



UNIVERSIDAD AUTÓNOMA CHAPINGO

DIVISIÓN DE CIENCIAS FORESTALES

**TELEDETECCIÓN MULTITEMPORAL DE LA REDUCCIÓN DEL VIGOR
VEGETAL EN EL NORTE DE LA SIERRA NEVADA, MÉXICO**

TESIS

QUE COMO REQUISITO PARCIAL
PARA OBTENER EL GRADO DE
MAESTRO EN CIENCIAS EN
CIENCIAS FORESTALES

PRESENTA:

HÉCTOR RENÉ BECERRIL CEJUDO



DIRECCIÓN GENERAL ACADÉMICA
DEPTO. DE SERVICIOS ESCOLARES
OFICINA DE EXÁMENES PROFESIONALES

enero de 2014

Chapingo, Estado de México




**TELEDETECCIÓN MULTITEMPORAL DE LA REDUCCIÓN DEL VIGOR
VEGETAL EN EL NORTE DE LA SIERRA NEVADA, MÉXICO**

Tesis realizada por el Ing. Héctor René Becerril Cejudo bajo la dirección del comité asesor indicado, aprobada por el mismo y aceptada como requisito parcial para obtener el grado de:

MAESTRO EN CIENCIAS EN CIENCIAS FORESTALES

Director:



Dr. Genaro Aguilar Sánchez

Co Director:



Dr. Eduardo Vargas Pérez

Asesor:



M.C. Alejandro Corona Ambriz

Asesor:



M. C. Francisco Alberto Domínguez Álvarez

Chapingo, Estado de México, enero de 2014

DEDICATORIA

A mi hijo CRISTÓBAL que a pesar de la distancia, la ausencia y los momentos difíciles durante este proceso, su alegría estuvo conmigo en todo momento.

A mis padres HÉCTOR y MARÍA DE JESÚS por su incansable apoyo en mi formación, por su compañía y enseñanza, y por haber sembrado en mi una forma de ver el mundo donde los valores y el respeto a la vida son los pilares para extender un sólido puente hacia nuestros sueños.

A mi hermano JORGE por su respaldo y su compañía en esta vida en la que hemos compartido cosas buenas y malas, con las que siempre hemos sabido fortalecer nuestros lazos como familia.

A mi primo TONY que ha sido y será siempre otro hermano para mí.

AGRADECIMIENTOS

A la Universidad Autónoma Chapingo por abrirme las puertas nuevamente y haberme permitido continuar con mi formación en esta gloriosa institución.

A la División de Ciencias Forestales por todas las facilidades brindadas durante esta investigación.

A los miembros de mi comité de tesis por sus atinadas observaciones y el apoyo necesario para la realización de esta investigación.

A mis maestros, por su invaluable aportación y apoyo en este proceso y de quienes me llevo lo mejor de sus enseñanzas y de su cátedra exquisita.

Al Consejo Nacional de Ciencia y Tecnología por el apoyo brindado para la realización de esta investigación.

BIOGRAFÍA

Héctor René Becerril Cejudo

(México 1977) Docente de tiempo completo del subsistema DGETA en Aguascalientes. Cursó sus estudios profesionales en la Universidad Autónoma Chapingo de donde egresó como ingeniero en agroecología. Fue director de agroecología y medio ambiente de la Federación de Colegios de Ingenieros Agrónomos de México, posteriormente fungió como subdirector de cuencas y después como subdirector de agricultura en la Subsecretaría de Fomento y Normatividad Ambiental de la SEMARNAT en la ciudad de México. Se desempeñó también como supervisor regional de la Comisión Nacional de las Zonas Áridas en el estado de Guerrero para la ejecución del Componente de Conservación y Uso Sustentable de Suelo y Agua dentro de la estrategia del Proyecto Estratégico para la Seguridad Alimentaria (COUSSA-PESA).

ÍNDICE DE CONTENIDO

I. INTRODUCCIÓN	1
1.1. Justificación	3
1.2. Hipótesis	3
1.3. Objetivo general	3
1.3.1. Objetivo específico	4
1.4. Marco de referencia	4
1.4.1. Localización	4
1.4.2. Fisiografía	5
1.4.3. Vegetación y uso de suelo	5
1.4.4. Clima	9
1.5. Marco teórico de referencia	9
1.5.1. Teledetección ambiental	9
1.5.2. Teledetección en estudios temporales	10
1.5.3. Principios de la teledetección	11
1.5.4. Las imágenes satelitales	14
1.5.5. Composiciones en color	15
1.5.6. El sensor Thematic Mapper	16

1.5.7. Procesamiento de imágenes	17
1.5.8. Análisis de Componentes Principales (ACP)	19
1.5.9. Álgebra del ACP	19
1.5.10. EL ACP en teledetección	23
1.5.11. EL ACP en estudios temporales	26
1.5.12. Clasificación supervisada	27
1.5.12.1. Clasificación por ángulo espectral	27
1.5.13. Evaluación de clasificaciones	29
1.5.13.1. Muestreo aleatorio estratificado	30
1.5.13.2. Tamaño de muestra	30
1.5.13.3. Matriz de confusión	32
1.5.13.4. Índice Kappa	33
II.... MATERIALES Y MÉTODOS	35
2.1. Materiales	35
2.2. Métodos	36
2.2.1. Procesamiento de imágenes	36
2.2.1.1. Corrección radiométrica	36
2.2.1.2. Composición de imagen multitemporal	37
2.2.1.3. Recorte de la escena y máscara	38

2.2.2. Exploración de correlaciones	39
2.2.3. Transformación por <i>Componentes Principales</i>	40
2.2.4. Selección de <i>componentes principales</i>	44
2.2.5. Generación de Imagen de referencia	46
2.2.6. Corrección de imagen de referencia	47
2.2.7. Clasificación de pixeles	48
2.2.7.1. Colección de firmas de referencia	48
2.2.7.2. Clasificación por ángulo espectral	51
2.2.7.3. Establecimiento de ángulos de búsqueda	51
2.2.7.4. Clasificación	52
2.2.7.5. Evaluación de la Clasificación	53
III.. RESULTADOS	56
IV.. DISCUSIÓN Y CONCLUSIONES	60
V.... LITERATURA CITADA	62
ANEXO 1-A	- 1 -
ANEXO 1-B	- 2 -

ÍNDICE DE FIGURAS

Figura 1. Localización geográfica de la zona de estudio..	5
Figura 2. Aspectos del relieve	6
Figura 3. Curvas de nivel.	6
Figura 4. Tipos de vegetación en la zona de estudio	8
Figura 5. Representación de los campos eléctrico y magnético.	12
Figura 6. Sectores del espectro electromagnético.	13
Figura 7. Arreglo de filas y columnas de una imagen digital	15
Figura 8. Gráficas de cinco firmas espectrales	18
Figura 9. Reacomodamiento de píxeles de una imagen para el ACP.	25
Figura 10. Ángulo espectral entre dos objetos a clasificar	29
Figura 11. Diseño de una matriz de confusión	33
Figura 12. Recorte y máscara para excluir zonas de poco interés	38
Figura 13. Diagrama de dispersión.	39
Figura 14. Representación gráfica de los eigenvectores.	45
Figura 15. Imagen de referencia	46
Figura 16. Imagen de referencia con modificación del contraste.	47
Figura 17. Enlace geográfico de dos ventanas en ENVI 4.1	50
Figura 18. Firma espectral con crecimiento de la banda 5	50
Figura 19. Matriz de confusión con los resultados de la clasificación	56

Figura 20. Imagen de zonas con reducción en el vigor vegetal.	57
Figura 21. Mapas de referencia.....	59

ÍNDICE DE CUADROS

Cuadro 1. Características de registro del sensor TM	16
Cuadro 2. Nivel de correspondencia del índice Kappa.	34
Cuadro 3. Datos de adquisición del sensor	35
Cuadro 4. Software.....	36
Cuadro 5. Estructura de la imagen multitemporal.	37
Cuadro 6. Matriz de correlación R.....	43
Cuadro 7. Matriz de transformación	44
Cuadro 8. Ángulos de búsqueda.	52
Cuadro 9. Superficie afectada por tipo de vegetación.....	58

TELEDETECCIÓN MULTITEMPORAL DE LA REDUCCIÓN DEL VIGOR VEGETAL EN EL NORTE DE LA SIERRA NEVADA, MÉXICO.

MULTI-TEMPORAL REMOTE SENSING OF *PLANT VIGOR REDUCTION* FOR THE NORTH OF SIERRA NEVADA WOOD, MÉXICO

Héctor René **Becerril Cejudo**¹ y Genaro **Aguilar Sánchez**²

Resumen

Los cambios en la vegetación se dan a escalas pequeñas y de forma gradual. La vegetación tiene una respuesta característica en las bandas 3, 4 y 5 del sensor Thematic Mapper (TM); incrementos en la banda 5 se asocian con la reducción del vigor vegetal. Se busca clasificar zonas que presentan reducción del vigor vegetal en el norte de la Sierra Nevada, México, usando una transformación por componentes principales de una imagen TM multitemporal y el algoritmo de clasificación por ángulo espectral. Los resultados muestran que 1,816 hectáreas presentan reducción en el vigor vegetal, principalmente en el bosque de pino. El índice Kappa fue de 0.37 indicando un nivel de correspondencia discreto.

Palabras clave: teledetección multitemporal, componentes principales, ángulo espectral.

Abstract

Changes in vegetation are generally low intensity and gradual through time. Vigorous vegetation has a characteristic response on bands 3, 4 and 5 of the Thematic Mapper sensor (TM). Increments in band 5 vegetation responses are associated with plant vigor reduction. This work aims to classify plant vigor reduction zones for the north of Sierra Nevada Wood, México, by using a principal components transformation on a multitemporal TM image and applying the spectral angle classifier algorithm. Classification results showed that 1,816 hectares express a plant vigor reduction, principally on pine forest; Kappa value obtained was 0.37 that represents a discrete correspondence level.

Key words: multitemporal remote sensing, principal components, spectral angle.

¹ Tesista

² Director

TELEDETECCIÓN MULTITEMPORAL DE LA REDUCCIÓN DEL VIGOR VEGETAL EN EL NORTE DE LA SIERRA NEVADA, MÉXICO

I. INTRODUCCIÓN

México es un país de gran importancia en cuanto a recursos forestales, siendo a nivel América Latina el tercer lugar por superficie forestal ocupada con 138 millones de hectáreas según datos de 2010 (DEL ÁNGEL-MOBARAK, 2012). La deforestación es el principal problema para las áreas forestales de México, entendiendo como deforestación no solo la pérdida de superficie arbolada efectiva sino también la fragmentación de los bosques, la cual muchas veces lleva a procesos irreversibles de pérdida de biodiversidad (SARUKHÁN *et al* citado por DEL ÁNGEL-MOBARAK, 2012).

La zona norte de la Sierra Nevada, localizada en la parte central de México, se ha visto afectada por eventos naturales como incendios forestales y el ataque de plagas, así como por actividades humanas como el cambio de uso de suelo con fines de pastoreo y la explotación forestal de recursos maderables y no maderables (SOTO, 2009).

La teledetección es una herramienta que facilita el monitoreo del territorio a partir del análisis de la respuesta espectral de las diferentes coberturas presentes en la superficie de la tierra. La vegetación vigorosa tiene una respuesta espectral característica que se expresa con valores altos de energía radiante reflejada en el sector del espectro electromagnético correspondiente al infra-rojo cercano, y valores bajos en el sector visible y en el infra-rojo medio. La alta respuesta en el sector infra-rojo cercano y la absorción en el sector visible está dada por el contenido de pigmentos en la planta sana,

la clorofila es el principal pigmento que condiciona esta respuesta. El contenido de agua en la planta por su parte, hace que se presente una alta absorción de energía en el infrarrojo medio; el aumento de la respuesta espectral de la vegetación en infrarrojo medio se interpreta típicamente como reducción del vigor vegetal.

La presente investigación tiene como objetivo identificar aquellas zonas forestales de la parte norte de la Sierra Nevada, México, que manifiesten un patrón de reducción del vigor vegetal dentro del periodo 1990 a 2000.

Para lograr los objetivos se realizó un proceso de clasificación supervisada sobre una imagen multitemporal formada con las bandas 3, 4 y 5 del sensor Thematic Mapper (TM) de los años 1990, 1993, 1995, 1997 y 2000, utilizando para esto el algoritmo de clasificación por ángulo espectral. Para el levantamiento de puntos de entrenamiento se usó una imagen de referencia generada por los componentes principales de la imagen multitemporal con el fin de mejorar la discriminación visual entre los píxeles que expresan el patrón vegetal de interés y aquellos otros que expresan cualquier otro. Los resultados obtenidos indican que existe una superficie de 1,816 hectáreas dentro de la zona de estudio que presentó una reducción en el vigor vegetal para el período analizado. El índice Kappa obtenido por la clasificación fue de 0.37, lo que indica que el nivel de correspondencia con la realidad es de un nivel discreto.

1.1. JUSTIFICACIÓN

Los cambios en la vegetación natural se dan típicamente a escalas muy pequeñas, como es el caso de los claros generados por la muerte de árboles en los ecosistemas forestales y las afectaciones producto de variaciones climáticas. Por tal motivo, es importante conocer y localizar aquellas áreas que presentan cambios de baja intensidad con el fin de planificar de manera preventiva acciones enfocadas a la conservación y restauración forestal. Los datos obtenidos de la presente investigación serán de gran utilidad para desarrollar estrategias y acciones de conservación específicas para la zona de estudio, del mismo modo, serán de interés para futuras investigaciones sobre el monitoreo de los recursos forestales y el estudio del cambio climático y sus impactos.

1.2. HIPÓTESIS

Usando los componentes principales de una imagen multitemporal del sensor TM y el algoritmo de clasificación por ángulo espectral, es posible clasificar áreas forestales que manifiesten cambios de menor escala a través del tiempo relacionados con el contenido de agua en la planta.

1.3. OBJETIVO GENERAL

Conocer el comportamiento de la vegetación forestal con respecto a posibles tendencias negativas relacionadas con el contenido de agua en la planta en el norte de la Sierra Nevada, México, dentro del periodo de 1990 a 2000.

1.3.1. OBJETIVO ESPECÍFICO

Del objetivo general establecido se desprende un objetivo específico:

1. Identificar zonas forestales que presenten reducción del vigor vegetal en el norte de la Sierra nevada, México.

1.4. MARCO DE REFERENCIA

A continuación se describen las características generales del área de estudio como son su localización geográfica, fisiografía y el tipo de vegetación y uso de suelo.

1.4.1. LOCALIZACIÓN

El área de estudio se localiza geográficamente entre los $98^{\circ}38'50''$ y los $98^{\circ}46'46''$ de Longitud Oeste; y entre los $19^{\circ}22'28''$ y los $19^{\circ}29'49''$ de Latitud Norte; se distribuye territorialmente sobre los estados de Puebla y Tlaxcala hacia el este y noreste, y sobre el Estado de México hacia el oeste (FIGURA 1).




Figura 1. En amarillo se indican los límites de la zona de estudio.

1.4.2. FISIOGRAFÍA

La zona de estudio pertenece al eje neo-volcánico transversal y sus principales cumbres son la montaña Telapón y la montaña Tláloc, siendo esta última la de mayor elevación con 4,200 msnm (FIGURA 2). El rango altitudinal va de los 2,800 a los 4,200 msnm (FIGURA 3).

1.4.3. VEGETACIÓN Y USO DE SUELO

En la zona de estudio se presentan diferentes comunidades vegetales a diferentes niveles de altitud del terreno destacando la mayor presencia de bosque de pino.




Figura 2. Aspectos del relieve desde una perspectiva norte-sur.




Figura 3. Curvas de nivel a cada 200 metros de elevación.

Existen diferentes distribuciones altitudinales de la vegetación dentro de la zona de estudio SANCHEZ (2004) y están definidas como se muestran a continuación:

- a) Encinar arbustivo: de los 2,750 a los 2,840 msnm.
- b) Bosque de encino: de los 2,850 a los 2,950 msnm.
- c) Bosque mixto: de los 2,900 a los 3,200 msnm.
- d) Bosque de oyamel: de los 3,100 a los 3,500 msnm.
- e) Bosque de pino: de los 3,500 a los 3,900 msnm.
- f) Zacatal alpino: de los 3,900 a los 4,100 msnm.

Los ecosistemas con presencia dominante de Pinos (*Pinus hartwegii* en las partes más altas, *Pinus montezumae* en las partes medias); estos se distribuyen sobre los municipios de Ixtapaluca, Chalco y Tlalmanalco; en esta zona se ha dificultado la reforestación debido a la poca humedad presente; así mismo, se ha reportado que la tala clandestina es otro factor de impacto para este ecosistema (SOTO, 2009).

Con respecto al ecosistema de bosque de oyamel, con presencia dominante de *Abies religiosa*, este se distribuye principalmente sobre los municipios de Atlautla, Tlalmanalco, Amecameca y Ecatepec; cabe destacar que esta zona estuvo bajo explotación forestal por empresas papeleras, principalmente por la Papelera San Rafael entre los años de 1987 a 1991 (SOTO, 2009).

Por último, el ecosistema de encino-pino, con diversidad de especies forestales y de arbustos con dominancia de encino y pino, tiene una distribución altitudinal que va de los 2,400 a los 3,400 msnm; este tipo de bosques no fue de interés para la explotación de

madera, sin embargo, se ha visto afectado por el ataque de plagas (descortezador y muérdago principalmente), por la tala con fines de extracción de leña y por el cambio de uso de suelo para la ganadería extensiva (SOTO, 2009).

La cartografía digital facilitada por el Instituto Nacional de Ecología ofrece una mejor apreciación de la distribución de los tipos de vegetación en la zona (FIGURA 4) donde se aprecia la mayor presencia de bosque de pino sobre otros tipos de vegetación como el bosque de oyamel y el bosque de pino-encino.




Figura 4. Tipos de vegetación en la zona de estudio con dominancia de bosque de pino.

1.4.4. CLIMA

SANCHEZ (2004) menciona la presencia de tres sub-climas en la parte correspondiente al declive occidental de la zona de estudio:

- C(w0)(w)b(i'): templado subhúmedo con precipitación media anual de 700 mm, con régimen de lluvias en verano y temperatura media anual entre 12 y 18°C.
- C(w1)(w)b(i'): templado sub-húmedo con precipitación media anual entre 800 y 900 mm, con régimen de lluvias en verano y temperatura media anual entre 12 y 18°C.
- C(w2)(w)b(i'): templado sub-húmedo con una precipitación media anual entre 900 y 1200 mm, con régimen de lluvias en verano y una temperatura media anual entre 10 y 14°C.

1.5. MARCO TEÓRICO DE REFERENCIA

En este apartado se describen las bases teóricas y las técnicas utilizadas para alcanzar los objetivos planteados.

1.5.1. TELEDETECCIÓN AMBIENTAL

El uso de imágenes obtenidas desde plataformas satelitales ha ido en aumento ya que sirven como fuente de datos para los Sistemas de Información Geográfica, principalmente en el análisis de fenómenos ambientales (ORDOÑES y MARTÍNEZ-ALEGRÍA, 2003). La aplicación principal de la teledetección ha sido la identificación y

clasificación de tipos de uso de suelo para la producción de mapas temáticos con fines de planificación territorial (FLORES and ISLAS, 2006).

En el pasado era difícil obtener datos consistentes sobre la superficie terrestre a escala regional, además de que la colecta de información demandaba tiempo y recursos (HAINES-YOUNG *et al.*, 1993). La ciencia de la percepción remota surge no solo por la cualidad de observar a distancia un fenómeno u objeto, sino porque además, gracias al avance tecnológico, se cuenta con los medios para registrar los datos del fenómeno u objeto observado (BARRET and CURTIS, 1992).

La teledetección es el arte y la ciencia de adquirir información sobre un objeto, superficie o fenómeno a partir de analizar los datos registrados por un dispositivo que no está en contacto directo con el objeto, superficie o fenómeno de estudio (LILLESAND and KIEFER, 1994).

La teledetección ambiental por su parte, puede definirse como el arte o la ciencia de observar y adquirir información sobre objetos, superficies y fenómenos presentes en la superficie terrestre mediante el uso de sensores que no están en contacto directo con los objetos, superficies o fenómenos de estudio. Para llevar a cabo la observación y adquisición de información, es necesario que exista algún tipo de interacción entre el sensor y el objeto o superficie de estudio; tal interacción es el flujo energético registrado por el sensor (CHUVIECO, 2010).

1.5.2. TELEDETECCIÓN EN ESTUDIOS TEMPORALES

La teledetección es una herramienta para el análisis territorial que hace posible conocer la localización de los cambios sobre la superficie terrestre desde una perspectiva

histórica, lo que permite hacer un seguimiento de fenómenos dinámicos como la deforestación y cambios de uso de suelo (MERTENS y LAMBIN citados por SERRA *et al.*, 2001) (CABELLO y PARUELO, 2008).

Gracias a la amplia superficie que cubren las imágenes obtenidas desde plataformas satelitales y a la capacidad de cubrir periódicamente la misma zona, se facilita el monitoreo y detección de fenómenos que se presentan en la superficie terrestre.

Por otra parte, los cambios en la vegetación se dan típicamente a escalas muy pequeñas, como es el caso de los claros generados por la muerte de árboles en los ecosistemas forestales y las afectaciones producto de variaciones climáticas; aunque también pueden presentarse cambios a escalas mayores e inmediatas donde la vegetación responde a disturbios intensos como puede ser un incendio forestal (HOBBS, R. J., and MOONEY, H. A. 1990).

El análisis multitemporal en teledetección implica entonces estudiar la misma superficie de terreno en diferentes momentos en el tiempo (LILLESAND and KIEFER, 1994; ZHOU *et al.*, 2008). Este seguimiento temporal de las superficies permite detectar cambios de diferentes magnitudes.

1.5.3. PRINCIPIOS DE LA TELEDETECCIÓN

Los principios de la teledetección se basan en las teorías cuántica y ondulatoria que establecen que, a menos que un cuerpo tenga una temperatura igual al cero absoluto (-273 °C), dicho cuerpo refleja, absorbe y emite energía; esta energía llamada energía electromagnética es emitida en forma de ondas.

Es posible observar un cuerpo en el espacio al percibir tanto la energía reflejada como la energía emitida por dicho cuerpo. La energía reflejada por el cuerpo observado proviene de una fuente de energía ajena al mismo como puede ser el sol. En algunos casos, la fuente de energía puede ser la propia plataforma de observación donde se encuentra el sensor, tal es el caso de los sistemas RADAR y LIDAR, los cuales emiten energía que después es reflejada por el objeto de estudio y finalmente es percibida por el sensor.

Las propiedades de la energía electromagnética han sido explicadas por la teoría ondulatoria, desarrollada por Huygens y Maxwell; y por la teoría cuántica desarrollada por Planck y Einstein (CHUVIECO, 2010).

La teoría ondulatoria dice que la energía electromagnética se transmite de un lugar a otro de manera continua, a la velocidad de la luz y en dos campos ortogonales entre sí correspondientes a un campo magnético y un campo eléctrico (FIGURA 5).




Figura 5. Representación de los campos eléctrico y magnético (Fuente: www.investigacionyciencia.es).

De acuerdo con la teoría ondulatoria, es posible describir el flujo de energía gracias a dos características del mismo: la longitud de onda (λ) y la frecuencia (ν); ambas características están inversamente relacionadas:

$$c = \lambda \nu$$

Donde c es igual a la velocidad de la luz, λ representa la longitud de onda normalmente en μm y ν es la frecuencia en hertzios.

Gracias a la teoría cuántica es posible conocer la cantidad de energía que transporta un fotón, siempre que se conozca su frecuencia:

$$Q = h\nu = h (c/\lambda)$$

Donde Q es la energía radiante del fotón en *Julios*, ν es la frecuencia y h es la constante de Planck (6.626×10^{-34} J s). Lo anterior indica que a menor longitud de onda el contenido energético será mayor y viceversa.

En la naturaleza, la sucesión de valores de longitud de onda se presenta de manera continua, sin embargo, arbitrariamente se definen y establecen bandas o segmentos donde se observan similitudes en el comportamiento de la radiación electromagnética. La representación de las longitudes de onda de este modo organizadas se conoce como espectro electromagnético (FIGURA 6).




Figura 6. Sectores del espectro electromagnético desde los rayos gamma (energía con mayor frecuencia) hasta las ondas de radio (energía de baja frecuencia) (Fuente: <http://earthobservatory.nasa.gov>).

Los diferentes tipos de cobertura presentes en la superficie terrestre reflejan la energía solar en diferentes longitudes de onda y en diferentes intensidades de acuerdo a las características físicas, químicas y geométricas de dichas coberturas, y de acuerdo a otros factores como son las condiciones ambientales, ángulo solar y tipo de suelo presente (BARRET and CURTIS, 1992).

1.5.4. LAS IMÁGENES SATELITALES

Una imagen satelital puede entenderse como un arreglo de pixeles acomodados en filas y columnas (FIGURA 7), cada pixel cuenta con coordenadas geográficas asignadas y representan individualmente un valor de intensidad de energía radiante de una determinada longitud de onda proveniente de una porción de la superficie terrestre; tal energía fue captada, registrada y codificada por un sensor remoto.

La imagen satelital puede entonces pensarse también como una matriz tridimensional donde cada intersección de filas y columnas corresponde a una posición geográfica y a un pixel; la otra dimensión está dada por la banda del espectro electromagnético a la que corresponde el dato registrado en ese pixel (FERRERO *et al.*, 2002).

Los sensores montados en plataformas satelitales o en plataformas aéreas pueden registrar variaciones de flujo de energía en diferentes longitudes de onda proveniente de la superficie terrestre; esta información se almacena de manera digital en diferentes canales de registro del sensor o bandas espectrales.




Figura 7. Arreglo de filas y columnas de una imagen digital (Fuente: <http://earthobservatory.nasa.gov>).

El número de bandas en las que puede registrar datos un sensor depende de la resolución espectral del mismo; la resolución espectral se refiere a la capacidad del sensor de percibir y diferenciar intensidades de energía radiante en diferentes segmentos adyacentes del espectro electromagnético.

1.5.5. COMPOSICIONES EN COLOR

Es posible generar distintas composiciones en color utilizando las diferentes bandas de un sensor. El procedimiento consiste en asignar una banda distinta a cada uno de los canales de colores primarios (azul, verde, rojo). Este procedimiento permite visualizar de manera simultánea información de distintas regiones del espectro electromagnético (CHUVIECO, 2010).

1.5.6. EL SENSOR THEMATIC MAPPER

El sensor Thematic Mapper (TM) de las plataformas Landsat 4 y 5, es un sensor del tipo multiespectral con capacidad de detectar energía radiante en siete bandas, correspondientes a siete diferentes longitudes de onda que van desde la porción visible del espectro electromagnético (de los 0.45 a los 0.7 μm) hasta el sector del infra-rojo y del infra-rojo térmico (de los 10.4 a los 12.5 μm).

La resolución espacial del sensor es media, ya que genera imágenes con pixeles cuyas dimensiones representan una porción del terreno de 30 x 30 m para las bandas multiespectrales (bandas 1,2,3,4,5,7), y de 120 x 120 m para la banda térmica (banda 6).

En cuanto a la resolución radiométrica del sensor, esta es de 8 bits, lo que quiere decir que puede registrar el equivalente a $2^8=256$ diferentes valores, correspondientes a distintas intensidades de energía radiante detectadas dentro de cada banda.

Una escena del sensor TM cubre una superficie cuadrada de 185 x 185 km (CUADRO 1), lo que permite monitorear fácilmente grandes superficies.

Cuadro 1. Características de registro del sensor TM (Global Land Cover Facility, 2013).

Satélite	Sensor	Bandas	Longitud de onda	Tamaño de escena	Tamaño de pixel
L-5	TM multi-spectral	1,2,3,4,5,7	0.45 - 2.35 μm	185 x 185 km	30 m
L-5	TM thermal	6	10.40 - 12.50 μm		120 m

1.5.7. PROCESAMIENTO DE IMÁGENES

Los sensores son diseñados para generar una respuesta lineal de la radiancia espectral incidente, esta radiancia se mide en Watts por metro cuadrado y por ángulo sólido de medida (estéreo-radián) para una longitud de onda λ (CHUVIECO, 2010).

Cada banda de un sensor multispectral tiene asignada una función de respuesta propia, y las características de esta función están regidas por instrumentos calibrados (LILLESAND and KIEFER, 1994).

Las unidades de radiancia son comúnmente transformadas a unidades de reflectividad aparente o reflectancia, que son unidades de magnitud relativa que describen la relación entre la cantidad de flujo energético reflejado por la superficie terrestre y la cantidad de flujo energético incidente en el tope de la atmósfera para diferentes longitudes de onda.

Para estudios en los que se busca comparar imágenes adquiridas en fechas distintas, es necesario aplicar sobre las mismas una corrección por elevación solar y una corrección de distancia tierra-sol para obtener nuevas unidades de reflectancia. Con estas dos correcciones, las imágenes adquiridas bajo distintos ángulos de iluminación solar son normalizadas por medio del cálculo del valor de brillo para un pixel, asumiendo que el sol estaba en la posición zenith en cada fecha (LILLESAND and KIEFER, 1994). Al aplicar esta corrección radiométrica sobre la imagen, es posible realizar el análisis multitemporal. Para poder hacer la corrección por ángulo solar y por distancia tierra-sol, es necesario previamente transformar los números digitales (ND) de todas las bandas a valores físicos de radiancia, con lo que se verán modificadas las respuestas espectrales de dichas bandas (FIGURA 8). A las gráficas que representan las respuestas espectrales de las bandas de un sensor se les conoce como firmas espectrales.




Figura 8. Gráficas de cinco firmas espectrales antes (izquierda) y después (derecha) de transformar los ND en valores físicos de radiancia.

Conociendo los coeficientes de calibración de la función de respuesta, es posible obtener los valores físicos de radiancia detectados por el sensor a partir de los ND. Los coeficientes de calibración se encuentran en el archivo de cabecera de la imagen adquirida, normalmente se trata de un archivo de texto.

De acuerdo con CHUVIECO (2010) y con LILLESAND and KIEFER (1996), la relación entre la radiancia y los ND originales se da de la siguiente manera:

$$L_{sen,k} = a_{0,k} + a_{1,k} ND_k$$

Donde:

$L_{sen,k}$ = Radiacia espectral recibida por el sensor en la banda k .

ND = Número digital o valor digital de la imagen en la banda k .

$a_{0,k}$ y $a_{1,k}$ corresponden a los coeficientes de calibración para la banda k donde:

$a_{0,k}$ es la intersección al origen de la función de respuesta.

$a_{1,k}$ es la pendiente de la función de respuesta.

1.5.8. ANÁLISIS DE COMPONENTES PRINCIPALES (ACP)

El análisis de componentes principales (ACP) es una técnica estadística dentro de la colección de los métodos multivariados, los cuales son usados comúnmente cuando se hacen muchas medidas sobre cada uno de los objetos de una o más muestras, entendiendo como medidas a diferentes variables y como objetos a unidades experimentales u observaciones (RENCER, 2002). Las técnicas estadísticas utilizadas en el análisis multivariado permiten al analista detectar patrones dentro de datos cuantitativos (SPICER, 2005).

El ACP fue introducido por Karl Pearson a principios del siglo XX, sin embargo, el tratamiento formal del método se debe a Hotelling (1933) y a Rao (1964); con este método se busca transformar un conjunto de p variables correlacionadas, en otras estructuras hipotéticas llamadas componentes principales (NEIL, 2002). El uso más común del ACP ha sido buscar maximizar la varianza de una combinación lineal de las variables (RENCER, 2002). Los componentes principales son entonces combinaciones lineales de variables aleatorias que tienen propiedades especiales en términos de varianza (ANDERSON, 2003).

En algunos tipos de estudios, los componentes principales son un fin por sí mismos y están sujetos a interpretación (RENCER, 2002).

1.5.9. ÁLGEBRA DEL ACP

A continuación se desarrolla una explicación del procedimiento para la obtención de los componentes principales de acuerdo a lo descrito por RENCER (2002), TIMM (2002) y JOHNSON and WICHERN (2007).

Si se tiene un conjunto de observaciones en el vector $\bar{y}'_{1 \times n} = [y_1, y_2, \dots, y_n]$ con media μ y cuya matriz de covarianza es de rango completo n , el objetivo del ACP es crear un nuevo conjunto de variables o componentes principales. Los componentes principales son combinaciones lineales de las variables del vector $\bar{y}$ que no están correlacionadas, de tal manera que el j -ésimo componente es máximo.

Las n observaciones en $\mathbf{Y}$ representadas por los vectores $\bar{y}_1, \bar{y}_2, \dots, \bar{y}_n$, forman una nube de puntos dentro de un espacio n -dimensional donde el ACP puede ser aplicado para cualquier distribución de $\mathbf{Y}$, lo que será más fácil de visualizar geométricamente si la nube de puntos es elipsoidal.

Si las variables están correlacionadas, entonces la nube de puntos no es paralela a ninguno de los ejes representados por $\bar{y}_1, \bar{y}_2, \dots, \bar{y}_n$. Se desea buscar entonces los ejes de la nube de puntos (los ejes del elipsoide) que tengan origen en $\bar{y}$ que es el vector de valor medio de $y_1, y_2, \dots, y_n$. Esto se logra trasladando el origen de $\bar{y}$ y rotando los ejes. Una vez rotados los ejes, las nuevas variables o componentes principales (z_i) no tendrán correlación. La rotación se consigue multiplicando cada y_i por una matriz ortogonal $\mathbf{A}$.

$$z_i = \mathbf{A} y_i$$

Dado que $\mathbf{A}$ es ortogonal ($\mathbf{A}'\mathbf{A}=\mathbf{I}$), la distancia al origen no cambia:

$$z_i' z_i = (\mathbf{A} y_i)' (\mathbf{A} y_i) = y_i' \mathbf{A}' \mathbf{A} y_i = y_i' y_i$$

De esta manera, una matriz ortogonal transforma y_i a un punto z_i que tiene la misma distancia al origen donde los ejes fueron rotados.

Encontrar los nuevos ejes es equivalente a encontrar la matriz ortogonal $\mathbf{A}$ que rota los ejes ajustados a la extensión natural de la nube de puntos de manera que los componente principales $z_1, z_2, \dots, z_n$ en $z = \mathbf{A}y$ no estén correlacionados. De esta manera, lo que se busca es que la matriz de covarianza de z expresada como $\Sigma_z = \mathbf{A}\Sigma\mathbf{A}'$ sea diagonal:

$$\Sigma_z = \mathbf{A}\Sigma\mathbf{A}' = \begin{bmatrix} S_{z1}^2 & 0 & \dots & 0 \\ 0 & S_{z2}^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & S_{zn}^2 \end{bmatrix},$$

Donde Σ es la matriz de covarianza de $y_1, y_2, \dots, y_n$. Se tiene entonces la expresión $\mathbf{C}'\Sigma\mathbf{C} = \mathbf{D} = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$ donde λ_i son los eigenvalores de Σ y $\mathbf{C}$ es la matriz ortogonal cuyas columnas son los eigenvectores normalizados de Σ . De esta manera la matriz ortogonal $\mathbf{A}$ que diagonaliza Σ es la transpuesta de la matriz $\mathbf{C}$:

$$\mathbf{A} = \mathbf{C}' = \begin{bmatrix} a'_1 \\ a'_2 \\ \vdots \\ a'_n \end{bmatrix}$$

Donde a_i es el i -ésimo eigenvector normalizado de Σ . Los componentes principales son entonces las variables transformadas:

$$z_1 = a_1' y, z_2 = a_2' y, \dots, z_n = a_n' y \quad \text{en } z = Ay$$

Con respecto a los eigenvalores de Σ , estos representan la varianza de los componente principales $z_i = a_i' y$:

$$s_{zi}^2 = \lambda_i$$

Como la rotación se ajusta a la extensión de la nube de puntos, $z_1 = a_1' y$ tiene la mayor varianza y $z_n = a_n' y$ tiene la menor varianza. Lo anterior debido a que la varianza de z_1 es λ_1 , que corresponde al eigenvalor mayor, y la varianza de z_n es λ_n , que corresponde al eigenvalor más pequeño.

Dado que los eigenvalores son las varianzas de los componentes principales, es posible hablar de proporción de la varianza explicada por los primeros k componentes principales. La proporción de la varianza explicada por el k -ésimo componente principal se obtiene de la siguiente expresión:

$$\text{Proporción} = \frac{\lambda_k}{\lambda_1 + \lambda_2 + \dots + \lambda_n}, \text{ para } k=1, 2, \dots, n$$

En algunos casos, los componentes principales serán mejor interpretados si se utiliza una matriz de correlación $\mathbf{R}$ en lugar de una matriz de covarianza Σ . Los casos en que se recomienda usar la matriz $\mathbf{R}$ para la aplicación del ACP son los siguientes:

- Si las varianzas difieren ampliamente.
- Si se utilizan diferentes unidades de medida.

En cualquiera de los dos casos, los componentes obtenidos a partir de Σ serán afectados por las variables con mayores varianzas, mientras que el resto de las variables tendrán una contribución mínima.

Como sucede con cualquier cambio de escala, cuando las variables son estandarizadas en el cambio de Σ a $\mathbf{R}$, la forma de la nube de puntos cambia. Sin embargo, debe notarse que una vez obtenida $\mathbf{R}$, cualquier cambio de escala en las variables no afectará los componentes debido a que $\mathbf{R}$ no se ve afectada por los cambios de escala. Es así que los componentes principales obtenidos de $\mathbf{R}$ son escalarmente invariantes.

1.5.10. EL ACP EN TELEDETECCIÓN

La forma vectorial de las imágenes permite aplicar transformaciones lineales sobre las mismas, donde las imágenes resultantes representan una descripción alternativa de los datos (FERRERO *et al.*, 2002). Las transformaciones de bandas de una imagen suelen tratarse de la transformación de múltiples bandas para obtener una sola imagen, por ejemplo en la generación de índices (REES, 2001); o puede tratarse también de transformaciones para reducir el número de imágenes en las que quede capturada la mayor parte de la información; tal es el caso más común del uso en teledetección de la transformación por componentes principales.

Debido a que bandas adyacentes del espectro electromagnético suelen tener similitudes al tratarse de longitudes de onda muy próximas (CHUVIECO, 2010), el ACP es una

técnica frecuentemente utilizada en teledetección para sintetizar la información este tipo de imágenes multiespectrales reduciendo la cantidad de bandas (DIGIROLAMO, 2006) y “eliminando” así información redundante. De la transformación se obtienen nuevas imágenes con mayor capacidad descriptiva y en las que es posible discriminar coberturas con una menor cantidad de datos, o en este caso, con una menor cantidad de bandas (FERRERO *et al.*, 2002).

La técnica de transformación por componentes principales se basa en el análisis de las relaciones que hay entre las bandas consideradas, donde a partir de la construcción de una matriz de covarianza Σ , se transforma un conjunto de bandas que están correlacionadas, en un nuevo conjunto de bandas no correlacionadas o componentes principales facilitando así la interpretación de los datos (PEÑA, 2002; CRACKNELL, 2007).

Así entonces, suponiendo que I_{ipq} denota la intensidad en la banda i en el pixel de la columna p y fila q de la imagen, el arreglo bidimensional de los pixeles o datos de las bandas (filas y columnas con coordenadas geográficas de Longitud y Latitud) debe ser modificado para formar con cada banda un vector (FIGURA 9) en el que sus elementos serán los elementos correspondientes a la población, y cada banda corresponde a un parámetro a medir sobre la población (CRACKNELL, 2007).




Figura 9. Reacomodamiento de pixeles de una imagen para el ACP.

Asumiendo que hay n bandas, entonces existen n parámetros a medir sobre cada elemento de la población, es decir, sobre cada pixel de la imagen original.

Con los vectores unidimensionales se forma una nueva matriz bidimensional X_{pxn} en la que la i -ésima fila contiene los n valores digitales de la j -ésima banda. El análisis de las relaciones que hay entre bandas puede hacerse de dos maneras:

- Utilizando una matriz de covarianza Σ
- Utilizando una matriz de correlación $\mathbf{R}$

En una matriz de covarianza Σ , los elementos de la diagonal son las varianzas dentro de cada banda, y los elementos fuera de la diagonal representan las covarianzas entre pares de bandas. Como la covarianza entre la banda i y la banda j , es la misma que hay entre la banda j y la banda i , esta matriz es simétrica.

En una matriz de correlación $\mathbf{R}$ los elementos de la diagonal representan los valores de las correlaciones de cada banda consigo misma y es igual a 1; los elementos fuera de la diagonal representan los valores de correlación entre pares de bandas; esta matriz, al igual que la matriz de covarianza también es simétrica (FERRERO *et al.*, 2002).

El objetivo de la transformación por componentes principales es generar un nuevo sistema de coordenadas en el espacio multiespectral en el que los datos se muestren o puedan ser representados sin correlación, para lograr esto es necesario diagonalizar la matriz de covarianza.

Con el fin de otorgar el mismo peso a todas las variables, estas deben ser estandarizadas, lo que es recomendable en teledetección (FERRERO *et al.*, 2002). Usando la matriz de correlación $\mathbf{R}$ se estandariza y se asigna la misma importancia a todas las variables.

1.5.11. EL ACP EN ESTUDIOS TEMPORALES

El ACP también se ha utilizado en el análisis de series temporales de imágenes, principalmente en estudios sobre cambio global de la vegetación (EASTMAN Y FULK citados por CHUVIECO, 2010) para la identificación de tendencias generales de las cubiertas y, además, para obtener información residual útil con el fin de detectar anomalías (CHUVIECO, 2010).

De acuerdo con RECHNER (2002), en algunos tipos de estudios, los componentes principales son un fin por sí mismos y están sujetos a interpretación. El uso del ACP en el estudio de imágenes multitemporales consiste en la interpretación de los eigenvectores de la matriz de transformación, donde se analiza la forma de los eigenvectores para buscar patrones o tendencias a partir del comportamiento de la respuesta espectral de las

bandas relacionadas con los elementos de estos eigenvectores (CHUVIECO, 2010). La forma de los eigenvectores que manifiesten un patrón o tendencia de interés determinará cual debe seleccionarse para la interpretación de los componentes principales utilizados en el estudio multitemporal.

1.5.12. CLASIFICACIÓN SUPERVISADA

El proceso de clasificación implica categorizar los píxeles contenidos en una imagen multiespectral o multibanda, lo que supone reducir la escala de medida toda vez que se transforma una variable continua en una discreta (CHUVIECO, 2010).

La clasificación supervisada se basa en el conocimiento que se tiene sobre el comportamiento y distribución de las coberturas representadas en la imagen. Esto permite identificar puntos o áreas representativas de los tipos de coberturas que se buscan categorizar, tales puntos o áreas se conocen como áreas de entrenamiento o puntos de referencia espectral.

En función de las áreas de entrenamiento es que se caracterizan las clases a partir de las cuales se agrupará el resto de los píxeles de la imagen de acuerdo a la similitud que tengan con estas áreas.

1.5.12.1. CLASIFICACIÓN POR ÁNGULO ESPECTRAL

La clasificación de coberturas sobre imágenes multiespectrales parte del hecho de que cada superficie tiene un patrón característico de reflectividad y absorción a través del espectro electromagnético (SOHN and REBELLO, 2013), lo que se manifiesta como un

patrón de respuesta a través de las bandas de un sensor multiespectral como el sensor TM. Este patrón de respuesta en las diferentes bandas se expresa en la firma espectral de cada tipo de cobertura. De lo anterior se asume que objetos similares tienen una firma espectral similar.

La firma espectral de un objeto puede verse como un vector n-dimensional en un espacio multiespectral (PETROPOULOS *et al.*, 2010). Dos objetos con características similares generan entonces vectores muy cercanos entre si dentro del espacio multiespectral, lo que permite clasificarlos a partir de la distancia formada por el ángulo que hay entre la norma de estos vectores (SOHN and REBELLO, 2013).

El algoritmo de mapeo ó clasificación por ángulo espectral (SAM por sus siglas en inglés) hace una clasificación a partir de medir la similitud del ángulo entre la norma de los vectores de las firmas espectrales de dos objetos (GIROUARD *et al.*, 2013). El clasificador calcula el arco-coseno del producto escalar entre los vectores de la firma espectral a clasificar (t_i) y las firmas espectrales de referencia (r), estas últimas capturadas de las regiones o puntos de entrenamiento; la ecuación del clasificador es la siguiente (CHO *et al.*, 2010):

$$\cos^{-1} = \frac{\sum_{i=1}^{nb} t_i r_i}{[\sum_{i=1}^{nb} t_i^2]^{0.5} [\sum_{i=1}^{nb} r_i^2]^{0.5}} \quad [6]$$

Donde:

nb = número de bandas

t_i = firma o espectro a clasificar

r_i = firma o espectro de referencia

La FIGURA 10 muestra un ejemplo esquemático del funcionamiento del algoritmo de clasificación por ángulo espectral para clasificar dos objetos usando tres bandas.




Figura 10. Ángulo espectral entre dos objetos a clasificar (t) y (r) (LUC et al., 2013).

El SAM es un método fácil y rápido que hace una clasificación a partir de la identificación de similitudes en las firmas espectrales de diferentes coberturas.

1.5.13. EVALUACIÓN DE CLASIFICACIONES

En la evaluación de un proceso de clasificación se aplican técnicas estadísticas de muestreo que permiten estimar el error que contienen los resultados obtenidos (CHUVIECO, 2010) y se incluyen las siguientes fases:

- a. Diseño de muestreo
- b. Recolección de datos auxiliares de referencia

- c. Comparación de resultados con los datos de referencia
- d. Análisis de los errores

Para el diseño del muestreo existen diferentes métodos o técnicas como el muestreo aleatorio simple, el muestreo aleatorio estratificado, muestreo por conglomerados., por mencionar algunos de los métodos más comúnmente utilizados en teledetección (CHUVIECO, 2010).

1.5.13.1. MUESTREO ALEATORIO ESTRATIFICADO

Una muestra se define como una colección de variables aleatorias extraídas de una población, esta muestra debe ser un subconjunto de la población (INFANTE Y ZÁRATE, 1984). En un diseño aleatorio estratificado, donde existen poblaciones diferenciadas en categorías, la muestra se extrae al azar de cada una de las poblaciones existentes.

1.5.13.2. TAMAÑO DE MUESTRA

En teledetección, el tamaño de muestra es un tema de importancia que se ha sometido al análisis y discusión por diferentes autores. Para seleccionar el tamaño de muestra en imágenes clasificadas suele utilizarse la expresión de la distribución binomial de probabilidad; sin embargo, esta técnica no fue diseñada para escoger un tamaño de muestra ajustable a una matriz de confusión. Una matriz de este tipo no se trata

únicamente de un problema de correcto o incorrecto, sino que más bien se trata de un asunto de cuales categorías están confundidas (CONGALTON, 1991).

Por otro lado, debido al gran número de píxeles que forman una imagen, las técnicas tradicionales del muestreo en muchos de los casos no aplican. Por tal motivo, se han establecido algunas consideraciones prácticas para determinar el tamaño de muestra. Algunos autores (CONGALTON, 1991; CHUVIECO, 2010) recomiendan distribuir un número mínimo de 50 muestras por categoría con fines de ajustar la información que posteriormente se usará para formar la matriz de confusión.

Sin embargo, la distribución binomial de probabilidad sigue siendo la más utilizada para establecer el tamaño de muestra de imágenes clasificadas y su expresión es la siguiente:

$$x = \frac{z^2 p(1-p)}{e^2} \quad [7]$$

Donde:

z = abscisa a la curva normal (nivel de confianza)

p = porcentaje estimado de errores en la clasificación

e = nivel permitido del error

En cuanto a los valores p estos pueden obtenerse de datos auxiliares o simplemente igualarse a 0.5 (CHUVIECO, 2010). La recolección de datos de referencia, que corresponde a la segunda fase del proceso de evaluación, puede hacerse a partir de medidas tomadas en campo o usar otras fuentes de datos de referencia o auxiliares como pueden ser datos cartográficos o bibliotecas espectrales.

Cuando se evalúan diferentes categorías producto de una clasificación, siguiendo la técnica de muestreo aleatorio estratificado, el número de muestras por clase se extrae ponderando de acuerdo al número de píxeles por clase.

1.5.13.3. MATRIZ DE CONFUSIÓN

Para el caso de imágenes clasificadas, una vez obtenidos los datos auxiliares o de referencia para la comparación de resultados, la estimación del nivel de precisión de la clasificación puede hacerse construyendo una matriz de confusión. La matriz se construye representando en las columnas las clases de referencia y en las hileras las categorías obtenidas de la clasificación. La diagonal contiene los valores donde hubo correspondencia entre las categorías clasificadas y los datos auxiliares de referencia, mientras que los marginales de la matriz indican los errores de asignación (CHUVIECO, 2010).

El cociente obtenido del número de píxeles correctamente clasificados entre el total de píxeles analizados indica la confiabilidad global de la clasificación. Los residuales en columnas indican los errores de omisión (puntos que corresponden a una categoría pero que no fueron incluidos en la clasificación), mientras que los residuales en hileras indican los errores de comisión (puntos clasificados en una categoría pero que no corresponden con la misma). La FIGURA 11 muestra la estructura de una matriz de confusión para evaluar una clasificación dicotómica con dos categorías. A partir de los datos de la matriz de confusión se obtiene un indicador de fiabilidad global de la clasificación, este indicador se obtiene con la siguiente expresión:

$$Global = \frac{\sum_{i=1}^k X_{ii}}{\sum_{i=1}^k \sum_{j=1}^k X_{ij}} * (100)$$

Donde k representa el número de categorías generadas por la clasificación.

		Datos de referencia	
Clasificación obtenida		C1	C2
	C1	A	B
	C2	C	D

Figura 11. Diseño de una matriz de confusión para evaluar una clasificación dicotómica.

1.5.13.4. ÍNDICE KAPPA

Una medida más confiable del nivel de correspondencia de la clasificación es el estadístico Kappa. Se trata de un índice que permite evaluar la exactitud obtenida en la clasificación comparando la correspondencia de los resultados con aquella que se obtendría de una selección al azar. La expresión para obtener el índice kappa es:

$$\kappa = \frac{n \sum_{i=1}^n X_{ii} - \sum_{i=1}^n X_{i.} X_{.i}}{n^2 - \sum_{i=1}^n X_{i.} X_{.i}} \quad [9]$$

Donde:

n = tamaño de muestra

X_{ii} = puntos correctamente clasificados

$(X_{i.})(X_{.i})$ = la correspondencia esperada en cada categoría

El CUADRO 2 muestra distintos niveles de correspondencia para diferentes valores obtenidos del índice Kappa (LANDIS and KOCH, 1960).

Cuadro 2. Nivel de correspondencia de diferentes valores del índice Kappa.

Valor Kappa	nivel de correspondencia
< 0,00	sin acuerdo
>0,00 - 0,20	insignificante
0,21 - 0,40	discreto
>0,41 - 0,60	moderado
0,61 - 0,80	sustancial
0,81 - 1,00	casi perfecto

Los valores del índice Kappa cercanos a uno indican una correspondencia perfecta o casi perfecta al comparar los valores de los pixeles de muestreo con los datos de referencia, mientras que valores cercanos a cero indican una correspondencia pobre, y nula si se trata de valores negativos.

II. MATERIALES Y MÉTODOS

En esta sección se hace una descripción detallada de los materiales, técnicas y procedimientos empleados en el desarrollo de la investigación.

2.1. MATERIALES

Para la investigación se utilizan imágenes multiespectrales del sensor Thematic Mapper (TM) de los años 1990, 1993, 1995, 1997 y 2000, específicamente las bandas 3, 4 y 5 correspondientes a los sectores rojo, infra-rojo cercano e infra-rojo medio del espectro electromagnético respectivamente. En el CUADRO 3 se muestran los datos de adquisición del sensor.

Cuadro 3. Datos de adquisición del sensor para las diferentes escenas utilizadas.

Sensor	Año	Mes	Día	Nombre del archivo	Elevación solar (Θ)	Fuente
TM	1990	3	18	LT50260471990077XXX04	49.413	USGS (2012)
TM	1993	2	22	LT50260471993053AAA04	43.496	USGS (2012)
TM	1995	2	28	LT50260471995059XXX01	42.684	USGS (2012)
TM	1997	3	5	LT50260471997064XXX01	47.212	USGS (2012)
TM	2000	2	10	LT50260472000041AAA02	42.646	USGS (2012)

Se utiliza además la cartografía temática digital de uso de suelo y vegetación escala 1:250,000 así como el modelo digital de terreno del Instituto Nacional de Ecología (INE) y del Instituto Nacional de Estadística, Geografía e Informática (INEGI).

El software para el procesamiento y análisis de imágenes son los paquetes *IDRISI selva* y *ENVI 4.1*; para el diseño de mapas se trabaja con *ArcGIS 10*. Se utiliza el software *Mathematica 8* para realizar operaciones con vectores y matrices (CUADRO 4).

Cuadro 4. Software utilizado en la investigación.

Software utilizado	Actividad realizada
IDRISI selva	Análisis de imágenes
ENVI 4.1	Análisis de imágenes
ArcMap 10	Diseño de mapas
Mathematica 8	Operaciones vectoriales
Word	Redacción de documento
Excel	Gráficas y cuadros

2.2. MÉTODOS

2.2.1. PROCESAMIENTO DE IMÁGENES

Se realiza un pre-tratamiento de las bandas que consiste en una corrección radiométrica, un recorte de las dimensiones de la escena y la aplicación de una máscara.

2.2.1.1. CORRECCIÓN RADIOMÉTRICA

Se transforman los valores de las bandas para obtener valores de reflectancia utilizando el software *ENVI 4.1* e ingresando los siguientes datos:

- Fecha de adquisición del sensor.
- Ángulo de elevación solar (Θ).

2.2.1.2. *COMPOSICIÓN DE IMAGEN MULTITEMPORAL*

Una vez realizadas las correcciones descritas sobre las bandas del sensor TM para cada una de las cinco fechas de estudio, estas se utilizan para crear una imagen multiespectral formada por 15 bandas (CUADRO 5).

Cuadro 5. Estructura de la imagen multitemporal de 15 bandas ordenadas en una secuencia espectral-cronológica.

Año	/Banda TM/	Orden
1990	b3	1
	b4	2
	b5	3
1993	b3	4
	b4	5
	b5	6
1995	b3	7
	b4	8
	b5	9
1997	b3	10
	b4	11
	b5	12
2000	b3	13
	b4	14
	b5	15

2.2.1.3. *RECORTE DE LA ESCENA Y MÁSCARA*

Una vez generada la imagen multitemporal, se hace un recorte de las dimensiones de la escena y se aplica una máscara para excluir del análisis aquellas zonas de agricultura y zonas de escasa o nula vegetación (FIGURA 12). Las coordenadas extremas para el recorte de la escena son:

- Esquina inferior derecha: $-98^{\circ} 38' 50''$ y $19^{\circ} 22' 17''$
- Esquina superior izquierda: $-98^{\circ} 46' 46''$ y $19^{\circ} 29' 49''$




Figura 12. Recorte y máscara para excluir zonas de poco interés en la escena.

La superficie total de estudio obtenida con el recorte y la aplicación de la máscara es de 16,392.51 hectáreas correspondientes a 182,139 píxeles. La razón para limitar la superficie de análisis a la zona forestal, es que las zonas de agricultura tienen una dinámica distinta a la forestal, lo que puede afectar la identificación de tendencias.

2.2.2. EXPLORACIÓN DE CORRELACIONES

Para confirmar la existencia de correlación entre las imágenes de las diferentes fechas se construyen diagramas de dispersión entre pares de bandas. En el espacio bidimensional de los diagramas se definen los ejes asignando la misma banda para diferentes años con el fin de detectar la presencia de correlación multitemporal.

Es necesaria la existencia de correlación multitemporal entre bandas para poder aplicar la transformación por componentes principales. Debido a que la cubierta forestal es constante en toda la serie temporal (con pequeñas variaciones) se cree de antemano que existe una alta correlación entre las bandas de las diferentes fechas. La forma de la nube de puntos de los diagramas de dispersión confirma la existencia de correlación multitemporal entre las bandas (FIGURA 13).




Figura 13. Diagrama de dispersión donde la orientación diagonal de la elipse que forma la nube de puntos indica la existencia de una alta correlación entre dos bandas.

2.2.3. TRANSFORMACIÓN POR COMPONENTES PRINCIPALES

Para la transformación por componentes principales se usa una matriz de correlación ($\mathbf{R}$), esto con el fin de normalizar los datos para que estos tengan la misma magnitud.

Posteriormente la imagen multitemporal es importada desde el programa *IDRISI selva* y se utiliza el módulo *PCA* para hacer la transformación lineal; se realiza además el procedimiento paso por paso utilizando el software *Mathematica 8* que cuenta con capacidades para la operación con matrices.

EL primer paso consiste en ingresar al entorno de *Mathematica 8* las bandas en formato de imagen *GeoTIFF* desde su ubicación en el disco, posteriormente se asigna un nombre de variable para cada imagen escribiendo las siguientes instrucciones:

```
:=Import["D:\\CARPETA1\\\"imagen.tif","GeoTIFF"]
```

```
:=im2= imagen.tif
```

Con esta instrucción la imagen con nombre de archivo “imagen.tif” es ingresada y registrada al entorno de *Mathematica 8* como la variable “im2”.

El paso siguiente es extraer los valores numéricos de reflectancia de los píxeles de cada banda y reordenarlos en forma de vectores. Con estos vectores se construye una nueva matriz $X_{p \times n}$, donde la i -ésima fila contiene los n valores digitales de la j -ésima banda. En la línea de escritura de comandos de *Mathematica 8* se escribe la siguiente instrucción:

```
:= ImageData[im2]
```

`:= b3 = Flatten[im2]`

Con esta instrucción se extraen los valores numéricos de *im2* y se crea con estos un vector denominado *b3*. El siguiente paso consiste en construir una matriz de correlación **R** cuyos elementos corresponden a los coeficientes de correlación de Pearson entre los pares de bandas de la matriz $X_{p \times n}$. Para obtener los coeficientes de correlación entre pares de bandas en el entorno de *Mathematica 8* se ingresa la siguiente instrucción:

`:= Correlation[b3,b4]`

La instrucción anterior genera como resultado el coeficiente de correlación entre los vectores *b3* y *b4*. Los elementos de la diagonal de la matriz **R** tienen valores igual a uno, que representan la correlación de cada banda consigo misma, los elementos fuera de la diagonal representan los coeficientes de correlación entre el resto de las bandas. El CUADRO 6 muestra las correlaciones obtenidas. La construcción de la matriz **R** en el entorno de *Mathematica 8* se hace ordenando los valores de correlación obtenidos de la matriz $X_{p \times n}$:

`:=R={{valores de correlación hilera 1}, {valores de correlación hilera 2},..., {valores de correlación hilera 15}}`

La siguiente instrucción permite visualizar el arreglo en su forma matricial:

:= R//MatrixForm

Con *Mathematica 8* es posible obtener los eigenvectores directamente de la matriz **R**, sin embargo se muestra a continuación la instrucción para obtener los eigenvalores:

Eigenvalues[N[R]]

Con esta instrucción se obtienen los eigenvalores de la matriz **R**. La instrucción para extraer los eigenvectores de la matriz **R** y mostrarlos en forma matricial es la siguiente:

Eigenvectors[N[R]]//MatrixForm

Con los eigenvectores se construye la matriz de transformación **T** (CUADRO 7) que contiene los coeficientes para hacer la transformación de las bandas del sensor TM en las nuevas imágenes o componentes principales.

La operación para transformar las bandas de la serie en los nuevos componentes principales denominados **Y₁, Y₂,...,Y₉**, consiste en multiplicar la matriz **X_{pxn}** por la matriz de transformación. De esta manera, para obtener **Y₁** se multiplican las bandas por cada elemento del eigenvector 1:

$$\mathbf{Y}_1 = (\text{elemento 1 EV1}) * \mathbf{b}_1 + (\text{elemento 2 EV1}) * \mathbf{b}_2 + \dots + (\text{elemento 15 EV1}) * \mathbf{b}_{15}$$

Cuadro 6. Matriz de correlación R para las bandas de la imagen multitemporal.

		1990			1993			1995			1997			2000		
		b3	b4	b5	b3	b4	b5	b3	b4	b5	b3	b4	b5	b3	b4	b5
1990	b3	1	0.49	0.92	0.93	0.56	0.89	0.92	0.52	0.88	0.92	0.51	0.87	0.87	0.58	0.81
	b4	0.49	1	0.53	0.49	0.9	0.55	0.5	0.9	0.59	0.46	0.86	0.54	0.5	0.82	0.57
	b5	0.92	0.53	1	0.89	0.61	0.95	0.87	0.58	0.94	0.87	0.54	0.93	0.83	0.62	0.87
1993	b3	0.93	0.49	0.89	1	0.6	0.92	0.95	0.54	0.9	0.93	0.52	0.88	0.89	0.62	0.83
	b4	0.56	0.9	0.61	0.6	1	0.66	0.58	0.95	0.68	0.55	0.89	0.63	0.6	0.89	0.68
	b5	0.89	0.55	0.95	0.92	0.66	1	0.91	0.62	0.97	0.88	0.58	0.94	0.86	0.69	0.9
1995	b3	0.92	0.5	0.87	0.95	0.58	0.91	1	0.55	0.91	0.92	0.51	0.87	0.89	0.63	0.82
	b4	0.52	0.9	0.58	0.54	0.95	0.62	0.55	1	0.66	0.51	0.9	0.59	0.56	0.89	0.65
	b5	0.88	0.59	0.94	0.9	0.68	0.97	0.91	0.66	1	0.88	0.61	0.94	0.87	0.71	0.91
1997	b3	0.92	0.46	0.87	0.93	0.55	0.88	0.92	0.51	0.88	1	0.53	0.92	0.9	0.57	0.83
	b4	0.51	0.86	0.54	0.52	0.89	0.58	0.51	0.9	0.61	0.53	1	0.6	0.53	0.86	0.6
	b5	0.87	0.54	0.93	0.88	0.63	0.94	0.87	0.59	0.94	0.92	0.6	1	0.86	0.65	0.91
2000	b3	0.87	0.5	0.83	0.89	0.6	0.86	0.89	0.56	0.87	0.9	0.53	0.86	1	0.65	0.92
	b4	0.58	0.82	0.62	0.62	0.89	0.69	0.63	0.89	0.71	0.57	0.86	0.65	0.65	1	0.7
	b5	0.81	0.57	0.87	0.83	0.68	0.9	0.82	0.65	0.91	0.83	0.6	0.91	0.92	0.7	1

Se observa que el primer componente es el resultado de una transformación lineal de las bandas usando los elementos del eigenvector 1 como coeficientes de transformación. El resto de los componentes principales se obtiene aplicando el mismo procedimiento sobre las demás bandas usando los eigenvectores restantes.

Los componentes principales son una serie de imágenes resultado de la combinación lineal de las bandas originales del sensor TM, y cada componente principal están muy relacionadas con el eigenvector cuyos elementos fueron utilizados como coeficientes de transformación.

Cuadro 7. Matriz de transformación donde las columnas son los eigenvectores de la matriz de correlaciones.

		EV1	EV2	EV3	EV4	EV5	EV6	EV7	EV8	EV9	EV10	EV11	EV12	EV13	EV14	EV15
1990	b3	0.27	-0.21	-0.36	-0.18	-0.01	0.16	0.53	0.26	-0.14	0.06	0.08	0.43	0.36	0.04	-0.1
	b4	0.21	0.42	-0.15	-0.16	0.07	0.6	0.07	-0.58	0.13	-0.04	-0.05	-0.02	0	-0.02	-0.04
	b5	0.27	-0.16	0.19	-0.45	-0.03	0.1	0.36	0.19	-0.05	0.06	0.02	-0.41	-0.51	-0.04	0.21
1993	b3	0.27	-0.19	-0.34	0.03	-0.21	-0.06	-0.16	0.07	0.36	-0.42	-0.55	-0.03	-0.01	0.12	0.28
	b4	0.24	0.37	-0.01	0.02	-0.12	0.11	-0.24	0.46	0.44	-0.07	0.53	0.13	-0.08	0.01	0.08
	b5	0.28	-0.13	0.23	-0.24	-0.22	-0.13	-0.12	-0.06	0.12	-0.25	0	-0.16	0.17	-0.16	-0.75
1995	b3	0.27	-0.19	-0.35	0.08	-0.25	-0.07	-0.33	-0.23	-0.43	0.03	0.26	0.2	-0.47	0.12	-0.09
	b4	0.23	0.4	0.02	-0.03	-0.12	0.11	-0.26	0.38	-0.38	0.38	-0.47	-0.1	0.1	0.05	-0.1
	b5	0.28	-0.11	0.22	-0.19	-0.17	-0.09	-0.23	-0.2	-0.23	-0.02	0.23	-0.1	0.53	-0.17	0.52
1997	b3	0.27	-0.22	-0.28	0.12	0.44	-0.09	-0.16	-0.03	0.25	0.43	-0.02	-0.12	-0.02	-0.55	-0.03
	b4	0.22	0.4	-0.13	-0.04	0.53	-0.41	0.1	0.03	-0.29	-0.48	0.04	-0.07	-0.02	-0.02	0
	b5	0.28	-0.14	0.29	-0.17	0.39	-0.13	-0.16	-0.14	0.21	0.26	-0.04	0.22	0.02	0.65	-0.02
2000	b3	0.27	-0.16	0.01	0.64	0.06	0.24	0.15	0.05	-0.09	-0.06	0.17	-0.5	0.16	0.3	-0.08
	b4	0.24	0.31	0.05	0.24	-0.39	-0.51	0.42	-0.26	0.19	0.29	-0.04	0.04	-0.05	-0.01	0.04
	b5	0.27	-0.08	0.54	0.35	0.08	0.2	0.06	0.04	-0.09	-0.19	-0.19	0.48	-0.2	-0.32	0.07

2.2.4. SELECCIÓN DE COMPONENTES PRINCIPALES

Se debe analizar la forma de los eigenvectores de la matriz de transformación para seleccionar los componentes principales de interés. Se buscan aquellos eigenvectores cuya forma exprese un comportamiento de aumento en los valores de la banda 5 con respecto a los valores de la banda 4. Para hacer una interpretación visual de la forma de los eigenvectores se construyen gráficas de barras con los datos de cada eigenvector.

Por su forma, el primer eigenvector se interpreta como el sustrato común entre todas las imágenes, denominado brillo estable y sus valores son positivos. El segundo eigenvector se denomina verdor estable debido a que muestra valores negativos para los elementos de los eigenvectores relacionados con las bandas 3 y 5 y valores positivos para la banda 4, lo que representa un comportamiento característico de la vegetación sana. El resto de

los eigenvectores se somete a interpretación para identificar otros comportamientos de interés para el analista, en este caso el comportamiento buscado es el de reducción de la humedad en la planta o reducción del vigor vegetal.

Se identifica en los eigenvectores 3 y 12 la expresión del patrón de aumento en la banda 5 y se identifica en el eigenvector 2 un patrón de estabilidad en el verdor a través de la serie temporal (FIGURA 14). Las características expresadas por los eigenvectores señalados son entonces las siguientes:

- Eigenvector 2: valores bajos de las bandas 3 y 5 y altos de la banda 4.
- Eigenvector 3: aumento gradual de los valores de la banda 5.
- Eigenvector 12: aumento gradual de los valores de la banda 5.




Figura 14. Representación gráfica de los eigenvectores 2, 3 y 12.

Con esta información se seleccionan los componentes 2, 3 y 12 para construir la imagen de referencia utilizada posteriormente en el proceso de clasificación de la imagen.

2.2.5. GENERACIÓN DE IMAGEN DE REFERENCIA

Los componentes principales seleccionados se usan para formar una composición de imagen en color que servirá como imagen de referencia en la fase de clasificación. La creación de la imagen de referencia tiene como objetivo facilitar la discriminación visual entre píxeles que presenten el patrón de interés (reducción del vigor vegetal) de aquellos píxeles que expresen cualquier otro comportamiento en la serie temporal. Se ha observado una buena discriminación visual al usar los componentes 12, 2 y 3 asignados a los canales rojo, verde y azul respectivamente (FIGURA 15).




Figura 15. Imagen de referencia con los componentes principales 12, 2 y 3.

2.2.6. CORRECCIÓN DE IMAGEN DE REFERENCIA

Previo a la clasificación se aplica además una corrección en el contraste sobre los tres canales de colores primarios de la imagen de referencia para resaltar los rasgos de interés (FIGURA 16). En este caso, la técnica de corrección con la que se observan mejores resultados es la ecualización del contraste.

Los píxeles en color blanco expresan el patrón de reducción en el vigor vegetal debido a que muestran valores altos de los tres componentes principales asignados a los canales de colores primarios (rojo, verde y azul); o dicho de otra forma, los píxeles blancos indican la presencia de vegetación en la que se manifiesta un aumento gradual en los valores de la banda 5 a través del tiempo.




Figura 16. Imagen de referencia con modificación del contraste.

2.2.7. CLASIFICACIÓN DE PÍXELES

La clasificación de imagen consiste en detectar y seleccionar los píxeles que expresen el patrón espectral de interés. El algoritmo de clasificación por ángulo espectral (SAM por sus siglas en inglés) permite hacer una clasificación de píxeles a partir de medir la similitud del ángulo formado por las normas de los vectores contruidos con las firmas espectrales de dos objetos (GIROUARD *et al.*, 2013). El clasificador calcula el arco-coseno del producto escalar entre los vectores de la firma espectral a clasificar (t_i) y las firmas espectrales de referencia (r) (CHO *et al.*, 2010) en el sentido que marca la ecuación 3:

$$\cos^{-1} = \frac{\sum_{i=1}^{nb} t_i r_i}{[\sum_{i=1}^{nb} t_i^2]^{0.5} [\sum_{i=1}^{nb} r_i^2]^{0.5}} \quad [3]$$

Donde:

nb = número de bandas

t_i = firma o espectro a clasificar

r_i = firma o espectro de referencia

2.2.7.1. COLECCIÓN DE FIRMAS DE REFERENCIA

Para la clasificación se crea una colección de firmas espectrales de referencia extraídas de puntos de entrenamiento correspondientes a un conjunto píxeles de la imagen multitemporal. Se seleccionan píxeles en cuya firma espectral se exprese el aumento gradual de la banda 5 acercándose a los valores de la banda 4 incluso superándolos en algunos casos. Para identificar los píxeles con el patrón de interés se usa la imagen de referencia como apoyo visual.

La colección de firmas espectrales se hace utilizando el programa *ENVI 4.1* estableciendo un enlace geográfico de dos ventanas de visualización; la primera ventana despliega la imagen multitemporal (Ventana 1) donde se coleccionan las firmas, y la segunda ventana despliega la imagen de referencia (Ventana 2).

Las ventanas cuentan con un visor de acercamiento que marca con un cruce de líneas en rojo el pixel localizado al centro del visor; debido al enlace geográfico entre las ventanas, dicho pixel corresponde a la misma coordenada geográfica tanto en ambas ventanas (FIGURA 17).

Posteriormente en la Ventana 1 se abre el visor *Z-profile*, donde se muestra la firma espectral del pixel localizado en el centro del visor de acercamiento marcado por las líneas de cruce. Debido a que el visor *Z-profile* es activado desde la Ventana 1, este muestra la firma espectral del pixel de la imagen multitemporal, que es precisamente de donde se busca extraer las firmas espectrales de interés.

Debido a que la imagen multitemporal es un arreglo de 15 bandas ordenadas en una secuencia espectro-temporal, lo que la firma espectral muestra es la evolución de la respuesta en las bandas 3, 4 y 5 a través de los cinco años analizados. Con la opción *Collect spectra* se hace una colección de diez firmas espectrales que expresen el patrón de interés (FIGURA 18). Esta colección de firmas se guarda con el nombre de Colección 1 en formato de texto para su análisis en *Mathematica 8*.




Figura 17. Enlace geográfico de dos ventanas en *ENVI 4.1*.

Con las firmas de referencia se crea un conjunto de vectores de 15 elementos y se calculan los ángulos formados entre sus normas (en unidades de radianes).




Figura 18. Firma espectral con un crecimiento de la banda 5 (triángulos) acercándose a los valores de la banda 4 (círculos).

2.2.7.2. CLASIFICACIÓN POR ÁNGULO ESPECTRAL

El algoritmo de clasificación por ángulo espectral (SAM por sus siglas en inglés) hace una clasificación de píxeles a partir de medir la similitud de los ángulos que forman las normas de los vectores generados con las firmas espectrales de dos objetos (GIROUARD *et al.*, 2013). El clasificador calcula el arco-coseno del producto escalar entre los vectores de la firma espectral a clasificar (t_i) y las firmas espectrales de referencia (r) (CHO *et al.*, 2010) en el sentido que marca la siguiente ecuación:

$$\cos^{-1} = \frac{\sum_{i=1}^{nb} t_i r_i}{[\sum_{i=1}^{nb} t_i^2]^{0.5} [\sum_{i=1}^{nb} r_i^2]^{0.5}} \quad [3]$$

Donde:

nb = número de bandas

t_i = firma o espectro a clasificar

r_i = firma o espectro de referencia

Para realizar este procedimiento se utiliza la herramienta de clasificación supervisada por ángulo espectral que viene dentro del programa *ENVI 4.1*.

2.2.7.3. ESTABLECIMIENTO DE ÁNGULOS DE BÚSQUEDA

Previamente a la clasificación se realizan algunas pruebas con diferentes ángulos de búsqueda para calibrar la precisión y establecer los ángulos con mayor precisión. Se establece un total de diez ángulos de búsqueda (CUADRO 8) y se ingresan en el programa *ENVI 4.1* para la clasificación de píxeles de la imagen multitemporal.

Cuadro 8. Ángulos de búsqueda en radianes para la clasificación por ángulo espectral.

Ángulo 1:	0.155
Ángulo 2:	0.1
Ángulo 3:	0.1
Ángulo 4:	0.084
Ángulo 5:	0.128
Ángulo 6:	0.06
Ángulo 7:	0.165
Ángulo 8:	0.160
Ángulo 9:	0.132
Ángulo 10:	0.059

2.2.7.4. CLASIFICACIÓN

Desde la ventana de diálogo de la herramienta *Spectral angle mapper* del paquete *ENVI 4.1* se importan las firmas espectrales de la Colección 1 y los ángulos de búsqueda para la clasificación por ángulo espectral de los píxeles de la imagen multitemporal.

El algoritmo de clasificación por ángulo espectral genera una categoría por cada firma de referencia ingresada, más una categoría de píxeles no clasificados cuyas firmas espectrales no presentan similitud con ninguna de las firmas de referencia. Posteriormente se combinan las categorías de los píxeles con similitud para crear dos únicas categorías o categorías finales:

- Categoría 1: píxeles con similitud con los píxeles de entrenamiento.
- Categoría 2: píxeles sin similitud con los píxeles de entrenamiento.

2.2.7.5. EVALUACIÓN DE LA CLASIFICACIÓN

Para la evaluación de la clasificación es necesario construir una matriz de confusión alimentada con los datos obtenidos de un muestreo, de este modo se verifica que tan precisa fue la clasificación. La evaluación se hace sobre una muestra de píxeles extraídos de la población total. La determinación del tamaño de muestra se hace mediante una técnica de muestreo aleatorio estratificado donde el tamaño de muestra es:

$$n_0 = \frac{(1.96^2)0.5(1-0.5)}{0.05^2} = 384.2 \approx 385$$

La asignación proporcional por clase se estima con la siguiente fórmula:

$$n_i = nW_i \quad \text{tal que} \quad \sum n_i = 385$$

Donde:

$$n = 385$$

$$W_i = N_i/N$$

$N = 183,139$ número total de píxeles en la imagen

N_i = número de píxeles en cada categoría de clasificación.

El factor de peso n para estimar una proporción de la población para cada clase usando un muestreo aleatorio estratificado con asignación proporcional es:

$$n_0 = \frac{(1.96^2)\sum W_i(0.5^2)}{0.05^2} \quad \text{con} \quad n_0/N \leq 0.05$$

De donde $n_0 = 385$ y por lo tanto el parámetro $n = 385$; y la asignación proporcional por categoría clasificada se obtiene de la siguiente manera:

$$N_1/N = 20,179 / 183,139 = 0.110$$

$$n_1 = 385 * 0.110 = 43$$

$$N_2/N = 161,960 / 183,139 = 0.889$$

$$n_2 = 385 * 0.889 = 342$$

La cantidad de muestras asignadas son 43 muestras para la Categoría 1 (pixeles clasificados como reducción del vigor vegetal) y 342 muestras de la Categoría 2 (Pixeles no clasificados) para un total de 385 muestras.

El siguiente paso es comparar la forma de la firma espectral del pixel muestreado con el patrón característico de la categoría asignada. Las firmas espectrales analizadas se extraen de la imagen multitemporal para la coordenada de cada punto de muestreo.

Durante el muestreo de pixeles clasificados como reducción del vigor vegetal se califica como acierto cuando la pendiente de la línea de tendencia resulta positiva a la hora de graficar los valores de la banda 5, y se califica como error cuando la pendiente es negativa. Los pixeles de que no fueron clasificados en la categoría de reducción del vigor vegetal se califican con el criterio opuesto.

Con los resultados se crea una matriz de confusión de la que se obtienen los indicadores de fiabilidad global, error de omisión, error de comisión y el índice Kappa.

Las muestras se distribuyeron geográficamente en coordenadas dentro de las categorías clasificadas y usando un generador de puntos aleatorios (ANEXO 1-A y 1-B).

El intervalo de confianza para la estimación del nivel de precisión de la clasificación se obtiene con datos de la matriz de confusión y utilizando la siguiente expresión:

$$IC = [L - \frac{\sqrt{p(1-p)}}{n} (z_{\alpha/2}), L + \frac{\sqrt{p(1-p)}}{n} (z_{\alpha/2})]$$

Donde:

IC = intervalo de confianza

L = traza de la matriz de confusión / n

n = 385

$Z_{\alpha/2} = 1.96$

Con los valores que se obtienen del índice Kappa y el intervalo de confianza, se puede tener una mejor idea del nivel de confiabilidad de la clasificación que con el solo valor de confiabilidad global.

III. RESULTADOS

Con los datos de la matriz de confusión (FIGURA 19) se obtuvo una fiabilidad global de 77.40%. El error de omisión fue de 67.74% y de 6.98% el caso del error de comisión. Lo anterior indica que casi siete de cada 10 pixeles no fueron clasificados en la categoría correspondiente aún cuando presentan el patrón característico; mientras que siete de cada 100 pixeles que fueron clasificados, no corresponden a la categoría asignada.

CLASIFICACIÓN	REFERENCIA			ERROR COMISION
		C1	C2	
	C1	40	3	
	C2	84	258	6.98
		124	261	
		298		
ERROR OMISION		67.74		
GLOBAL		77.40		

Figura 19. Matriz de confusión con los resultados de la evaluación de la clasificación.

Debe señalarse que el error de omisión es muy alto, lo que quiere decir que existe un gran número de pixeles que no fueron clasificados como reducción del vigor vegetal cuando en realidad si pertenecen a la clase. El índice Kappa de 0.37 indica un nivel de correspondencia discreto de acuerdo a lo establecido por LANDIS and KOCH (1961).

Finalmente, el intervalo de confianza se calculó a partir de la siguiente expresión:

$$IC = [L - \frac{\sqrt{p(1-p)}}{n} (z_{\alpha/2}), L + \frac{\sqrt{p(1-p)}}{n} (z_{\alpha/2})] = [73 - 81]$$

Con estos datos puede asegurarse con un 95% de probabilidad que la fiabilidad real de la clasificación se encuentra entre el 73 y el 81%.

Por último, el comportamiento de reducción del vigor vegetal se presentó en una superficie de 1,816 hectáreas dentro de la zona forestal (FIGURA 20).




Figura 20. Imagen de zonas con reducción en el vigor vegetal resaltadas en color negro.

De acuerdo a los resultados de la clasificación, el tipo de vegetación más afectado por el fenómeno de reducción del vigor vegetal fue el bosque de pino con una superficie afectada de 1,323.9 ha (CUADRO 9).

Cuadro 9. Superficie afectada por tipo de vegetación.

VEGETACIÓN	SUPERFICIE (ha)
AGRICULTURA DE TEMPORAL ANUAL	14.65
BOSQUE CULTIVADO	2.15
BOSQUE DE ENCINO	26.55
BOSQUE DE ENCINO-PINO	4.69
BOSQUE DE OYAMEL	248
BOSQUE DE PINO	1,323.9
BOSQUE DE PINO-ENCINO	73.70
PASTIZAL INDUCIDO	43.68
VEGETACIÓN SECUNDARIA ARBUSTIVA DE BOSQUE DE ENCINO	66.49
VEGETACIÓN SECUNDARIA ARBUSTIVA DE BOSQUE DE OYAMEL	8.37
VEGETACIÓN SECUNDARIA ARBUSTIVA DE BOSQUE DE PINO	0.12
VEGETACIÓN SECUNDARIA ARBUSTIVA DE BOSQUE DE PINO-ENCINO	3.70

La mayor frecuencia del evento de reducción del vigor vegetal se dio en la franja altitudinal que va de los 3,200 a los 3,600 msnm y con mayor incidencia en la exposición este-noreste del macizo montañoso. En el mapa de vegetación y la imagen satelital de la FIGURA 21 puede observarse que el fenómeno se presenta en menor grado en zonas correspondientes a la vegetación de bosque de oyamel, y tiene una incidencia mayor en el tipo de vegetación correspondiente a bosque de pino.




Figura 21. Mapas de referencia: elevación (superior izquierda), pendiente del terreno (superior derecha), vegetación (inferior izquierda), imagen satelital (inferior derecha).

IV. DISCUSIÓN Y CONCLUSIONES

Las técnicas utilizadas permitieron alcanzar los objetivos de la investigación de manera parcial ya que de acuerdo a los resultados de las clasificaciones, se sabe que no se clasificaron en su totalidad aquellos píxeles que presentan el comportamiento vegetal de interés. Los resultados obtenidos de la clasificación indican un nivel de correspondencia discreto de acuerdo a los valores del índice Kappa. Cabe resaltar que los procedimientos se realizaron utilizando un mínimo de firmas espectrales de referencia, lo que demuestra que el método de clasificación planteado es práctico y que puede utilizarse como una herramienta que agilice la supervisión y monitoreo del estado de salud de superficies forestales. Sin embargo, es necesario subrayar que es posible mejorar los resultados a partir de aumentar la cantidad de firmas espectrales de referencia.

Como ya se ha mencionado, la metodología planteada representa un procedimiento sencillo y rápido para el monitoreo de cambios de menor escala a través del tiempo dentro de grandes superficies forestales que de otra manera sería difícil detectar y que además sería complicado financiar otras estrategias de monitoreo en campo.

Se concluye que el algoritmo de clasificación por ángulo espectral es una técnica eficiente para la clasificación de imágenes en las que se busca detectar zonas que presenten similitud con un patrón de respuesta espectral-temporal. Por su parte, la técnica de transformación por componentes principales aplicada a una imagen multitemporal-multiespectral demostró ser una herramienta útil para detectar visualmente patrones de cambio a través del tiempo, sin embargo, la selección de los componentes principales a partir de la interpretación de la forma de los eigenvectores sigue siendo una labor interpretativa que demanda amplio conocimiento del analista o

investigador sobre el comportamiento de la respuesta espectral de los diferentes tipos de cubierta presentes en la escena de estudio.

La superficie forestal con presencia de reducción del vigor vegetal es pequeña dentro del área de estudio, sin embargo, tiene una dispersión geográfica amplia dentro de la zona, lo que debe ser motivo de atención para actuar de manera preventiva ante la posible presencia de procesos de desertificación y/o degradación de suelos debido a la fragmentación del ecosistema forestal, lo que también aumenta el efecto de borde dentro del ecosistema y lo hace vulnerable ante la acción eólica y la evapotranspiración. Se recomienda iniciar estudios dirigidos a identificar las causas de la presencia de la pérdida en el vigor vegetal dentro del área de estudio así como planificar acciones de restauración forestal para retardar cualquier proceso de degradación provocado por la fragmentación de las comunidades arbóreas.

Por último se recomienda continuar con este tipo de trabajos usando datos más recientes para generar información complementara sobre la respuesta de la vegetación a posibles cambios climáticos.

V. LITERATURA CITADA

ANDERSON, T.W. 2003. An introduction to multivariate statistical analysis. Wiley-Interscience. John Wiley and Sons. USA. 721 p.

BARRET, E., and CURTIS, L. F. 1992. Introduction to environmental remote sensing. Chapman & Hall. London. England. 426 p.

CABELLO, J., y PARUELO J. M. 2008. La teledetección en estudios ecológicos (en línea). Revista Ecosistemas no 17. pp: 1-3. Consultado el 20 de agosto de 2013. Disponible en:

<http://www.redalyc.org/articulo.oa?id=54017106001>

CHO, M. A., *et al.* 2010. Improving discrimination of Savannah tree species through a multiple endmember spectral angle mapper approach: canopy level analysis (en línea). Consultado el 10 de octubre de 2012. Disponible en: <http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=5559438&url=http%3A%2F%2Fieeexplore.ieee.org%2Fiel5%2F36%2F5607221%2F05559438.pdf%3Farnumber%3D5559438>

CHUVIECO, EMILIO. 2010. Teledetección ambiental: la observación de la tierra desde el espacio. Ariel Ciencia. España. 590 p.

CONGALTON, RUSSEL G. 1991. A review of assessing the accuracy of classifications of remotely sensed data (en línea). Consultado el 8 de Julio de 2013. Disponible en: http://horizon.science.uva.nl/public/SCGE2010/GDA/congalton1991_rse.pdf

CRACKNELL, ARTHUR. 2007. Introduction to remote sensing. CRC press. Florida. E.E.U.U. 335p.

DEL ÁNGEL-MOBARAK, GUSTAVO. 2012. El medio forestal de México. In: La Comisión Nacional Forestal en la historia y en el futuro de la política forestal de México. DEL ÁNGEL-MOBARAK, GUSTAVO (Comp). CIDE. México. pp: 37-77.

DIGIROLAMO, PAUL ALRIK. 2006. A comparison of change detection methods in an urban environment using Landsat TM and ETM+ satellite imagery: a multi-temporal, multispectral analysis of Gwinnett County, GA 1991-2000 (en línea). Consultado el 18 de septiembre de 2013. Disponible en: http://scholarworks.gsu.edu/cgi/viewcontent.cgi?article=1017&context=anthro_theses

FERRERO, S. B., PALACIO, M. G., y CAMPANELLA, O. R. 2002. Análisis de componentes principales en teledetección: consideraciones estadísticas para optimizar su interpretación (en línea). Revista teledetección no 17: 43-54. Consultado el 18 de noviembre de 2012. Disponible en: <http://www.aet.org.es/revistas/revista17/AET17-05.pdf>

FLORES GARNICA, J., and ISLAS GUTIERREZ, F. 2006. Alternative approaches for land use identification systems using remote sensing. *In: Modeling and remote sensing applied to agriculture (U.S. and Mexico)*. RICHARDSON, C. W., *et al* (eds). USDA-INIFAP. USA. pp: 189-209.

GIROUARD, G., *et al.* 2013. Validated spectral angle mapper algorithm for geological mapping: comparative study between Quickbird and Landsat-TM (en línea). Consultado el 28 de septiembre de 2013. Disponible en: <http://www.isprs.org/proceedings/XXXV/congress/comm4/papers/432.pdf>

GLOBAL LAND COVER FACILITY. 2013. Base de datos University of Maryland (en línea). Consultado el 11 de febrero de 2012. Disponible en: <http://glcf.umd.edu/data/landsat>

HAINES-YOUNG, R *et al.* 1993. Landscape ecology and GIS. Taylor & Francis. England. 281 p.

HOBBS, R. J., and MOONEY, H. A. 1990. Remote sensing of biosphere functioning. Stanford University. Department of biological sciences. USA. 312 p.

JOHNSON, R.A., and WICHERN, D.W. 2007. Applied multivariate statistical analysis. Prentice-Hall. USA. 773 p.

LANDIS, J.R., and KOCH, G.G. 1960. The measurement of observer agreement for categorical data (en línea). Consultado el 8 de septiembre de 2013. Disponible en: <http://www.jstor.org/discover/10.2307/2529310?uid=3738664&uid=2&uid=4&sid=21103033820083>

LILLESAND, T. M., and KIEFER, R. W. 1994. Remote sensing and image interpretation. John Wiley & Sons. USA. 750 p.

LUC, BERTELS *et al.* 2005. Optimized spectral angle mapper classification of spatially heterogeneous dynamic dune vegetation, a case study along de Belgian coastline (en línea). Consultado el 2 julio de 2013. Disponible en: http://publications.vgt.vito.be/documents/LB/not_used/Full_V2.PDF

ORDOÑES, CELESTINO y MARTÍNEZ-ALEGRÍA, R. 2003. Sistemas de Información Geográfica. Aplicaciones: prácticas con IDRISI 32 al análisis de riesgos naturales y problemáticas medioambientales. Alfaomega. España. 227 p.

PEÑA, DANIEL. 2002. Análisis de datos multivariantes. McGraw Hill. España. 539 p.

REES, W. G. 2001. Physical principles of remote sensing. Cambridge University. UK. 343 p.

PETROPOULOS, GEORGE P., *et al.* 2010. A comparison of spectral angle mapper and artificial neural network classifiers combined with Landsat TM imagery analysis for obtaining burnt area mapping (en línea). Consultado el 18 de octubre de 2013. Disponible en:

<http://www.mdpi.com/1424-8220/10/3/1967>

RENCER, A.C. 2002. Methods of multivariate analysis. Brigham Young University. John Wiley & Sons.E.E.U.U. 708 p.

SPICER, JOHN. 2005. Making sense of multivariate data analysis. SAGE publications. USA. 233p.

SÁNCHEZ GONZÁLEZ, ARTURO. 2004. Análisis sinecológico florístico y biogeográfico de la vegetación del norte de la Sierra Nevada, México. Chapingo, México. Tesis doctoral. 153 p.

SOHN, YOUNSING and REBELLO, N. 2013. Supervised and unsupervised spectral angle classifiers (en línea). Consultado el 1 de octubre de 2013. Disponible en: http://asprs.org/a/publications/pers/2002journal/december/2002_dec_1271-1280.pdf

SOTO ORTEGA, LAURA L. 2009. Estudio geoespacial para determinar áreas de distribución potencial de especies forestales en la Sierra Nevada. Chapingo, México. Tesis de Maestría. 113 p.

TIMM, NEIL. H. 2002. Applied multivariate analysis. Springer. USA. 693p.

ZHOU, WEIQI., *et al.* 2008. Object-based land cover classification and change analysis in the Baltimore metropolitan area using multitemporal high resolution remote sensing data (en línea). Consultado el 18 de junio de 2013. Disponible en:

<http://www.mdpi.org/sensors/papers/s8031613.pdf>

ANEXO 1-A

Coordenadas geográficas de los puntos de muestreo de la Categoría 1 usados para la evaluación de la clasificación.

ID	Lat	Long
1	19.487	-98.704
2	19.485	-98.694
3	19.480	-98.732
4	19.472	-98.652
5	19.467	-98.700
6	19.465	-98.657
7	19.464	-98.702
8	19.464	-98.700
9	19.462	-98.751
10	19.462	-98.660
11	19.451	-98.765
12	19.450	-98.689
13	19.450	-98.737
14	19.430	-98.673
15	19.421	-98.779
16	19.421	-98.771
17	19.418	-98.677
18	19.418	-98.771
19	19.415	-98.767
20	19.413	-98.779
21	19.407	-98.667

ID	Lat	Long
22	19.406	-98.763
23	19.406	-98.753
24	19.405	-98.737
25	19.398	-98.670
26	19.396	-98.673
27	19.395	-98.710
28	19.394	-98.671
29	19.392	-98.668
30	19.390	-98.694
31	19.388	-98.777
32	19.386	-98.693
33	19.386	-98.670
34	19.385	-98.656
35	19.384	-98.775
36	19.381	-98.659
37	19.379	-98.694
38	19.378	-98.654
39	19.377	-98.692
40	19.376	-98.779
41	19.375	-98.657
42	19.375	-98.657
43	19.436	-98.671

ANEXO 1-B

Coordenadas geográficas de los puntos de muestreo distribuidos en la Categoría 2 para la evaluación de la clasificación.

ID	Lat	Long
1	19.497	-98.673
2	19.497	-98.674
3	19.497	-98.651
4	19.496	-98.660
5	19.495	-98.665
6	19.494	-98.667
7	19.494	-98.670
8	19.494	-98.680
9	19.493	-98.671
10	19.493	-98.665
11	19.493	-98.687
12	19.493	-98.664
13	19.493	-98.704
14	19.493	-98.674
15	19.492	-98.649
16	19.491	-98.704
17	19.491	-98.695
18	19.491	-98.688
19	19.491	-98.686
20	19.489	-98.677
21	19.489	-98.667
22	19.489	-98.700
23	19.486	-98.689
24	19.486	-98.664
25	19.485	-98.731
26	19.485	-98.681
27	19.485	-98.656
28	19.484	-98.650
29	19.483	-98.663
30	19.483	-98.684
31	19.481	-98.679
32	19.481	-98.693
33	19.480	-98.682

ID	Lat	Long
34	19.480	-98.734
35	19.480	-98.725
36	19.480	-98.664
37	19.479	-98.713
38	19.478	-98.652
39	19.478	-98.716
40	19.478	-98.712
41	19.477	-98.696
42	19.477	-98.689
43	19.477	-98.679
44	19.476	-98.668
45	19.476	-98.655
46	19.476	-98.648
47	19.476	-98.726
48	19.475	-98.704
49	19.475	-98.649
50	19.474	-98.700
51	19.473	-98.712
52	19.473	-98.699
53	19.473	-98.688
54	19.472	-98.670
55	19.471	-98.681
56	19.469	-98.733
57	19.469	-98.695
58	19.469	-98.722
59	19.467	-98.741
60	19.467	-98.694
61	19.466	-98.670
62	19.466	-98.661
63	19.465	-98.657
64	19.464	-98.702
65	19.464	-98.750
66	19.464	-98.737

ID	Lat	Long
67	19.463	-98.736
68	19.463	-98.735
69	19.463	-98.724
70	19.463	-98.652
71	19.463	-98.750
72	19.463	-98.740
73	19.463	-98.737
74	19.463	-98.678
75	19.462	-98.749
76	19.462	-98.730
77	19.461	-98.690
78	19.461	-98.681
79	19.460	-98.714
80	19.460	-98.689
81	19.459	-98.681
82	19.459	-98.696
83	19.458	-98.722
84	19.458	-98.719
85	19.458	-98.658
86	19.458	-98.749
87	19.458	-98.655
88	19.457	-98.703
89	19.457	-98.681
90	19.457	-98.676
91	19.457	-98.648
92	19.457	-98.712
93	19.457	-98.660
94	19.457	-98.683
95	19.456	-98.659
96	19.456	-98.660
97	19.456	-98.751
98	19.455	-98.692
99	19.455	-98.751
100	19.455	-98.661
101	19.454	-98.743
102	19.454	-98.738
103	19.454	-98.729
104	19.453	-98.679
105	19.453	-98.759
106	19.453	-98.719

ID	Lat	Long
107	19.452	-98.779
108	19.452	-98.734
109	19.452	-98.732
110	19.452	-98.711
111	19.452	-98.746
112	19.452	-98.679
113	19.450	-98.759
114	19.450	-98.736
115	19.450	-98.729
116	19.450	-98.673
117	19.450	-98.717
118	19.449	-98.699
119	19.449	-98.709
120	19.448	-98.684
121	19.448	-98.677
122	19.448	-98.748
123	19.448	-98.725
124	19.447	-98.696
125	19.447	-98.652
126	19.446	-98.703
127	19.446	-98.742
128	19.446	-98.737
129	19.445	-98.663
130	19.445	-98.688
131	19.444	-98.724
132	19.444	-98.737
133	19.444	-98.728
134	19.444	-98.711
135	19.444	-98.660
136	19.444	-98.702
137	19.442	-98.654
138	19.442	-98.741
139	19.441	-98.766
140	19.441	-98.703
141	19.441	-98.737
142	19.441	-98.699
143	19.441	-98.659
144	19.441	-98.717
145	19.439	-98.678
146	19.439	-98.764

ID	Lat	Long
147	19.439	-98.712
148	19.439	-98.712
149	19.438	-98.743
150	19.438	-98.729
151	19.438	-98.649
152	19.438	-98.732
153	19.437	-98.652
154	19.436	-98.707
155	19.436	-98.710
156	19.436	-98.735
157	19.436	-98.655
158	19.435	-98.664
159	19.435	-98.704
160	19.435	-98.703
161	19.434	-98.764
162	19.434	-98.771
163	19.434	-98.729
164	19.434	-98.714
165	19.433	-98.666
166	19.433	-98.773
167	19.432	-98.760
168	19.431	-98.737
169	19.431	-98.675
170	19.431	-98.700
171	19.431	-98.671
172	19.431	-98.742
173	19.430	-98.775
174	19.430	-98.655
175	19.430	-98.665
176	19.429	-98.674
177	19.429	-98.665
178	19.428	-98.739
179	19.428	-98.655
180	19.427	-98.674
181	19.427	-98.704
182	19.427	-98.732
183	19.426	-98.684
184	19.426	-98.676
185	19.426	-98.664
186	19.425	-98.666

ID	Lat	Long
187	19.425	-98.742
188	19.424	-98.775
189	19.423	-98.697
190	19.423	-98.669
191	19.423	-98.666
192	19.423	-98.735
193	19.422	-98.696
194	19.422	-98.775
195	19.422	-98.673
196	19.421	-98.696
197	19.421	-98.669
198	19.421	-98.683
199	19.421	-98.743
200	19.421	-98.661
201	19.421	-98.741
202	19.420	-98.730
203	19.420	-98.650
204	19.418	-98.697
205	19.418	-98.734
206	19.418	-98.664
207	19.418	-98.657
208	19.418	-98.751
209	19.418	-98.751
210	19.418	-98.729
211	19.417	-98.648
212	19.415	-98.658
213	19.415	-98.675
214	19.415	-98.701
215	19.415	-98.767
216	19.415	-98.736
217	19.414	-98.778
218	19.414	-98.731
219	19.414	-98.731
220	19.414	-98.755
221	19.414	-98.739
222	19.414	-98.746
223	19.414	-98.727
224	19.413	-98.668
225	19.413	-98.695
226	19.412	-98.763

ID	Lat	Long
227	19.412	-98.760
228	19.412	-98.741
229	19.412	-98.775
230	19.412	-98.757
231	19.412	-98.663
232	19.412	-98.768
233	19.411	-98.665
234	19.410	-98.680
235	19.410	-98.703
236	19.410	-98.661
237	19.410	-98.660
238	19.409	-98.747
239	19.409	-98.707
240	19.408	-98.733
241	19.408	-98.726
242	19.408	-98.693
243	19.408	-98.735
244	19.407	-98.711
245	19.407	-98.684
246	19.407	-98.714
247	19.407	-98.683
248	19.406	-98.778
249	19.406	-98.780
250	19.405	-98.713
251	19.405	-98.671
252	19.405	-98.683
253	19.403	-98.716
254	19.403	-98.755
255	19.403	-98.749
256	19.403	-98.709
257	19.402	-98.711
258	19.401	-98.743
259	19.401	-98.665
260	19.401	-98.741
261	19.400	-98.763
262	19.400	-98.710
263	19.400	-98.700
264	19.399	-98.722
265	19.399	-98.739
266	19.399	-98.772

ID	Lat	Long
267	19.398	-98.768
268	19.398	-98.733
269	19.398	-98.774
270	19.397	-98.695
271	19.397	-98.725
272	19.397	-98.778
273	19.396	-98.736
274	19.396	-98.685
275	19.396	-98.694
276	19.396	-98.661
277	19.396	-98.751
278	19.396	-98.748
279	19.395	-98.729
280	19.395	-98.749
281	19.395	-98.686
282	19.393	-98.685
283	19.393	-98.717
284	19.393	-98.655
285	19.393	-98.656
286	19.392	-98.763
287	19.392	-98.743
288	19.392	-98.723
289	19.390	-98.711
290	19.390	-98.745
291	19.390	-98.738
292	19.390	-98.655
293	19.390	-98.742
294	19.390	-98.654
295	19.389	-98.738
296	19.389	-98.735
297	19.389	-98.679
298	19.389	-98.753
299	19.389	-98.699
300	19.388	-98.680
301	19.388	-98.669
302	19.388	-98.741
303	19.387	-98.739
304	19.387	-98.751
305	19.387	-98.746
306	19.387	-98.779

ID	Lat	Long
307	19.386	-98.659
308	19.386	-98.711
309	19.385	-98.745
310	19.385	-98.721
311	19.384	-98.721
312	19.384	-98.751
313	19.384	-98.688
314	19.384	-98.760
315	19.384	-98.704
316	19.383	-98.683
317	19.383	-98.750
318	19.383	-98.748
319	19.383	-98.739
320	19.382	-98.776
321	19.382	-98.698
322	19.382	-98.650
323	19.382	-98.723
324	19.381	-98.732

ID	Lat	Long
325	19.381	-98.650
326	19.380	-98.663
327	19.380	-98.676
328	19.379	-98.699
329	19.379	-98.684
330	19.378	-98.712
331	19.378	-98.690
332	19.378	-98.685
333	19.377	-98.764
334	19.377	-98.755
335	19.377	-98.722
336	19.376	-98.720
337	19.375	-98.667
338	19.375	-98.655
339	19.375	-98.732
340	19.375	-98.769
341	19.375	-98.703
342	19.429	-98.765