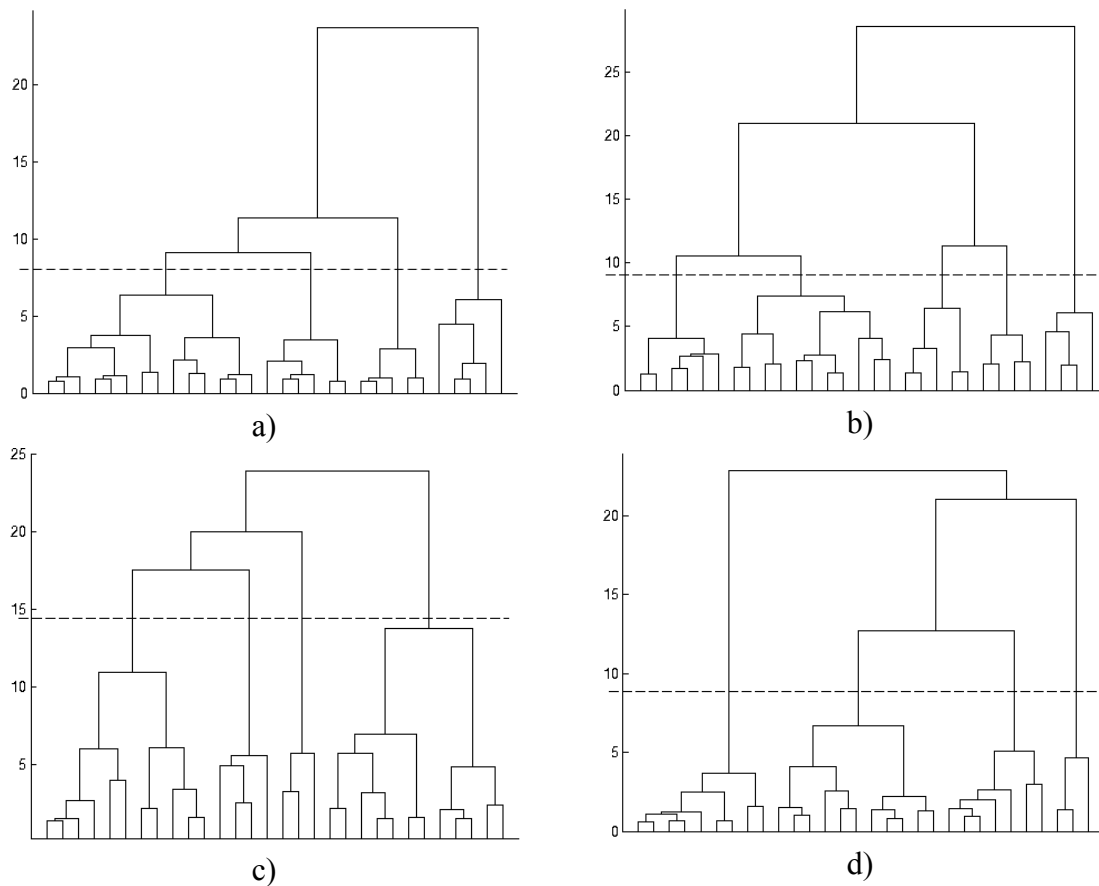


Figura 4.20. Agrupación jerárquica de los *clusters* en un espacio formado por las métricas a) PARA - FORMA, b) PARA - FORMA - RCC, c) PERIM – RCC - CONTIG y d) RCC - CONTIG de la imagen sintética.

	C1	C2	C3	C4
C1	0.0000	1.4056	1.9688	1.7121
C2		0.0000	1.6191	1.8060
C3			0.0000	1.9388
C4				0.0000
Promedio = 1.7417				

a)

	C1	C2	C3	C4	C5
C1	0.0000	1.4479	2.0000	1.9985	1.9984
C2		0.0000	1.9746	1.7858	1.9961
C3			0.0000	1.8544	2.0000
C4				0.0000	1.9997
C5					0.0000
Promedio = 1.9055					

b)

	C1	C2	C3	C4
C1	0.0000	1.7596	1.9992	1.7774
C2		0.0000	1.9998	1.5378
C3			0.0000	2.0000
C4				0.0000
Promedio = 1.8457				

c)

	C1	C2	C3	C4
C1	0.0000	1.3741	1.9091	2.0000
C2		0.0000	1.9979	1.8808
C3			0.0000	2.0000
C4				0.0000
Promedio = 1.8603				

d)

	C1	C2	C3	C4
C1	0.0000	2.0000	2.0000	2.0000
C2		0.0000	2.0000	2.0000
C3			0.0000	2.0000
C4				0.0000
Promedio = 2.0000				

e)

Tabla 4.11. a), b), c) y d) corresponden al resultado de la separabilidad de las clases por Jeffries Matusita en la imagen sintética, donde el conjunto de las métricas en cada caso es: a) PARA - FORMA, b) PARA - FORMA - RCC, c) PERIM – RCC - CONTIG y d) RCC - CONTIG de la imagen sintética. e) muestra el análisis de la separabilidad entre las clases mediante la divergencia transformada siendo el mismo resultado en todos los casos expuestos para la imagen sintética.




Figura 4.21. Mapas temáticos resultantes de la clasificación morfológica de la imagen sintética con los conjuntos de las métricas: a) PARA – FORMA 4 clases, b) PARA - FORMA – RCC, 4 clases, c) PERIM – RCC – CONTIG 5 clases y d) RCC – CONTIG 4 clases.

4.7 Discusión y limitaciones

El desarrollo e implementación de la clasificación multivariada de las métricas del paisaje tiene la intención de producir un elemento de cuantificación de la heterogeneidad morfológica y de la estructura de los parches que componen a una misma clase. En el caso de la Ciudad de México, con las imágenes 1989 y 2001 se detectan los cambios temporales y espaciales de los patrones que forman a la ciudad, por lo que es factible cuantificar la evolución de una zona urbana en ciudades medianas y grandes. La combinación de las métricas RCC-CONTIG resultan ideales para discernir la periferia de la concentración de la ciudad. Esto difiere según la resolución espacial de la imagen a ocupar, como se nota al

cambiar de resolución de la imagen Landsat TM a la imagen SPOT-5. En la imagen SPOT-5 al tener mayor resolución, la fragmentación de los parches se incrementa considerablemente lo que ocasiona que los parches del interior de la ciudad se comporten de manera similar a los de la periferia.

Los cambios de usos del suelo y de la estructura del paisaje son una componente importante de las alteraciones globales que tienen lugar actualmente tanto en Europa (EEA, 2006) como en el resto del mundo. Actualmente se ha incrementado el interés por la caracterización y cuantificación de las alteraciones que acaecen en los paisajes (Turner, 2005) así como en la expansión de los campos agrícolas (Aguilera y Talavera, 2009) los cuales consisten de nodos y segmentos. A menudo sus nodos y segmentos son propiedades características de su composición (por ejemplo el tipo de vegetación) y características espaciales (por ejemplo el ancho) (MacGarigal, 2014). El uso de las métricas del paisaje, así como, la combinación de ellas son un método efectivo para realizar la caracterización estructural de los campos agrícolas como se aprecia en las Figuras 4.7 y 4.9

Para la geomorfología quien estudia las formas de la superficie terrestre y los procesos que la originan (Leopold, *et al.*, 1995) esta técnica resulta de utilidad, ya que para entender las limitaciones y las fuerzas que determinan la estructura morfológica de los cuerpos de agua abiertos se puede requerir de una clasificación multivariada de los descriptores morfológicos. Esto lo podemos visualizar en las Figuras resultantes de las Cuerpos de agua de Tabasco así como de la Inundación de Tabasco. Cabe resaltar que la escala es un factor de suma importancia de la imagen que se ocupe para la evaluación de sus patrones.

Un resultado interesante en ambos casos de Tabasco es la combinación del conjunto de métricas PERIM – RCC – CONITG, la cual aporta la capacidad de discernir los cuerpos de agua tales como son los ríos. En la imagen Cuerpos de agua de Tabasco (Figura 4.15) no todos los ríos son resaltados debido a que la parte principal del río Grijalva se encuentra irrigando a las lagunas mostrándose en la imagen como un solo parche complejo, mientras que los segmentos del río, que debido a la resolución de la imagen, no se encuentran conectados al segmento de su cauce principal, se aprecian resaltados en azul del resto de los parches. En la Figura 4.20 de la Inundación de Tabasco se aprecia que la combinación de

esas métricas resulta apropiada para la separación de los ríos del resto de los cuerpos de agua.

Limitaciones

En cuanto a las limitaciones de esta metodología encontramos las siguientes:

- 1) Se deber ser rigurosamente cuidadoso al momento de realizar la segmentación de la imagen ya que entre menor sea la calidad de segmentación el cálculo de los descriptores morfológicas para cada patrón tendrá errores.
- 2) El algoritmo jerárquico aglomerativo, el cual fue el que mejor caracterizó las estructuras morfológicas, tiene una mayor duración en su proceso que los no jerárquicos, por lo que no es muy recomendado cuando la cantidad de parches que componen una clase del paisaje es extremadamente grande.
- 3) El patrón detectado en cualquier imagen está en función de la escala, abarcando el área comprendida dentro de los límites del paisaje como el tamaño del pixel. Desde el punto de vista estadístico, no podemos extrapolar más allá de la población muestreada, ni podemos detectar patrón o parche más allá de la medida del paisaje o por debajo de la resolución del pixel. Es fundamental definir la extensión y el tamaño de pixel para un estudio en particular, en la mayor medida posible, de lo contrario los patrones del paisaje detectados tendrá poco sentido y hay una buena posibilidad de llegar a conclusiones erróneas.
- 4) Sí durante la clasificación multivariada combinamos métricas de alta correlación en diferentes grupos, por ejemplo FRAC – CONTIG y FORMA – CONTIG donde FRAC y FORMA tienen muy alta correlación, existen variaciones mínimas en el mapa temática resultante, pero importantes según el objetivo que se busque.

Capítulo 5

Conclusiones



Imagen del satélite Landsat 7 de la Sierra Madre Oriental, México.

5.1 Conclusiones generales

La clasificación multivariada de las métricas del paisaje tiene la finalidad de generar un elemento de cuantificación de la morfología y estructura de los parches pertenecientes a una clase. Esta clasificación es una diferenciación cuantitativa basada en la estructura morfológica proporcionada por las métricas del paisaje de un parche.

En este trabajo se emplearon imágenes ópticas, de radar y sintéticas, esta última como apoyo de la validación del método. Para llevar a cabo una clasificación multivariada se requiere de varias inspecciones.

El proceso de segmentación difiere dependiendo del archivo de imagen y el objetivo a resaltar. La segmentación genera una imagen de dos clases: los parches y el resto de la imagen. Con base en los parches, las métricas del paisaje son calculadas. Es indispensable realizar una normalización a la gama de valores de los descriptores para evitar el predominio de una métrica. En algunos casos es necesario efectuar una transformación del histograma de la métrica para producir un histograma de comportamiento similar al Gaussiano.

La correlación entre el grupo de métricas de baja a media resultó conveniente al momento de realizar una clasificación multivariada.

El algoritmo *clustering* jerárquico aglomerativo resulta óptimo para dividir a un conjunto de patrones por sus características morfológicas. La separación entre clases fue validada por medio del análisis de la Divergencia Transformada y Jeffries Matusita.

Los resultados fueron satisfactorios al revelar la estructura en cada clase y cuantificarla. El proceso de clasificación multivariada dividió a los parches según su forma. En los mapas temáticos de salida se exhibieron parches que presentan una estructura morfológica muy compleja con un perímetro áspero, agujeros internos y una forma compleja. Así como, a los parches que muestran una morfología simple con perímetro liso y sin orificios intrínsecos.

Una clasificación multivariada da una idea de las diferencias morfológicas de un conjunto de parches que pertenece a la misma clase. Esta clasificación es una diferenciación cuantitativa basada en la estructura morfológica proporcionada por las métricas del paisaje de un parche.

Varias aplicaciones se pueden idear para la clasificación multivariada de las métricas del paisaje. Para cuantificar la evolución de una zona urbana en las ciudades medianas y grandes. Para el estudio de la cobertura de la tierra de una inundación. Para determinar la

estructura de campos de la agricultura. Además, como auxiliar al modelar las fuerzas que definen la estructura morfológica de los cuerpos de agua abiertos u otras estructuras de la cobertura terrestre.

5.2 Trabajo futuro

Siempre existe la posibilidad de realizar nuevos métodos y técnicas que nos permitan analizar un objetivo en particular, los siguientes puntos describen los trabajos futuros que permitan explorar las capacidades de la clasificación multivariada de las métricas del paisaje.

1. Obtener una muestra estadísticamente válida de las métricas empleadas en una clasificación, de esta manera calcular la media y matriz de covarianza para ingresarlos en un clasificador supervisado.
2. Determinar a las métricas y conjunto de métricas que son invariantes en la clasificación a diferentes escalas en una determinada un área de estudio.
3. Realizar una precisión semántica con los resultados obtenidos.

Referencias Bibliográficas

- Aguilera, F., Botequilha-Leitão, A., 2012. Selección de métricas de paisaje mediante análisis de componentes principales para la descripción de los cambios de uso y cobertura del suelo del algarve, Portugal. *GeoFocus (Artículos)*, nº 12, p. 93-121. ISSN: 1578-5157
- Aguilera, F., Talavera, R., 2009. “Valoración de escenarios futuros a través de la conectividad del paisaje”. *Observatorio medioambiental*, 12, pp. 17-36.
- Ardila, J., Espejo, O., Herrera, J., 2005. Validación de una metodología de clasificación de imágenes satelitales en un entorno orientado a objetos. *Ingeniería*, Vol. 10 No.1 pp:61-69
- Baker W., Cai Y., 1992. The r.le programs for multiscale analysis of landscape structure using the GRASS geographical information system. *Landscape Ecology*, Vol. 4, pp 291-302.
- Barba, E., Rangel, J., Ramos, R., 2006. Clasificación de los humedales de tabasco mediante sistemas de información geográfica. *Universidad y Ciencia* 22 (2): pp 101-110.
- Benz, U., Hofmann, P., Willhauck, G., Lingenfelder, I., Heynen, M., 2004. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS Journal of Photogrammetry & Remote Sensing*, 58(3-4) pp. 239–258.
- Beucher S., 1992. The watershed transformation applied to image segmentation. *Scanning Microscopy Supplement*, 6, pp.299–314.
- Borak, J., Lambin, E., Strahler, A., 2000. The use of temporal metrics for land cover change detection at coarse spatial scales, *International Journal of Remote Sensing*, Vol.21, pp. 1425 – 1432.
- Bulley, H., Bishop, M., Schroder, J., Haritashaya, U., 2013. Integration and classification tree analysis and spatial metrics to assess changes in supraglacial lakes in the Karakoram Himalaya, *International Journal of Remote Sensing*, Vol. 34, pp. 387 – 411.
- Botequilha-Leitão, A., 2001. Sustainable Land Planning. Towards a planning framework. Exploring the role of spatial statistics as a planning tool. Tesis doctoral. Instituto Superior Técnico. Universidade Técnica de Lisboa. Lisboa.

- Blaschke, T., Lang, S., Hay, G., 2008. Object-Based Image Analysis. Spatial Concepts for Knowledge-Driven Remote Sensing Applications. Berlin: Springer.
- Brinkhoff, T., 2015. Major Agglomerations of the World. Recuperado el 25 de Julio del 2015, de City Population Sitio web:
<http://www.citypopulation.de/world/Agglomerations.html>.
- Campbell, J., 2007. Introduction to Remote Sensing. Taylor and Francis, London, pp. 280-281.
- Canty, M., 2007. Image Analysis, Classification and Change Detection in Remote Sensing, CRC Taylor & Francis.
- Carleer, A., Debeir, O., Wolff, E., 2005. Assessment of very high spatial resolution satellite image segmentations. Photogrammetric Engineering & Remote Sensing, 71(11), pp. 1285–1294.
- Chandra A., Ghosh, S., 2006. Remote Sensing and Geographical Information System. University of Michigan. Alpha Science. 298 pp.
- Clark, P., Rilee, M., 2010. Remote Sensing Tools for Exploration. Observing and Interpreting the Electromagnetic Spectrum. New York: Springer.
- Costa, L., Marcondes, C., 2001. Shape Analysis and Classification. Theory and Practice, Image Processing Series
- Cushman, S., McGarigal, K., Neel, M., 2008. Parsimony in landscape metrics: Strength, universality and consistency. Ecological Indicators, 8, pp. 691-703.
- Dagnielie, P., 1975. Analyse statistique á plusieurs variables. Les Presses agronomiques de Gembloux. Belgique. 362 pp. 184.
- Dey, V., Zhang Y., Zhong, M., 2010. A Review on Image Segmentation Techniques with Remote Sensing Perspective. In: Wagner W., Székely, B. (eds.): ISPRS TC VII Symposium – 100 Years ISPRS, Vienna, Austria, July 5–7, 2010, IAPRS, Vol. XXXVIII, Part 7A
- Dramstad, W., Olson, J., Forman, R.T.T., 1997: Landscape Ecology Principles in Landscape Architecture and Land-Use Planning. Harvard University Graduate School of Design, Island Press and ASLA, USA.
- Elachi, Ch., 1987. Introduction to the Physics and Technniques of Remote Sensing. USA: John Wiley & Sons, Inc.
- Englert, B., Scully, M., Walther, H., 1994. The Duality in Matter and Light. Scientific American. 271 (6): 86-92.

- ERMEX. Estación de recepción México de la constelación Spot. Consultado el 2 de abril del 2015 de: <http://www.semar.gob.mx/s/informacion-sector/ciencia/ermexs.html>
- ESA, European Space Agency. Missions. Consultado el 12 de Noviembre de 2015 de: <https://sentinel.esa.int/web/sentinel/user-guides/sentinel-2-msi>
- European Environment Agency (EEA), 2006. Urban Sprawl in Europe. EEA Report N°10/2006. Copenhagen.
- FEESCM, 2000. Distrito Federal y Zona Metropolitana del Valle de México.
- Forman, R., 1995: Land Mosaics: The ecology of landscapes and regions. Cambridge. EE.UU.
- Forman, R., Godron, M., 1986. Landscape Ecology. New York: John Wiley & Sons. 619 pp.
- Gergel, S., Turner, M., 2002. Learning Landscape Ecology. A Practical Guide to Concept and Techniques. Springer-Verlag, New York.
- Greenhill, D., Ripke, L., Hitchman, A., Jones, G., Wilkinson, G., 2003. Characterization of suburban areas for land use planning using landscape ecological indicators derived from Ikonos-2 multispectral imagery, IEEE Transactions on Geoscience and Remote Sensing, Vol. 41, pp. 2015 – 2021.
- Gómez-Pompa, A., Dirzo, R., Fernández, B., Becerra, E., 1995. Las Reservas de la Biosfera y otras Áreas Naturales Protegidas de México. SEMARNAP. INE. CONABIO. 160 pp.
- Gonzalez, R., Woods, R., 2008. Digital Image Processing. USA: Pearson Education, Inc.
- Hayness, C. Digital Infrared Capture and Workflow. CRHfoto. Consultado el 5 de Junio del 2015 de: <http://www.crhfoto.co.uk/crh/digital%20infra-red/digital-ir.htm>.
- Herold, M., Scepan, J., Clarke, K., 2002. The use of remote sensing and landscape metrics to describe structures and changes in urban land use, Environment and Planning, Vol. 34, pp. 1443 – 1458.
- Huang, C., Geiger, E.L., and Kupper, J.A., 2006. Sensitivity of landscape metrics to classification scheme, International Journal of Remote Sensing, Vol. 27, pp. 2927 – 2948.
- INAFED. Enciclopedia de los municipios y delegaciones de México. Distrito Federal. Consultado el 30 de Julio de 2015 de: <http://www.inafed.gob.mx/work/enciclopedia/EMM09DF/mediofisico.html>

- INAFED. Enciclopedia de los municipios y delegaciones de México. Irapuato, Guanajuato. Consultado el 02 de Agosto de 2015 de <http://www.inafed.gob.mx/work/enciclopedia/EMM11guanajuato/mediofisico.html>
- INE. 2000. Programa de Manejo Reserva de la Biosfera Pantanos de Centla, México. 220 pp.
- INEGI-INIDEG Cuaderno estadístico municipal, Irapuato Guanajuato, 2001. Consultado el 02 de Agosto de: http://internet.contenidos.inegi.org.mx/contenidos/productos/prod_serv/contenidos/espanol/bvinegi/productos/historicos/2104/702825933296/702825933296_1.pdf
- INEGI. Cuéntame, Información por entidad. Distrito Federal. Consultado el 15 de Julio del 2015 de: <http://www.cuentame.inegi.org.mx/monografias/informacion/df/territorio/default.aspx?tema=me&e=09>
- INEGI. Anuario Estadístico del Estado de Tabasco. 446 pp consultado el 30 de Julio del 2015 de: http://www.inegi.org.mx/prod_serv/contenidos/espanol/bvinegi/productos/integracion/pais/anuario_multi/2012/tab/702825004060.pdf
- INEGI, 2010. Marco Geoestadístico Municipal, Irapuato.
- Jähne, B., 2005. Digital Image Processing. 6th. Ed. Berlin: Springer.
- Jähne, B., HauBecker, H., 2000. Computer Vision and Applications. A Guide for Students and Practitioners. San Diego: Academic Press.
- Jensen, J., 2000. Remote Sensing of the Environment: An Earth Resource Perspective USA: Prentice-Hall, Inc.
- Kapetsky, J., Aguilar, J., 2009. Sistemas de información geográfica, sensores remotos y mapeo para el desarrollo y la gestión de la acuicultura marina. FAO Documento Técnico de Pesca No. 458. Roma, FAO. 125p.
- Kettig, R., Landgrebe, D., 1976. Classification of multispectral image data by extraction and classification of homogeneous objects. IEEE Transactions on Geoscience Electronics, 14(1), pp. 19-26.
- Klinkenberg, B., 1994. A review of methods used to determine the fractal dimension of linear features, Mathematical Geology, Vol. 26, pp. 23 – 46.
- Leopold, L., Wolman, G., Miller, J., 1995. Fluvial Processes in Geomorphology. New York: Dover Publication, Inc.

- Li, S., 2009. Markov Random Field modelling in Image Analysis. Springer-Verlag, Heidelberg , New York, pp. 21-47.
- Lillesand, T., Kiefer, L., 2001. Remote sensing and image interpretation. 4th. Ed. USA: John Wiley & Sons, Inc.
- Lira, J., Frulla, L., 1998. An automated region growing algorithm for segmentation of texture regions in SAR images, *International Journal of Remote Sensing*, Vol. 19, pp. 3595 - 3606.
- Lira, J., 2006. Segmentation and morphology of open water bodies from multispectral images, *International Journal of Remote Sensing*, Vol. 27, pp. 4015 - 4038.
- Lira, J., Rodriguez, A., 2006. A divergence operator to quantify texture from multi-spectral satellite images, *International Journal of Remote Sensing*, Vol. 27, pp. 2683 – 2702.
- Lira, J., Hidalgos, L., 2007. Segmentation of urban built up area using Fisher discriminant analysis, intensity and vegetation strength of Landsat images, *WSEAS Transactions on Signal Processing*, Vol. 3, pp. 95 - 101.
- Lira, J., 2009. A Method to Derive Texture-relief From ASTER Bands 3N and 3B, *International Journal of Remote Sensing*, Vol. 30, pp. 6329 – 6341.
- Lira J., 2010. Tratamiento Digital de Imágenes Multiespectrales, 2da. Ed. México: Instituto de Geofísica, UNAM.
- Lira, J., 2014. Morphologic analysis of the temporal change of forest cover, *Geofísica Internacional*, Vol. 53, pp. 117 – 133.
- Lozano D., Hori M., 2007. El uso de la percepción remota y de los sistemas de información geográfica para el monitoreo ambiental. Recuperado el 14 de Julio del 2015, del Instituto Nacional de Ecología Sitio web: <http://www2.inecc.gob.mx/publicaciones/libros/507/cap4.html>
- Malinveni, E.S., Tasset, A., Bernardini, A., 2010. Automatic land use/land cover classification system with rules based both on objects attributes and landscape indicators, *Proceedings, GEOBIA 2010, Geographic Object-Based Image Analysis*, Ghent, Belgium, ISPRS, Vol. XXXVIII-4/C7.
- Mandelbrot, B., 1982. *The Fractal Geometry of Nature*. New York: W. H. Freeman and Co.
- Marín, E., 2014. Operadores vectoriales para el estudio de cambios morfológicos en imágenes multiespectrales. Tesis de maestría. Posgrado en ciencia e ingeniería de la computación UNAM.

- McGarigal, K. 2002. Landscape pattern metrics. Pp: 1135-1142. En: El-Shaarawi A.H. and Piegorsch W.W. (eds.) 2002. Encyclopedia of Environmetrics Volume 2. John Wiley & Sons, Sussex, England.
- McGarigal K., 2014. Fragstas, (unpublished computer program user manual and guide). Department of Environmental Conservation. University of Massachusetts, Amherst.
- Molina, Z. y Chuvieco E., 1996. Evaluación de índices texturales para discriminar morfología urbana: análisis de la ciudad de Maracay (Venezuela). Revista de Teledetección. No. 7.
- Mushkin, A., Gillespie, A., 2006. Mapping sub-pixel surface roughness on Mars using high-resolution satellite image data. Geophysical Research Letters.
- Mushkin, A., Gillespie A., 2005. Estimating sub-pixel surface roughness using remotely sensed stereoscopic dat. Remote Sensing of Environment, pp. 75 – 83.
- Olsen, E., Ramsey R., Winn, D., 1993. A Modified Fractal Dimension as a Measure of Landscape Diversity. Photogrammetric Engineering & Remote Sensing. Vol. 59, pp. 1517 – 1520.
- Ortiz-Pérez, M., Silke Cram, C., 2005. “Diferenciación eco-geográfica de Tabasco”. En Bueno J., Álvarez F. y Santiago S. (eds.) Biodiversidad del estado de Tabasco, pp. 305-322. México: Instituto de Biología, UNAM-CONABIO
- Oyana, T. J., Johnson, S.J., Wang, G., 2014. Landscape metrics and change analysis of a national wildlife refuge at different spatial resolutions, International Journal of Remote Sensing, Vol. 35, pp. 3109 – 3134.
- Parks-Watch, 2003. Perfil de Parque-México, Reserva de la Biosfera Pantanos de Centla. Consultado el 3 marzo del 2015 de: http://www.parkswatch.org/parkprofiles/pdf/pcbr_spa.pdf
- Patino J., Duque J., 2012. A review of regional science applications of satellite remote sensing in urban settings. Computers, Environment and Urban Systems, Vol. 37, pp. 1-17.
- Paudel, S., Yuan, F., 2012. Assessing landscape changes and dynamics using patch analysis and GIS, International Journal of Applied Earth Observation and Geoinformation, Vol. 16, pp. 66 – 76.
- Peng, J., Wang, Y., Ye, M., Wu, J., Zhang, Y., 2007. Effects of land-use categorization on landscape metrics: A case study in urban landscape of Shenzhen, China, International Journal of Remote Sensing, Vol. 28, pp. 4877 - 4895.

- Perea, A., Meroño, J., Aguilera, J., 2009. Clasificación orientada a objetos en fotografías aéreas digitales para la discriminación de usos del suelo. *Interciencia*. INCI Vol.34 No.9. pp. 612-616.
- Perevochtchikova, M., Lezama, J., 2010. Causas de un desastre: Inundaciones del 2007 en Tabasco, México. *Journal of Latin American Geography* 9(2):73-98.
- Plexida, S., Sfougaris, A.I., Ispikoudis, I.P., 2014. Selecting landscape metrics as indicators of spatial heterogeneity - A comparison among Greek landscapes, *International Journal of Applied Earth Observation and Geoinformation*, Vol. 26, pp. 26 – 35.
- Richards, J. A., Jia, X., 2006. *Remote Sensing Digital Image Analysis: An Introduction*. 4th Ed. New York: Springer-Verlag.
- Richards, J., 2013. *Remote Sensing Digital Image Analysis: An Introduction*. 5th Ed. New York: Springer-Verlag.
- Rodríguez, R., Lira, J., Rodríguez, I., 2012. Subsidence risk due to groundwater extraction in urban areas using fractal analysis of satellite images, *Geofísica Internacional*, Vol. 51, pp. 157 - 167.
- Rodríguez, A., 2008. Un operador divergencia para cuantificar textura a partir de imágenes multiespectrales de satélite. Tesis de maestría. Facultad de ingeniería UNAM.
- Rogers, C., 1993. Describing landscape: índices of structure. M.S. Thesis, Simon Fraser University, Burnaby, British Columbia. 170 pp.
- Rosenfield, A., Davis, L., 1979. Image segmentation and image model. *Proceedings of IEEE*, 67(5), pp. 764-772.
- Sabins, F., 2000. *Remote Sensing Principles and Interpretation*. New York: W. H. Freeman and Company.
- Saura, S., Castro, S., 2007. Scaling functions for landscape pattern metrics derived from remotely sensed data: Are their subpixel estimates really accurate, *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 62, pp. 201 – 216.
- SERNAPAM, Tabasco. Consultado el 02 de Agosto de: <http://www.sernapam.tabasco.gob.mx/content/commemoraci%C3%B3n-del-decreto-de-reserva-de-la-biosfera-pantanos-de-centla>
- Stein, A., Beurs, K., 2005. Complexity metrics to quantify semantic accuracy in segmented Landsat images, *International Journal of Remote Sensing*, Vol. 26, pp. 2937 – 2951.
- Sun, W., Xu, G., Gong, P., Liang, S., 2006. Fractal analysis of remotely sensed images: A review of methods and applications, *International Journal of Remote Sensing*, Vol. 27, pp. 4963 – 4990.

- Swain, P., Davis, S., 1978. *Remote Sensing: The Quantitative Approach*, McGraw-Hill, New York.
- Thakur, R., Dikshit, O., 1997. Contextual classification with IRS LISS-II imagery. *ISPRS Journal of Photogrammetry & Remote Sensing*, 52(2). pp. 92-100.
- Tischendorf, L., 2001. Can landscape indices predict ecological processes consistently? *Landscape Ecology*, 16, pp. 235–254.
- Turner M.G., O'Neill R.V., Gardner R.H., Milne B.T., 1989. Effects of changing spatial scale on the analysis of landscape pattern, *Landscape Ecology*, Vol. 3, pp. 153 – 162.
- Turner, M.G., 2005. “Landscape Ecology: What is the state of the science?” *Annual Review of Ecology, Evolution, and Systematics.*, 36, pp. 319-344.
- Uuemaa, E.; Antrop, M.; Roosaare, J.; Marja, R. y Mander, U., 2009. “Landscape Metrics and Indices: An Overview of Their Use in Landscape Research”, *Living Rev. Landscape Res.*, (3) 1. Artículo en línea: <http://www.livingreviews.org/lrlr-2009-1>
- Visa, A., Valkealahti, K., Simula, O., 1991. Cloud detection based on texture segmentation by neural network methods. *IEEE International Joint Conference on Neural Networks*, 2, pp. 1001-1006.
- Wang, D., Terman, D., 1997. Image segmentation based on oscillatory correlation. *Neural Computation*, 9(4), pp. 805-836.
- Ward, J., 1963. Hierarchical Grouping to Optimize an Objective Function, *Journal of the American Statistical Association*, 58, 236–244.
- West, R., Psuty, N, Thom, B., 1985. *Las tierras bajas de Tabasco en el sureste México, Gobierno del Estado de Tabasco: Instituto de Cultura de Tabasco, México (Tabasco), Serie Monografía pp. 21-44.*
- Xiaoxia, S., Jixian, Z., Zheng Jun, L., 2005: A comparison of object-oriented and pixel-based classification approaches using QUICKBIRD Imagery. *Proceeding of XXXVI ISPRS meeting, 16 October 2005, Hangzhou, China*, pp. 309–312.
- Zhong, C., Zhongmin, Z., DongMei, Y., Renxi, C., 2005. Multi-scale segmentation of the high resolution remote sensing image. In: *Proceedings of IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 5, pp. 3682- 3684.