CLASIFICACIÓN DE IMÁGENES DE ALTA RESOLUCIÓN ESPACIAL POR MEDIO DEL ANÁLISIS DE TEXTURAS CASO DE ESTUDIO: TABIO/CUNDINAMARCA



UNIVERSIDAD DISTRITAL
FRANCISCO JOSÉ DE CALDAS

JAIME ESTEBAN RODRÍGUEZ NIÑO
CRISTIAN CAMILO ARAUJO BARBOSA

Universidad Distrital Francisco José de Caldas
Facultad de Ingeniería, Ingeniería Catastral y Geodesia
Bogotá D.C., Colombia
2015

CLASIFICACIÓN DE IMÁGENES DE ALTA RESOLUCIÓN ESPACIAL POR MEDIO DEL ANÁLISIS DE TEXTURAS CASO DE ESTUDIO: TABIO/CUNDINAMARCA

JAIME ESTEBAN RODRÍGUEZ NIÑO
CRISTIAN CAMILO ARAUJO BARBOSA

Trabajo de investigación presentado como requisito parcial para optar al título de:
Ingenieros Catastrales y Geodestas

Director:
Ph.D. Iván Lizarazo Salcedo

Línea de Investigación:
Análisis de imágenes orientado a la caracterización y detección de cambios en objetos y fenómenos geográficos.
Grupo de Investigación:
NIDE – Núcleo de Investigación de Datos Espaciales

Universidad Distrital Francisco José de Caldas
Facultad de Ingeniería, Ingeniería Catastral y Geodesia
Bogotá D.C., Colombia
2015

Dedicatoria

Principalmente a mi Madre, que ha sido parte fundamental para el desarrollo y cumplimiento de mis sueños, a mi Padre, mi familia y todas aquellas personas que de una u otra forma me han apoyado incondicionalmente.

Jaime Esteban Rodríguez Niño

Dedicado a la memoria de mi Madre, quien me formó durante la primera etapa de mi vida y quién me enseñó a luchar por las cosas que quiero, a la memoria de mi Tío, quien fue para mí un hombre ejemplar, a mi Hermana quien asumió la responsabilidad de terminar el trabajo que mi Madre dejó empezado, siempre apoyándome y guiándome por los caminos de la vida, a mi Familia y a quienes me han apoyado incondicionalmente durante mi desarrollo tanto personal, como profesional.

Cristian Camilo Araujo Barbosa

AGRADECIMIENTOS

Queremos agradecer inmensamente a todos aquellos que de alguna forma nos ayudaron a realizar el presente proyecto, principalmente al director del mismo, Ph.D Iván Lizarazo Salcedo, por su paciencia, ayuda, orientación, tiempo invertido y apoyo brindado a lo largo del desarrollo del trabajo.

A la Universidad Distrital Francisco José de Caldas por permitirnos cruzar un camino lleno de conocimientos y experiencias únicas.

Al Instituto Geográfico Agustín Codazzi, Subdirección de Geografía y Cartografía por habernos suministrado la información fundamental para la realización del proyecto.

A la alcaldía Municipal de Tabio por permitirnos llevar a cabo el proyecto en el municipio.

RESUMEN

La finalidad del proyecto es disminuir la incertidumbre que se encuentra en el ámbito del uso de texturas al momento de ser incluidas en los procedimientos de clasificaciones de cobertura del suelo en imágenes de alta resolución espacial; validando su exactitud temática respecto a los métodos convencionales. Además, realizar un análisis general de las medidas de textura para que puedan ser utilizadas en diferentes campos, no solo en la teledetección.

Para cumplir los objetivos propuestos se realizaron múltiples pruebas en la creación de bandas de textura para analizar los cambios generados, evaluando los diferentes parámetros, en una zona, que en su mayoría, estuviera compuesta por coberturas de vegetación, para luego realizar clasificaciones supervisadas por 3 diferentes algoritmos.

Para comparar y validar las clasificaciones de cobertura del suelo generadas por el método convencional y las convencionales con las bandas de textura incorporadas, se utilizó la matriz de confusión con un total de 1350 puntos distribuidos alrededor de la zona de estudio. Los resultados mostraron un aumento significativo de exactitud de clasificación al combinar las bandas espectrales y de textura.

Palabras clave: bandas de textura, coberturas vegetales, clasificación de cobertura del suelo.

TABLA DE CONTENIDO

RESUMEN ..... **V**

LISTA DE FIGURAS ..... **VI**

LISTA DE TABLAS ..... **VIII**

LISTA DE ANEXOS ..... **X**

1. INTRODUCCIÓN **11**

1.1 ANTECEDENTES 11
1.2 PLANTEAMIENTO DEL PROBLEMA 14
1.3 JUSTIFICACIÓN 15
1.4 OBJETIVOS 19
1.4.1 GENERAL *19*
1.4.2 ESPECÍFICOS *19*

2. MARCO TEÓRICO Y ESTADO DEL ARTE **20**

2.1 MARCO TEÓRICO 20
2.1.1 COBERTURA DEL SUELO *20*
2.1.2 SISTEMA DE CLASIFICACIÓN DEL SUELO *20*
2.1.3 CORRELACIÓN *21*
2.1.4 CLASIFICACIÓN SUPERVISADA *22*
2.1.5 ALGORITMOS DE CLASIFICACIÓN *24*
2.1.5.1 CLASIFICADOR DE MÍNIMA DISTANCIA *24*
2.1.5.2 CLASIFICADOR DE MÁXIMA VEROSIMILITUD *26*
2.1.5.3 PARALELEPÍPEDO CON MÁXIMA VEROSIMILITUD COMO CRITERIO DE DESEMPATE *29*
2.1.6 FILTRO DE SUAVIZADO *30*
2.1.7 TEXTURA *32*
2.1.8 MATRÍZ DE CO-OCURRENCIA DE NIVELES DE GRISES *33*
2.1.9 PARÁMETROS DE HARALICK *35*
2.1.10 INTERPOLACIÓN *36*
2.1.11 MODELO DIGITAL DE ELEVACIÓN *38*
2.1.12 EXACTITUD TEMÁTICA *39*
2.1.12.1 MATRIZ DE ERROR *40*
2.1.12.2 PORCENTAJE DE CLASIFICACIÓN CORRECTA *41*
2.1.12.3 EXACTITUD DEL USUARIO *42*
2.1.12.4 EXACTITUD DEL PRODUCTOR *42*
2.1.12.5 ÍNDICE KAPPA *43*
2.1.13 ORTORECTIFICACIÓN *43*
2.1.14 ERROR MEDIO CUADRÁTICO *45*
2.2 ESTADO DEL ARTE 46

2.2.1 ANÁLISIS DE TEXTURA EN GENERAL ... 46
2.2.2 ANÁLISIS DE TEXTURA EN OTROS CAMPOS ... 49
2.2.3 ANÁLISIS DE TEXTURAS EN COLOMBIA ... 50
2.2.4 ANÁLISIS DE TEXTURAS EN TELEDETECCIÓN ... 51

3. DATOS Y MÉTODOS ... 58

3.1 ÁREA DE ESTUDIO ... 58
3.1.1 UBICACIÓN ... 58
3.1.2 EXTENSIÓN ... 59
3.1.3 HIDROGRAFÍA ... 61
3.1.4 CLIMA ... 61
3.1.5 TOPOGRAFÍA ... 61
3.1.6 RECURSOS NATURALES ... 63
3.1.7 ECONOMÍA ... 63
3.1.8 COMERCIO ... 63
3.1.9 SECTOR AGROPECUARIO ... 64
3.1.10 MINERÍA ... 64
3.2 DATOS ... 65
3.2.1 AEROGOTOGRAFÍAS DIGITALES ... 65
3.2.2 MODELO DIGITAL DE ELEVACIÓN ... 68
3.3 MÉTODOS ... 69
3.3.1 PRE-RECONOCIMIENTO ... 69
3.3.2 SISTEMA DE CLASIFICACIÓN ... 73
3.3.3 ORTORECTIFICACIÓN ... 81
3.3.4 IMÁGENES DE TEXTURA ... 86
3.3.5 RECONOCIMIENTO EN CAMPO ... 105
3.3.6 CLASIFICACIÓN DE COBERTURA ... 105
3.3.7 VALIDACIÓN ... 112

4. RESULTADOS ... 114

4.1 PARÁMETROS DE LA MATRIZ DE COOCURRENCIA ... 114
4.1.1 ORIENTACIÓN ... 114
4.1.2 DISTANCIA DE PIXEL ... 115
4.1.3 DIMENSIONES MATRIZ ... 117
4.2 EXACTITUD TEMÁTICA ... 118
4.2.1 PORCENTAJE DE CLASIFICACIÓN CORRECTA GENERAL ... 118
4.2.2 COEFICIENTE KAPPA GENERAL ... 119
4.2.3 ALGORITMO DE PARALELEPÍPEDO ... 120
4.2.4 EXACTITUD DEL PRODUCTOR ... 121
4.2.5 EXACTITUD DEL USUARIO ... 122
4.2.6 COEFICIENTE KAPPA ... 123

DISCUSIÓN ... 124

ORTORECTIFICACIÓN ... 124

PARÁMETROS DE HARALICK *125*
CLASIFICACIÓN DE COBERTURA DEL SUELO *126*
VALIDACIÓN *127*

CONCLUSIONES 129

ANEXOS..... 131

BIBLIOGRAFÍA 143

LISTA DE FIGURAS

Figura 2. 1 Algoritmo de Mínima Distancia..... 26
Figura 2. 2 Algoritmo de Máxima Verosimilitud.. 28
Figura 2. 3 Algoritmo de Paralelepípedo con Máxima Verosimilitud como criterio de desempate. 30
Figura 2. 4 Ventana móvil para el cálculo de la matriz de co-ocurrencia.. 33
Figura 2. 5 Vecinos del pixel X de acuerdo al ángulo utilizado en el cálculo de la matriz de co-ocurrencia.. 34
Figura 2. 6 Interpolación por convolución cúbica. 38
Figura 2. 7 Modelo Digital de Elevación..... 39
Figura 2. 8 Ejemplo matemático de la Matriz de Error. 41
Figura 2. 9 Sin proceso de ortorectificación (izquierda) y con proceso de ortorectificación (derecha). 45
Figura 3. 1 Ubicación de Tabio en el Departamento de Cundinamarca 58
Figura 3. 2 Zona de Estudio..... 60
Figura 3. 3 Topografía de la Zona de Estudio..... 62
Figura 3. 4 Línea del vuelo 2270300412009. 66
Figura 3. 5 Sensibilidad espectral de la Vexcel Ultracam D. 67
Figura 3. 6 Metodología general del proyecto..... 69
Figura 3. 7 Vista general de la zona de estudio, Zona con poca vegetación. 70
Figura 3. 8 Vista general de la zona de estudio, Pastizales y vía..... 70
Figura 3. 9 Vista general de la zona de estudio, Pastos y Bosque. 71
Figura 3. 10 Vista general de la zona de estudio, Invernaderos. 71
Figura 3. 11 Vista general de la zona de estudio, Zona urbana. 72
Figura 3. 12 Vista general de la zona de estudio. 72
Figura 3. 13 Metodología del proceso de ortorectificación..... 81
Figura 3. 14 Imagen digital 383 Ortorectificada. 85
Figura 3. 15 Mosaico ortorectificado. 85
Figura 3. 16 Metodología del proceso de creación de nuevas bandas de textura. 86
Figura 3. 17 Ejemplo de distancia y relación espacial entre píxeles. 93
Figura 3. 18 Metodología de clasificación de cobertura del suelo. 105
Figura 3. 19 Polígonos de entrenamiento sobre el área de estudio. 107
Figura 3. 20 Clasificación por el algoritmo de paralelepípedo (izquierda) y posterior al filtrado (derecha). 108
Figura 3. 21 Puntos de validación distribuidos en la zona de estudio. 112
Figura 4. 1 Porcentaje de Clasificación correcta general de la clasificación de cobertura del suelo de los diferentes algoritmos supervisados..... 118
Figura 4. 2 Coeficiente KAPPA de la clasificación de cobertura del suelo de los diferentes algoritmos utilizados. 119

Figura 4. 3 Exactitud del productor de la clasificación supervisada por el algoritmo de paralelepípedo de las bandas espectrales junto con las de textura. 121
Figura 4. 4 Exactitud del usuario de la clasificación supervisada por el algoritmo de paralelepípedo de las bandas espectrales junto con las de textura. 122
Figura 4. 5 Coeficiente KAPPA de la clasificación supervisada por el algoritmo de paralelepípedo de las bandas espectrales junto con las de textura. 123

LISTA DE TABLAS

Tabla 2. 1 Sistema de clasificación de cobertura y uso de la tierra de la Unión Geográfica Internacional. 21
Tabla 2. 2 Medidas de textura propuestas por (Haralick & Shanmugam, 1974) (Haralick, 1973). .. 36
Tabla 3. 1 Coordenadas de los límites de la zona de estudio. 59
Tabla 3. 2 Leyenda y área de las categorías de pendiente presentes en la zona de estudio. 62
Tabla 3. 3 Nombres y códigos de las aerofografías digitales solicitadas en el Banco Nacional de Imágenes. 65
Tabla 3. 4 Características de las aerotofografías digitales. 67
Tabla 3. 5 Características del modelo digital de elevación. 68
Tabla 3. 6 Sistema de clasificación Corine Land Cover nivel 1 y 2, adaptado para Colombia. 76
Tabla 3. 7 Sistema de clasificación adaptado a la zona de estudio. 77
Tabla 3. 8 Coberturas: Zonas Urbanizadas, Invernaderos y Zonas de Extracción Minera y Escombrera, presentes en la zona de estudio en imagen multiespectral RGB (321) (Izquierda) y en el pre-reconocimiento de campo (derecha). 78
Tabla 3. 9 Coberturas: Cuerpos de Agua, Pastos y Herbazales presentes en la zona de estudio en imagen multiespectral RGB (321) (Izquierda) y en el pre-reconocimiento de campo (derecha). 79
Tabla 3. 10 Coberturas: Cultivos Transitorios, Bosques y Tierra sin o con poca vegetación presentes en la zona de estudio en imagen multiespectral RGB (321) (Izquierda) y en el pre-reconocimiento de campo (derecha). 80
Tabla 3. 11 Error medio cuadrático de los puntos de control. 83
Tabla 3. 12 Error medio cuadrático de los puntos de amarre. 84
Tabla 3. 13 Matriz de correlación entre las bandas de la imagen multiespectral. 87
Tabla 3. 14 Lista de las medidas texturas de la matriz de co-ocurrencia usados en algunos estudios de análisis de textura. 88
Tabla 3. 15 Matriz de correlación entre bandas de textura y espectrales seleccionadas. 89
Tabla 3. 16 Promedios de correlación entre las bandas de texturas y espectrales seleccionadas. . 90
Tabla 3. 17 Matriz de correlación entre las bandas de textura seleccionadas. 92
Tabla 3. 18 Parámetros para la creación de las bandas de textura. 93
Tabla 3. 19 Imágenes de la zona de estudio, multiespectral RGB (321) y bandas de texturas seleccionadas. 95
Tabla 3. 20 Cobertura de zonas urbanizadas en combinación multiespectral RGB (321) y en las bandas de texturas seleccionadas. 96
Tabla 3. 21 Cobertura de invernaderos en combinación multiespectral RGB (321) y en las bandas de texturas seleccionadas. 97
Tabla 3. 22 Cobertura de zonas de extracción minera y escombrera en combinación multiespectral RGB (321) y en las bandas de texturas seleccionadas. 98
Tabla 3. 23 Cobertura de cuerpos de agua en combinación multiespectral RGB (321) y en las bandas de texturas seleccionadas. 99

Tabla 3. 24 Cobertura de pastos en combinación multiespectral RGB (321) y en las bandas de texturas seleccionadas. 100
Tabla 3. 25 Cobertura de Herbazales en combinación multiespectral RGB (321) y en las bandas de texturas seleccionadas. 101
Tabla 3. 26 Cobertura de cultivos transitorios en combinación multiespectral RGB (321) y en las bandas de texturas seleccionadas..... 102
Tabla 3. 27 Cobertura de bosques en combinación multiespectral RGB (321) y en las bandas de texturas seleccionadas. 103
Tabla 3. 28 Cobertura de tierras sin o con poca vegetación en combinación multiespectral RGB (321) y en las bandas de texturas seleccionadas. 104
Tabla 3. 29 Grupos de bandas para las clasificaciones de cobertura del suelo. 106
Tabla 3. 30 Leyenda de los mapas de clasificación de cobertura del suelo..... 108
Tabla 3. 31 Imagen multiespectral RGB (321) y clasificaciones supervisadas por 3 algoritmos usando bandas espectrales solamente y en combinación con bandas de textura, Zona Urbana y cultivos. 109
Tabla 3. 32 Imagen multiespectral RGB (321) y clasificaciones supervisadas por 3 algoritmos usando bandas espectrales solamente y en combinación con bandas de textura, Invernaderos, Cultivos Transitorios y Pastizales y Herbazales. 110
Tabla 3. 33 Imagen multiespectral RGB (321) y clasificaciones supervisadas por 3 algoritmos usando bandas espectrales solamente y en combinación con bandas de textura, Zona de Extracción Minera y Escombrera, Cuerpos de Agua y pastizales. 111
Tabla 4. 1 Matriz de correlación entre las medidas de texturas seleccionadas variando su orientación, con las 4 posibilidades, con una ventana móvil de 11x11. 114
Tabla 4. 2 Matriz de correlación entre las bandas de textura seleccionadas variando su distancia de pixel de referencia, orientación al oriente y una ventana móvil de 25x25..... 116
Tabla 4. 3 Matriz de correlación entre las bandas de textura seleccionadas variando la ventana móvil, con una relación espacial de (1,0). 117
Tabla 4. 4 Matriz de confusión de la clasificación supervisada por el algoritmo de paralelepípedo. 120

LISTA DE ANEXOS

A. Mapa de zona de estudio en imagen multiespectral combinación RGB (321). 131
B. Mapa de Clasificación Supervisada por el algoritmo de Mínima Distancia con bandas espectrales. 132
C. Mapa de Clasificación Supervisada por el algoritmo de Máxima Verosimilitud con bandas espectrales. 133
D. Mapa de Clasificación Supervisada por el algoritmo de Paralelepípedo con Máxima Verosimilitud como criterio de desempate con bandas espectrales. 134
E. Mapa de Clasificación Supervisada por el algoritmo de Mínima Distancia con bandas espectrales y texturas con ventana móvil de 25x25. 135
F. Mapa de Clasificación Supervisada por el algoritmo de Máxima Verosimilitud con bandas espectrales y texturas con ventana móvil de 25x25. 136
G. Mapa de Clasificación Supervisada por el algoritmo de Paralelepípedo con Máxima Verosimilitud como criterio de desempate con bandas espectrales y texturas con ventana móvil de 25x25. 137
H. Mapa de Banda de Textura de Homogeneidad con relación espacial (0,1) y ventana móvil de 25x25. 138
I. Mapa de Banda de Textura de Contraste con relación espacial (0,1) y ventana móvil de 25x25. 139
J. Mapa de Banda de Textura de Segundo Momento Angular con relación espacial (0,1) y ventana móvil de 25x25. 140
K. Mapa de Banda de Textura de Correlación con relación espacial (0,1) y ventana móvil de 25x25. 141
I. Mapa de Topografía de la zona de estudio 142

1. INTRODUCCIÓN

Este apartado centra al lector en el tema general, enseñando los diferentes estudios a través del tiempo, la importancia, y el porqué se consideró importante para llevarlo a cabo la profundización en el estudio del análisis de textura en las clasificaciones de cobertura del uso del suelo, aplicado a zonas que tienden a ser homogéneas por sus características espectrales, siendo que cada una de estas son coberturas diferentes.

1.1 ANTECEDENTES

La teledetección espacial se define como aquella técnica que permite adquirir imágenes de la superficie terrestre desde sensores instalados en plataformas espaciales, suponiendo que entre la Tierra y el sensor existe una interacción energética, ya sea por reflexión de la energía solar o de un haz energético artificial, ya por emisión propia. A su vez, es preciso que ese haz energético recibido por el sensor se transmita a la superficie terrestre, donde la señal detectada pueda almacenarse y, en última instancia, ser interpretada para una determinada aplicación (Chuvieco, 1996).

Existen métodos alternativos indirectos que usan imágenes captadas mediante sensores remotos en plataformas satelitales o aviones. Estas técnicas surgieron en la década de 1970 con el satélite LANDSAT, para monitorear regularmente los recursos naturales terrestres (Valdez-Lazalde, 2007).

Las imágenes generadas por estos sensores proveen datos cualitativos y espacialmente continuos de la superficie, resultando así particularmente útiles para describir el uso de la tierra en grandes extensiones (Paruelo, 2009), además de proveer datos e información para facilitar la planificación y el manejo de recursos forestales. La aparición de nuevos sensores remotos satelitales con mejor resolución espacial, espectral, radiométrica y temporal (Ikonos, QuickBird, SPOT), mantiene la posibilidad de usar esa tecnología para el manejo de recursos forestales, especialmente cuando hay restricciones de tiempo y de personal para el trabajo de campo (Valdez-Lazalde, 2007).

Además ha abierto nuevas posibilidades para generar cartografía detallada y realizar análisis del uso urbano del suelo (Herold, Liu, & Clarke, 2003). Una ventaja del uso de imágenes de alta resolución, es la reducción del problema de mezcla de píxeles, proporcionando un gran potencial para extraer información más detallada de la estructura de la cobertura del suelo que los datos de mediana resolución (Moran, 2010).

El conocimiento de los patrones espectrales típicos de las distintas coberturas terrestres nos permite interpretar las imágenes provenientes de sensores remotos. Por ejemplo, la vegetación vigorosa refleja muy poca energía en la región del visible, debido a la gran absorción por parte de las clorofilas para realizar la fotosíntesis, y refleja una alta proporción de la energía en la región del infrarrojo cercano, debido a la estructura característica de los tejidos de las hojas (Di Bella, Posse, Beget, Fischer, & Veron, 2008).

El análisis espacial de la información ecológica contenida en las imágenes satelitales puede estar orientado hacia la clasificación de los tipos de cobertura, al mapeo de los ecosistemas o hacia la caracterización de los patrones espaciales tanto de paisajes como de comunidades vegetales (Alperín, Borges, & Sarandón, 2007).

Una de las aplicaciones que hacen uso de los productos multiespectrales, provenientes de sensores remotos y que han ganado popularidad en los últimos tiempos son las clasificaciones temáticas del uso y cobertura del suelo (Mhangara & Odindi, 2012). La clasificación de cobertura del suelo implica clasificar la imagen multiespectral en varias coberturas del suelo como vegetación, agua, urbano, etc. Algunos de los usos de la clasificación de la cobertura del suelo se dan en la planeación, conservación de los recursos naturales de la tierra, estudio de los efectos climatológicos y el análisis del cambio de la forma de la tierra (Jenicka & Suruliandi, 2014). Por ende, la generación de clases urbanas de uso y cobertura del suelo, es indispensable para un buen entendimiento y administración de los procesos sociales, ecológicos y psicológicos urbanos. (Mhangara & Odindi, 2012).

La discriminación de tipos de cobertura (cultivos de verano, de invierno, montes forestales, cuerpos de agua, pasturas, etc.) se basa en la unicidad de su respuesta espectral y en los cambios temporales que en ellos pudieran operar (Paruelo, 2009).

Existen numerosos métodos de clasificación basados en el dominio espectral para asignar un valor a un tipo de vegetación determinado. Sin embargo en imágenes de alta resolución, el dominio espacial adquiere gran importancia, y los análisis de textura se hacen relevantes en los procesos de clasificación (Anaya, Duque, & Valencia, 2008). Adicionalmente a las características espectrales, la textura es una importante característica espacial usada para identificar objetos o regiones de interés en una imagen (Haralick & Shanmugam, 1974).

1.2 PLANTEAMIENTO DEL PROBLEMA

Científicos e investigadores de la comunidad de teledetección, comenzaron a utilizar datos de alta resolución espacial, y era de esperarse que los métodos computacionales de clasificación y segmentación basados en la respuesta espectral, estuvieran condenados a dar rendimientos insatisfactorios (Maillard, 2003)

Dada la variabilidad estructural característica de numerosas superficies forestales, la información espectral es, a menudo, insuficiente para la clasificación de unidades, requiriéndose información sobre su estructura espacial (Ruíz, Recio, & Fernández, 2005).

En otras ocasiones, el problema surge por la resolución espacial insuficiente de la mayoría de los sensores multiespectrales. Aunque este problema se va diluyendo de forma progresiva con la nueva generación de sensores de alta resolución, se carece de una serie histórica suficiente para el estudio de fechas pasadas y, en ocasiones, la información espectral suministrada se limita a tres bandas del espectro visible y una del infrarrojo, resultando insuficiente para ciertos estudios. (Ruíz, Recio, & Fernández, 2005).

En las imágenes de alta resolución espacial, un factor importante para mejorar el rendimiento de la clasificación, es reducir la variación espacial entre las mismas coberturas de suelo (Moran, 2010), ya que como cada píxel hace referencia a una parte de un objeto, el tratamiento basado en un píxel pierde validez (Presutti, 2004).

En otras palabras, el aumento de la resolución espacial incrementa el número de píxeles puros, de manera que la firma espectral de los mismos deja de representar la cubierta en su conjunto y comienza a caracterizar los componentes de la misma (R. Ciriza, 1988). La alta variación espectral de la misma cobertura, la confusión espectral entre diferentes coberturas, y el problema de sombras, a menudo conducen a un desempeño pobre en la clasificación de la cobertura del suelo cuando se hace uso de los métodos tradicionales; como lo son los métodos de clasificación que están basados exclusivamente en la firma espectral del pixel, pero no hacen uso de la información contenida en las imágenes de alta resolución (Moran, 2010).

1.3 JUSTIFICACIÓN

El uso de imágenes de sensores remotos en la agricultura se ha planteado como una alternativa para obtener datos cuantitativos que permiten ubicar y caracterizar los cultivos con el fin de tomar decisiones para la planificación y el manejo. En los últimos años, debido al gran avance en el desarrollo de los sensores remotos en cuanto al número de sistemas disponibles, la resolución espacial, espectral y temporal y la tendencia a disminuir el costo, ha surgido un número mayor de aplicaciones que van desde la identificación y el monitoreo de cultivos, estado nutricional, manejo del agua, manejo sanitario, predicción de cosechas, recursos genéticos, zonificación de aptitud de tierras, hasta la agricultura de precisión, entre otras. En Colombia, el uso de los datos provenientes de sensores remotos ha sido aplicado principalmente en estudios de cobertura vegetal en los cuales los cultivos se agrupan como una clase general; en consecuencia, son pocos los trabajos enfocados a la diferenciación de cultivos y a la obtención de información aplicable específicamente a la agricultura (Martínez, 2010).

La información multiespectral y la alta resolución espacial de las de las fotografías aéreas multiespectrales ofrecen un gran potencial para la clasificación de uso y cobertura del suelo (Mhangara & Odindi, 2012), donde los métodos basados únicamente en la respuesta espectral del píxel, pueden quedarse cortos, el análisis de texturas en imágenes ofrece posibilidades interesantes para resolver estas limitaciones, en especial en lo referente a la caracterización de la heterogeneidad estructural de las clases (Ruíz, Recio, & Fernández, 2005).

Los nuevos sensores de alta resolución permiten combinar bandas espectrales y de texturas en la clasificación, aprovechando su sinergia y mejorando las clasificaciones (Ruíz, Recio, & Fernández, 2005). Diferentes publicaciones han mostrado que las diferentes variaciones espaciales texturales ofrecen información valiosa acerca de la configuración estructural de los objetos y sus vecinos; información que puede ser utilizada para resolver los errores de las clases basadas en la respuesta espectral. (Mhangara & Odindi, 2012).

Tradicionalmente la textura se ha interpretado desde el punto de vista cualitativo entre liso y rugoso, sin embargo el uso de matrices permite realizar una medición cuantitativa (Anaya, Duque, & Valencia, 2006).

El estudio de la textura proporciona información sobre la distribución espacial de las variaciones de tono de una imagen. Su utilización resulta especialmente interesante en el ámbito de la agricultura, ya que ayuda a discriminar cultivos vegetales espectralmente similares. El estudio de la textura desde el punto de vista estadístico se centra en el análisis de la distribución espacial de los Niveles Digitales. Este enfoque se basa en la identificación de parámetros que cuantifican los patrones de variación que caracterizan a un grupo de píxeles y que describen la interdependencia, o co-ocurrencia, existente entre los mismos (R. Ciriza, 1988).

Hay diferentes métodos para el estudio de texturas. Sin embargo, el método comúnmente más utilizado para medir matemáticamente la textura es la matriz de co-ocurrencia de niveles de grises o GLCM por sus siglas en inglés (Grey Level Co-occurrence Matrix), basadas en estadísticas de segundo orden (Presutti, 2004). Por otro lado, varios estudios han concluido que el uso de la transformada de Fourier en el análisis de texturas, generalmente genera resultados pobres (Jensen, 2004).

Sin embargo, la idoneidad del método de extracción de variables de textura empleado viene dada en función del tipo de clases con las que se trabaje, no parece existir un criterio común (Ruíz, Recio, & Fernández, 2005). En la práctica, es común que haya dificultades al momento de identificar las texturas adecuadas, ya que éstas varían dependiendo del paisaje bajo investigación y las imágenes a procesar. La identificación de las texturas acertadas, implica determinar las medidas texturales, banda espectral, tamaño de la matriz movible, y otros parámetros. La dificultad de identificar las medidas texturales adecuadas y los costos computacionales para realizar los procesos, limitan el uso de texturas en la clasificación de imágenes (Moran, 2010). Y aunque las medidas texturales han sido incorporadas en las clasificaciones multiespectrales, aún no se ha adoptado algún algoritmo de cálculo lo suficientemente efectivo (Presutti, 2004).

Las medidas texturales juegan un papel importante en la clasificación de la cobertura del suelo usando productos de sensores remotos (Jenicka & Suruliandi, 2014) Y teniendo en

cuenta que su aplicación puede ser multipropósito, es necesario investigar con un enfoque experimental, el uso, complemento y/o perfeccionamiento de las diferentes técnicas, además de las tradicionales, para poder generar productos con mayor fiabilidad y precisión, ya que éstos pueden ser la base de diferentes estudios ajenos a la teledetección.

CONTEXTO CON LA INGENIERÍA CATASTRAL Y GEODESIA – ICG

La Ingeniería Catastral y Geodesia tiene como objetivo el estudio del recurso tierra con énfasis en el manejo social como fuente generadora de bienestar, utilizando las ciencias básicas, métodos de ingeniería y ciencias de la tierra en forma Integral, apoyada del conocimiento científico e investigativo así como de técnicas y tecnologías especializadas en la medición y representación gráfica. Durante 44 años este programa curricular se ha destacado en el contexto Colombiano, Latinoamericano y en el ámbito mundial coexistiendo tan solo algunos homólogos en el continente Asiático y Europeo; el perfil de sus profesionales y la experiencia adquirida tanto en la parte académica como laboral de los mismos, ha hecho que esta ingeniería sea indispensable y reconocida en el quehacer del desarrollo económico y científico del país en las áreas de Catastro, Geomática, Geodesia, Economía, Planeación y Ordenamiento Territorial (Universidad Distrital, 2015).

Ya que el objetivo principal de formación de la Ingeniería Catastral y Geodesia es contribuir a la formación de excelentes seres humanos capaces de generar, analizar y administrar información de datos espaciales (Astronomía, Geodesia, Percepción Remota y Cartografía) que le permitan planificar los Recursos Naturales (Economía, Sociología, Catastro, Derecho, Ordenamiento) para el uso sostenible de dichos recursos utilizando modernas tecnologías tales como GPS, SIG, y en general las disciplinas relacionadas con la GEOMÁTICA (Universidad Distrital, 2015), los estudios en el campo de la percepción remota y la teledetección tienen una connotación fundamental, están relacionadas con los principales ejes de la carrera, tienen múltiples aplicaciones dentro de nuestra misión formativa como Ingenieros Catastrales Y Geodestas que se basa en el recurso Tierra, ya sea para adelantar procesos de clasificación de coberturas buscando optimizar recursos como tiempo o costos, o para adelantar procesos de planificación y ordenamiento territorial.

Aparte de tener la distinción al ser únicos como carrera dentro del contexto nacional, tenemos una enorme responsabilidad para contribuir al desarrollo de metodologías o procedimientos que permitan mejorar los existentes, siempre en la búsqueda de optimizar recursos, utilizando las nuevas tecnologías disponibles, por ende, teniendo en cuenta que en Colombia, el uso de los datos provenientes de sensores remotos ha sido aplicado principalmente en estudios de cobertura vegetal en los cuales los cultivos se agrupan como una clase general, lo que es un error y que son pocos los trabajos enfocados a la diferenciación de cultivos y a la obtención de información aplicable a temas tan importantes para nuestro país como la agricultura, sumado al avance de los productos necesarios para estos estudios, como la resolución de las imágenes obtenidas remotamente, son para nuestra competencia profesional, problemas que implican investigar y probar nuevos procedimientos que estén a la vanguardia de nuestros homólogos alrededor del mundo, por ende para solucionar el problema de la mezcla de coberturas en los métodos tradicionales que se basan únicamente en la respuesta espectral del píxel en imágenes de alta resolución, debido a que los píxeles dejan de ser una cobertura y se convierten en un componente de la misma, se propone la aplicación de estadísticas de segundo orden de la Matriz de Co-ocurrencia de Niveles de Gris propuesta por Haralick en 1973, buscando mejorar la exactitud de la clasificación tradicional de las coberturas en el presente estudio.

1.4 OBJETIVOS

Para el proyecto se plantearon los siguientes objetivos:

1.4.1 GENERAL

- Clasificar la cobertura del suelo existente en una zona con alta presencia de clases vegetales (Municipio de Tabio/Cundinamarca), a partir de una imagen digital de alta resolución espacial, por medio del análisis de texturas, evaluando su exactitud respecto a los métodos convencionales.

1.4.2 ESPECÍFICOS

- Determinar los parámetros óptimos para aplicar la matriz de co-ocurrencia de niveles de grises, generando así, nuevas bandas o imágenes de textura.
- Realizar la clasificación de coberturas de suelo a partir de las imágenes de textura.
- Evaluar los métodos de clasificación de cobertura del suelo por los sistemas convencionales y el análisis de textura.

2. MARCO TEÓRICO Y ESTADO DEL ARTE

Éste capítulo describe todo lo necesario para poder entender correctamente todos los procesos que se describen a lo largo del proyecto.

2.1 MARCO TEÓRICO

A continuación se definen todos aspectos que se consideran relevantes para el desarrollo del proyecto:

2.1.1 COBERTURA DEL SUELO

Se refiere al tipo de material presente en la superficie (agua, tierra, vegetación, creaciones humanas) (Jensen, 2004).Formada por diferentes tipos de objetos (vegetación, suelos, agua, etc.) que reciben la señal energética procedente de la fuente de energía y la refleja o emite de acuerdo con sus características físicas y químicas. La cobertura puede originarse de ambientes naturales producto de la evolución ecológica (bosques, sabanas, lagunas, etc.) o a partir de ambientes artificiales creados y mantenidos por el hombre (cultivos, represas, ciudades, etc.) (Wilches & Hernando, 2005).

2.1.2 SISTEMA DE CLASIFICACIÓN DEL SUELO

La clasificación establece la identidad de las superficies u objetos delineados por la interpretación. Existen diversos sistemas de clasificación de cobertura y uso de la tierra que han sido preparados con el fin de estudiar coberturas locales con objetivos particulares. En la elaboración se han utilizado criterios y parámetros diferentes, lo que ha traído clasificaciones con diferentes estructuras (Wilches & Hernando, 2005).

Coberturas
1. Centros poblados y tierras no agrícolas
2. Tierras hortícolas
3. Árboles frutales y otros cultivos
4. Tierras de cultivos
5. Pastos permanentes mejorados.
6. Praderas no mejoradas
7. Tierras de bosques
8. Pantanos y ciénagas
9. Tierras improductivas

Tabla 2. 1 Sistema de clasificación de cobertura y uso de la tierra de la Unión Geográfica Internacional. Adaptado de (Wilches & Hernando, 2005).

La **Tabla 2. 1** muestra un ejemplo de un sistema de clasificación del uso y cobertura del suelo. Como se mencionaba anteriormente, se encuentran diferentes variedades de sistemas de clasificación, ya que se diseñan teniendo en cuentan múltiples características.

2.1.3 CORRELACIÓN

La correlación es el valor de la localización de la posición de un punto de control en la imagen maestra habiendo sido identificado en la tratada. El algoritmo de similitud secuencial de detección (SSDA), como el tratado por Bernstein (1983), es de este tipo.

Supongamos que un punto de control ha sido elegido en la imagen tratada y es necesario determinar su contraparte en la imagen maestra. En principio una muestra rectangular de píxeles que rodean el punto de control en la imagen tratada se puede extraer como una ventana que se correlaciona con la imagen maestra. Debido a las propiedades espaciales de la pareja de imágenes cerca de los puntos de control debería existir una alta correlación cuando la ventana de puntos se encuentra por encima de su región contraparte exacta en la imagen maestra y por lo tanto se identifica la ubicación principal del punto de control. Obviamente no es necesario mover la ventana de comparación sobre la imagen principal completa ya que el usuario sabe aproximadamente donde debe producirse el punto de control en la imagen maestra. En consecuencia, sólo es necesario

especificar una región de búsqueda por ubicación aproximada. Los sistemas de software que ofrecen esta opción permiten al usuario elegir tanto el tamaño de la ventana de píxeles desde el punto de control de imagen hasta el tamaño de la región de búsqueda en la imagen maestra sobre la que se mueve la ventana de píxeles tratados para detectar una aceptable correlación.

La medida de correlación utilizada no tiene que ser sofisticada. De hecho una verificación de similitud simple que se puede utilizar es, calcular la suma de las diferencias absolutas de los brillos de píxeles de la ventana en la imagen tratada y original, para cada posible ubicación de la ventana en la región de búsqueda. La ubicación que da la más pequeña diferencia absoluta define la posición del punto de control como ese píxel en el centro actual de la ventana. Obviamente, la sensibilidad del método se reducirá si hay una gran diferencia promedio de brillo entre las dos imágenes, por ejemplo en las variaciones estacionales. Por tanto, un refinamiento consiste en calcular la diferencia absoluta resumido de los brillos de píxeles en relación con sus respectivas medias en la ventana de búsqueda (Richards & Jia, 2006).

2.1.4 CLASIFICACIÓN SUPERVISADA

La clasificación de imágenes obtenidas remotamente puede ser representada como una combinación de reconocimiento de patrones, análisis de imágenes y la técnica de clasificación. En teledetección, la clasificación de una imagen es una parte importante del reconocimiento de patrones. La principal aplicación de las imágenes clasificadas es mostrar un patrón significativo en forma de clases, son ampliamente utilizadas en diversos campos, como la planificación urbana, la agricultura, la silvicultura, la geología, la hidrología, el monitoreo del océano, la vigilancia costera y la cobertura y uso de la tierra. La salida de imágenes provenientes de sensores remotos debidamente clasificadas, se presenta en forma de mapas temáticos que representan el uso de la tierra, la vegetación, los cuerpos de agua, estudios ambientales y socioeconómicos, razón por la cual muchos investigadores tienen gran interés en la clasificación de imágenes de teledetección.
En general, la clasificación de imágenes de teledetección puede ser conocido como un proceso de agrupación de píxeles en un conjunto finito de clases individuales en base a los valores de sus datos. Al píxel se le asigna una clase particular si satisface ciertas

reglas. Las clases pueden ser conocidas, si el investigador es capaz de separar las clases en el área de estudio, de lo contrario las clases son desconocidas, pero en ambos casos, el número de categorías de clase se puede determinar. El uso de la clasificación previa de conocimientos se conoce como clasificación supervisada y cuando las clases son desconocidas la clasificación es no supervisada.

En la clasificación no supervisada no se requiere ningún conocimiento previo del investigador para identificar las clases de la clasificación. En lugar de los conocimientos previos, la clasificación no supervisada utiliza las características directamente de los datos de entrada para la generación de las clases para la clasificación, calcula la distancia mínima entre el objeto principal y cada posible clase, proceso que se prolongará hasta encontrar la mínima distancia y asignarle al objeto la clase correspondiente.
La clasificación supervisada requiere de zonas de entrenamiento basadas en píxeles, para "enseñar" al clasificador a determinar los límites en el conjunto de características. La precisión en la determinación de las fronteras de decisión depende de la cantidad de muestras en las zonas de entrenamiento y el tipo de información adquirida de cada clase. (Sisodia, Tiwari, & Kumar, 2014)

Un clasificador supervisado puede proporcionar una mejor clasificación que un clasificador no supervisado. Sin embargo, en adición a la limitación de datos de entrenamiento, un clasificador supervisado puede resultar en un exceso de clasificación para algunas áreas homogéneas. Aunque puede ser menos potente, un clasificador sin supervisión puede clasificar generalmente bien esas áreas espectralmente homogéneas. (Yang, Du, & Ma, 2010)

Pero, aunque la clasificación no supervisada parece más elegante y automatizada que la clasificación supervisada, en teledetección cuando una imagen tiene un mismo valor de reflectancia en más de una clase, la precisión de la clasificación no supervisada se reduce debido al problema de píxeles mixtos. En este caso la clasificación supervisada tiende a dar una mayor precisión. (Sisodia, Tiwari, & Kumar, 2014)

Por todo lo expuesto hasta aquí, para el desarrollo del presente trabajo se decidió adoptar como método de clasificación, la clasificación supervisada, debido a que la zona de

estudio presenta múltiples coberturas y se puede encontrar el problema de discriminación de fronteras entre clases.

En ésta clasificación, la identificación y localización de algunas coberturas del suelo (urbano, vegetación o cuerpos de agua) son conocidos a priori a través de una combinación de trabajo de campo, interpretación de fotografías aéreas, análisis de mapas y la experiencia personal. El análisis intenta localizar sitios específicos en los datos de los sensores remotos que representan ejemplos homogéneos de estos tipos de cobertura de suelo. Dichas áreas se conocen generalmente como áreas de entrenamiento porque las características espectrales de esas áreas conocidas son usadas para entrenar los algoritmos de clasificación para realizar la clasificación de cobertura del resto de la imagen. Parámetros de estadística multivariada (media, desviación estándar, matrices de covarianza, matrices de correlación, e.t.c.) son calculadas para cada área de entrenamiento. Cada pixel, con y sin área de entrenamiento, es evaluado y se asigna a la clase en la cual tiene la mayor similitud (Jensen, 2004).

2.1.5 ALGORITMOS DE CLASIFICACIÓN

Los criterios más comunes para establecer las fronteras estadísticas entre clases son:

- Mínima Distancia: Método por el cual el pixel se asigna a la clase más cercana.
- Paralelepípedos: Permite señalar al usuario unos umbrales de dispersión asociados a cada clase.
- Máxima verosimilitud: cada pixel se asigna a aquella clase con la que posee mayor probabilidad de pertenencia.

2.1.5.1 CLASIFICADOR DE MÍNIMA DISTANCIA

El criterio más sencillo para asignar un píxel a una de las categorías consiste en incluirlo en la más cercana; esto es, en aquella que minimice la distancia entre ese píxel y el centroide de clase. Lógicamente, no se trata de una distancia geográfica, sino espectral, consecuencia de comparar los Niveles Digitales de cada píxel con los del centro de las distintas categorías, para todas las bandas que intervienen en el análisis.

Pueden considerarse varias formas de medir esa distancia espectral entre píxeles y clases. La más empleada, en este sentido, es la distancia euclidiana.

Este algoritmo es bastante sencillo y rápido de ejecutar, y puede ofrecer buenos resultados cuando no se observe un gran solape entre categorías. Puesto que siempre que existe una clase más cercana, no deja lugar a píxeles sin clasificar, incluso aunque éstos se alejen notablemente del centro de clase. Esto puede provocar errores de comisión importantes, sobre todo cuando no se incluye en la leyenda alguna categoría claramente presente en la imagen.

De una u otra forma, el método de mínima distancia se ha empleado con frecuencia en aplicaciones temáticas, especialmente cuando el área de estudio no presentaba una gran complejidad. (Chuvieco, 1996)

La precisión del clasificador de mínima distancia depende del entender las características de la zona y la precisión de las estadísticas de entrenamiento, por lo que tiene una capacidad relativamente débil a respuesta espectral similar. (Zheng, Liu, Qian, & Liang, 2010)

Pueden considerarse varias formas de medir esa distancia espectral entre píxeles y clases. La más empleada, en este sentido, es la distancia Euclidiana:

$$d_{xA} = \sqrt{\sum_{k=1}^{m} (ND_{x,k} - \overline{ND}_{A,k})^2}$$

Ecuación 2. 1 *Distancia Euclidiana, regla de decisión del Método de Mínima Distancia.*

Donde $\boldsymbol{d_{xA}}$ es la medida de la distancia entre el pixel **x** y la categoría **A**, que se calcula como la raíz cuadrada del sumatorio de las diferencias entre el ND (Nivel Digital) de ese píxel y el ND medio de la categoría **A**, para las m bandas que intervienen en la clasificación. Tras calcular esta medida para todas las categorías, puede obtenerse el valor $\boldsymbol{d_{xA}}$ más pequeño, asignando el píxel **x** a esa categoría.

La distancia que calcula este algoritmo es lineal, sin considerar la propia dispersión de cada categoría o la correlación que exista entre las bandas. Tiende, por tanto, a delimitar grupos circulares de radio proporcional a la situación de cada categoría (Chuvieco, 1996).

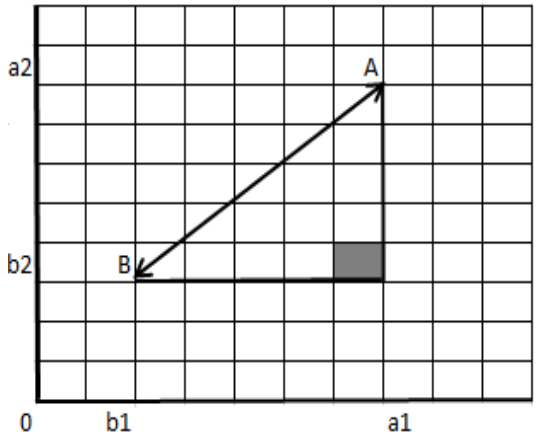


Figura 2. 1 Algoritmo de Mínima Distancia. Tomado de (Jensen, 2004).

La **Figura 2. 1** representa gráficamente el procedimiento realizo por el algoritmo de clasificación supervisada, mínima distancia.

2.1.5.2 CLASIFICADOR DE MÁXIMA VEROSIMILITUD

Este método considera que los Niveles Digitales (ND) en el seno de cada clase se ajustan a una distribución normal. Esto nos permite describir esa categoría por una función de probabilidad, a partir de su vector de medias y matriz de varianza-covarianza. En pocas palabras, esa función asemeja la distribución real de los ND en esa categoría, por lo que nos sirve para calcular la probabilidad de que un píxel (con un determinado ND) sea miembro de ella. El cálculo se realiza para todas las categorías que intervienen en la clasificación, asignando el píxel a aquella que maximice la función de probabilidad.

El clasificador de máxima verosimilitud es el más complejo y el que demanda mayor volumen de cálculo. Sin embargo es el más empleado, por su robustez y por ajustarse con más rigor a la disposición original a los datos. (Chuvieco, 1996)

Los resultados de clasificación por máxima verosimilitud son muy dependientes de la selección de muestras de entrenamiento. Si las muestras de entrenamiento no representan todas las clases de fondo, algunos píxeles que tienen características similares con la clase de destino son falsamente etiquetados como un píxel de destino, por ende, los resultados de la clasificación conducen a una alta tasa de falsas alarmas.

Con una buena representación de fondo, se reduce la tasa de falsas alarmas. (Demirci, Yazgan, & Ersoy, 2005)

El algoritmo de máxima verosimilitud asigna de acuerdo a las características del vector **X,** a la clase a la que tiene mayor probabilidad de pertenecer. Asume que los datos tienen una distribución normal para todas las clases. La regla de decisión utiliza dos parámetros estadísticos, el vector principal **Mc** de la clase y Vector **VcA** de la matriz de Varianza. El vector **X** es evaluado en la clase **c** si:

$$P_c \geq P_i, \qquad donde\ i = 1,2,3,\dots,m$$

Ecuación 2. 2 *Evaluación de la Clase.*

Con distribución Gaussiana e igual probabilidad de que la clase esté por fuera de la clase **m**:

$$P_c = -0.5In[\det(V_c)] + [0.5(X - M_c)^T V_c^{-1}(X - M_c)]$$

Ecuación 2. 3 *Evaluación de la Clase con distribución Gaussiana.*

Donde $\mathbf{det}(\boldsymbol{V_c})$ es el determinante de la matriz de covarianza, para:

$$\mu_{ck} = \frac{1}{u}\sum_{i=1}^{u} B\,V_{ik}, \quad k = 1,2,3,\dots,n$$

Ecuación 2.4 *Determinante de la Matriz de Covarianza.*

Donde **u** es el número de píxeles para la clase **c** de la banda **k**, que está fuera de la banda **n** clase **m**, y:

$$Cov_{ckl} = \frac{1}{n}\sum_{k=1}^{n}(BV_{cik} - \mu_{ck})(BV_{cil} - \mu_{cl}) \quad donde, k, l = 1,2,3,\dots,n$$

Ecuación 2.5 *Cálculo de la Covarianza.*

La matriz de covarianza y su vector principal para la clase **c** están definidos por:

$$V_c = \begin{bmatrix} cov_{c11} & cov_{c12} & \cdots & cov_{c1n} \\ cov_{c21} & cov_{c22} & \cdots & cov_{c2n} \\ \vdots & \vdots & \cdots & \vdots \\ cov_{cn1} & cov_{cn2} & \cdots & cov_{cnn} \end{bmatrix} \qquad donde\ \ M_c = (\mu_{c1}, \mu_{c2}, \ldots\ldots, \mu_{cn})^T$$

Ecuación 2.6 *Matriz de Covarianza.*

El algoritmo de la clasificación por máxima verosimilitud estima el valor de **Pc**, para cada característica del vector **X** de un pixel desconocido para clasificarlo dentro de una clase, eligiendo la clase que tiene la máxima probabilidad.

Si la clase no tiene la misma probabilidad de ocurrencia, se podría asignar peso a cada clase **c** dependiendo de la probabilidad inicial**,** $\boldsymbol{a_c}$**,** la regla de decisión define si el vector **X** está en la clase **c**, como se muestra a continuación:

$$P_c(a_c) \geq P_i(a_i), \quad i = 1,2, \ldots\ldots, m$$

Ecuación 2.7 *Probabilidad de ocurrencia.*

Donde la regla de decisión de Bayes, finalmente queda definida como:

$$P_c = Ina_c - 0.5In[\det(V_c)] + [0.5(X - M_c)^T V_c^{-1}(X - M_c)]$$

Ecuación 2.8 *Regla de decisión de Bayes, del método de Máxima Verosimilitud.*

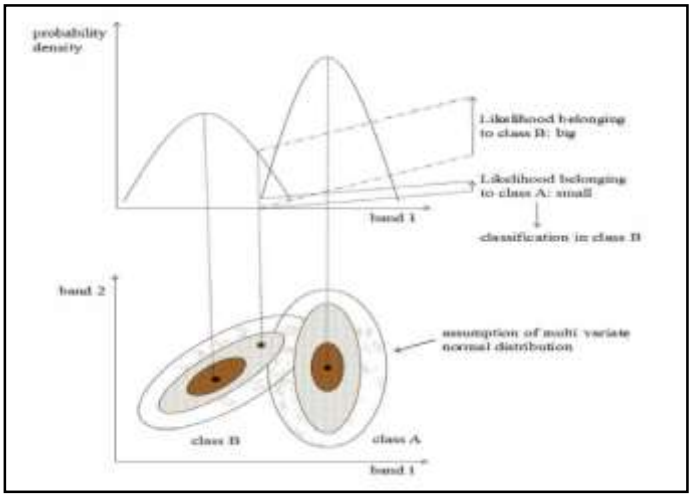


Figura 2. 2 *Algoritmo de Máxima Verosimilitud. Tomado de (Sisodia, Tiwari, & Kumar, 2014).*

Recientemente, se han utilizado métodos complejos de la combinación de la clasificación supervisada y no supervisada buscando cambiar los defectos de los métodos tradicionales de clasificación de imágenes individuales, compensar sus deficiencias, y abrir una amplia perspectiva de la clasificación de imágenes (Zheng, Liu, Qian, & Liang, 2010). La **Figura 2. 2** representa gráficamente el procedimiento realizado por el algoritmo de clasificación supervisada, mínima distancia.

2.1.5.3 PARALELEPÍPEDO CON MÁXIMA VEROSIMILITUD COMO CRITERIO DE DESEMPATE

En este clasificador, la varianza se introduce considerando la gama de niveles de gris para cada conjunto de categorías de formación. La gama está definida por los niveles de gris más altos y más bajos en cada banda. Un pixel desconocido se clasifica de acuerdo a la categoría de paralelepípedo (o región de decisión) en la que se encuentra. Los píxeles que están fuera de todos los paralelepípedos serán etiquetados "sin clasificar". El clasificador paralelepípedo con máxima verosimilitud como criterio de desempate es un cruce entre el clasificador de paralelepípedo y el clasificador de máxima verosimilitud completa. El concepto básico es el uso de la clasificación de paralelepípedo a menos que se tenga un empate (superposición), en cuyo caso dicho empate se resuelve mediante el uso de la clasificación de máxima verosimilitud completa.

En el proceso de formación del algoritmo se requiere de una supervisión por grupos de píxeles de localización (polígonos) que deben ser ejemplos representativos de cada tipo de cobertura de la tierra para ser calificadas. Las clases del sitio de entrenamiento son conocidas a priori de la verdad terreno. La computadora entonces "se entrena" a sí misma para reconocer cada cobertura de la tierra mediante el uso de los niveles de gris de los centros de formación para calcular firmas espectrales para cada cobertura de la tierra (Wang, 2002).

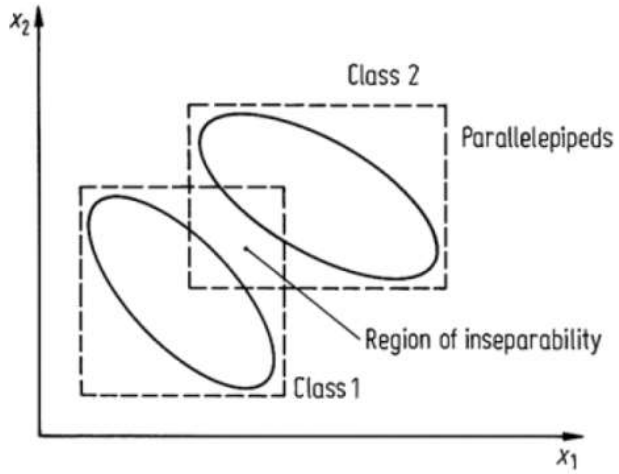


Figura 2. 3 Algoritmo de Paralelepípedo con Máxima Verosimilitud como criterio de desempate. Tomado de (Richards & Jia, 2006)

La **Figura 2. 3** representa gráficamente el procedimiento realizado por el algoritmo de clasificación supervisada, paralelepípedo utilizando el algoritmo de máxima verosimilitud como criterio de desempate.

2.1.6 FILTRO DE SUAVIZADO

Resulta bastante frecuente que los resultados de una clasificación digital adolezcan de una excesiva fragmentación. En otras palabras, las diversas categorías se imbrincan entre sí, en una compleja sucesión espacial. Manchas de color, más o menos homogéneas, se encuentran salpicadas por píxeles asignados a otras categorías, perdiéndose su unidad geográfica y dificultando la interpretación de los resultados. Este suceso se denomina coloquialmente, en la bibliografía anglosajona, "*efecto de sal y pimienta"* (salt and pepper), y se debe a una doble causa:

- Por un lado, a que la mayor parte de los criterios de asignación no tienen en cuenta la pertenencia de píxeles vecinos.
- Por otro, a la propia complejidad del paisaje, directamente relacionada con la aparición de píxeles de borde – fronterizos a dos o más categorías – que son los principales responsables de la discontinuidad visible en el mapa.

Para solventar este problema, suele aplicarse una técnica de suavización de resultados, similar en la concepción, aunque no en la ejecución, a los filtros de paso bajo. Sobre la imagen clasificada no puede aplicarse un filtro convencional, puesto que cualquier promedio de píxeles vecinos introduciría cambios imprevisibles en la clasificación. En otras palabras, no se trata de una imagen de tono continuo, sino de una imagen categorizada, en donde no tiene sentido establecer análisis de gradientes. Por esta razón, se aplican sobre la imagen esquemas de filtraje originales, basados sobre medidas categóricas en lugar de promedios.

El objetivo último es reasignar aquellos píxeles aislados o poco significativos, facilitando una distribución espacial más nítida de las distintas categorías. Para ello, se procede a comparar la clase asignada a cada pixel con la que ofrecen los píxeles vecinos. Si esa clase es similar a los píxeles del entorno, se mantiene la asignación original; caso contrario, se modifica. La técnica es independiente del tamaño de la ventana móvil que se utilice. En la terminología habitual se distinguen, a este respecto, dos tipos de filtro:

- Filtro Modal: en el cual, el pixel situado en el centro de la matriz se asigna a la categoría más frecuente entre los píxeles vecinos, siempre que, lógicamente, no pertenezca ya a ella.
- Filtro de Mayoría: el píxel central se asigna a la categoría que cuente con la mitad más uno de los píxeles vecinos. En caso de que ninguna categoría rebase ese valor, el píxel central mantiene su asignación primitiva.

La elección entre uno u otro método depende del tipo de paisaje analizado y del algoritmo que se haya empleado en la clasificación. Lógicamente, el primero ofrece una mayor generalización que el segundo, por lo que puede ser conveniente su empleo es caso de paisajes muy complejos y cuando la escala de trabajo sea media o pequeña.

Se ha comprobado por diversos autores, que la aplicación de esta técnica proporciona un aumento significativo de la exactitud conseguida en la clasificación. Este efecto es debido, principalmente, a la eliminación de asignaciones anómalas debidas a píxeles de borde (Chuvieco, 1996).

2.1.7 TEXTURA

El análisis de textura es un problema básico en el procesamiento de imágenes y despliegue visual en los computadores. Es un problema en aplicaciones de diferentes campos, como lo son, reconocimiento de objetos, teledetección y recuperación de imágenes basado en contenido. Incluso no hay una definición exacta para el término de textura (Backes, Casanova, & Bruno, 2013). Aunque a continuación se citan algunas de definiciones:

- La textura de una imagen es una cuantificación de la variación espacial de valores de tono que es imposible definirlo precisamente por su carácter sensorial. El uso de la textura de una imagen proviene de la habilidad innata de los humanos de reconocer diferencias texturales (Presutti, 2004).
- La textura es una característica espacial importante usada para identificar objetos o regiones de interés en una imagen (Haralick & Shanmugam, 1974).
- Textura es la propiedad que representa la superficie y estructura en una imagen. Generalmente, la textura se puede definir como una repetición regular de un elemento o patrón en una superficie (Srinivasan & Shobha, 2008).

Sin embargo, los tres enfoques principales usados en el procesamiento de imágenes para describir la textura de una región son los estadísticos, estructurales y espectrales (Gonzalez & Woods, 1993). El enfoque estadístico es el que más interesa en el presente proyecto:

- El estudio de la textura desde el punto de vista estadístico se centra en la distribución espacial de los niveles digitales. Éste enfoque se basa en la identificación de parámetros que cuantifican los patrones de variación que caracterizan a un grupo de píxeles y que describen la interdependencia, o co-ocurrencia, existente entre los mismos (Ciriza, González, Audícana, & Albiuza, 2012).
- Desde un enfoque estadístico, las imágenes de textura tienen un patrón gráfico complejo, en los cuales, diferentes estadísticas se pueden obtener para caracterizar dichos patrones (Chen, Nixon, & Thomas, 1995).

2.1.8 MATRÍZ DE CO-OCURRENCIA DE NIVELES DE GRISES

Describe la frecuencia de un nivel de gris que aparece en una relación espacial específica con otro valor de gris, dentro del área de una ventana determinada. La matriz de co-ocurrencia es un resumen de la forma en que los valores de los píxeles ocurren al lado de otro valor en una pequeña ventana. Normalmente el procedimiento de generación de imágenes de textura requiere que el analista defina cinco variables:

I. Tamaño de la ventana.
II. Banda espectral de entrada.
III. Las texturas derivadas.
IV. Cuantización (número de bits) del canal de salida.
V. La componente espacial (la distancia interpixel y el ángulo para el computo de la co-ocurrencia).

Respecto del tamaño de la ventana, ésta debe ser cuadrada y con número impar de píxeles. El resultado del cálculo de la textura es un único número que representa la ventana completa, el cual es colocado en el lugar del pixel central. Luego, la ventana se mueve un pixel y el cálculo se repite calculando una nueva matriz de co-ocurrencia para esta nueva ventana y resultando un nuevo valor, para el píxel central de esta nueva posición de la ventana. De éste modo se construye toda una nueva imagen con valores de texturas.

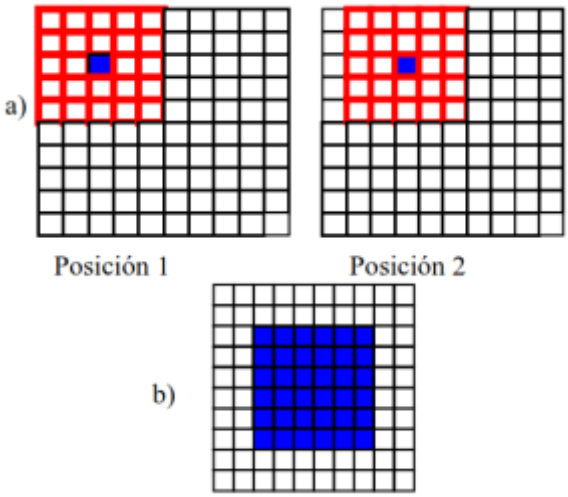


Figura 2. 4 *Ventana móvil para el cálculo de la matriz de co-ocurrencia. Tomado de (Presutti, 2004).*

En **a)** (**Figura 2. 4**) se muestra sobre una imagen de dimensiones de 10 x 10 píxeles, una ventana móvil de 5 x 5 píxeles en dos posiciones y el pixel central que recibe el resultado. **b)** (**Figura 2. 4**) Muestra los píxeles que reciben el resultado y las 2 filas y las 2 columnas del borde de la imagen que reciben el valor de textura calculados en los vecinos cercanos.

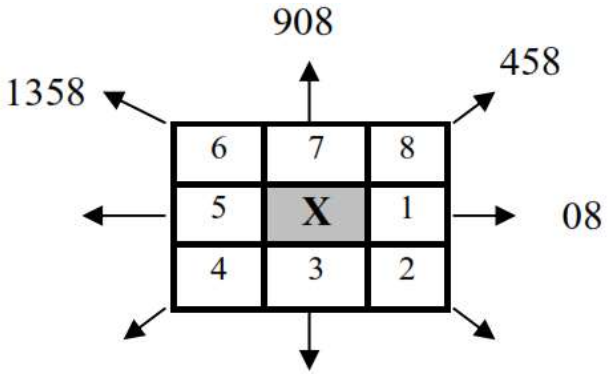


Figura 2. 5 Vecinos del pixel X de acuerdo al ángulo utilizado en el cálculo de la matriz de co-ocurrencia. Tomado de (Presutti, 2004).

La relación espacial entre el pixel de referencia y su vecino (**Figura 2. 5**) puede ser en cualquiera de las 8 direcciones (Norte, Sur, Este, Oeste y las 4 diagonales), pero solo se toman cuatro, ya que el Norte es opuesto al Sur y en vez de contarlas separadamente hay formas más sencillas de medirlas (matriz simétrica). Cuando se habla de una relación "espacialmente invariante" se eligen las cuatro direcciones Norte, Sur, Este, Oeste y se promedian. (Esto también se expresa respectivamente como 0°, 45°, 90° y 135°). (Presutti, 2004).

Adicionalmente a la distribución de las ocurrencias entre píxeles vecinos y de referencia se puede tener una aproximación a la magnitud en diferencia entre Números Digitales con una coocurrencia mayor a cero GLDV (Gray Level Difference Vector). De esta forma cabe esperar que coberturas vegetales cuya reflectividad sea muy homogénea (textura lisa) presente números digitales muy similares o iguales, es decir con valores GLCM altos, mientras que los valores GLDV serán bajos. Por el contrario GLCM bajo y GLDV alto indicaría una textura rugosa. Otro parámetro importante es el tamaño de la ventana para el cálculo dado que ventanas muy grandes podrían incluir píxeles que no fueran representativos de las parcelas y ventanas muy pequeñas excluiría la variabilidad de las mismas (Anaya, Duque, & Valencia, 2006).

Todas estas variables podrían generar muchos datos. Asumiendo que se usan 7 medidas de texturas (aunque pueden ser mas), 6 bandas espectrales (a menudo mas), tamaños de ventanas que varían entre 3x3 y 21x21, 3 niveles de cuantización del canal de salida (8, 16 y 32 bits) y 4 direcciones posibles (componente espacial), el resultado podrían ser más de 5000 imágenes de textura para una sola aplicación. Esto sobrepasa a los más sofisticados clasificadores (Presutti, 2004).

2.1.9 PARÁMETROS DE HARALICK

(Haralick, 1973), definió 14 características inherentes al análisis de la textura, entre ellas la entropía, la variancia, la correlación y el contraste. Cada una de estas características varía de acuerdo al tipo de imagen en función del dominio espectral, la resolución espacial y las características del objeto en estudio (dimensión, forma y distribución espacial) (Anaya, Duque, & Valencia, 2006).

A continuación se enlistan 13 medidas de textura que propuso (Haralick, 1973), las cuales serán evaluadas en el presente proyecto:

N: Número de niveles de grises.
P: Matriz de co-ocurrencia de niveles de grises de N* N, simétrica normalizada.
V: Vector diferencial de niveles de grises de dimensión N, normalizado.
P(i,j): Matriz de co-ocurrencia normalizada.

$$\sum_{i=0}^{N-1}\sum_{j=0}^{N-1} P(i,j) = 1$$

Ecuación 2. 9 *Normalización de la matriz de co-ocurrencia.*

Medida	Ecuación	Medida	Ecuación
Homogeneidad	$\sum_{i=0}^{N-1}\sum_{j=0}^{N-1}\frac{P(i,j)}{1+(i-j)^2}$	Segundo Momento Angular	$\sum_{i=0}^{N-1}\sum_{j=0}^{N-1}P(i,j)^2$
Contraste	$\sum_{i=0}^{N-1}\sum_{j=0}^{N-1}P(i,j)*(i-j)^2$	Correlación	$\sum_{0}^{N-1}\sum_{j=0}^{N-1}\frac{P(i,j)*(i-media\ i)*(j-media\ j)}{\sqrt{(variancia\ i*variancia\ j)}}$
Disimilitud	$\sum_{i=0}^{N-1}\sum_{j=0}^{N-1}P(i,j)*\ \lvert i-j\rvert$	Segundo Momento Angular VDNG	$\sum_{k=0}^{N-1}V(k)^2$
Media	$\sum_{i=0}^{N-1}\sum_{j=0}^{N-1}P(i,j)*\ i$	Entropía VDNG	$\sum_{k=0}^{N-1}-V(k)*\log V(k)$
Desviación estándar	$\sqrt{\sum_{i=0}^{N-1}\sum_{j=0}^{N-1}P(i,j)*(i-media\ i)^2}$	Media VDNG	$\sum_{k=0}^{N-1}V(k)*k$
Entropía	$\sum_{i=0}^{N-1}\sum_{j=0}^{N-1}-P(i,j)*\log\ P(i,j)$	Contraste VDNG	$\sum_{k=0}^{N-1}V(k)*k^2$
Diferencia Inversa (Para *i* diferente de *j*)	$\sum_{i=0}^{N-1}\sum_{j=0}^{N-1}\frac{P(i,j)}{\lvert i-j\rvert^2}$	VDGN	Vector Diferencial de Niveles de Grises

Tabla 2. 2 Medidas de textura propuestas por (Haralick & Shanmugam, 1974) (Haralick, 1973).

Siendo ***P i,j*** la probabilidad de co-ocurrencia de los valores de gris ***i*** y ***j***, para una distancia dada.

2.1.10 INTERPOLACIÓN

Es la estimación del valor de una función discreta de una posición desconocida, basado en los valores conocidos que se encuentran alrededor. A través de éste proceso se puede construir en cualquier punto arbitrario (Mikós, 2007).

Es el proceso de estimación de los valores intermedios de un evento continuo de muestras discretas. Se utiliza ampliamente en el procesamiento digital de imágenes para ampliar o reducir imágenes y corregir las distorsiones espaciales (Keys, 1981).

2.1.10.1 CONVOLUCIÓN CÚBICA

Aplica una función bicúbica para promediar el valor de salida a partir de los 16 (4x4) píxeles más próximos. Equivale a aplicar, en primer lugar, cuatro interpolaciones unidimensionales horizontales entre cuatro píxeles (dos a un lado y dos a otro) y posteriormente otra interpolación unidimensional, en este caso vertical, entre los cuatro valores obtenidos anteriormente (Hermosilla, Bermejo, Balaguer, & Ruiz, 2006).

La interpolación por convolución cúbica utiliza los dieciséis píxeles circundantes, de la ventana de 4x4. Los polinomios cúbicos están equipados a lo largo de las cuatro líneas y cuatro píxeles que rodean el punto central de la imagen, como se representa en la **Figura 2.6** para formar cuatro interpolantes. Un quinto polinomio cúbico se ajusta entonces a través de estos para sintetizar un valor de brillo para la ubicación correspondiente en la cuadrícula de pantalla.

La forma real del polinomio que se utiliza para la interpolación se deriva de las consideraciones de la teoría del muestreo y las cuestiones relacionadas con la construcción de una función continua (es decir, interpolación) a partir de un conjunto de muestras. Un excelente tratamiento del problema ha sido dado por Shlien (1979), quien analiza varios polinomios cúbicos posibles que podrían ser utilizados para el proceso de interpolación y que también demuestra que la interpolación es una operación de convolución. Sobre la base de la elección de un polinomio adecuado (atribuible a Simon (1975)) el algoritmo que se utiliza para realizar la interpolación es la convolución cúbica (Moik, 1980):

$$\begin{aligned}\emptyset(i,j+1+j') = j'\{j'(j'[\emptyset(i,j+3)-\emptyset(i,j+2)+\emptyset(i,j+1)-\emptyset(i,j)] \\ +[\emptyset(i,j+2)-\emptyset(i,j+3)-2\emptyset(i,j+1)+2\emptyset(i,j)])+[\emptyset(i,j+2)-\emptyset(i,j)]\} \\ +\emptyset(i,j+1)\end{aligned}$$

Ecuación 2. 10 *Algoritmo interpolación por convolución cúbica.*

La interpolación por convolución cúbica o re-muestreo, rinde un producto de imagen que es generalmente suave en aspecto y que debe ser tratado para llegar al producto final que se utiliza a menudo en la fotointerpretación. Sin embargo, ya que da píxeles en la

cuadrícula de visualización, con brillos que son interpolados de los datos originales, no se recomienda seguir la clasificación ya que los nuevos valores de brillo pueden ser ligeramente diferentes a los valores de radiancia reales detectados por los sensores de los satélites (Richards & Jia, 2006)

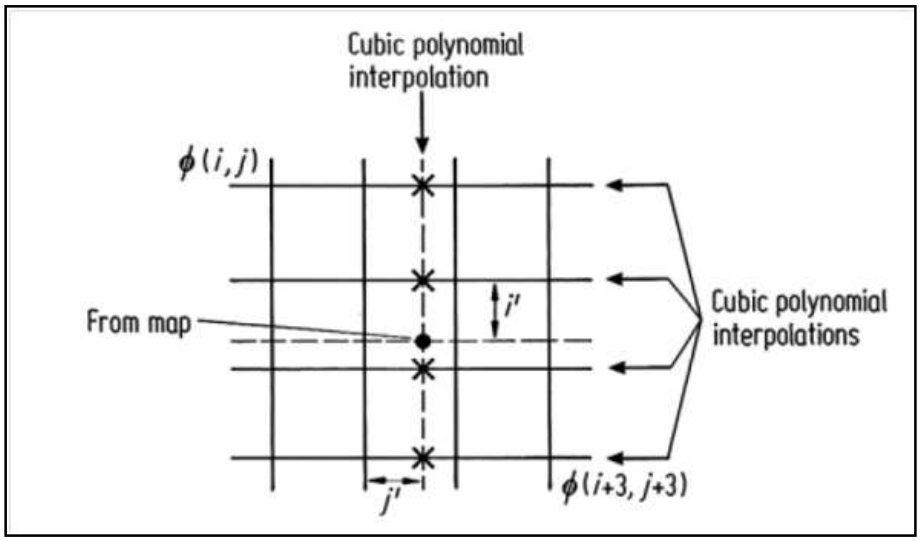


Figura 2. 6 *Interpolación por convolución cúbica. Tomado de (Richards & Jia, 2006).*

La **Figura 2. 6** representa gráficamente el procedimiento realizado por el método de convolución cúbica.

2.1.11 MODELO DIGITAL DE ELEVACIÓN

Un Modelo Digital de Elevación es un arreglo continuo de valores numéricos que corresponden con los valores estimados de elevación de puntos en la superficie del terreno. Se consideran valores estimados ya que los valores registrados en el modelo se obtienen generalmente a través de un proceso de interpolación o de medición indirecta. Los puntos del terreno representados en el modelo están espaciados y distribuidos de forma regular, de acuerdo con un patrón que corresponde a una retícula en la que sus lados son de la misma dimensión. (Díaz, 2006). En la **Figura 2. 7** se puede detallar una representación gráfica de un modelo digital de elevación.

El objetivo fundamental de un Modelo Digital de Elevación es representar una superficie con precisión, de manera que las elevaciones puedan estimarse para un lugar determinado. Es, por lo tanto, necesario disponer de algoritmos eficientes y precisos para el cálculo de elevaciones de la superficie entre puntos dados. (Kidnera, 2003)

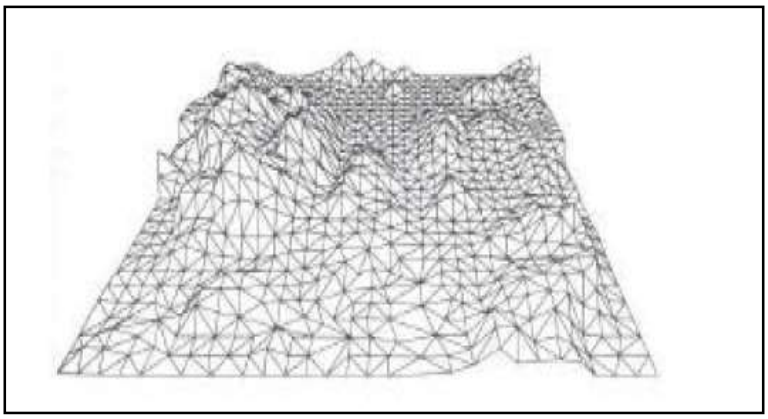


Figura 2. 7 Modelo Digital de Elevación. Tomado de (Priego & Porres, 2001).

Los Modelos Digitales de Elevación (MDE) se pueden interpolar a resoluciones más altas por medio de los métodos bilineal simple o convolución bicúbica con un enfoque adecuado. Se supone que el MDE se define como una rejilla cuadrada libre de error. Las mediciones de elevación óptima que se encuentran irregularmente distribuidas, deben ser re-muestreadas a una cuadrícula. La precisión alcanzable depende principalmente de la dimensión fractal de la superficie y las desviaciones estándar de la diferencia de altura entre los puntos de rejilla adyacentes en el MDE original. La precisión depende sólo ligeramente del factor por el que se aumenta la resolución del MDE, y es típicamente entre 0.2σ y 0.6σ (Rees W. G., 2000).

2.1.12 EXACTITUD TEMÁTICA

La evaluación de la exactitud es un término general para comparar la clasificación con información geográfica que se asume verdadera, con el fin de determinar la veracidad del proceso de clasificación, se calcula por medio de los siguientes estadísticos:

2.1.12.1 MATRIZ DE ERROR

Una matriz de error, es una matriz cuadrada de números que figuran en filas y columnas, expresa el número de unidades de muestra asignados a una categoría particular de una clasificación en relación con el número de unidades de muestra asignados a una categoría concreta en otra clasificación. En la mayoría de los casos, en las clasificaciones en las que se considera que los datos de referencia son correctos, éstos pueden ser generados a partir de una fotografía aérea, observación de tierra, o la medición en campo.

Las columnas suelen representar estos datos de referencia, mientras que las filas indican la clasificación generada a partir de los datos de teledetección (es decir, el mapa). Cabe señalar que los datos de referencia han sido a menudo referidos como los datos de "la verdad terreno"

Ahora, si bien es cierto que se supone que los datos de referencia son más aproximados a la realidad que el mapa que está siendo utilizado para evaluar, no es del todo cierto que estos datos son perfectos o representan "la verdad". Por lo tanto, el término "verdad terreno" es inadecuado y, en algunos casos, muy engañoso.

Una matriz de error es una forma muy efectiva para representar la exactitud de un mapa en el que las precisiones individuales de cada categoría están claramente descritos, junto con los dos errores de inclusión (errores de comisión) y los errores de exclusión (errores de omisión) presentes en la clasificación. Un error de comisión se define simplemente como un área que se incluye en una categoría cuando no pertenece a dicha categoría. Un error omisión está excluyendo una zona de la categoría a la que pertenece. Cada error es una omisión de la categoría correcta y una comisión a una categoría equivocada.

Supongamos que **n** muestras se distribuyen en las celdas **K**, aquí cada muestra se asigna a una de las categorías k en el mapa (por lo general las filas), y de forma independiente a una de las mismas categorías **k** en el conjunto de datos de referencia (por lo general las columnas). Donde **nij** denota el número de muestras clasificadas en la categoría **i** (**i = 1, 2, ..., k**) en el mapa y la categoría **j** (**j = 1, 2, ..., k**) en el conjunto de datos de referencia, como se representa en la **Figura 2. 8** (Congalton & Green, 2009).

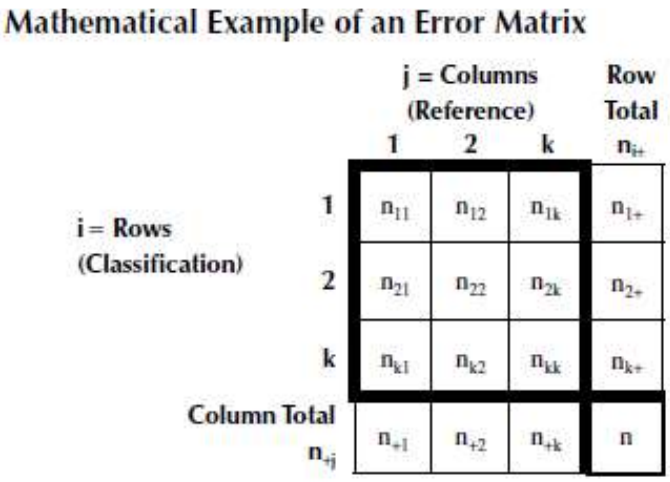


Figura 2. 8 Ejemplo matemático de la Matriz de Error. Tomado de (Congalton & Green, 2009).

2.1.12.2 PORCENTAJE DE CLASIFICACIÓN CORRECTA

Este índice, ampliamente usado en clasificación de imágenes, relaciona los elementos bien clasificados con respecto al total de puntos chequeados.

$$PCC = \frac{n\sum_{i=1}^{n} X_{ii}}{\sum_{i=1}^{n}\sum_{j=1}^{n} X_{ii}} * 100$$

***Ecuación 2. 11** Porcentaje de clasificación correcta.*

Donde n es el número de filas de la matriz, **Xii** es el número de observaciones en la fila **i** y la columna **j**, $\boldsymbol{x_{i+}}$, y $\boldsymbol{x_{+i}}$ son los totales marginales para la fila **i** y la columna **j**, respectivamente

El valor del índice de fiabilidad dará una idea general de la confianza que puede ofrecer la clasificación de las imágenes, si bien no aporta ningún dato sobre una de las clases.

Para obtener información de la fiabilidad de cada una de las categorías, es necesario realizar un análisis de los elementos marginales de la matriz de confusión (Perea, Meroño, & Aguilera, 2009).

2.1.12.3 EXACTITUD DEL USUARIO

Este valor expresa la ocurrencia de que el valor al que hace referencia una determinada clase de la imagen clasificada coincida con la realidad terreno. Es decir, si un usuario seleccionara en la imagen generada un determinado punto clasificado con un determinado valor, este índice nos determina la probabilidad de que realmente el punto seleccionado, tenga ese valor en la realidad.

Su cálculo para una determinada categoría, se realizará dividiendo el valor del acuerdo realidad clasificación de esa categoría (elemento de la diagonal principal), entre la suma de todos los valores de los elementos de la matriz clasificados en la realidad con esa categoría (Perea, Meroño, & Aguilera, 2009).

$$F_{u,i} = \frac{X_{ii}}{\sum_{i=1}^{n} X_{i+}} * 100$$

Ecuación 2. 12 *Exactitud del usuario.*

Donde n es el número de filas de la matriz, Xii es el número de observaciones en la fila **i** y la columna **j**, $\boldsymbol{x_{i+}}$, y $\boldsymbol{x_{+i}}$ son los totales marginales para la fila **i** y la columna **j**, respectivamente.

2.1.12.4 EXACTITUD DEL PRODUCTOR

Considerando una categoría de la clasificación, la exactitud del productor determina la probabilidad de que los valores del terreno clasificados con ese valor, queden incluidos en esa categoría. Su cálculo se realizará dividiendo el valor de acuerdo a la categoría considerada (elemento de la diagonal principal de la matriz de confusión), entre la suma de todos los valores de los elementos de la matriz clasificados en la realidad con ese valor (Perea, Meroño, & Aguilera, 2009).

$$F_{p,i} = \frac{X_{ii}}{\sum_{i=1}^{n} X_{i+}} * 100$$

Ecuación 2. 13 *Exactitud del productor.*

Donde **n** es el número de filas de la matriz, **Xii** es el número de observaciones en la fila **i** y la columna **j,** $\boldsymbol{x_{i+}}$, y $\boldsymbol{x_{+i}}$ son los totales marginales para la fila **i** y la columna **j**, respectivamente

2.1.12.5 ÍNDICE KAPPA

El análisis categórico multivariante permite analizar las múltiples relaciones entre las distintas categorías de la clasificación. Con este propósito se calcula el índice Kappa (k), que ofrece una visión del acuerdo entre la clasificación y la realidad, y el que cabría esperar simplemente por azar. Esto supone delimitar la bondad del ajuste de la clasificación, eliminando los efectos debido puramente al azar. Valores próximos a 1 representan un alto acuerdo entre la realidad y la imagen, mientras que valores próximos a 0 indicarán que el acierto entre la imagen clasificada y los valores de referencia son consecuencia única del azar. Si se consideran N puntos de control, el valor Kappa será calculado según la expresión (Perea, Meroño, & Aguilera, 2009):

$$K = \frac{N * \sum_{i=1}^{n} x_{ii} - \sum_{i=1}^{n} (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^{n} (x_{i+} * x_{+i})}$$

Ecuación 2. 14 *Índice Kappa.*

Donde n es el número de filas de la matriz, Xii es el número de observaciones en la fila **i** y la columna **j**, x_{i+}, y x_{+i} son los totales marginales para la fila **i** y la columna **j**, respectivamente.

2.1.13 ORTORECTIFICACIÓN

Debido a la geometría de mapeo del sistema de escaneo de trabajo, y teniendo en cuenta las propiedades de proyección central, los objetos elevados en una imagen muestran una

desalineación de distancia en el sensor. Éste efecto en las imágenes ópticas se ve influenciada por la altura de objeto y la distancia al eje NADIR del sensor.
La transformación necesaria (ortoproyección) depende de la escala de mapeo y se puede describir en tres etapas separadas. Para escenarios de pequeña escala, tienen que tenerse en cuenta la curvatura de la tierra y de las distorsiones de los sistemas nacionales de coordinación.

- En una primera etapa, la matriz de píxeles de la ortofoto se inicializa por un modelo digital de terreno (MDT).
- En un segundo paso, se realiza la transformación del punto del terreno en un sistema de coordenadas cartesianas tangencial. Esto tiene su punto cero en el centro de la escena en el elipsoide de la Tierra.
- En un tercer paso, para cada punto se calcula la transformación geométrica entre el sistema tangencial y la imagen de coordenadas, sabiendo la orientación interior y exterior de los sensores en el momento de adquisición de datos. El último paso incluye la transformación del valor de gris de la imagen del sistema de coordenadas a la coordenada correspondiente en la matriz de ortofotos. La ortofoto resultante de estos pasos de cálculo depende directamente de la calidad del modelo del sensor y la resolución del modelo de altura.

Los datos de imagen con el modelo de sensor conocido contienen los parámetros de la orientación interior y el exterior del sistema sensor, así como los datos de calibración radiométrica para cada elemento de pixel. Si la exactitud de los datos de orientación no tiene la precisión requerida, se lleva a cabo la medición de puntos de control terrestre (GCP). El número requerido de GCP depende de la precisión necesaria y el GCP se distribuirá uniformemente sobre la imagen.

Aparte de la influencia de los datos de orientación el resultado de ortorectificación, también depende de la calidad del modelo de altura.

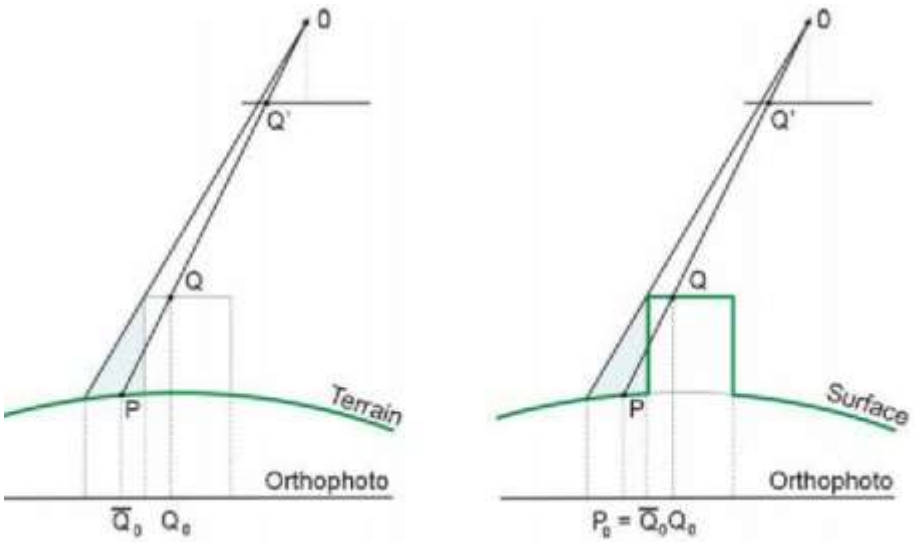


Figura 2. 9 Sin proceso de ortorectificación (izquierda) y con proceso de ortorectificación (derecha). Tomado de (Thiele, Schulz, Thoennessen, & Cadario, 2006).

En la **Figura 2. 9**, el edificio representado por el punto ***Q,*** se proyecta en un sistema coordenado en la imagen como el punto ***Q'***. Si el modelo de altura no contiene objetos elevados hechos por el hombre (**Figura 2. 9**, izquierda) el punto ***Q*** se transforma a la posición ***Q0***. De lo contrario el punto se proyecta en ***Q0,*** que corresponde a su geo-localización correcta (**Figura 2. 9**, derecha) (Thiele, Schulz, Thoennessen, & Cadario, 2006).

2.1.14 ERROR MEDIO CUADRÁTICO

El RMSE es un indicador muy empleado, ya que evalúa de modo conjunto la cuantía del sesgo (indicado por el error medio) como de la dispersión (indicado por la desviación típica de los errores) del error de posición en la imagen.

Resulta interesante resaltar que cuando el error medio tiende a cero el RMSE se aproxima a la desviación típica de los errores. Por lo tanto, bajo la hipótesis de que el error planimétrico de la imagen sigue una distribución normal, puede afirmarse que el RMSE corresponde aproximadamente al 68 % de probabilidad (el 68 % de los errores en la imagen tiene un valor inferior al **RMSE**). Manteniendo la hipótesis de normalidad es posible estimar los valores de error unidimensional (en ***x*** o ***y***) con un 90%, 95% y 99% de

probabilidad, multiplicando el valor de **RMSE** (en ***x*** o ***y***) por 1,65, 1,96 y 2,58 respectivamente. El error máximo absoluto (en ***x*** o ***y***) puede ser aproximado multiplicando el **RMSE** por 3,89 (correspondiente al 99,99% de probabilidad).

$$RMSE_x = \sqrt{\frac{\sum_{i=1}^{n} e_{Xi}^2}{n}}$$

Ecuación 2. 15 *Error medio cuadrático en X.*

$$RMSE_y = \sqrt{\frac{\sum_{i=1}^{n} e_{Yi}^2}{n}}$$

Ecuación 2. 16 *Error medio cuadrático en Y.*

Donde e_{Xi} y e_{Yi} representan la diferencia entre las coordenadas ***x*** e ***y*** reales y las tomadas de la imagen, y ***n*** representa el número de puntos de comprobación (Rico, Gil, González, & Sanmartín, 2006).

2.2 ESTADO DEL ARTE

A continuación se hace un recorrido por la bibliografía referente al análisis de texturas, donde se encontró que es un tema que tiene múltiples enfoques, los cuales se especifican por separado.

2.2.1 ANÁLISIS DE TEXTURA EN GENERAL

La textura en general, se define como la repetición de un patrón espacial básico, cuya estructura puede ser periódica, o parcialmente periódica (aleatoria). (La Serna, Contreras, & Ruiz, 2010) Según Chuvieco esta variable hace referencia a la heterogeneidad espacial

de una determinada cubierta, al contraste espacial entre los elementos que la componen. Visualmente se manifiesta como la rugosidad o suavidad de los tonos de gris. Cuanto más similares sean, la tonalidad será más homogénea en el interior de la cubierta y la textura será más lisa. Por el contrario, si existe una alta heterogeneidad en los niveles de gris de esa cubierta, aparecerá como muy rugosa, como textura grosera (Santamaría, 2014).

Además, la textura de una superficie hace referencia a la distribución de valores de intensidad a nivel espacial y por sus propiedades es fácil de evaluarla en: fineza, rugosidad, suavidad, granulación, aleatoriedad, etc.

Al no existir una definición estándar de textura, no existe una clasificación estándar de los métodos para análisis de textura, aquella que más se destaca es la que se basa en Métodos estadísticos.

En los métodos estadísticos, se distinguen los de primer y segundo orden. Los estadísticos de primer orden involucran píxeles simples, por ejemplo en un histograma normalizado de los niveles de gris de una imagen, se pueden considerar datos como la media, varianza, suavidad, sesgo, curtosis, correlación, energía o entropía para caracterizar una textura. Los estadísticos de segundo orden consideran propiedades de pares de píxeles, por ejemplo métodos de matrices de coocurrencia los cuales consideran características como energía, entropía, contraste, homogeneidad y correlación. (La Serna, Contreras, & Ruiz, 2010)

En 1995 (Panniggiani, 1995) en su trabajo denominado *"An investigation of the textural characteristics associated with gray level cooccurrence matrix statistical parameters"*, investigaron el significado estadístico de seis parámetros provenientes de la MCNG (Matriz de Co ocurrencia de Niveles de Gris), por medio de una evaluación teórica con el fin de mantener la independencia de la imagen de la de prueba. Los seis parámetros estadísticos elegidos fueron la energía, el contraste, la varianza, correlación, la entropía y el momento inverso de diferencia, que son considerados los más relevantes entre los 14 parámetros originalmente propuesto por Haralick en 1973. Los resultados muestran que entre los seis parámetros estadísticos de MCNG, cinco conjuntos diferentes pueden ser identificados, cada conjunto con un significado textural específico. El primer conjunto contiene a la energía y la entropía, mientras que los cuatro parámetros restantes pueden

considerarse como pertenecientes a cuatro grupos diferentes. Dos parámetros, la energía y el contraste, se consideran los más eficientes para discriminar diferentes patrones de textura. Y como aporte final, usaron la recursividad, otro parámetro de la MCNG con el fin de reemplazar la energía que presenta algún grado de correlación con el contraste.

En el año 2007, (Ortiz, 2007) en su trabajo denominado "*Caracterización de café cereza empleando técnicas de visión artificial"*, utilizaron características de textura obteniendo descripciones de la suavidad, rugosidad y regularidad de una región, mediante el método de extracción de características de textura por medio del análisis estadístico, en otras palabras la Matriz de Co-ocurrencia de Niveles de Gris. La matriz de coocurrencia permitió obtener información de la distribución de las intensidades de los píxeles dentro de la imagen y sus relaciones con el vecindario. Explican que en el proceso de maduración del café existen etapas donde un color se presenta de manera homogénea sobre toda la epidermis, mientras que en otras etapas hay una variación suave o brusca de diferentes colores. Las características de textura aplicadas a las imágenes de café fueron enfocadas en el análisis de la suavidad, en la distribución de la intensidad de los colores para todas las etapas, así como en el análisis de la rugosidad para las etapas finales cuando los frutos están demasiado maduros o secos. Con base en la matriz de coocurrencia obtuvieron los descriptores de textura. Extrajeron 11 descriptores: Entropía, Uniformidad, Contraste, Correlación, Momento de diferencia de orden k, Momento inverso de diferencia de orden k, Máxima probabilidad, Homogeneidad local, Varianza, Directividad y Tendencia de Clúster. Evaluaron estas características en cada una de las componentes R, G y B, de la imagen obteniendo así 33 características.

Tres años después (2010), (La Serna, Contreras, & Ruiz, 2010) publicaron su artículo denominado "*Procesamiento digital de textura: técnicas utilizadas en aplicaciones actuales de CBIR"*, donde presentan una revisión bibliográfica de los principales métodos y técnicas de la característica visual de textura para procesamiento digital de imágenes, en donde además, analizan aspectos como por ejemplo, que en una textura formada por la repetición periódica de un patrón, la repetición es regular o estructurada, como lo es el caso de una pared de ladrillos y en el caso de textura formada por la repetición parcialmente periódica, el patrón se presenta de manera irregular o aleatoria, como por ejemplo los tejidos de los intestinos humanos. Otro aspecto destacable que resaltan en el artículo es que a la textura la caracteriza su invarianza a los desplazamientos, debido a

que siempre se repite cierto patrón a lo largo de una superficie, de esta manera la percepción visual es prácticamente independiente de la posición.

2.2.2 ANÁLISIS DE TEXTURA EN OTROS CAMPOS

El uso de análisis de texturas en imágenes no es exclusivo de la teledetección, en el área de la imagenología médica, la segmentación es necesaria para el estudio anatómico de órganos, la asistencia en cirugías y para el estudio del comportamiento de lesiones o enfermedades, entre otras aplicaciones. En particular, la ausencia de contraste suele afectar notoriamente los resultados de los enfoques basados en intensidades. Para resolver esta problemática se han propuesto numerosas alternativas, algunas de las cuales se basan en la combinación de las intensidades en distintas modalidades de una misma imagen o la utilización de información de texturas. (Manterola, 2003).

En 2009 (Ríos-Díaz, Martínez-Payá, & Aledo, 2009) en el estudio "*El análisis textural mediante las matrices de co-ocurrencia (MCNG) sobre imagen ecográfica del tendón rotuliano es de utilidad para la detección cambios histológicos tras un entrenamiento con plataforma de vibración",* realizan especial énfasis en que la aplicación del análisis textural sobre una imagen ecográfica, es relativamente reciente. Citan a autores como Christodoulou y Mougiakakou, quienes trabajaron sobre imágenes ecográficas de la carótida con el objetivo de caracterizar la textura de las placas de ateroma y obtener información con la que entrenar a una red neural para la identificación automática. Y concluyen que distintos investigadores han conseguido mejoras en los diagnósticos mediante imagen ecográfica en tumores prostáticos, en tumores del pulmón, en tumores de endometrio, o en patología hepática, gracias a la aplicación del análisis de texturas.

Para 2013, (Manterola, 2003) presentaron el estudio "*Extracción de objetos en imágenes médicas tridimensionales basada en características texturales"*, donde proponen un algoritmo basado en texturas para la segmentación de imágenes médicas tridimensionales. En particular, utilizan indicadores de textura calculados a partir de estadísticas de segundo orden, conseguidas mediante matrices de coocurrencia de niveles de gris. El resultado obtenido consiste en un conjunto de mallas de superficie asociadas a los objetos de interés dentro de la imagen**.**

Y en 2014, (Aldana, Orozco, & Barreto, 2014) en su estudio "*Identificación de lesiones cerebrales de esclerosis múltiple en imágenes de resonancia magnética mediante análisis de textura"*, establecen que al ser uno de los métodos más prometedores, por su poder de discriminación en lesiones tempranas y su costo computacional, el análisis de texturas ha sido ampliamente aplicado en imágenes médicas; algunos ejemplos de ello son la segmentación de estructuras anatómicas, diagnostico de distrofia en musculo esquelético, diferenciación de tejido sano y patológico en el cerebro humano, clasificación de lesiones de cérvix, mediciones de textura en imágenes de ecocardiografía para diagnostico asistido de cardiomiopatías, clasificación de tejidos normales en imágenes tomográficas. Pero específicamente en Esclerosis Múltiple (EM), los trabajos están enfocados en la segmentación semiautomática, detección temprana de la enfermedad, detección y caracterización de lesiones utilizando algoritmos automáticos y análisis de texturas para tumores intracraneales, el propósito de este trabajo fue identificar cambios patológicos que indicaran lesiones de Esclerosis Múltiple en imágenes cerebrales de resonancia magnética, utilizando los métodos de Matriz de Co-ocurrencia y transformada wavelet para el análisis de textura.

2.2.3 ANÁLISIS DE TEXTURAS EN COLOMBIA

En Colombia, el campo de investigación en análisis de Texturas a pesar de ser un tema relativamente nuevo, ha venido tomando fuerza

La primera revisión data de 2005, con la publicación "*comparación de modelos de clasificación automática de patrones texturales de minerales presentes en los carbones colombianos"*, (Bedoya, 2005) donde se presentan algunos resultados obtenidos bajo diferentes modelos de clasificación de patrones texturales de minerales presentes en imágenes digitales. Por medio de matrices de coocurrencia, en este caso, seleccionaron 8 ángulos (0, 45, 90, 135 grados y sus respectivos ángulos opuestos) como resultado del desarrollo experimental, dado que los patrones texturales utilizados no presentaban una regularidad bien definida; por lo cual, necesitaron una cobertura completa del patrón textural (invarianza rotacional), aspecto brindado por la cantidad y dirección de los ángulos seleccionados. Inicialmente extrajeron 12 atributos texturales de cada patrón, los cuales fueron sometidos a un proceso de selección de los mejores atributos, por medio de

técnicas de minería, seleccionando contraste, entropía, disimilaridad, varianza y prominencia, además escogieron un tamaño para la imagen de la textura de 32 x 32 píxeles, motivado principalmente por el tamaño de los minerales en las imágenes (carbonato y pirita); dado que un tamaño superior incorporaría ruido, lo cual afectaría el comportamiento de los clasificadores ensayados.

En el año 2008, (Anaya, Duque, & Valencia, 2008), publicaron el estudio "A*nálisis de textura en imágenes de satélite en el ámbito de la biodiversidad y la estructura en un bosque de los andes colombianos"*, en el que evalúan la relación entre la textura calculada a partir de una imagen de satélite Ikonos con la diversidad y la estructura a lo largo de un corredor con 43 parcelas en los bosques andinos de nuestro país. Para ello, utilizaron índices de diversidad calculados en 43 parcelas y mapas detallados de Usos del Suelo que separan los bosques desde un punto de vista estructural. A partir de la imagen obtuvieron valores de textura utilizando Matrices de Co-ocurrencia de Niveles de Gris, GLCM (por sus siglas en Inglés, Gray Level Cooccurrence matrix) y GLDV (Grey Level Difference Vector).

Dos años después (2010), el estudio "D*etección de bordes utilizando la matriz de coocurrencia: aplicación a la segmentación de imágenes de frutos de café"*, publicado por (Betancur, Mora, & Viera, 2010), presentó un sistema de segmentación de imágenes de frutos de café basado en el análisis de las características de textura computadas de la matriz de coocurrencia. Se cuantificaron 121 indicadores de los cuales se seleccionaron aquellos con mayor discriminación entre dos clases posibles: 'Centro de Fruto' y 'Borde'. La segmentación utilizó la imagen de bordes, buscando en esta sus regiones arcoconexas. El sistema detector de bordes fue realizado con un clasificador bayesiano de cinco indicadores como entrada extraídos de un elemento estructural, lo que resultó en la partición de la imagen. La salida del clasificador es la pertenencia hacia una de las dos clases para una región de 4x4 (elemento estructural).

2.2.4 ANÁLISIS DE TEXTURAS EN TELEDETECCIÓN

Un análisis de contexto espacial considera a información contenida en la vecindad de cada pixel. En este análisis espacial resultan de interés las técnicas estadísticas de

análisis de texturas que proporcionan información sobre la distribución de los niveles de gris en relación a la vecindad de cada pixel mediante el cálculo de medidas estadísticas que describen características como variabilidad, homogeneidad, contraste, etc. Estas medidas permiten generar nuevas imágenes o bandas de textura que pueden utilizarse, solas o combinadas con las bandas espectrales, para clasificar la imagen. En 1991, Bähr describió la técnica de clasificación utilizando características espectrales y de textura. Sostuvo que la clasificación puramente espectral de una imagen produce errores de clasificación típicos especialmente en las zonas urbanizadas y que la aplicación adicional de características de textura conduce a mejoras evidentes. En 2013, Mhangara y Odindi, comprobaron que la utilización conjunta de la información textural obtenida por medio de las medidas propuestas por Haralick en 1973 y la información espectral contenida en fotografías aéreas ofrecen gran potencial en la clasificación temática del uso del suelo y cobertura urbana. (Santamaría, 2014)

Los primeros acercamientos respecto al análisis de características texturales los hicieron en *1973* (Haralick, 1973) en el trabajo *"Textural features for image classification".* Donde describen catorce parámetros texturales basados en la espacialización de los tonos de gris en una imagen, que posteriormente aplican a una imagen satelital ERTS-1[1], una fotografía aérea de escala 1:20.000 y un fotomicrógrafo. Una de las conclusiones relevantes del trabajo es que a partir de los resultados obtenidos, afirman que el método de análisis de texturas tiene una amplia aplicabilidad a los sistemas de clasificación de imágenes.

En el año 2001, (Ruíz, Acosta, Sarría, Porres, & Pardo, 2001) en "M*ejora de la eficiencia de la segmentación de imágenes por texturas mediante filtros de energía"*, utilizan un método complementario al análisis de texturas y es la aplicación de los filtros de energía. Trabajan sobre imágenes pancromáticas a una resolución espacial alta, donde además de aplicar algunos parámetros de Haralick, utilizan siete filtros de energía, obteniendo como resultado, una mejora en la segmentación y la reducción del efecto frontera entre grupos de textura o clases diferentes.

[1] Fue el primer satélite del programa Landsat, puesto en órbita en el año de 1972.

Para 2002, en el trabajo "*Integración de datos geoespaciales para la caracterización de la vegetación: una herramienta potencial para estimar las variaciones microclimáticas"* publicado por (Ruiz, Fdez.-Sarría, Pardo, Porres, & Recio, 2002), se expuso una metodología de integración de datos geoespaciales obtenidos a partir de diversas fuentes (fotografías aéreas pancromáticas, imágenes multiespectrales de satélite y modelos digitales de elevación), para la extracción de información cuantitativa relativa a las unidades del paisaje, con énfasis en la vegetación, y su posterior análisis para su clasificación en información cualitativa respecto al tipo, distribución y densidad de la vegetación de crecimiento espontáneo. La información cuantitativa se refiere a cada pixel y consiste en (1) índices de vegetación, obtenidos a partir de los datos multiespectrales, que informan acerca de la biomasa y del tipo de vegetación presente, (2) características de textura extraídas de las fotografías aéreas que describen su distribución espacial, y (3) descriptores espaciales del relieve y de la radiación solar que llega a cada punto, obtenidos a partir de los modelos digitales de elevación. Los resultados, fueron cotejados mediante trabajos de comprobación sobre el terreno, evaluando por separado y conjuntamente, y evidencian la utilidad de la metodología en la caracterización de unidades de vegetación a nivel local y en la mejora del cartografiado de las unidades del terreno mediante el análisis combinado de los datos. Como conclusión determinan que la metodología utilizada, que incluye el análisis de texturas, ofrece un evidente potencial en la localización y estimación de la variabilidad natural de la vegetación con vistas a la modelización de su posible impacto sobre aspectos de degradación del suelo, desertificación, o para cuantificar la intensidad de fenómenos climáticos extremos sobre ámbitos espaciales locales.

(Fdez. Sarría, 2003) En el trabajo "*Análisis de imágenes mediante texturas: aplicación a la clasificación de unidades de vegetación",* del año 2003, utilizan imágenes con una resolución espectral más alta que el trabajo del 2001(60 cm), trabajando en dos ámbitos geográficos distintos para discriminar los resultados de cada uno de estos. A diferencia de dicha publicación, se adiciona una comparación entre distintos métodos de clasificación, encontrando que el análisis de textura es una alternativa cuando las coberturas son heterogéneas espectralmente o cuando no se dispone de la información suficiente para aplicar los métodos convencionales. Sin embargo, señalan la debilidad del efecto frontera entre clases, que se da al aplicar el método de textura.

Para el mismo 2003, un estudio para clasificar las regiones urbanas y no urbanas en imágenes pancromáticas, denominado "U*rban and non urban area classification by texture characteristics and data fusion"* publicado por (Morales, Moctezuma, & Parmiggiani, 2003), presenta un procedimiento que tiene en cuenta la información parcial proporcionada por los estadísticos de las características texturales, luego, sobre la base de un algoritmo de fusión de datos, los datos de textura se fusionan y se obtiene un resultado de clasificación binario. El estudio implementa la Matriz de Coocurrencia de Niveles de Gris para evaluar los parámetros texturales aplicados a las imágenes de alta resolución que muestran una escena urbana de la Ciudad de México. Los resultados alcanzados mostraron que las características de la energía, correlación y sombra clúster sobresalen entre los 14 parámetros originalmente propuesto por Haralick ya que fueron los más relevantes para las escenas utilizadas. Como el algoritmo de matrices de co-ocurrencia requiere una gran cantidad de procesamiento de computación, proponen un nuevo enfoque que disminuye el tiempo de cálculo. Las imágenes que fueron inicialmente probadas con 256 niveles de gris se redujeron a 64. Por medio de un algoritmo de correlación óptima, los resultados de la textura relevantes en el proceso de fusión se redujeron a 2 niveles de gris. Los resultados obtenidos por este método muestran que se puede realizar una buena clasificación de las calles, bloques y regiones no urbanas. Los algoritmos de este trabajo se implementaron utilizando MATLAB.

En 2005, los autores (Sarría, Recio, & Ruiz, 2005), en un artículo titulado "C*lasificación de entornos forestales mediterráneos mediante técnicas de análisis de texturas",* realizan una labor similar su misma publicación del año 2003, con la diferencia de trabajar ambas técnicas (análisis de texturas y los métodos convencionales de clasificación) de forma conjunta, teniendo como resultado un incremento notable en la exactitud de clasificación.

Para el 2007, se realizó un estudio en el que se hizo un intento hacia la generación automática de mapas de la forma de relieve a partir de datos de sensores remotos ópticos, denominado **"**M*achine extraction of landforms from multispectral images using texture and neural methods"*, publicado por (Chowdhury, Deshmukh, & Goswami, 2007), el énfasis de este trabajo fue explorar el potencial de la Matriz de Coocurrencia de Niveles de Gris, extrayendo las estadísticas provenientes del análisis de textura y luego

computarla a partir de una base de datos bastante extensa, usando imágenes multiespectrales para la discriminación de relieve.

En 2009 en el trabajo *"Sub-classification of farmland in high resolution rs images based on textural and spectral features"*, publicado por (Lu, Tian, Qiu, Du, & Shi, 2009), se establece que las características texturales se adoptan para clasificar las tierras de cultivo en imágenes de alta resolución en el campo de la teledetección, cuando las características espectrales de la zona son similares. Sobre la base del análisis de las contribuciones a la clasificación causada por diferentes características texturales, propusieron el método de clasificación con características texturales ponderadas. Discuten el algoritmo de la sub-clasificación de tierras de cultivo en imágenes de alta resolución, utilizando para tal fin la imagen de textura combinada Brodatz y una imagen remota de alta resolución. Los resultados muestran que este algoritmo es eficaz al mejorar la exactitud de la clasificación.

Tres años después (2012), en el artículo "*Potencial of texture-based classification in urban landscapes using multispectral aerial potos",* (Odindi, 2012) realiza estudios de textura en zonas urbanas con imágenes ÁSTER y AVHRR, que a su vez, compara y valida con aerofotografías digitales, teniendo como conclusión inicial, que el uso de texturas de Haralick y los métodos de análisis espectral, trabajados de forma conjunta, aumentan de manera positiva el resultado en las clasificaciones, al igual que lo afirmaron (Fernandez, Recio, & Sarrìa, 2005). Pero aclara, que en la aplicación individual de estos métodos, el análisis de texturas es más eficiente.

Para ese mismo año, (Ursani, Kpalma, Lelong, & Ronsin, 2012) propone un nuevo procedimiento para la asignación de uso de la tierra agrícola que presenta una debilidad conocida de los métodos clásicos basados en la respuesta espectral del píxel en situaciones de cultivos mixtos, denominado *"Fusion of textural and spectral information for tree crop and other agricultural cover mapping with very-high resolution satellite images",* donde utilizan un par de imágenes pancromáticas y multiespectrales de muy alta resolución e integran los resultados de la clasificación de dos análisis paralelos e independientes, respectivamente, sobre la base de la información espectral y textural. La imagen multiespectral fue dividida en segmentos espectralmente homogéneos, pero no

contiguos, utilizando clasificación no supervisada. En paralelo, la imagen pancromática se dividió en una cuadrícula de bloques cuadrados en los que se lleva a cabo una clasificación supervisada impulsada por texturas. Por último, las clasificaciones espectral y de textura se fusionan para generar el mapa de uso del suelo. Este método fue contrastado con los métodos basados en objetos que realizan secuencialmente segmentación de imágenes y clasificación. Los resultados fueron evaluados tanto cuantitativa como cualitativamente, en base a los datos la verdad-terreno de la encuesta de campo. La evaluación cuantitativa se presenta en términos de precisión global (de 80% a 100% dependiendo de la zona) y los coeficientes kappa. Se realiza la comparación visual del mapa resultante con la realidad sobre el terreno, con el análisis de los mapas de error binarios. La fusión de las clasificaciones espectrales y texturales se traduce en la delimitación fronteriza más fina y mejora la precisión de la clasificación general de uso de la tierra agrícola en un 27% con respecto a la clasificación textural solamente.

En el año 2014, (Santamaría, 2014), en la publicación *"Enfoque estadístico de análisis de textura: su aplicación a la clasificación de un ortofotomosaico del valle de inundación del arroyo Naposta Grande"* evaluaron la aplicación del enfoque estadístico de análisis de texturas a la clasificación de fotografías aéreas de escala grande. Basando el enfoque en el cálculo de medidas estadísticas que incorporan la relación espacial entre píxeles y permiten generar bandas de textura. En el estudio se utilizó un ortofotomosaico correspondiente al valle del arroyo Napostá Grande, en la ciudad de Bahía Blanca, Argentina. Realizaron la clasificación supervisada del ortofotomosaico utilizando tanto la información espectral como la información espacial proporcionada por las bandas de textura. Calcularon la matriz de correlación entre las distintas bandas para establecer la mejor combinación que optimizara la clasificación y evaluaron los resultados mediante las matrices de confusión. La metodología utilizada contribuyó a mejorar notablemente la clasificación del ortofotomosaico basada únicamente en la información espectral.

Y el más reciente artículo presentado, fue realizado por (Suruliandi, 2014), en Abril del 2014, titulado *"A textural approach for land cover classification of remotely sensed image"*, donde hizo uso de una imagen IRS P6 del sensor LISS-IV (Satélite Indio), proponiendo un modelo experimental multivariado (MDLTP, por sus siglas en inglés) para la clasificación de coberturas a partir de sensores remotos, obteniendo como resultado más del 90 % de exactitud en la clasificación final.

Teniendo en cuenta toda esta serie de trabajos, se concluye que el empleo del análisis y la caracterización de la textura, es una técnica con resultados sobresalientes respecto a los métodos convencionales de clasificación que se basan exclusivamente en la respuesta espectral y no aprovechan las ventajas de utilizar imágenes de alta resolución, donde ya el píxel deja de ser una cobertura y se convierte en componente de una, además de que ofrece la ventaja de aplicarlo de forma individual o combinada con las bandas de textura, lo que presupone una mejora en la exactitud de la clasificación. Aunque es un tema que se ha tratado desde hace más de 40 años, aún no se estipula una metodología general para la implementación de la técnica de análisis de textura en las diferentes aplicaciones en las que se utiliza, por ende se pueden presentar ciertas limitaciones al momento de recurrir a las texturas en algunos campos, debido a la falta de un criterio unificado, porque como fue presentado, el análisis de texturas es abordado por distintas metodologías o el uso de distintos parámetros, cambios de resolución en la imagen original y cambios en el tamaño de ventana a utiliza, por eso es importante tener un amplio repertorio de estudios de esta índole para poder determinar con mejores bases cuales son las características que mejor se adoptan al desarrollo del presente Trabajo de Grado.

3. DATOS Y MÉTODOS

En el presente apartado se describen todos los datos que fueron utilizados para llevar a cabo el proyecto. Así mismo, se muestra detalladamente los procesos a los cuales fueron sometidos dichos datos.

3.1 ÁREA DE ESTUDIO

Aquí se especifica las características generales del municipio objeto de estudio. La elección del área de estudio estuvo sujeta a la disponibilidad de datos, facilidad de ingreso a la zona, y lo más importante, que las características allí contenidas cumplieran con los requisitos necesarios para evaluar correctamente los objetivos propuestos.

3.1.1 UBICACIÓN

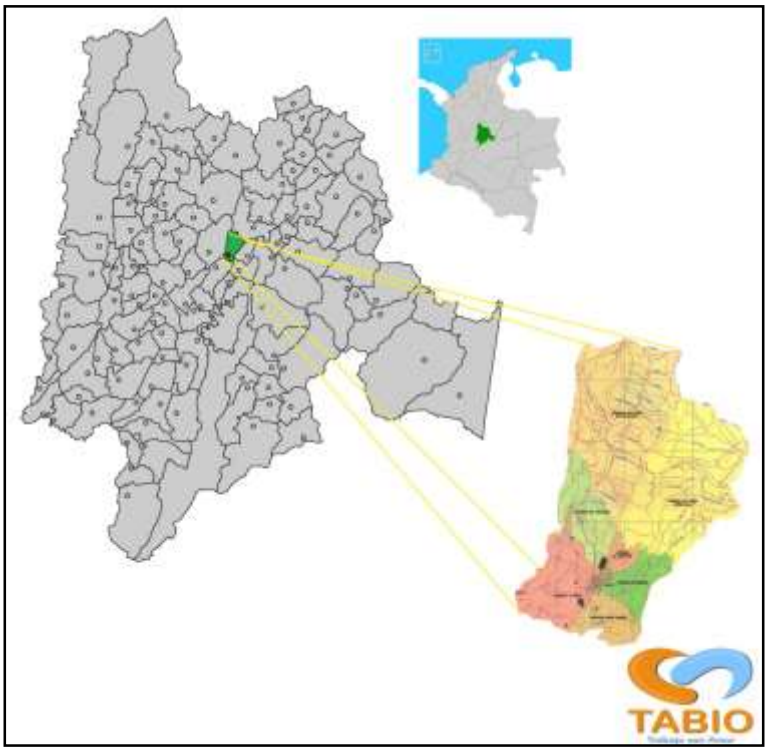


Figura 3. 1 Ubicación de Tabio en el Departamento de Cundinamarca (Camacho, 2008)

El municipio de Tabio se encuentra ubicado en el Departamento de Cundinamarca en la Provincia de Sabana Centro, a una distancia de Bogotá de 50 Kms; limita por el norte con Municipio de Zipaquirá, al oriente con el Municipio de Cajicá, al occidente con el Municipio de Subachoque y al sur con el Municipio de Tenjo como se puede apreciar en la **Figura 3. 1**. Su territorio forma un valle contorneado por ondulaciones suaves, que se recortan por el relieve montañoso de la Cordillera de los Monos, la Cuchilla Canica, la Peña de Juaica, El Cerro, La Costurera y el Monte Pincio. Con una altitud mínima de 2569 metros sobre el nivel del mar en el casco urbano y una máxima de 3200 metros sobre el nivel del mar en el sector de Llano Grande (Camacho, 2008).

3.1.2 EXTENSIÓN

El municipio de Tabio cuenta con una extensión de 7496 Hectáreas, de las cuales 51.8 hectáreas corresponden a el área urbana y 7442.2 corresponde al área rural (Camacho, 2008).

COORDENADAS		
ESQUINA	**X**	**Y**
Superior derecha	602725,5	548061,9
Superior izquierda	597208,8	548061,9
Inferior derecha	602725,5	542437,2
Inferior izquierda	597208,8	542437,2

Tabla 3. 1 Coordenadas de los límites de la zona de estudio.

En la **Tabla 3. 1** se encuentran las coordenadas de las esquinas que conforman el rectángulo imaginario del área de estudio. Las coordenadas se encuentran en el sistema de referencia Universal Transversal de Mercator, zona 18 Norte, con el elipsoide de referencia WGS 1984.

04° 57’ 28’’ N
74° 07’ 23.5’’ O

04° 57’ 27.7’’ N
74° 04’ 24.4’’ O



04° 54’ 24.8’’ N
74° 07’ 23.7’’ O

04° 54’ 24.6’’ N
74° 04’ 24.6’’ O

Figura 3. 2 Zona de Estudio

La zona de interés (**Figura 3. 2**) está comprendida entre límites urbanos y rurales del municipio de Tabio, la cual tiene una extensión total de 3103.60 hectáreas.

3.1.3 HIDROGRAFÍA

El territorio de Tabio pertenece parcialmente a la cuenca del Río Riofrío que nace en el páramo de guerrero al norte de Zipaquirá y es afluente del río Bogotá, durante su recorrido recibe diversos afluentes como las quebrada de pozo ondo, cussa, el hornillo, el alcaparro o yamontuza, entre otra y pertenece parcialmente también a la cuenca del Río Chicú, cuyos afluentes son las quebradas de Guandoque y Tince (Camacho, 2008).

3.1.4 CLIMA

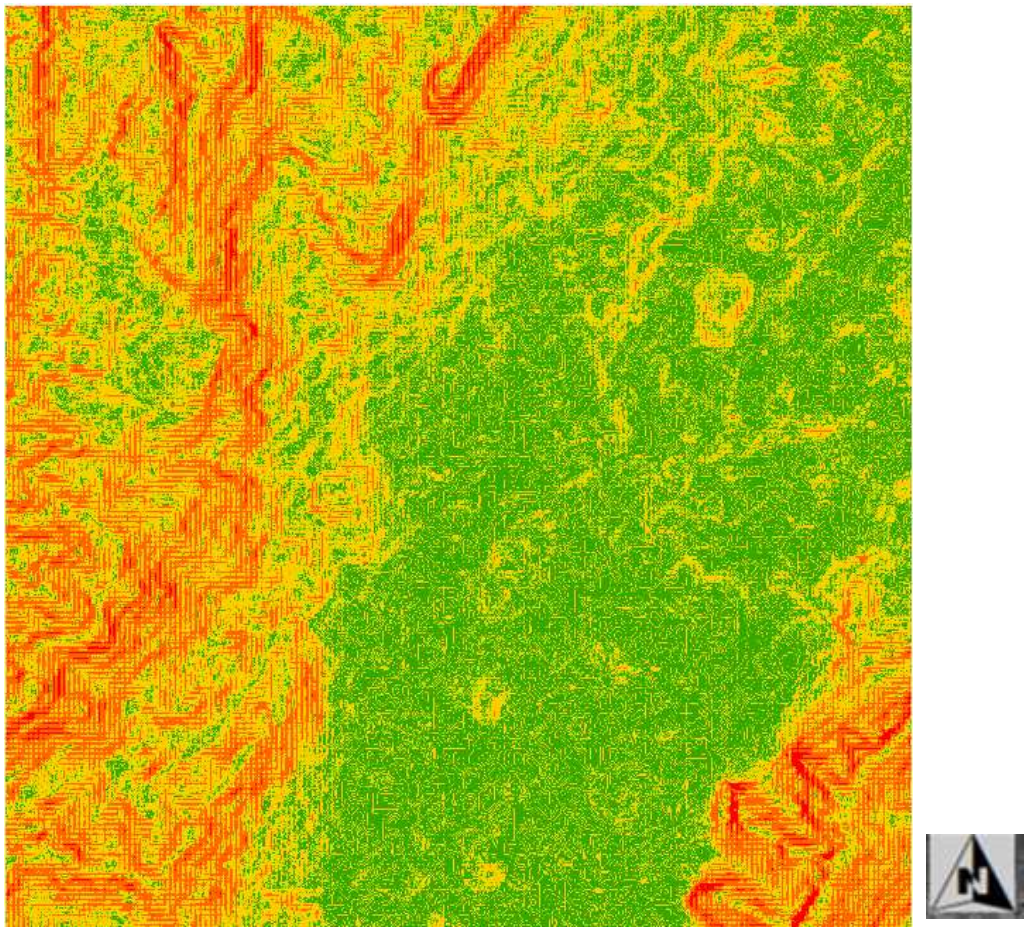
Por estar situado en la zona tórrida, la temperatura en Tabio, al igual que en toda Colombia, es principalmente dependiente de la altura y las estaciones son prácticamente inexistentes, por esto se tienen unas máximas y mínimas constantes a través del año con pequeñas variaciones en las etapas secas como Diciembre-Enero y Junio-Julio, cuando es más soleado y se pueden alcanzar al mediodía 23°, pero al haber poca nubosidad, por las noches y madrugadas se puede llegar a los 4°,en las etapas lluviosas la temperatura va de 10° mínima a 20° como máxima (Camacho, 2008).

3.1.5 TOPOGRAFÍA

Tabio como los municipios vecinos, hace parte de la frontera de la sabana, rodeado de montañas pertenecientes a la cordillera occidental, el accidente topográfico más importante es la montaña de Juaica, con una altura de 3.100 metros. Tabio está rodado por los montes de la cordillera de los monos, denominada así por el asentamiento de los colonos alemanes en la vereda de Río frío, el Alto de Canica, La Costurera, Montepincio, el Cerro de la Peña de Juaica, el páramo de Guerrero, los montes de Carron, los cerros de Agua Caliente, Llano Grande, montes del Tiquiza, montes de Lourdes, monte de Torobarroso y monte de Sabazynda (Camacho, 2008).

04° 57' 28" N *04° 57' 27.7" N*

74° 07' 23.5" O *74° 04' 24.4" O*



04° 54' 24.8" N *04° 54' 24.6" N*

74° 07' 23.7" O *74° 04' 24.6" O*

Figura 3. 3 *Topografía de la Zona de Estudio*

Categoría	Leyenda	Pendiente (%)	Área (Ha)	Porcentaje
Plano		0--3	1024,99	33,03%
Ligeramente Inclinado		3--7	232,91	7,50%
Moderadamente Inclinado		7--12	198,52	6,40%
Fuertemente Inclinado		12--25	1111,05	35,80%
Quebrado		25--50	506,65	16,32%
Empinado		50--76	29,49	0,95%
Total			3103,60	100,00%

Tabla 3. 2 *Leyenda y área de las categorías de pendiente presentes en la zona de estudio.*

En la **Figura 3. 3** se encuentran discriminadas gráficamente las diferentes categorías de pendientes que se encuentran en la zona de estudio. De igual forma, en la **Tabla 3. 2** están detalladas las áreas de cada una de estas categorías y la leyenda para interpretar correctamente la figura en mención. En el **Anexo I** se encuentra el mapa completo de la zona de estudio para su mejor visualización.

3.1.6 RECURSOS NATURALES

Los recursos naturales están constituidos por pasturas y zonas aptas para cultivos. En su suelo se cultivan transitoriamente la papa, el maíz, la arveja, la zanahoria. El principal cultivo de forma industrial es la floricultura. Otro recurso natural que posee gran atractivo turístico son las fuentes termales (Camacho, 2008).

3.1.7 ECONOMÍA

La economía del municipio es dependiente del mercado externo, con una vocación agrícola, especialmente en el área de la floricultura; la producción agrícola es casi exclusiva de los cultivos transitorios (papa, maíz, arveja y zanahoria) obligando a la importación de artículos de consumo cotidiano.

La estructura económica de Tabio tiene una baja participación industrial y muestra una mayor participación del sector primario, con mediana participación en el sector secundario y terciario (Camacho, 2008).

3.1.8 COMERCIO

La economía no se centra en actividades específicas, está relacionada con varias actividades, entre las cuales sobresale la floricultura (sin ser la base), lo que ha permitido el desarrollo de una gran diversidad de sectores. La actividad comercial se encuentra diferenciada en dos mercados objetivos, surgidos como respuesta a dos necesidades específicas que son: el comercio local, con oferta de productos y servicios dirigidos al consumo de sus habitantes, por lo general son negocios de carácter familiar y el otro, que

responde en gran parte a las características turísticas y culturales del municipio, como son los restaurantes especializados en comidas típicas que ofrecen gran variedad de postres y golosinas y las artesanías de gran importancia para los turistas (Camacho, 2008).

3.1.9 SECTOR AGROPECUARIO

La agricultura sigue siendo la actividad que más empleo genera; predomina el minifundio con las características de huerta casera, con cultivos de tubérculos, frutas flores y hortalizas. Los terrenos de mayor extensión se dedican al cultivo de cereales (Maíz, Arveja y Zanahoria) son abundantes pero no superan en cantidad al minifundio.

La actividad ganadera es mixta, leche y carne; a pesar de no ser un municipio ganadero ocupa un renglón de importancia.

La floricultura ocupa el segundo lugar en hectáreas cultivadas y económicamente ocupa el primer lugar en importancia dentro de las actividades agrícolas.

El primer lugar en hectáreas cultivadas lo ocupan los cultivos transitorios como la papa, la arveja y el maíz.

En la producción pecuaria se da el primer lugar de importancia a la población bovina, preferiblemente orientada a la producción de leche, con explotación en su mayoría con poca o mediana tecnificación.

En cuanto a cada área utilizada para cada subsector, esta se destina el 60% dedicada al sub sector pecuario y el 40% dedicada el subsector agrícola (Camacho, 2008).

3.1.10 MINERÍA

Este renglón tiene un aporte bajo en el desarrollo económico del municipio y los principales productos que explotan son: gravas, gravillas, arena de peña y piedra. Esta actividad genera graves impactos al medio ambiente y a los recursos naturales, como es el caso de las gravilleras donde es necesario hacer obras de adecuación, recuperación y reforestación de la capa vegetal y así mismo el recurso forestal nativo de estas áreas.

Es importante el análisis del perfil del empleo en el Municipio por cuanto la inasistencia de este se constituye en un factor de riesgo asociado con problemas de salud en la población

como también los bajos ingresos económicos que no permiten satisfacer las necesidades básicas. Un buen porcentaje de la población empleada está vinculada al sector informal de la economía, pero no existen estudios que permitan precisar está problemática (Camacho, 2008).

3.2 DATOS

Todos los datos que fueron base para generar los diferentes productos y resultados, para el desarrollo el proyecto, están enlistados y descritos detalladamente en el presente capítulo.

3.2.1 AEROGOTOGRAFÍAS DIGITALES

NOMBRE	CÓDIGO BNI[2]
22703004122009-0383C	401003000008216
22703004122009-0384C	401003000008217
22703004122009-0385C	401003000008218
22703004122009-0386C	401003000008219
22703004122009-0387C	401003000008220
22703004122009-0470C	401003000008461
22703004122009-0471C	401003000008463
22703004122009-0472C	401003000008465
22703004122009-0473C	401003000008467
22703004122009-0474C	401003000008467

Tabla 3. 3 Nombres y códigos de las aerofografías digitales solicitadas en el Banco Nacional de Imágenes[3].

En la **Tabla 3. 3** se encuentran los códigos con los cuales fueron solicitadas las imágenes la Instituto Geográfico Agustín Codazzi. Aerofotografías que fueron utilizadas para el desarrollo del proyecto.

[2] Banco Nacional de imágenes.

[3] El Banco Nacional de Imágenes es un conjunto de políticas, organizaciones, estándares y tecnologías que trabajan conjuntamente para producir, compartir y usar información geográfica y satelital necesaria para colaborar en el desarrollo del país (BNI, 2015).

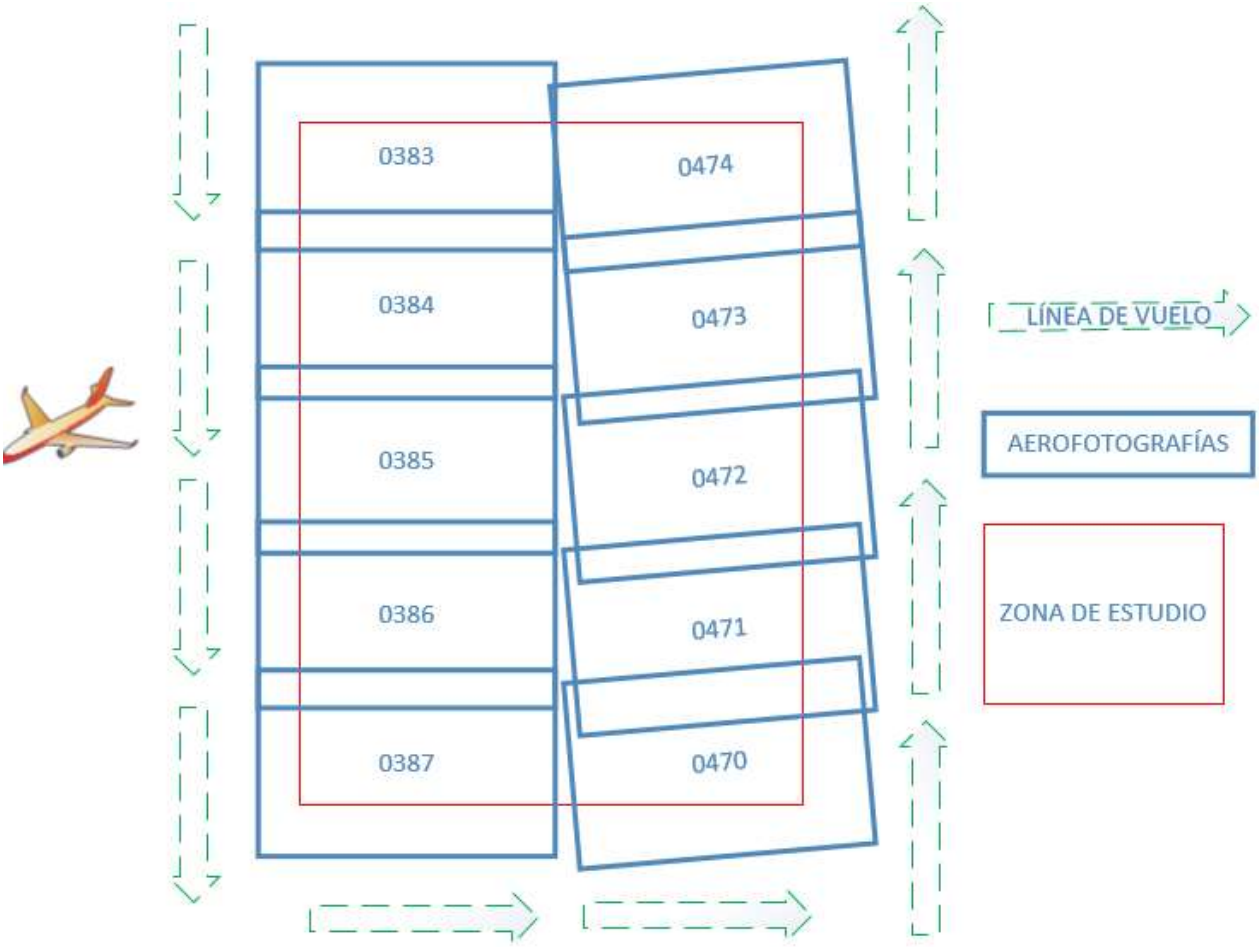


Figura 3. 4 Línea del vuelo 2270300412009.

La **Figura 3. 4** describe la línea de vuelo de toma de las fotografías aéreas utilizadas en el proyecto, la cual está compuesta por dos fajas.

Realizar el diseño de la línea de vuelo fue importante porque se debía conocer su ubicación respecto al norte geográfico para el posterior proceso de ortorectificación.

Bandas espectrales	Azul
	Verde
	Rojo
	Infrarrojo Cercano
Resolución espacial	0,3 metros
Resolución radiométrica	8 bits
Resolución espectral	**Figura 3. 5**
Fecha de toma	04/12/2009
Número de filas	11500
Número de columnas	7500
Distancia focal	105,2 mm
Apertura del lente	f= 1/1,40
Formato digital	TIFF
Nivel formato	3[4]
Campo de visión	55°

Tabla 3. 4 Características de las aerotofografías digitales.

En la **Tabla 3. 4** se encuentran las diferentes características de las imágenes digitales utilizadas.

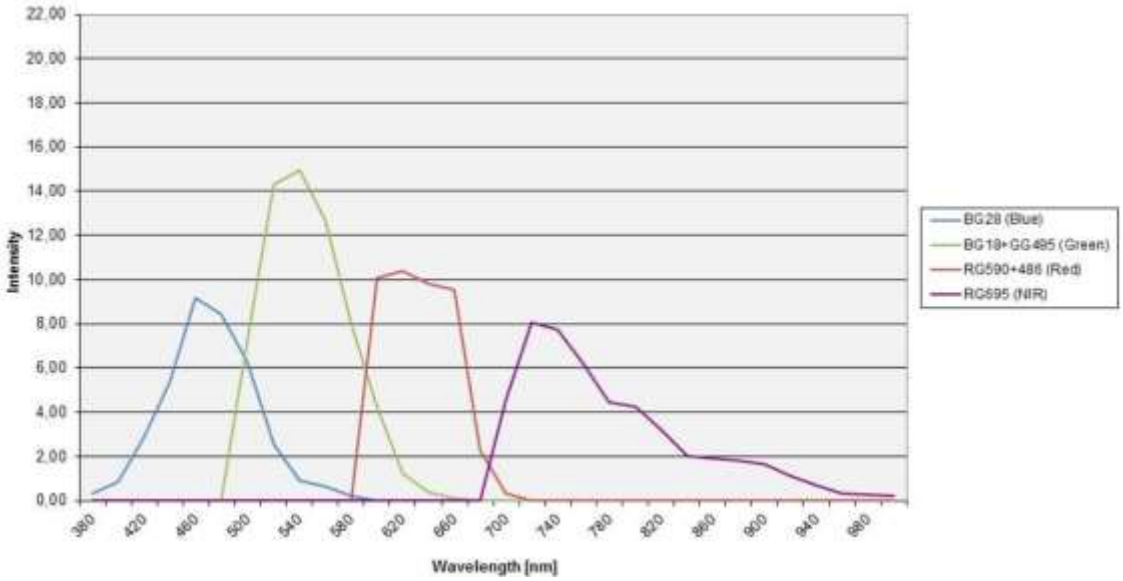


Figura 3. 5 Sensibilidad espectral de la Vexcel Ultracam D. Tomado de (USGS D. o., 2010).

[4] Imágenes con resolución total, que fueron sometidas al proceso de fusión con la banda pancromática.

La **Figura 3. 5** muestra la gráfica, longitud de onda contra intensidad, de las sensibilidades de cada una de las bandas espectrales de las imágenes digitales utilizadas, que se conoce como resolución radiométrica. Allí se encuentran cuatro curvas las cuales corresponden a cada una de las longitudes de onda capturadas por el sensor; cada color corresponde a la misma longitud de onda, es decir, la curva roja corresponde a la resolución radiométrica del espectro correspondiente al rojo, excepto en la curva de color morado, que corresponde al infrarrojo cercano.

3.2.2 MODELO DIGITAL DE ELEVACIÓN

Resolución	30 metros
Formato digital	TIFF
Tamaño	Franjas de 1°
Datum	WGS84 (Horizontal)
	EGM96 (Vertical)
Coordenadas	Geográficas
Fecha	11/02/2000

Tabla 3. 5 Características del modelo digital de elevación.

La **Tabla 3. 5** contiene todas las características del modelo digital de elevación utilizado en el proyecto, el cual fue descargado de *"earth explorer"*[5] (USGS, NGA, & NASA, 2000). Dicho modelo fue sometido a diferentes procesos que se explican de manera detallada a lo largo del documento.

[5] Es una de las diferentes plataformas destinadas a la descarga de diferentes productos, como imágenes digitales, modelos de elevación, imágenes de temperatura, entre otros.

3.3 MÉTODOS

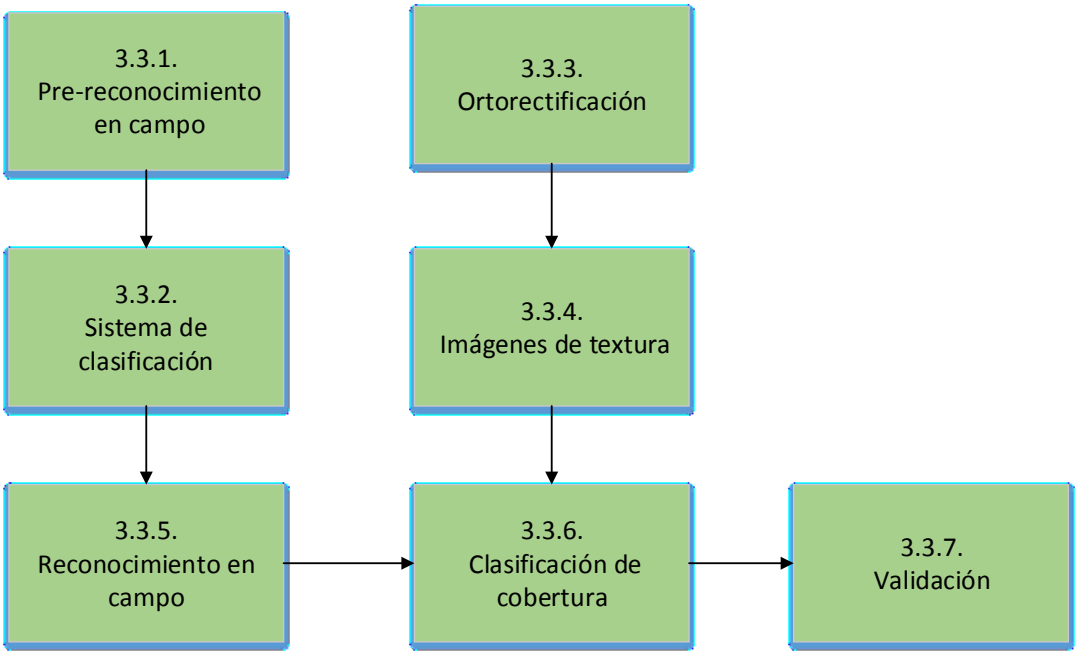


Figura 3. 6 Metodología general del proyecto.

La **Figura 3. 6** se encuentra la metodología general utilizada a lo largo de todo el proyecto. Sin embargo, algunos de los procedimientos vale la pena describirlos más a fondo, por ende, se enfatizan con su respectiva sub-metodología, a medida que se explica cada uno de ellos, si así se consideró necesario.

3.3.1 PRE-RECONOCIMIENTO

Antes de dar inicio al proyecto, se llevó a cabo una visita a campo para estar familiarizado con la zona de estudio, detectar las coberturas existentes, establecer los límites de la zona de interés y tomar un registro fotográfico. Todo lo anterior, para realizar y reforzar procesos posteriores.

De la **Figura 3. 7** a la **Figura 3. 12** se pueden visualizar capturas gráficas generales de la zona de estudio, donde claramente se aprecian las coberturas presentes.



Figura 3. 7 Vista general de la zona de estudio, Zona con poca vegetación.



Figura 3. 8 Vista general de la zona de estudio, Pastizales y vía.



Figura 3. 9 *Vista general de la zona de estudio, Pastos y Bosque.*



Figura 3. 10 *Vista general de la zona de estudio, Invernaderos.*



Figura 3. 11 *Vista general de la zona de estudio, Zona urbana.*



Figura 3. 12 *Vista general de la zona de estudio.*

3.3.2 SISTEMA DE CLASIFICACIÓN

Nivel 1	Nivel 2	Imagen de referencia
1) TERRITORIOS ARTIFICIALIZADOS Comprende las áreas de las ciudades y las poblaciones y, aquellas áreas periféricas que están siendo incorporadas a las zonas urbanas mediante un proceso gradual de urbanización o de cambio del uso del suelo hacia fines comerciales, industriales, de servicios y recreativos	**1.1) ZONAS URBANIZADAS:** Las zonas urbanizadas incluyen los territorios cubiertos por infraestructura urbana y todos aquellos espacios verdes y redes de comunicación asociados con ellas, que configuran un tejido urbano.	
	1.2) ZONAS INDUSTRIALES O COMERCIALES Y REDES DE COMUNICACIÓN: Comprende los territorios cubiertos por infraestructura de uso exclusivamente comercial, industrial, de servicios y comunicaciones. Se incluyen tanto las instalaciones como las redes de comunicaciones que permiten el desarrollo de los procesos específicos de cada actividad.	
	1.3) ZONAS DE EXTRACCIÓN MINERA Y ESCOMBRERAS: Comprende las áreas donde se extraen o acumulan materiales asociados con actividades mineras, de construcción, producción industrial y vertimiento de residuos de diferente origen.	
	1.4) ZONAS VERDES ARTIFICIALIZADAS, NO AGRÍCOLAS: Comprende las zonas verdes localizadas en las áreas urbanas, sobre las cuales se desarrollan actividades comerciales, recreacionales, de conservación y amortiguación, donde los diferentes usos del suelo no requieren de infraestructura construida apreciable. En general, estas zonas verdes son áreas resultantes de procesos de planificación urbana o áreas que por los procesos de urbanización quedaron embebidas en el perímetro de la ciudad.	

Nivel 1	Nivel 2	Imagen de referencia
2) TERRITORIOS AGRÍCOLAS Son los terrenos dedicados principalmente a la producción de alimentos, fibras y otras materias primas industriales, ya sea que se encuentren con cultivos, con pastos, en rotación y en descanso o barbecho. Comprende las áreas dedicadas a cultivos permanentes, transitorios, áreas de pastos y las zonas agrícolas heterogéneas, en las cuales también se pueden dar usos pecuarios además de los agrícolas.	**2.1) CULTIVOS TRANSITORIOS:** Comprende las áreas ocupadas con cultivos cuyo ciclo vegetativo es menor a un año, llegando incluso a ser de sólo unos pocos meses, como por ejemplo los cereales (maíz, trigo, cebada y arroz), los tubérculos (papa y yuca), las oleaginosas (el ajonjolí y el algodón), la mayor parte de las hortalizas y algunas especies de flores a cielo abierto. Tienen como característica fundamental, que después de la cosecha es necesario volver a sembrar o plantar para seguir produciendo.	
	2.2) CULTIVOS PERMANENTES: Comprende los territorios dedicados a cultivos cuyo ciclo vegetativo es mayor a un año, produciendo varias cosechas sin necesidad de volverse a plantar; se incluyen en esta categoría los cultivos de herbáceas como caña de azúcar, caña panelera, plátano y banano; los cultivos arbustivos como café y cacao; y los cultivos arbóreos como palma africana y árboles frutales.	
	2.3) PASTOS: Comprende las tierras cubiertas con hierba densa de composición florística dominada principalmente por la familia Poaceae, dedicadas a pastoreo permanente por un período de dos o más años. Algunas de las categorías definidas pueden presentar anegamientos temporales o permanentes cuando están ubicadas en zonas bajas o en depresiones del terreno. Una característica de esta cobertura es que en un alto porcentaje su presencia se debe a la acción antrópica, referida especialmente a su plantación, con la introducción de especies no nativas principalmente, y en el manejo posterior que se le hace.	
	2.4) ÁREAS AGRÍCOLAS HETEROGÉNEAS: Son unidades que reúnen dos o más clases de coberturas agrícolas y naturales, dispuestas en un patrón intrincado de mosaicos geométricos que hace difícil su separación en coberturas individuales; los arreglos geométricos están relacionados con el tamaño reducido de los predios, las condiciones locales de los suelos, las prácticas de manejo utilizadas y las formas locales de tenencia de la tierra.	

Nivel 1	Nivel 2	Imagen de referencia
3) BOSQUES Y ÁREAS SEMI-NATURALES: Comprende un grupo de coberturas vegetales de tipo boscoso, arbustivo y herbáceo, desarrolladas sobre diferentes sustratos y pisos altitudinales que son el resultado de procesos climáticos; también por aquellos territorios constituidos por suelos desnudos y afloramientos rocosos y arenosos, resultantes de la ocurrencia de procesos naturales o inducidos de degradación. Para la leyenda de coberturas de la tierra de Colombia, en esta categoría se incluyen otras coberturas que son el resultado de un fuerte manejo antrópico, como son las plantaciones forestales y la vegetación secundaria o en transición.	**3.1) BOSQUES:** Comprende las áreas naturales o seminaturales, constituidas principalmente por elementos arbóreos de especies nativas o exóticas. Los árboles son plantas leñosas perennes con un solo tronco principal, que tiene una copa más o menos definida. De acuerdo con FAO (2001), esta cobertura comprende los bosques naturales y las plantaciones. Para la leyenda de coberturas de la tierra de Colombia, en esta categoría se incluyen otras formas biológicas naturales, tales como la palma y la guadua. Para efectos de clasificación de unidades de esta leyenda, los bosques son determinados por la presencia de árboles que deben alcanzar una altura del dosel superior a los cinco metros. Para su diferenciación los bosques fueron clasificados de acuerdo con tres criterios fisonómicos estructurales fácilmente observables en imágenes de sensores remotos como son la densidad y la altura, y un elemento interpretable del terreno que se puede inferir del sensor como es la condición de drenaje.	
	3.2) ÁREAS CON VEGETACIÓN HERBÁCEA Y/O ARBUSTIVA: Comprende un grupo de coberturas vegetales de tipo natural y producto de la sucesión natural, cuyo hábito de crecimiento es arbustivo y herbáceo, desarrolladas sobre diferentes sustratos y pisos altitudinales, con poca o ninguna intervención antrópica. Para la leyenda de CORINE Land Cover adaptada para Colombia, en esta clase se incluyen otros tipos de cobertura tales como las áreas cubiertas por vegetación principalmente arbustiva con dosel irregular y presencia de arbustos, palmas, enredaderas y vegetación de bajo porte.	
	3.3) ÁREAS ABIERTAS, SIN O CON POCA VEGETACIÓN: Comprende aquellos territorios en los cuales la cobertura vegetal no existe o es escasa, compuesta principalmente por suelos desnudos y quemados, así como por coberturas arenosas y afloramientos rocosos, algunos de los cuales pueden estar cubiertos por hielo y nieve.	

Nivel 1	Nivel 2	Imagen de referencia
4) ÁREAS HÚMEDAS: Comprende aquellas coberturas constituidas por terrenos anegadizos, que pueden ser temporalmente inundados y estar parcialmente cubiertos por vegetación acuática, localizados en los bordes marinos y al interior del continente	**4.1) ÁREAS HÚMEDAS CONTINENTALES:** Las áreas húmedas hacen referencia a los diferentes tipos de zonas inundables, pantanos y terrenos anegadizos en los cuales el nivel freático está a nivel del suelo en forma temporal o permanente.	
	4.2) ÁREAS HÚMEDAS COSTERAS: Sobre las zonas costeras se diferenciaron las zonas de pantanos litorales y las áreas que presentan procesos de inundación relacionados con la marea.	
Nivel 1	**Nivel 2**	**Imagen de referencia**
5) SUPERFICIES DE AGUA: Son los cuerpos y cauces de aguas permanentes, intermitentes y estacionales, localizados en el interior del continente y los que bordean o se encuentran adyacentes a la línea de costa continental, como los mares.	**5.1) AGUAS CONTINENTALES:** Son cuerpos de aguas permanentes, intermitentes y estacionales que comprenden lagos, lagunas, ciénagas, depósitos y estanques naturales o artificiales de agua dulce (no salina), embalses y cuerpos de agua en movimiento, como los ríos y canales.	
	5.2) AGUAS MARÍTIMAS: Esta cobertura comprende los cuerpos de agua natural salada y salobre asociada con mares u océanos que bordean el litoral.	

Tabla 3. 6 Sistema de clasificación Corine Land Cover nivel 1 y 2, adaptado para Colombia. Adaptado (IDEAM, 2010)

A partir de los datos recolectados en el pre-reconocimiento de campo (**capítulo 3.3.1**), se adoptó inicialmente el sistema de clasificación Corine Land Cover adaptado para Colombia escala 1:100.000 nivel 2 (IDEAM, 2010), el cual se puede visualizar en la **Tabla 3. 6**.

Identificador	Cobertura
1	Zonas Urbanizadas
2	Invernaderos
3	Zonas de extracción minera y escombrera
4	Cuerpos de agua
5	Pastos
6	Herbazales
7	Cultivos Transitorios
8	Bosques
9	Tierras sin o con poca vegetación.

Tabla 3. 7 Sistema de clasificación adaptado a la zona de estudio.

Sin embargo, luego de analizar dicho sistema de clasificación junto con las coberturas presentes en la zona de estudio, se decidió realizar una modificación y adoptar un nuevo sistema de clasificación (**Tabla 3. 7**). El cambió realizado, fue en su mayoría por las coberturas que no se encontraban presentes en la zona de estudio; la única adición fue la cobertura “Invernaderos”, ya que se consideró importante resaltarla en una sola clase por sus características espectrales y de textura.

Cobertura	RGB (321)	Pre-reconocimiento
Zonas Urbanizadas		
Invernaderos		
Zona de Extracción Minera y Escombrera		

Tabla 3. 8 *Coberturas: Zonas Urbanizadas, Invernaderos y Zonas de Extracción Minera y Escombrera, presentes en la zona de estudio en imagen multiespectral RGB (321) (Izquierda) y en el pre-reconocimiento de campo (derecha).*

Cobertura	RGB (321)	Pre-reconocimiento
Cuerpos de Agua		
Pastos		
Herbazales		

Tabla 3. 9 *Coberturas: Cuerpos de Agua, Pastos y Herbazales presentes en la zona de estudio en imagen multiespectral RGB (321) (Izquierda) y en el pre-reconocimiento de campo (derecha).*

Cobertura	RGB (321)	Pre-reconocimiento
Cultivos Transitorios		
Bosques		
Tierras sin o con poca vegetación		

Tabla 3. 10 *Coberturas: Cultivos Transitorios, Bosques y Tierra sin o con poca vegetación presentes en la zona de estudio en imagen multiespectral RGB (321) (Izquierda) y en el pre-reconocimiento de campo (derecha).*

De la **Tabla 3. 8** a la **Tabla 3. 10** se visualizan las coberturas presentes en la zona de estudio, tanto en las imágenes multiespectrales en combinación RGB (321), o combinación en color natural, como en la vista a campo en el pre-reconocimiento, según el sistema de clasificación adoptado para el proyecto (**Tabla 3. 7**).
Para una visualización completa de la zona de estudio en la imagen multiespectral RGB (321), se puede consultar el **Anexo A.**

3.3.3 ORTORECTIFICACIÓN

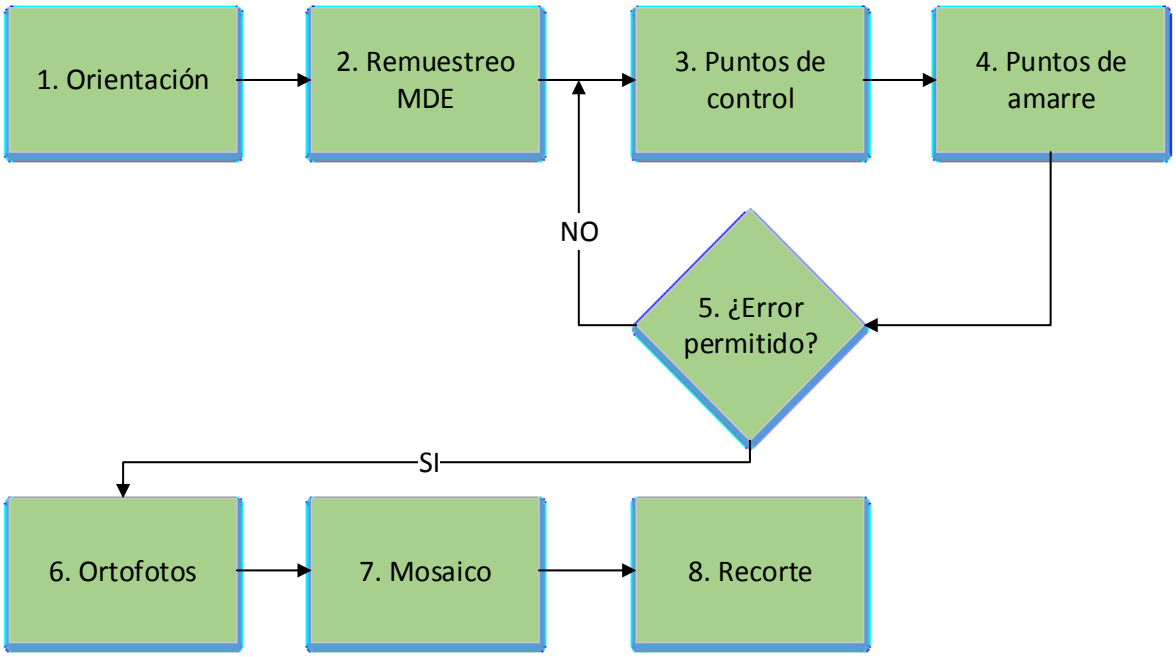


Figura 3. 13 Metodología del proceso de ortorectificación.

La **Figura 3. 13** muestra la metodología utilizada para obtener el mosaico de imágenes ortorectificado. Dichos procesos se detallan a continuación:

1. ORIENTACIÓN

Las imágenes originalmente no tenían ningún tipo de corrección ni procesamiento. Por ende, el primer paso para llevar a cabo la ortorectificación fue orientarlas con el Norte hacia arriba en cada una de ellas.

Como la zona de estudio comprende dos fajas (**Figura 3. 4**), algunas de éstas debían tener una rotación diferente. De la imagen 383 a la 387, correspondía 90 grados, y de la 470 a la 474, correspondía 270 grados en el sentido de las manecillas del reloj.

2. REMUESTREO MDE

El modelo digital de elevación originalmente se encontraba geo-referenciado. Pero por las características que presentaba (**Tabla 3. 5**), fue sometido a 3 procesos para que se ajustara correctamente a las necesidades de los procesos posteriores.

2.1 TRANSFORMACIÓN DE SISTEMA DE PROYECCIÓN

El sistema de proyección se transforma de coordenadas geográficas a Universal Transversal de Mercator. Todos los datos utilizados en el proyecto se transformaron al sistema de coordenadas mencionado, si era necesario, para que hubiera unicidad en el sistema de referencia geográfica, y así, poder trabajar con los datos conjuntamente, sin ningún problema. El proceso se realizó con el método de re-muestreo de convolución cúbica.

2.2 REMUESTREO

Como la resolución del modelo digital de elevación original es baja respecto a la resolución de las imágenes digitales, por efectos de precisión en la toma de puntos de control y de amarre se re-muestreó a una resolución de 2 metros, con el método de convolución cúbica.

Los modelos digitales de elevación pueden ser interpolados a mayores resoluciones con un re-muestro bilineal simple o convolución cúbica, generando resultados adecuados, teniendo en cuenta que el modelo digital de elevación se encuentra definido en una grilla cuadrada el cual está libre de error (Rees W. , 2000).

El proceso en mención genera un alto grado de confianza respecto a la precisión, ya que la zona de estudio no presenta cambios topográficos importantes cada 30 metros

(resolución original del Modelo Digital de Elevación). Por lo tanto, al realizar la interpolación, el resultado es muy cercano al real.

2.3 RECORTE

El archivo original abarcaba una gran extensión, por eso se realizó un corte que contuviera solamente la zona de estudio, ya que son los datos interés para el proyecto.

3. PUNTOS DE CONTROL

Para cada una de las imágenes se tomaron 12 puntos de control (120 en total por el grupo de imágenes), debidamente distribuidos, tomando como referencia los datos contenidos en Google Earth[6] (coordenadas de cada uno de los puntos). Dicha fuente se ajusta a las necesidades de los puntos de control, porque permiten obtener las coordenadas de un punto cualquiera, con buena exactitud para el presenten caso; éstas se encuentran en el sistema de referencia Universal Transversal de Mercator (también pueden ser visualizadas en coordenadas geográficas), con el elipsoide de referencia WGS 84.
Como valor de la altura de cada punto es un dato fundamental, por el proceso de ortorectificación, fue extraída del modelo digital de elevación.

Imagen	Error X	Error Y
383	2,53	1,91
384	2,89	3,10
385	3,85	1,80
386	4,71	3,19
387	3,73	2,30
470	2,12	1,43
471	3,57	1,56
472	2,33	1,91
473	5,09	2,29
474	3,56	2,00
Total	**3,42**	**2,13**

Tabla 3. 11 Error medio cuadrático de los puntos de control.

[6] Visualizador virtual del planeta en múltiples imágenes satelitales provenientes de diferentes sensores remotos.

En la **Tabla 3. 11** se muestran los errores medios cuadráticos, resultantes de la toma de puntos de control, tanto del total de las imágenes como de cada una de ellas. Los datos se encuentran en unidad pixel. Por lo tanto, el error medio cuadrático total en ***X*** equivale a 1.026 metros y en ***Y*** a 0.639 metros.

4. PUNTOS DE AMARRE

N. de Puntos	Error X	Error Y
41	1,59	1,50

Tabla 3. 12 Error medio cuadrático de los puntos de amarre.

Las imágenes hasta éste punto ya se encuentran geo-referenciadas, debido al proceso anterior. Los puntos de amarre se calcularon con un proceso automático, distribuidos entre todas las imágenes. Como se aprecia en la **Tabla 3. 12**, el error medio cuadrático en ***X*** equivale a 0.477 metros y en ***Y*** a 0.450 metros.

5. ¿ERROR PERMITIDO?

Ya que la idea es tener el menor error posible, luego de tomar los puntos de control y amarre, se rectificó el error medio cuadrático de cada uno de ellos, para volver a tomar dichos puntos o eliminarlos, de ser necesario. Y con esto, conseguir un error mínimo teniendo en cuenta la finalidad del proyecto y los datos disponibles.

6. ORTOFOTOS



Figura 3. 14 Imagen digital 383 Ortorectificada.

Ya se contaba con los datos necesarios para generar individualmente las imágenes ortorectificadas (**Figura 3. 14**). Para el proceso, se utilizó el método de convolución cubica, siempre respetando la resolución original de las imágenes.

7. MOSAICO



Figura 3. 15 Mosaico ortorectificado.

Teniendo las imágenes ortorectificadas, se realizó el mosaico de las mismas, como se aprecia en la **Figura 3. 15**.

8. RECORTE

Como el resultado final es una imagen con bordes irregulares (**Figura 3. 15**), por los ajustes de altura que el proceso de ortorectificación conlleva, se realizó un corte del perímetro para tener una imagen rectangular definida (**Figura 3. 2**).

3.3.4 IMÁGENES DE TEXTURA

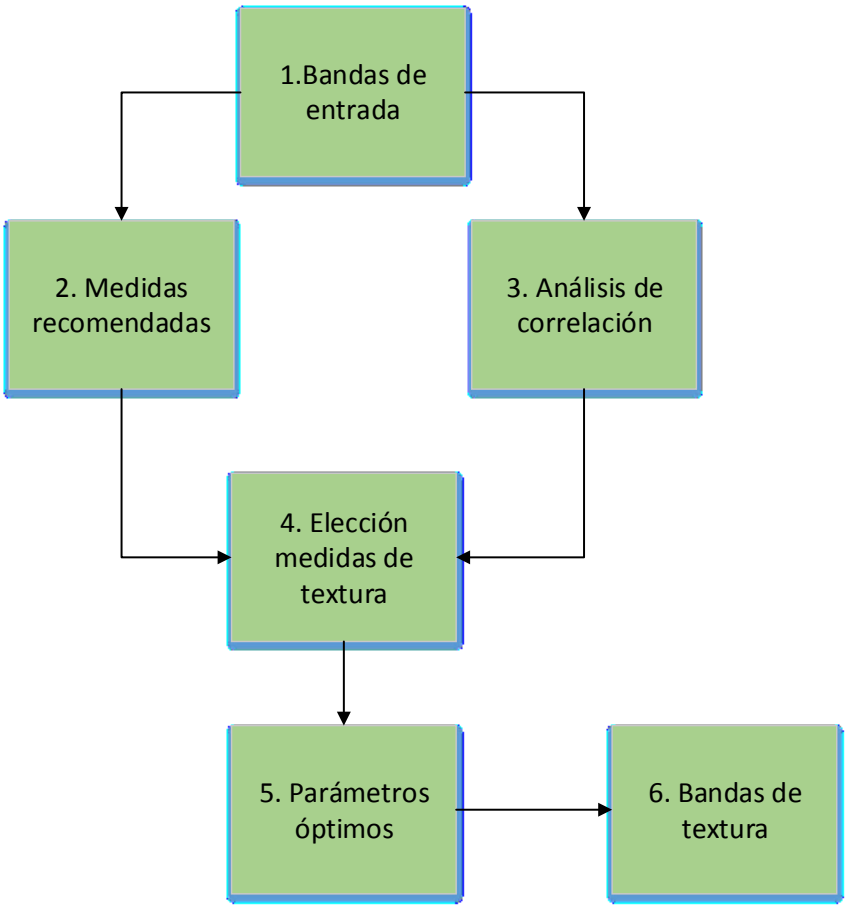


Figura 3. 16 *Metodología del proceso de creación de nuevas bandas de textura.*

La creación de las nuevas imágenes de textura, es de los procedimientos más importantes dentro del proyecto, porque es la técnica base para cumplir los objetivos propuestos; por ende, los resultados del presente apartado, afectaron directamente los resultados finales.

En la **Figura 3. 16** se encuentra el diagrama de procesos utilizado para la creación de las nuevas imágenes de textura. Como se describía anteriormente, hay múltiples combinaciones de los diferentes parámetros al momento de crear una imagen de textura; por esto se consultan las recomendaciones de diferentes autores para optimizar la creación de éstas bandas. Sin embargo, como el proyecto también tiene un enfoque experimental, se realizó análisis de correlación entre los diferentes parámetros y múltiples pruebas.

1. BANDAS ESPECTRALES

Con el fin de no aumentar el número de datos de entradas para el cálculo de texturas y evitar la redundancia de las 4 bandas espectrales, solo se hace uso de 2 para la elección de las medidas de textura. Dichas bandas fueron seleccionadas teniendo en cuenta la información que aporta cada una de ellas y la correlación existente.

	Banda Azul	**Banda Verde**	**Banda Roja**	**Banda NIR**
Banda Azul	1,00	0,96	0,94	0,51
Banda Verde	0,96	1,00	0,96	0,64
Banda Roja	0,94	0,96	1,00	0,56
Banda NIR	0,51	0,64	0,56	1,00

Tabla 3. 13 Matriz de correlación entre las bandas de la imagen multiespectral.

En la **Tabla 3. 13** se muestra la correlación existente entre cada una de las bandas. Se puede apreciar que la menor correlación se encuentra entre las bandas del azul y del infrarrojo cercano; de igual forma la correlación entra la banda del rojo y del infrarrojo es baja. Sin embargo, la banda más adecuada para realizar análisis de textura en vegetación, es el infrarrojo cercano alrededor de 0.83 micras (Asner, Bustamante, &

Townsend, 2003). Por lo anterior, las nuevas bandas de texturas fueron obtenidas a partir de la banda de infrarrojo cercano. Y por las características espectrales de la banda correspondiente al rojo, la banda de infrarrojo cercano y el rojo, fueron las seleccionadas para ser comparadas con las medidas de textura, y realizar la respectiva selección.

2. MEDIDAS RECOMENDADAS

Las medidas más usadas en orden de popularidad son: Segundo Momento Angular, Entropía, Inercia, Correlación y Momento de Diferencia Inversa (Maillard, 2003). Por otro lado, de las medidas que propuso (Haralick, 1973), las 3 más utilizadas son el Segundo Momento Angular, Contraste y Correlación (Presutti, 2004).

Autor(es) y año	Parámetro usado
Haralick, 1973, 3 experimentos	(a) ASM, Con, Cor
	(b) ASM, Con, Cor, Ent
	(c) ASM, Con, Cor, SSq, IDM, Sav, SV, SEnt, Ent, DV, Dent,
Haralick, 1979	ASM, Con, Cor, IDM, Ent
Davis et al., 1979	ASM, Con, Cor, Ent
Conners and Harlow, 1980	ASM, Cor, IDM, Ent
Rosenfeld and kak, 1982	ASM, Con, IDM, Ent
Gonzalez and Wood, 1992	ASM, Cor, IDM, Ent, Otro
Sali and Wolfson, 1992	ASM, Con, IDM, Ent, Dent
Wu and Chen, 1992	ASM, Con, Cor, IDM, SAv, SV, SEnt, Ent, DV, DEnt, IMC
Anys and He, 1995	SSq, ASM, Ent, Con, Cor, Otros
Dikshit, 1996	Ent, Con, IDM, ASM
Hay et al. (1996)	ASM, Ent, IDM, SV

Tabla 3. 14 Lista de las medidas texturas de la matriz de co-ocurrencia usados en algunos estudios de análisis de textura. Adaptado de (Maillard, 2003). [7]

En la **Tabla 3. 14** se encuentran las medidas de textura, en orden de relevancia, que han utilizado diferentes autores en estudios del análisis de textura. Allí se da una evidente

[7] **Leyenda. ASM**: Segundo momento angular, **Con**: Contraste, **Cor**: Correlación, **SSq**: Suma de cuadrados, **IDM:** Diferencia de momento inverso, **SAv**: Suma de promedios, **SV**: Suma de variancia, **SEnt**: Suma de entropía, **DV:** Diferencia de variancia, **DEnt:** Diferencia de entropía, **IMC:** Información de medidas de correlación, **MCC:** Coeficiente de máxima correlación, **otros:** Otras medidas.

tendencia por algunas medidas como el Segundo momento angular, contraste, correlación y entropía.

3. ANÁLISIS DE CORRELACIÓN

Al igual que en la elección de las bandas espectrales, con base en el resultado del análisis de correlación existente entre las bandas de textura junto con las de textura, se hizo la correspondiente selección de las medidas.

Las siguientes medidas de textura se calcularon a partir de la banda del infrarrojo cercano, con la relación espacial (0,1), es decir, al norte con un pixel de distancia y con una ventana móvil de dimensiones 11 x 11.

Banda	1	2	3	4	5	6	7	8	9	10	11	12	13	Roja	NIR
1	1,00	-0,36	-0,61	-0,08	-0,45	-0,91	0,66	-0,03	0,93	-0,89	-0,61	-0,36	0,99	-0,04	-0,23
2	-0,36	1,00	0,91	0,01	0,78	0,36	-0,10	-0,09	-0,33	0,63	0,91	1,00	-0,44	0,13	0,05
3	-0,61	0,91	1,00	0,03	0,81	0,57	-0,22	-0,09	-0,54	0,85	1,00	0,91	-0,69	0,12	0,12
4	-0,08	0,01	0,03	1,00	-0,05	-0,07	-0,08	-0,23	-0,10	0,03	0,03	0,01	-0,07	0,42	0,87
5	-0,45	0,78	0,81	-0,05	1,00	0,50	-0,17	0,34	-0,44	0,71	0,81	0,78	-0,52	0,09	0,02
6	-0,91	0,36	0,57	-0,07	0,50	1,00	-0,75	0,19	-0,95	0,87	0,57	0,36	-0,91	-0,08	0,07
7	0,66	-0,10	-0,22	-0,08	-0,17	-0,75	1,00	-0,20	0,83	-0,50	-0,22	-0,10	0,62	0,01	-0,16
8	-0,03	-0,09	-0,09	-0,23	0,34	0,19	-0,20	1,00	-0,12	0,03	-0,09	-0,09	-0,01	-0,13	-0,19
9	0,93	-0,33	-0,54	-0,10	-0,44	-0,95	0,83	-0,12	1,00	-0,85	-0,54	-0,33	0,91	-0,03	-0,22
10	-0,89	0,63	0,85	0,03	0,71	0,87	-0,50	0,03	-0,85	1,00	0,85	0,63	-0,93	0,05	0,16
11	-0,61	0,91	1,00	0,03	0,81	0,57	-0,22	-0,09	-0,54	0,85	1,00	0,91	-0,69	0,12	0,12
12	-0,36	1,00	0,91	0,01	0,78	0,36	-0,10	-0,09	-0,33	0,63	0,91	1,00	-0,44	0,13	0,05
13	0,99	-0,44	-0,69	-0,07	-0,52	-0,91	0,62	-0,01	0,91	-0,93	-0,69	-0,44	1,00	-0,04	-0,22
Roja	-0,04	0,13	0,12	0,42	0,09	-0,08	0,01	-0,13	-0,03	0,05	0,12	0,13	-0,04	1,00	0,56
NIR	-0,23	0,05	0,12	0,87	0,02	0,07	-0,16	-0,19	-0,22	0,16	0,12	0,05	-0,22	0,56	1,00

Tabla 3. 15 Matriz de correlación entre bandas de textura y espectrales seleccionadas.[8]

[8] **Leyenda: 1:** Homogeneidad, **2:** Contraste, **3:** Disimilitud, **4:** Media, **5:** Desviación estándar, **6:** Entropía, **7:** Segundo momento angular, **8:** Correlación, **9:** Segundo momento angular del vector diferencial de niveles de grises, **10:** Entropía del vector diferencial de niveles de grises, **11:** Media del vector diferencial de niveles de grises, **12:** Contraste del vector diferencial de niveles de grises, **13:** Diferencia inversa, **Roja:** Banda del rojo, **NIR:** Banda del infrarrojo cercano.

Es importante resaltar que se adopta una distancia corta (1 pixel) con una ventana grande (11x11) respecto al valor de distancia, para que en la mayoría de píxeles se realicen los cálculos y no allá ausencia de ellos, como ocurren en los bordes de las imágenes. Es decir, con una distancia similar al tamaño de la ventana, sólo hubieran sido efectivos los cálculos de los píxeles del centro de la misma (dependiendo de la orientación elegida), dejando sin datos los demás, provocando un cálculo no efectivo para la comparación mencionada.

La **Tabla 3. 15** muestra los coeficientes de correlación existente entre las 13 medidas de textura junto con las dos bandas espectrales seleccionadas anteriormente.

Banda	1	2	3	4	5	6	7	8	9	10	11	12	13	Roja	NIR
Texturas	0,61	0,53	0,63	0,14	0,57	0,62	0,42	0,19	0,61	0,67	0,63	0,53	0,63	0,11	0,19
Texturas + bandas	0,54	0,47	0,56	0,21	0,50	0,54	0,37	0,19	0,54	0,60	0,56	0,47	0,57	0,20	0,27

Tabla 3. 16 Promedios de correlación entre las bandas de texturas y espectrales seleccionadas.

Como en posteriores capítulos se realizaron procedimientos con diferentes combinaciones (bandas de textura, y bandas de textura con espectrales), los resultados de la **Tabla 3. 16** sirvieron como ayuda para la toma decisiones, ya que enseña los promedios de los valores absolutos de la correlación de cada banda con las demás separadamente; entre las bandas de textura, y en combinación con las bandas espectrales del rojo y el infrarrojo cercano. En dichos datos se puede apreciar el grado de semejanza entre las bandas.

4. ELECCIÓN MEDIDAS TEXTURALES

Teniendo en cuenta los resultados de los dos procesos anteriores (**Tabla 3. 15** y **Tabla 3. 16**), se toman las medidas texturales definitivas, que entrarán en el proceso de clasificación de cobertura del suelo.

Para la elección de las diferentes medidas, se tuvieron algunas consideraciones en cuenta, además de la correlación. Por ejemplo, el resultado promedio de la correlación de la **media** es la menor de todas, pero si se observa la correlación que tiene ésta medida

contra la banda espectral del infrarrojo cercano (**Tabla 3. 15**), es de 0.87, y la correlación de las dos bandas espectrales contra las demás medidas de textura, tienen un grado de correlación menor a 0.25. Lo que indicó que la medida de textura en cuestión, aporta casi la misma información a las bandas espectrales.

Por lo anterior, le medida de textura de **media** se descartó. Porque aunque podría haberse incluido en la combinación de los procesos de solamente bandas de textura, los resultados podrían ser similares a la combinación de texturas y bandas espectrales por el alto grado de correlación entre la **media** y la banda de infrarrojo cercano.

Ahora, la medida de **correlación** llamó la atención por su grado de correlación bajo, y además, es una de las recomendadas por diferentes autores (**Tabla 3. 14**). Por ende, se adoptó inmediatamente.

La siguiente medida que arrojó un grado bajo de correlación, respecto a las demás, es el **segundo momento angular**; 0.42 entre las bandas de textura y 0.37 en combinación con las bandas espectrales. De igual forma, era una medida recomendada por diferentes estudios (**Tabla 3. 14**), entrando a hacer parte de las medidas elegidas.

Siguiendo el orden del valor bajo del coeficiente de correlación, aparece el **contraste** y **el contraste del vector diferencial de niveles de grises,** los cuales tienen el mismo promedio de correlación (**Tabla 3. 16**) porque la correlación entre éstas dos bandas es 1.00, es decir, tienen la misma información. Pero el **contraste** es la medida elegida porque es frecuentemente utilizada en análisis de textura (**Tabla 3. 14**).

Continuando con la elección apareció **el segundo momento angular de**l **vector diferencial de niveles de grises**. Pero tiene un alto grado de correlación con el **segundo momento angular** (0.83). Por ende no se toma en cuenta. De igual forma se descartó la **desviación estándar** por su grado de correlación con el **contraste** (0.78). También sale del grupo de medidas de textura la **disimilitud** y **la media del vector diferencial de grises** porque contienen un grado de correlación de 0.91 contra el **contraste.**

La **Homogeneidad** y **entropía** tienen un coeficiente correlación alto entre ellas; razón por la cual sólo se podía seleccionar una. Y aunque la **entropía** es una de las medidas

comunes (**Tabla 3. 14**), la **homogeneidad**, entre las dos medidas, es la que tiene menos grado de correlación con las demás medidas elegidas; así que ésta última es la seleccionada.

Las medidas restantes, **entropía del vector diferencial** y **diferencia inversa**, son descartadas por el grado de correlación existente contra la **homogeneidad**, siendo de 0.89 y de 0.99 respectivamente.

Medida	Homogeneidad	Contraste	Segundo momento angular	Correlación
Homogeneidad	1,00	-0,36	0,66	-0,03
Contraste	-0,36	1,00	-0,10	-0,09
Segundo momento angular	0,66	-0,10	1,00	-0,20
Correlación	-0,03	-0,09	-0,20	1,00

Tabla 3. 17 Matriz de correlación entre las bandas de textura seleccionadas.

Cabe mencionar que adicionalmente a de los parámetros señalados, se tuvo en cuenta el coeficiente de correlación entre las bandas seleccionadas (**Tabla 3. 17**), dando como resultado las medidas de: **Homogeneidad**, **contraste¸ segundo momento angular** y **correlación**.

5. PARÁMETROS ÓPTIMOS

Adicional a las medidas de textura, se encuentran otros parámetros (tamaño de matriz y relación espacial) que se deben tener en cuenta al momento de crear las nuevas bandas de textura. Recordando el enfoque experimental que tiene el proyecto, el cálculo de las nuevas bandas de textura se realizó con diferentes valores en cada uno de los parámetros para poderlos analizarlos.

Con el fin de evaluar los cambios entre la variación de los diferentes parámetros del cálculo de las texturas (**Tabla 3. 18**), se realizó una comparación, con base en el coeficiente de correlación, con múltiples combinaciones, y así se disminuyó el número de pruebas en posteriores procesos.

Para analizar el impacto del cambio de cada uno de los parámetros, se realizaron múltiples pruebas, según correspondía, en imágenes de textura haciendo modificando solamente la variable a estudiar.

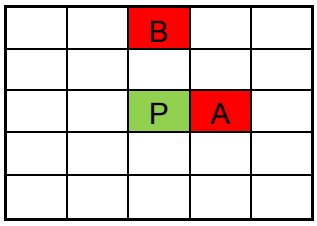


Figura 3. 17 *Ejemplo de distancia y relación espacial entre píxeles.*

Para un mejor entendimiento acerca de los parámetros de distancia y relación espacial, se ejemplifica un caso con ayuda de la **Figura 3. 17**. El objeto de estudio es el pixel ***P*** dentro de una ventana móvil de 5x5. La relación espacial se ingresa en coordenadas ***(X,Y)***, lo que sería: La coordenada ***X*** es el desplazamiento horizontal, y la coordenada ***Y*** es el desplazamiento vertical. Entendiendo lo anterior, la relación espacial (**1,0**) da como resultado el estudio con base en el pixel ***A***, ya que es un pixel a la derecha y cero hacia arriba (distancia de 1 pixel en 0°). Lo que quiere decir que la relación espacial (**0,2**) indica que se debe realizar el proceso junto al pixel ***B*** (0 píxeles a la derecha y 2 hacia arriba o distancia de 2 píxeles en 90°).

Banda espectral	Infrarrojo
Medidas	Homogeneidad, Contraste, Segundo momento Angular, Correlación
Matriz móvil	5x5, 11x11, 25x25, 51x51
Distancia pixel	5,9,15,25 (Según correspondía)
Dirección espacial	Oriente, Nor-oriente, Norte, Nor-occidente

Tabla 3. 18 *Parámetros para la creación de las bandas de textura.*

La **Tabla 3. 18** muestra todos los parámetros utilizados, con sus respectivas variaciones, para análisis de los diferentes parámetros para la creación de bandas de textura.

El parámetro que se refiere a “banda espectral” que corresponde a infrarrojo (**Tabla 3. 18**), quiere decir que de dicha banda es donde se van a calcular o crear las bandas de textura.

6. BANDAS DE TEXTURA

Luego de obtener los parámetros óptimos para los cálculos de las bandas de textura, se calcularon las bandas definitivas que posteriormente entraron en los procedimientos de clasificación.

Para ejemplificar visualmente las bandas de textura, se realizó una muestra de cada textura seleccionada por cada una de las coberturas presentes en la zona de estudio. La **Tabla 3. 19** muestra la zona de estudio en combinación RGB (321), para una mejor identificación, junto a cada una de las texturas. Y para contemplar adecuadamente los cambios en cada una de las texturas calculadas, de la **Tabla 3. 20** a la **Tabla 3. 28** se enseñan cada una de las coberturas sin ningún tipo de mejoramiento de contraste. Así mismo, en los **Anexos H** (Homogeneidad)**, I** (Contraste)**, J** (Segundo Momento Angular) y **K** (Correlación) se encuentran los mapas de las cuatro medidas de texturas seleccionadas, de la zona de estudio completa.

Las bandas enseñadas en las tablas fueron calculadas con una referencia espacial (1,0) con una ventana móvil de 5x5.

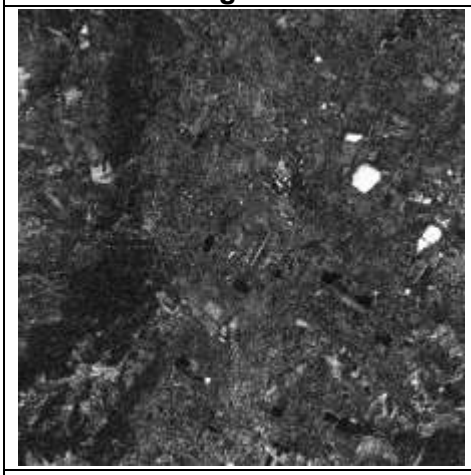
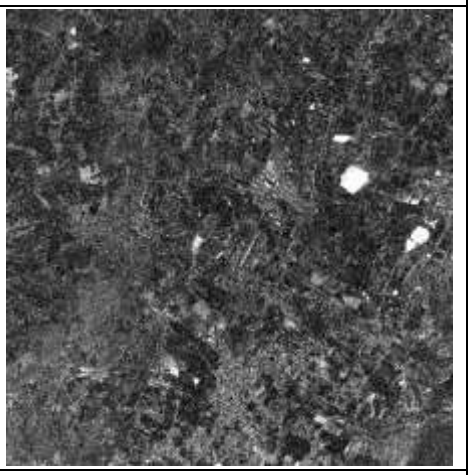
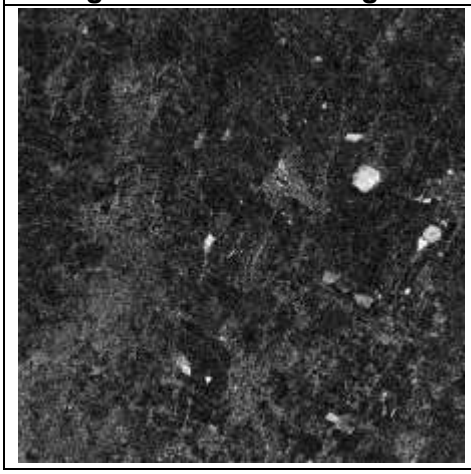
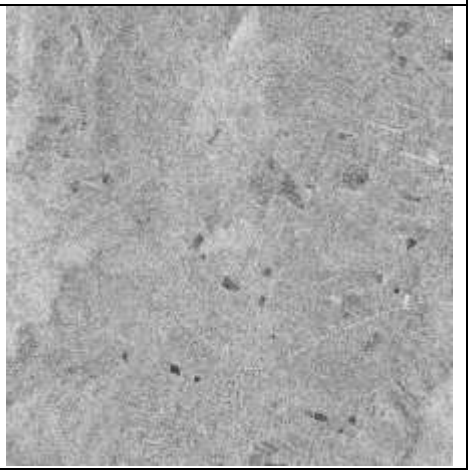
RGB 321	
	
Homogeneidad	**Contraste**
	
Segundo Momento Angular	**Correlación**
	

Tabla 3. 19 Imágenes de la zona de estudio, multiespectral RGB (321) y bandas de texturas seleccionadas.

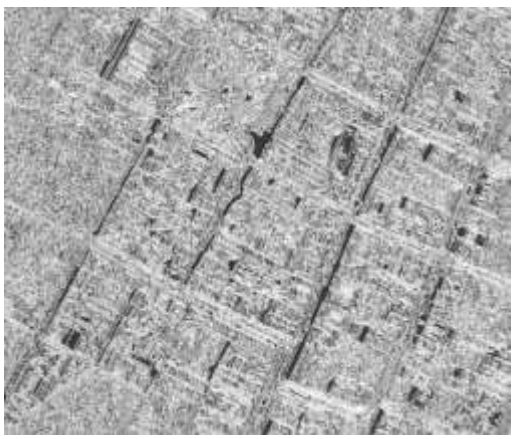
Zonas Urbanizadas	**RGB 321**	
		
	Homogeneidad	**Contraste**
		
	Segundo Momento Angular	**Correlación**
		

Tabla 3. 20 Cobertura de zonas urbanizadas en combinación multiespectral RGB (321) y en las bandas de texturas seleccionadas.

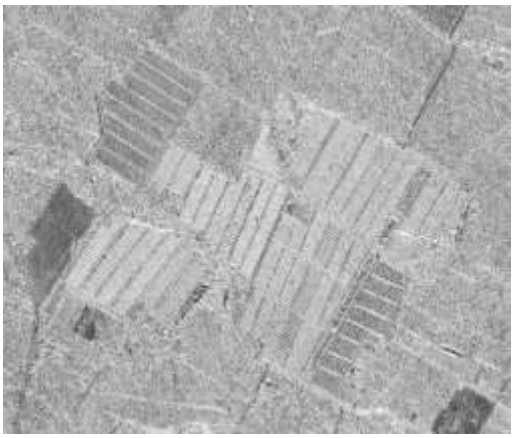
Invernaderos	**RGB 321**	
		
	Homogeneidad	**Contraste**
		
	Segundo Momento Angular	**Correlación**
		

Tabla 3. 21 *Cobertura de invernaderos en combinación multiespectral RGB (321) y en las bandas de texturas seleccionadas.*

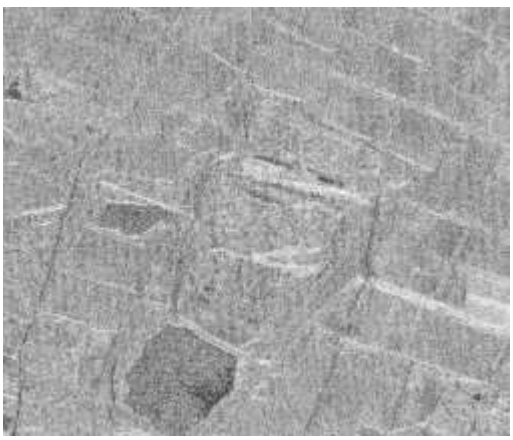
Zonas de extracción minera y escombrera	**RGB 321**	
		
	Homogeneidad	**Contraste**
		
	Segundo Momento Angular	**Correlación**
		

Tabla 3. 22 Cobertura de zonas de extracción minera y escombrera en combinación multiespectral RGB (321) y en las bandas de texturas seleccionadas.

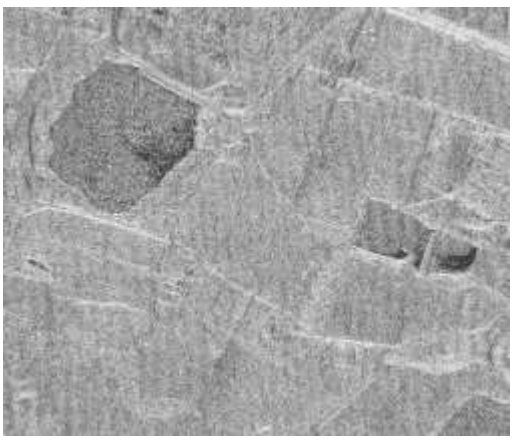
	RGB 321	
		
	Homogeneidad	**Contraste**
Cuerpos de Agua		
	Segundo Momento Angular	**Correlación**
		

Tabla 3. 23 Cobertura de cuerpos de agua en combinación multiespectral RGB (321) y en las bandas de texturas seleccionadas.

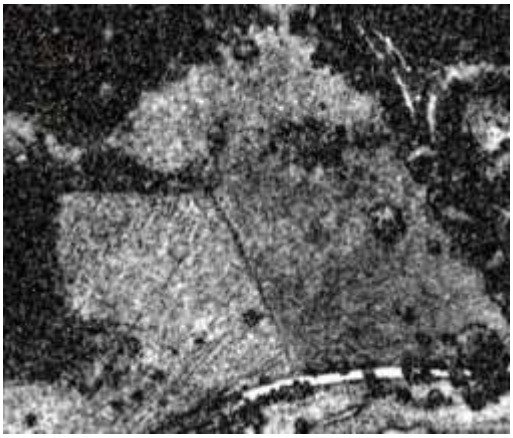
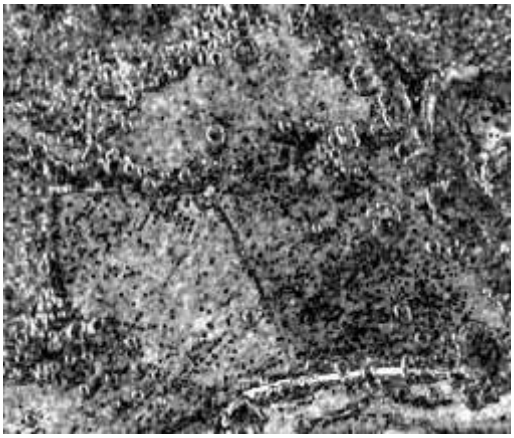
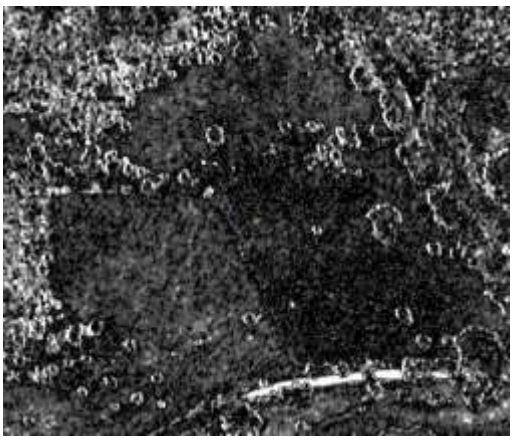
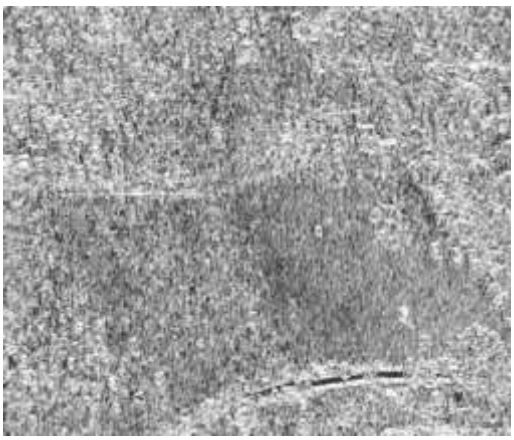
Pastos	**RGB 321**	
		
	Homogeneidad	**Contraste**
		
	Segundo Momento Angular	**Correlación**
		

Tabla 3. 24 Cobertura de pastos en combinación multiespectral RGB (321) y en las bandas de texturas seleccionadas.

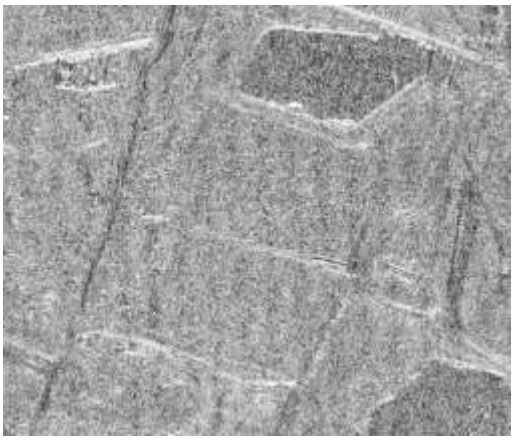
Herbazales	**RGB 321**	
		
	Homogeneidad	**Contraste**
		
	Segundo Momento Angular	**Correlación**
		

Tabla 3. 25 Cobertura de Herbazales en combinación multiespectral RGB (321) y en las bandas de texturas seleccionadas.

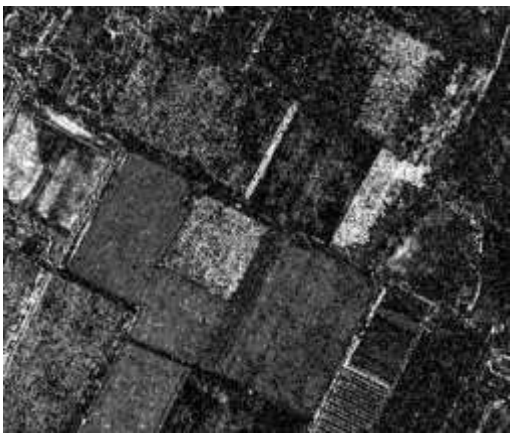
Cultivos Transitorios	**RGB 321**	
		
	Homogeneidad	**Contraste**
		
	Segundo Momento Angular	**Correlación**
		

Tabla 3. 26 Cobertura de cultivos transitorios en combinación multiespectral RGB (321) y en las bandas de texturas seleccionadas.

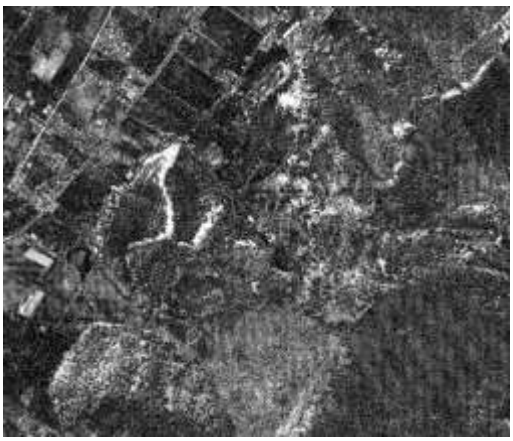
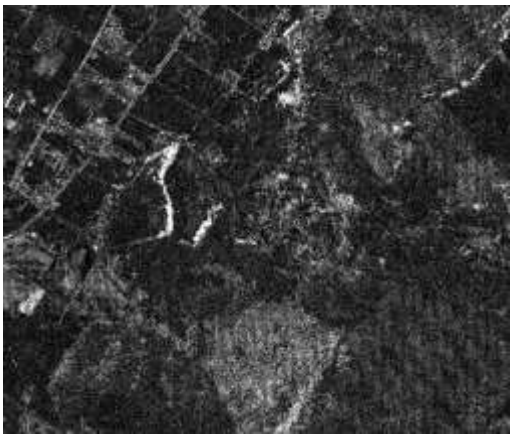
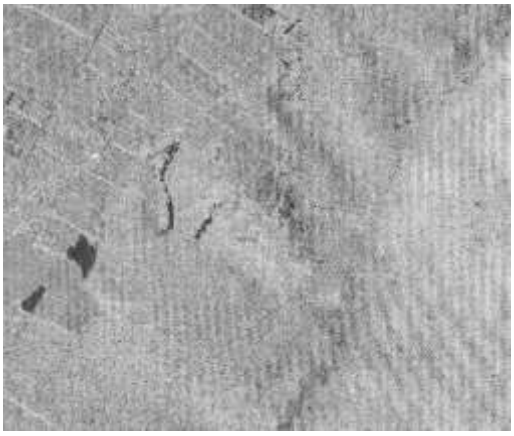
Bosques	**RGB 321**	
		
	Homogeneidad	**Contraste**
		
	Segundo Momento Angular	**Correlación**
		

Tabla 3. 27 Cobertura de bosques en combinación multiespectral RGB (321) y en las bandas de texturas seleccionadas.

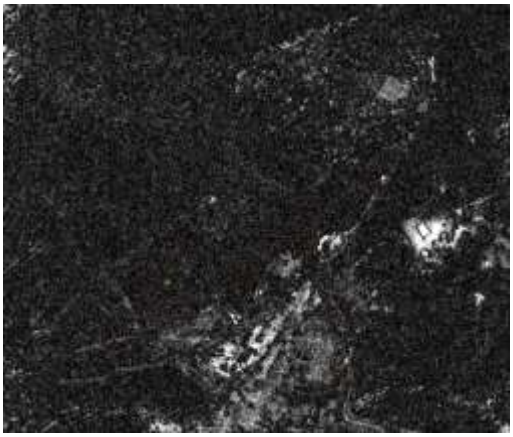
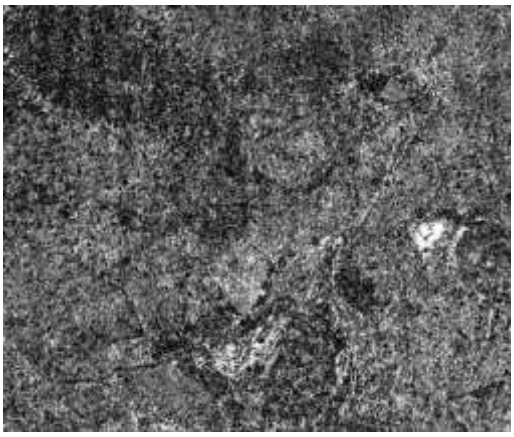
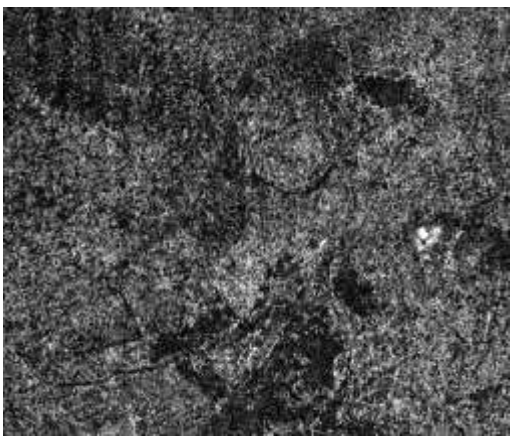
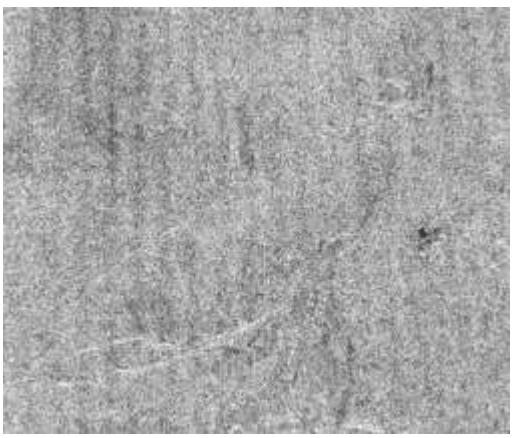
	RGB 321	
		
	Homogeneidad	**Contraste**
Tierras sin o con poca vegetación		
	Segundo Momento Angular	**Correlación**
		

Tabla 3. 28 Cobertura de tierras sin o con poca vegetación en combinación multiespectral RGB (321) y en las bandas de texturas seleccionadas.

3.3.5 RECONOCIMIENTO EN CAMPO

Para poder realizar el proceso de clasificación de cobertura del suelo con un resultado coherente, fue necesario tomar datos en campo para la posterior validación. Sin embargo, como las imágenes digitales fueron tomadas en el año 2009, hubo zonas que se debieron analizar con precaución por el posible cambio que podría haberse dado a través de los 5 años aproximadamente (tiempo transcurrido de la fecha de toma de las imágenes y la visita a campo), bien sea por cambios naturales o cambios provocados por el hombre.

3.3.6 CLASIFICACIÓN DE COBERTURA

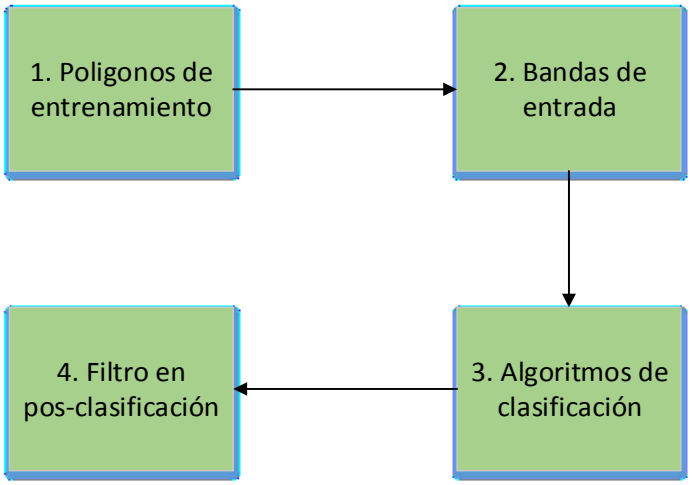


Figura 3. 18 Metodología de clasificación de cobertura del suelo.

La **Figura 3. 18** muestra la metodología realizada en el proceso de clasificación de cobertura del suelo, el cual se detalla a continuación:

1. POLÍGONOS DE ENTRENAMIENTO

Los polígonos se tomaron con base en la información tomada en campo, ayuda de Google Earth y la interpretación visual de los integrantes del proyecto.

Cabe señalar que se acudió a la alcaldía de Tabio, solicitando cualquier tipo de datos que pudieran haber servido para el procedimiento, pero desafortunadamente no contaban con alguno de ellos; como por ejemplo mapas de cobertura y uso del suelo.

2. BANDAS DE ENTRADA

Algoritmo	Bandas de Entrada	
Mínima Distancia	Espectrales	Espectrales +Textura
Máxima Verosimilitud	Espectrales	Espectrales +Textura
Paralelepípedo	Espectrales	Espectrales +Textura

Tabla 3. 29 Grupos de bandas para las clasificaciones de cobertura del suelo.

Como bien se ha señalado a lo largo del proyecto, las clasificaciones se partieron en dos grupos básicamente. Un grupo consta de realizar la clasificación haciendo uso solamente de las bandas espectrales como se puede ver en la **Tabla 3. 29**; es decir, las bandas correspondientes al azul, verde, rojo e infrarrojo cercano. Y el otro grupo contiene las bandas espectrales y las de textura; es decir, las bandas correspondientes al azul, verde, rojo, infrarrojo cercano, homogeneidad, contraste, segundo momento angular y correlación. Y así con esto, evaluar los cambios que presenta incorporar las texturas en las clasificaciones.

3. ALGORITMOS DE CLASIFICACIÓN

Para realizar la clasificación se eligió solamente algoritmos de clasificación supervisada. Los algoritmos fueron el de Máxima Verosimilitud, Mínima Distancia y Paralelepípedo con máxima verosimilitud como criterio de desempate (que a lo largo del proyecto se nombra como Paralelepípedo). Y como se mencionaba anteriormente, se decidió el uso de clasificación supervisada, ya que al realizar cada una de las clasificaciones no supervisadas, éstas deberían ser sometidas a pos-procesamiento individuales, perdiendo un punto de igualdad entre las mismas al momento de realizar las respectivas comparaciones. Cabe recordar que los polígonos de entrenamiento, puntos de la

evaluación de exactitud, y filtros aplicados a cada una de los clasificadores supervisadas, son iguales.

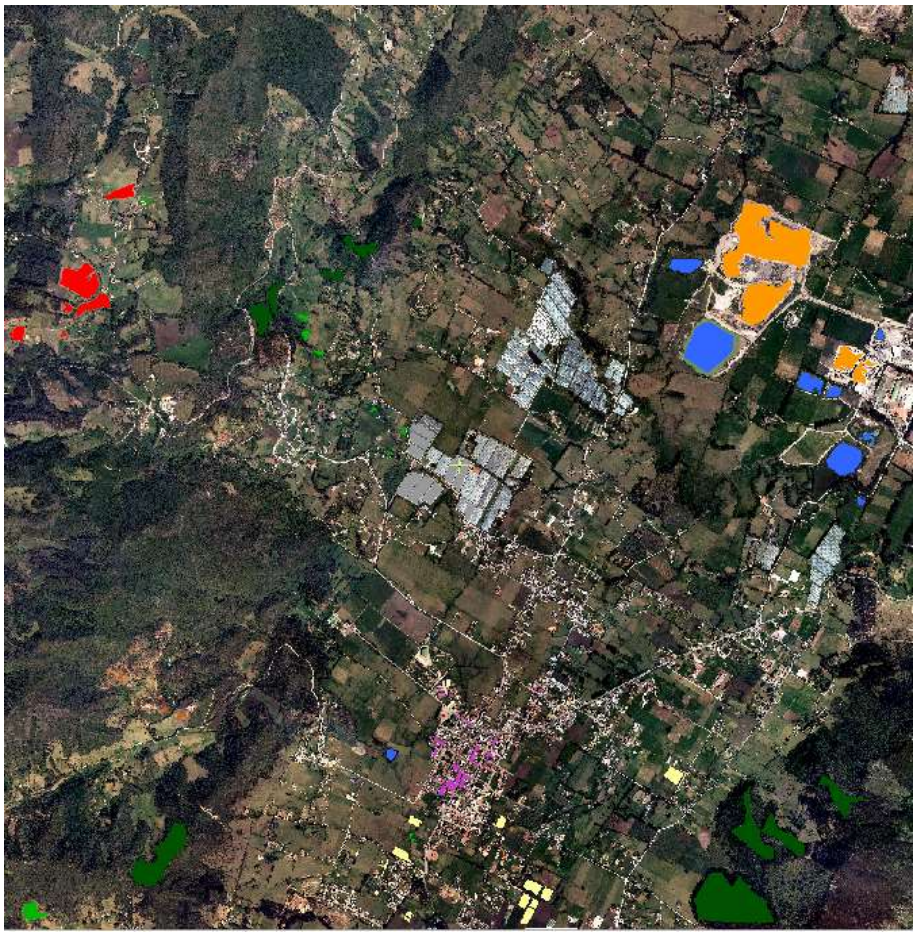


Figura 3. 19 Polígonos de entrenamiento sobre el área de estudio.

En la **Figura 3. 19** se encuentran los polígonos de entrenamiento creados para ser ingresados al proceso de clasificación de cobertura del suelo por los algoritmos supervisados. Se puede apreciar que en las diferentes coberturas se tomaron varios polígonos; esto fue así porque las diversas clases presentaban diferentes características espectrales y de texturas, por ende se necesitaba recopilar información adicional de cada cobertura, para obtener buenos resultados de clasificación.

4. FILTRO EN POST-CLASIFICACIÓN

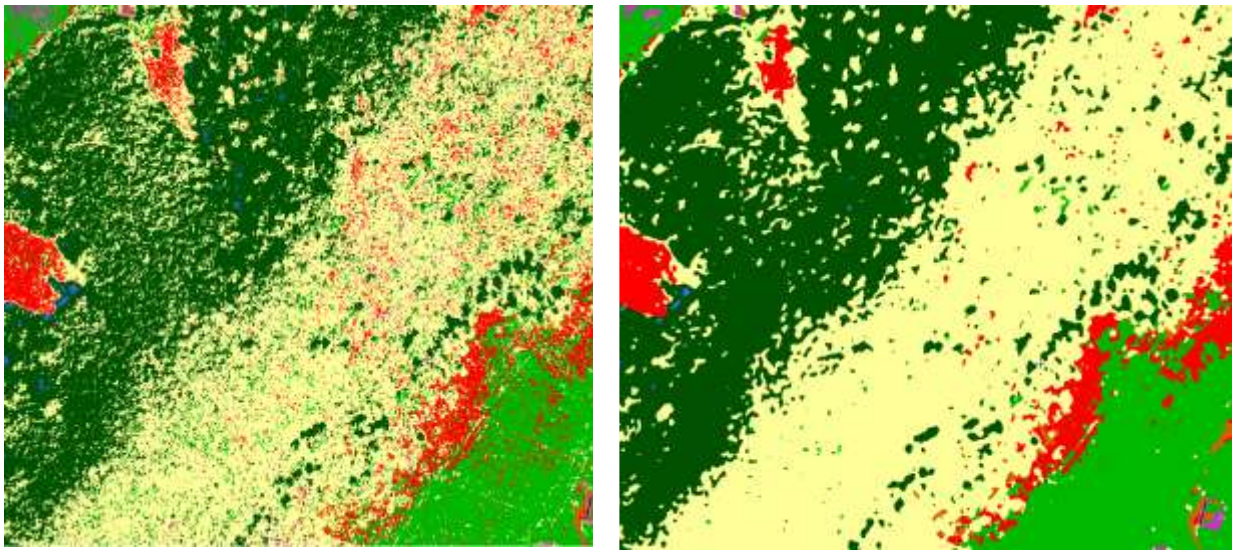


Figura 3. 20 Clasificación por el algoritmo de paralelepípedo (izquierda) y posterior al filtrado (derecha).

Después de realizar las clasificaciones, generalmente hay zonas con ruido, como se puede observar en la **Figura 3. 20** (izquierda). A dicho efecto se le conoce como "sal y pimienta", por los píxeles individuales que se generan en el proceso de clasificación. Para disminuir éste efecto y generar nuevos polígonos más uniformes y evitar errores en el proceso de evaluación de exactitud, se utilizó un filtro de moda de 7x7. Lo que hace es tomar una ventana de 7x7 y asignar al pixel central el promedio de los píxeles vecinos.

Dicho proceso se aplicó dos veces, para generar mejores polígonos sin deteriorar los resultados originales como se observa en la **Figura 3. 20** (derecha).

Cobertura	Leyenda
Zonas Urbanizadas	
Invernaderos	
Zonas de Extracción Minera o Escombrera	
Cuerpos de Agua	
Pastos	
Herbazales	
Cultivos Transitorios	
Bosques	
Tierras sin o con poca vegetación	

Tabla 3. 30 Leyenda de los mapas de clasificación de cobertura del suelo.

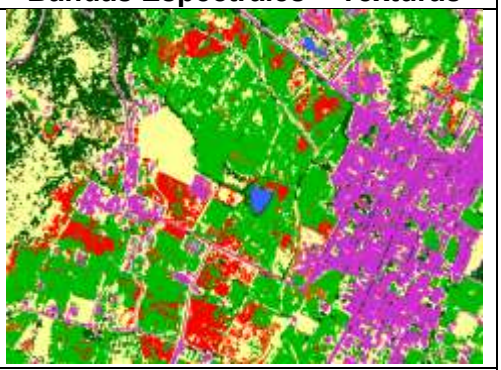
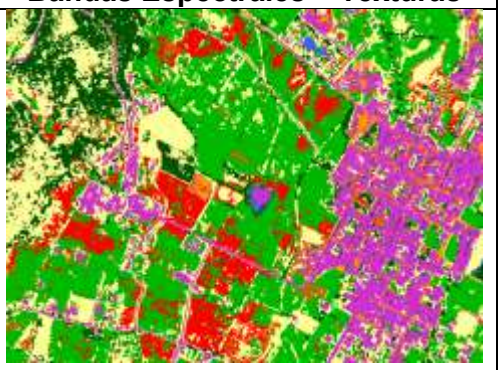
Imagen Original	**Multiespectral RGB (321)**	
		
Mínima Distancia	**Bandas Espectrales**	**Bandas Espectrales + Texturas**
		
Máxima Verosimilitud	**Bandas Espectrales**	**Bandas Espectrales + Texturas**
		
Paralelepípedo	**Bandas Espectrales**	**Bandas Espectrales + Texturas**
		

Tabla 3. 31 *Imagen multiespectral RGB (321) y clasificaciones supervisadas por 3 algoritmos usando bandas espectrales solamente y en combinación con bandas de textura, Zona Urbana y cultivos.*

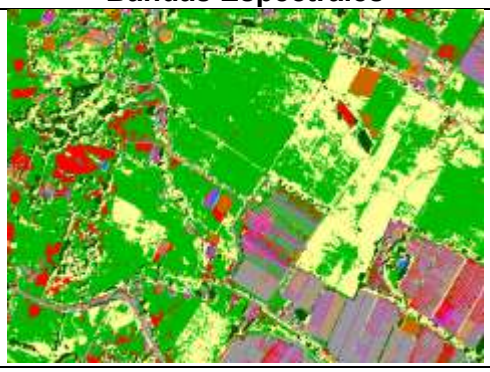
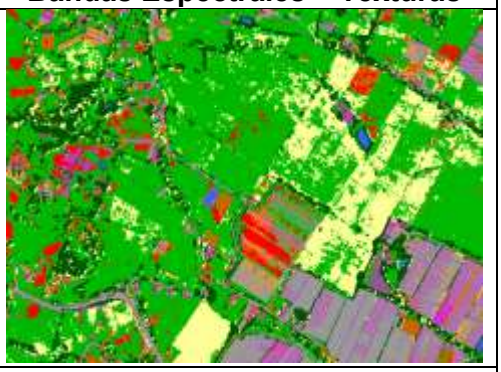
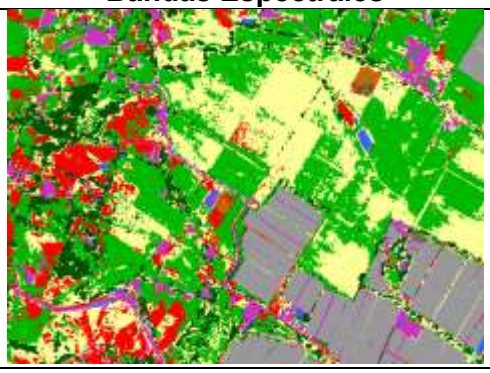
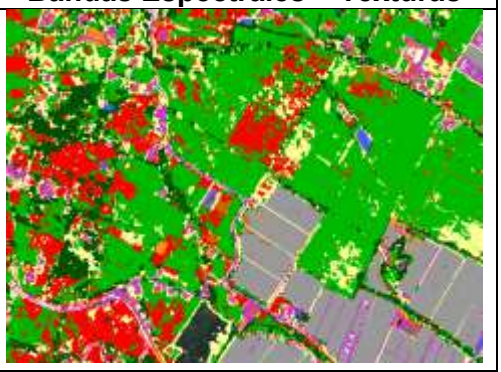
Imagen Original	**Multiespectral RGB (321)**	
		
Mínima Distancia	**Bandas Espectrales**	**Bandas Espectrales + Texturas**
		
Máxima Verosimilitud	**Bandas Espectrales**	**Bandas Espectrales + Texturas**
		
Paralelepípedo	**Bandas Espectrales**	**Bandas Espectrales + Texturas**
		

Tabla 3. 32 *Imagen multiespectral RGB (321) y clasificaciones supervisadas por 3 algoritmos usando bandas espectrales solamente y en combinación con bandas de textura, Invernaderos, Cultivos Transitorios y Pastizales y Herbazales.*

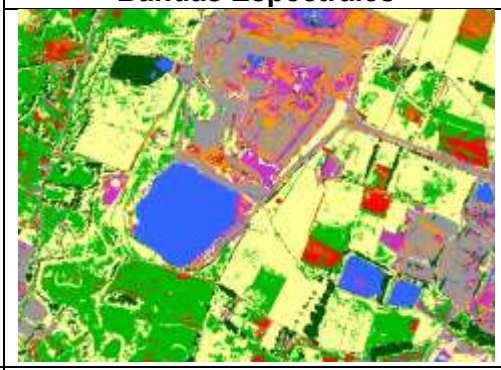
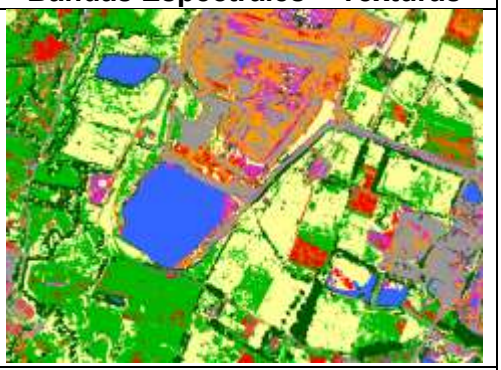
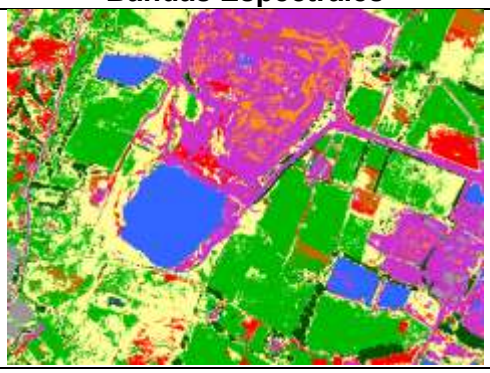
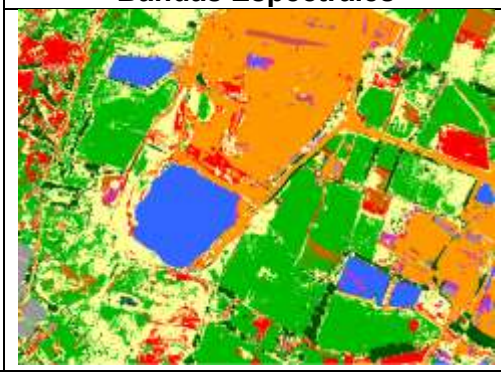
Imagen Original	**Multiespectral RGB (321)**	
		
Mínima Distancia	**Bandas Espectrales**	**Bandas Espectrales + Texturas**
		
Máxima Verosimilitud	**Bandas Espectrales**	**Bandas Espectrales + Texturas**
		
Paralelepípedo	**Bandas Espectrales**	**Bandas Espectrales + Texturas**
		

Tabla 3. 33 *Imagen multiespectral RGB (321) y clasificaciones supervisadas por 3 algoritmos usando bandas espectrales solamente y en combinación con bandas de textura, Zona de Extracción Minera y Escombrera, Cuerpos de Agua y pastizales.*

De la **Tabla 3. 31** a la **Tabla 3. 33** se puedan observar 3 zonas diferentes, en las cuales se encuentran todas las coberturas de la zona de estudio, donde se comparan visualmente las clasificaciones realizadas por los tres algoritmos de clasificación supervisada junto con la imagen RGB (321). La **Tabla 3. 30** contiene la leyenda para cada una de las figuras presentadas en dichas tablas. Para una visualización completa de cada una de las clasificaciones realizadas, se pueden consultar los **Anexos B** (Clasificación por Mínima Distancia con bandas espectrales), **C** (Clasificación por Máxima Verosimilitud con bandas espectrales), **D** (Clasificación por Paralelepípedo con Máxima verosimilitud como criterio de desempate con bandas espectrales), **E** (Clasificación por Mínima Distancia con bandas espectrales y texturas), **F** (Clasificación por Máxima Verosimilitud con bandas espectrales y texturas) y **G** (Clasificación por Paralelepípedo con Máxima verosimilitud como criterio de desempate con bandas espectrales y texturas).

3.3.7 VALIDACIÓN



Figura 3. 21 Puntos de validación distribuidos en la zona de estudio.

Desafortunadamente no siempre se pueden evaluar gran cantidad de puntos en muestras aleatorias. Por eso, se debe realizar un balance entre los datos estadísticos y lo que en la práctica es correcto llevar a cabo. Una buena regla para decidir el número de puntos que se deben evaluar, es tomar un mínimo de 50 puntos por clase en la matriz de confusión. Si el área es muy grande (mayor a 1 millón de Ha) o el sistema de clasificación tiene gran cantidad de clase (mayor a 10), el número mínimo de muestras debería ser de 75 a 100 puntos por clase. Sin embargo el número de puntos se puede ajustar dependiendo de la finalidad del proyecto (Jensen, 2004). Teniendo en cuenta lo anterior, se decidió evaluar la exactitud de clasificación de los mapas de cobertura del suelo, utilizando la matriz de confusión, tomando 1350 puntos, distribuidos aleatoriamente de manera estratificada para cada clase, como se puede apreciar en la **Figura 3. 21**; es decir, proporcionalmente a la extensión de cada clase, tendrá mayor o menor cantidad de puntos en la zona de estudio (asumiendo que todas las coberturas ocupan la misma extensión, se toman 150 puntos por clase). Todas las clasificaciones fueron evaluadas con los mismos puntos para que los resultados pudieran ser comparables. Por cada cobertura se tomó más de un polígono de entrenamiento, ya que cada una de éstas, contenía características espectrales y de textura diferentes. En total, los polígonos ocuparon el 2.7 % de la imagen.

4. RESULTADOS

A continuación se presentan y explican los resultados obtenidos a lo largo del proceso del proyecto.

4.1 PARÁMETROS DE LA MATRIZ DE COOCURRENCIA

Las matrices resultantes del cálculo de correlación entre las diferentes variables se analizan a continuación para cada una de dichas variables o parámetros estudiados.

4.1.1 ORIENTACIÓN

Relación espacial	Relación espacial	1,0				1,1				0,1				-1,1			
	Medida	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)	(12)	(13)	(14)	(15)	(16)
1,0	(1)	1,00	-0,35	0,65	-0,01	0,95	-0,34	0,63	0,03	0,93	-0,31	0,65	-0,11	0,94	-0,31	0,63	-0,05
	(2)	-0,35	1,00	-0,09	-0,12	-0,30	0,91	-0,08	-0,04	-0,31	0,74	-0,09	0,13	-0,29	0,78	-0,08	0,07
	(3)	0,65	-0,09	1,00	-0,18	0,70	-0,09	1,00	-0,09	0,65	-0,09	1,00	-0,20	0,70	-0,09	1,00	-0,11
	(4)	-0,01	-0,12	-0,18	1,00	-0,06	-0,03	-0,18	0,78	-0,11	0,12	-0,19	0,46	-0,08	0,07	-0,19	0,63
1,1	(5)	0,95	-0,30	0,70	-0,06	1,00	-0,32	0,68	0,05	0,94	-0,29	0,70	-0,10	0,93	-0,25	0,68	-0,10
	(6)	-0,34	0,91	-0,09	-0,03	-0,32	1,00	-0,08	-0,12	-0,32	0,78	-0,09	0,08	-0,27	0,64	-0,08	0,20
	(7)	0,63	-0,08	1,00	-0,18	0,68	-0,08	1,00	-0,09	0,62	-0,08	1,00	-0,20	0,67	-0,08	1,00	-0,12
	(8)	0,03	-0,04	-0,09	0,78	0,05	-0,12	-0,09	1,00	-0,01	0,07	-0,10	0,63	-0,05	0,19	-0,10	0,40
0,1	(9)	0,93	-0,31	0,65	-0,11	0,94	-0,32	0,62	-0,01	1,00	-0,35	0,65	-0,03	0,94	-0,32	0,62	-0,04
	(10)	-0,31	0,74	-0,09	0,12	-0,29	0,78	-0,08	0,07	-0,35	1,00	-0,09	-0,10	-0,30	0,89	-0,08	0,00
	(11)	0,65	-0,09	1,00	-0,19	0,70	-0,09	1,00	-0,10	0,65	-0,09	1,00	-0,19	0,70	-0,09	1,00	-0,11
	(12)	-0,11	0,13	-0,20	0,46	-0,10	0,08	-0,20	0,63	-0,03	-0,10	-0,19	1,00	-0,08	0,00	-0,20	0,74
-1,1	(13)	0,94	-0,29	0,70	-0,08	0,93	-0,27	0,67	-0,05	0,94	-0,30	0,70	-0,08	1,00	-0,31	0,68	0,01
	(14)	-0,31	0,78	-0,09	0,07	-0,25	0,64	-0,08	0,19	-0,32	0,89	-0,09	0,00	-0,31	1,00	-0,08	-0,12
	(15)	0,63	-0,08	1,00	-0,19	0,68	-0,08	1,00	-0,10	0,62	-0,08	1,00	-0,20	0,68	-0,08	1,00	-0,11
	(16)	-0,05	0,07	-0,11	0,63	-0,10	0,20	-0,12	0,40	-0,04	0,00	-0,11	0,74	0,01	-0,12	-0,11	1,00

Tabla 4. 1 Matriz de correlación entre las medidas de texturas seleccionadas variando su orientación, con las 4 posibilidades, con una ventana móvil de 11x11[9].

[9] **Leyenda: (1)(5)(6)(13)** : Homogeneidad, **(2)(6)(10)14)**: Contraste, **(3)(7)(11)(15):** Segundo momento angular, **(4)(8)(12)(16)**: Correlación.

La **Tabla 4. 1** muestra la matriz de correlación calculada entre las 4 variables de textura seleccionadas, con una ventana móvil de 11x11, distancia de 1 pixel, variando el parámetro de orientación. Para realizar el análisis se tomó como base la primera matriz (relación espacial 1,0) y se comparó con las demás (valores resaltados en rojo).

Dependiendo de la medida de textura a calcular, habrá un mayor o menor impacto, en el resultado realizar una variación de dirección:

- El **segundo momento angular** es inmune al cambio de dirección ya que la correlación entre las diferentes posibilidades no varía.
- La **correlación** tiene cambios significativos aplicando una variación de la dirección el cual arrojó resultados con diferencias de 0.22 y 0.54.
- La **homogeneidad** y el **contraste** se encuentran con grados de correlación media-alta de 0.74 a 0.95, lo cual no es un rango significativamente alto para considerar el impacto que podría generar en la banda de textura de dichas variables; pero si se debe tener en cuenta.

4.1.2 DISTANCIA DE PIXEL

La **Tabla 4. 2** muestra la matriz de correlación calculada entre las 4 variables de textura seleccionadas, con una ventana móvil de 25x25, orientación al oriente, variando el parámetro de distancia de pixel de referencia. Para realizar el análisis se tomó como base la primera matriz (relación espacial 5,0) y se comparó con las demás (valores resaltados en rojo).

De todos los parámetros analizados, la distancia del pixel de referencia, es la que menos cambios presenta.

Relación espacial	Relación Medida	5,0				9,0				15,0				25,0			
		(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)	(12)	(13)	(14)	(15)	(16)
5,0	(1)	1,00	-0,27	0,69	0,10	0,99	-0,23	0,67	0,12	0,96	-0,18	0,66	0,11	0,92	-0,14	0,64	0,06
	(2)	-0,27	1,00	-0,08	0,00	-0,31	0,96	-0,08	-0,11	-0,33	0,89	-0,08	-0,13	-0,33	0,78	-0,08	-0,05
	(3)	0,69	-0,08	1,00	-0,03	0,71	-0,07	1,00	-0,01	0,73	-0,06	0,99	0,00	0,74	-0,06	0,99	0,01
	(4)	0,10	0,00	-0,03	1,00	0,04	0,14	-0,03	0,88	-0,03	0,28	-0,04	0,61	-0,11	0,41	-0,04	0,34
9,0	(5)	0,99	-0,31	0,71	0,04	1,00	-0,28	0,70	0,09	0,98	-0,25	0,69	0,09	0,95	-0,20	0,67	0,06
	(6)	-0,23	0,96	-0,07	0,14	-0,28	1,00	-0,07	-0,04	-0,32	0,96	-0,07	-0,11	-0,32	0,86	-0,07	-0,05
	(7)	0,67	-0,08	1,00	-0,03	0,70	-0,07	1,00	-0,02	0,72	-0,07	1,00	0,00	0,73	-0,06	0,99	0,01
	(8)	0,12	-0,11	-0,01	0,88	0,09	-0,04	-0,02	1,00	0,03	0,09	-0,02	0,80	-0,04	0,25	-0,02	0,46
15,0	(9)	0,96	-0,33	0,73	-0,03	0,98	-0,32	0,72	0,03	1,00	-0,30	0,71	0,08	0,98	-0,26	0,70	0,06
	(10)	-0,18	0,89	-0,06	0,28	-0,25	0,96	-0,07	0,09	-0,30	1,00	-0,07	-0,09	-0,31	0,93	-0,07	-0,06
	(11)	0,66	-0,08	0,99	-0,04	0,69	-0,07	1,00	-0,02	0,71	-0,07	1,00	0,00	0,73	-0,06	1,00	0,01
	(12)	0,11	-0,13	0,00	0,61	0,09	-0,11	0,00	0,80	0,08	-0,09	0,00	1,00	0,04	0,01	0,00	0,69
25,0	(13)	0,92	-0,33	0,74	-0,11	0,95	-0,32	0,73	-0,04	0,98	-0,31	0,73	0,04	1,00	-0,31	0,72	0,08
	(14)	-0,14	0,78	-0,06	0,41	-0,20	0,86	-0,06	0,25	-0,26	0,93	-0,06	0,01	-0,31	1,00	-0,07	-0,13
	(15)	0,64	-0,08	0,99	-0,04	0,67	-0,07	0,99	-0,02	0,70	-0,07	1,00	0,00	0,72	-0,07	1,00	0,01
	(16)	0,06	-0,05	0,01	0,34	0,06	-0,05	0,01	0,46	0,06	-0,06	0,01	0,69	0,08	-0,13	0,01	1,00

Tabla 4. 2 Matriz de correlación entre las bandas de textura seleccionadas variando su distancia de pixel de referencia, orientación al oriente y una ventana móvil de 25x25.

- El **segundo momento angular**, al igual en que en parámetro de orientación, no presentó ningún cambio notorio (correlaciones entre 0.99 y 1.00).
- Las correlaciones entre la **homogeneidad**, son superiores a 0.90.
- Los valores en la medida de **contraste**, son significativamente altos, siendo 0.78 el valor más bajo.
- La **correlación** tiene un comportamiento opuesto al **segundo momento angular.** Entre más grande sea la diferencia del pixel de referencia, su cambio se hace notorio. Sin embargo, tienen que ser diferencias considerables. Como se detalla en la **Tabla 4. 2**, la correlación baja se genera en la distancia de 5 a 25 píxeles.

4.1.3 DIMENSIONES MATRIZ

Ventana Móvil	Ventana Móvil	5x5				11x11				25x25				51x51			
	Medida	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)	(12)	(13)	(14)	(15)	(16)
5x5	(1)	1,00	-0,30	0,67	-0,02	0,89	-0,32	0,58	-0,02	0,79	-0,29	0,49	0,05	0,70	-0,26	0,43	0,10
	(2)	-0,30	1,00	-0,10	-0,13	-0,27	0,81	-0,07	-0,07	-0,23	0,64	-0,05	-0,06	-0,20	0,56	-0,05	-0,08
	(3)	0,67	-0,10	1,00	-0,17	0,68	-0,10	0,92	-0,14	0,64	-0,09	0,80	-0,07	0,60	-0,09	0,70	-0,02
	(4)	-0,02	-0,13	-0,17	1,00	-0,04	-0,12	-0,15	0,47	-0,05	-0,10	-0,13	0,30	-0,04	-0,09	-0,11	0,22
11x11	(5)	0,89	-0,27	0,68	-0,04	1,00	-0,35	0,65	-0,01	0,92	-0,34	0,58	0,06	0,83	-0,31	0,51	0,12
	(6)	-0,32	0,81	-0,10	-0,12	-0,35	1,00	-0,09	-0,12	-0,31	0,86	-0,08	-0,09	-0,28	0,75	-0,07	-0,12
	(7)	0,58	-0,07	0,92	-0,15	0,65	-0,09	1,00	-0,18	0,65	-0,09	0,92	-0,11	0,61	-0,08	0,83	-0,05
	(8)	-0,02	-0,07	-0,14	0,47	-0,01	-0,12	-0,18	1,00	-0,01	-0,09	-0,18	0,69	-0,01	-0,08	-0,17	0,53
25x25	(9)	0,79	-0,23	0,64	-0,05	0,92	-0,31	0,65	-0,01	1,00	-0,37	0,64	0,07	0,95	-0,35	0,58	0,14
	(10)	-0,29	0,64	-0,09	-0,10	-0,34	0,86	-0,09	-0,09	-0,37	1,00	-0,09	-0,11	-0,34	0,92	-0,08	-0,14
	(11)	0,49	-0,05	0,80	-0,13	0,58	-0,08	0,92	-0,18	0,64	-0,09	1,00	-0,15	0,63	-0,09	0,95	-0,09
	(12)	0,05	-0,06	-0,07	0,30	0,06	-0,09	-0,11	0,69	0,07	-0,11	-0,15	1,00	0,07	-0,09	-0,17	0,82
51x51	(13)	0,70	-0,20	0,60	-0,04	0,83	-0,28	0,61	-0,01	0,95	-0,34	0,63	0,07	1,00	-0,37	0,62	0,15
	(14)	-0,26	0,56	-0,09	-0,09	-0,31	0,75	-0,08	-0,08	-0,35	0,92	-0,09	-0,09	-0,37	1,00	-0,09	-0,16
	(15)	0,43	-0,05	0,70	-0,11	0,51	-0,07	0,83	-0,17	0,58	-0,08	0,95	-0,17	0,62	-0,09	1,00	-0,13
	(16)	0,10	-0,08	-0,02	0,22	0,12	-0,12	-0,05	0,53	0,14	-0,14	-0,09	0,82	0,15	-0,16	-0,13	1,00

Tabla 4. 3 Matriz de correlación entre las bandas de textura seleccionadas variando la ventana móvil, con una relación espacial de (1,0).

La **Tabla 4. 3** muestra la matriz de correlación calculada entre las 4 variables de textura seleccionadas, orientación al oriente, distancia de 1 pixel de referencia, variando el parámetro de ventana móvil. Para realizar el análisis se tomó como base la primera matriz (ventana móvil 5x5) y se comparó con las demás (valores resaltados en rojo).

Aunque era de esperarse, éste es el parámetro que más cambios genera, ya que al aumentar el tamaño de la ventana móvil, muchos más datos entrarán en ella; por ende, a medida que sean mayores sus dimensiones, la correlación entre ellas será más baja.

- Las medidas que menos afecta el cambio de la variable son la **homogeneidad** y **el segundo momento angular**. Pero se deben tener en cuenta las variaciones.

- El **contraste** tiene un cambio medio-alto al realizar la variación del parámetro en mención.
- Como en los demás parámetros, el **contraste** tiene un alto grado de variación.

4.2 EXACTITUD TEMÁTICA

Al haber encontrado que el parámetro de dimensiones de ventana móvil, es el que genera cambios significativos, se decidió que dicha variable era la única que sería modificada en las múltiples clasificaciones, y con ayuda de la evaluación de exactitud temática, determinar qué valor de tamaño de ventana móvil era el más óptimo para el presente estudio.

4.2.1 PORCENTAJE DE CLASIFICACIÓN CORRECTA GENERAL

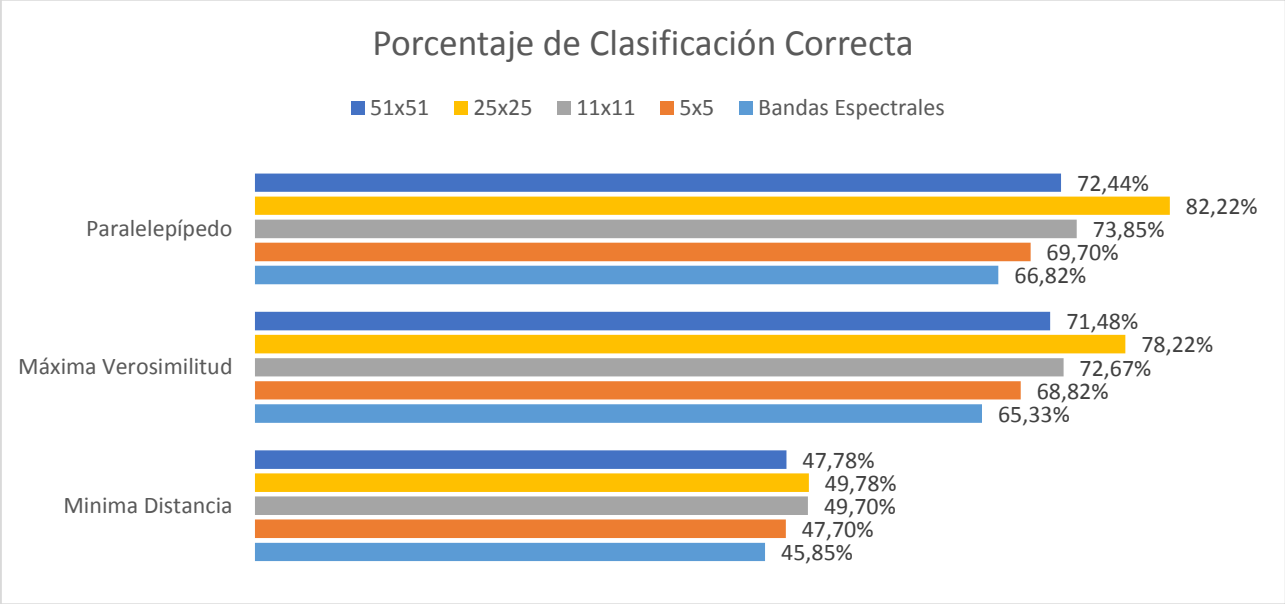


Figura 4. 1 Porcentaje de Clasificación correcta general de la clasificación de cobertura del suelo de los diferentes algoritmos supervisados.

La **Figura 4. 1** muestra los porcentajes de clasificación correcta que se obtuvo a partir de las clasificaciones de cobertura del suelo por el método supervisado, haciendo uso de los algoritmos de paralelepípedo, máxima verosimilitud y mínima distancia. Cada algoritmo se aplicó ingresando solamente las bandas espectrales y combinando estas últimas con las bandas de textura (se había optado por realizar clasificaciones solamente con las bandas de textura, como tercer grupo, pero al obtener resultados de exactitud menores al 30%, se descartó inmediatamente). Cada grupo de bandas de textura que ingresó a la clasificación fueron con los parámetros de relación espacial (1,0) y variando los tamaños de la ventana móvil entre 5x5, 11x11, 25x25 y 51x51.

- Los algoritmos de paralelepípedo y máxima verosimilitud son los que arrojaron mejores resultados.
- Combinando las bandas de textura junto a las espectrales, los resultados de clasificaciones siempre fueron iguales o mayores.
- Al incorporar las medidas de textura con la ventana móvil de 5x5, los resultados aumentaron en un bajo grado.

4.2.2 COEFICIENTE KAPPA GENERAL

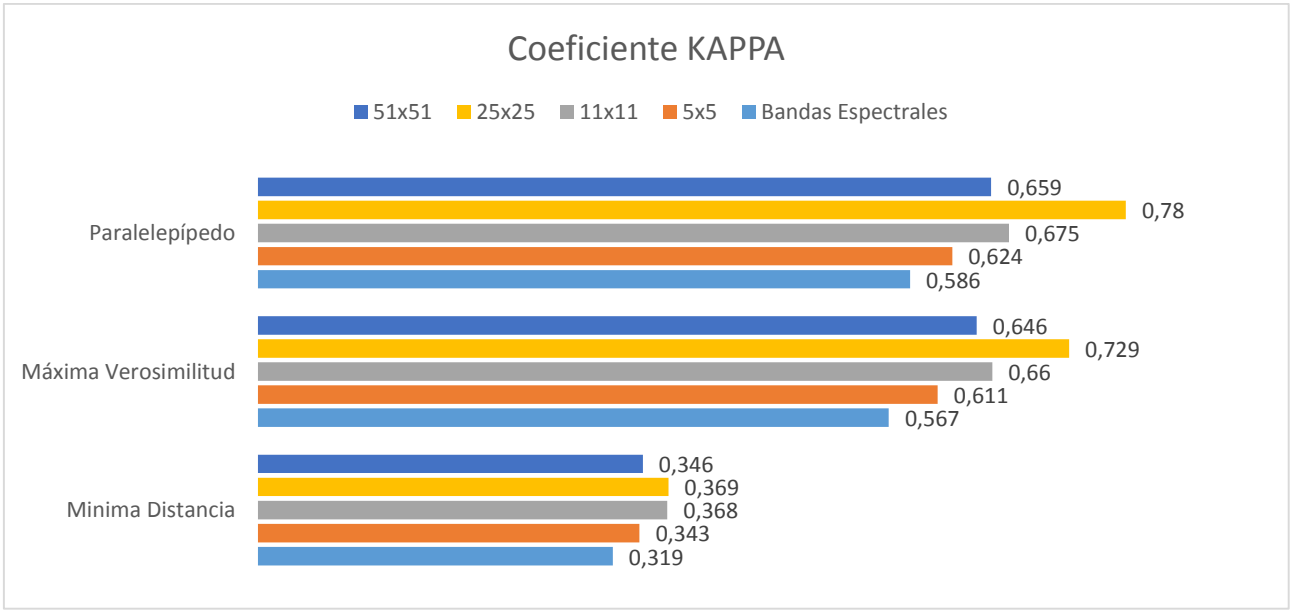


Figura 4. 2 Coeficiente KAPPA de la clasificación de cobertura del suelo de los diferentes algoritmos utilizados.

La **Figura 4. 2** muestra los coeficientes KAPPA que se obtuvieron a partir de las clasificaciones de cobertura del suelo por el método supervisado, haciendo uso de los algoritmos de paralelepípedo, máxima verosimilitud y mínima distancia. Cada algoritmo se aplicó haciendo uso de solamente las bandas espectrales y combinando estas últimas con las bandas de textura.

- El coeficiente más alto es de 0.78 lo que se traduce en que la clasificación realizada por el algoritmo de paralelepípedo con las bandas espectrales y de textura, es un buen resultado.

4.2.3 ALGORITMO DE PARALELEPÍPEDO

A continuación se presentan los resultados del proceso individual que obtuvo el mayor porcentaje de exactitud, el cual fue el algoritmo del paralelepípedo con máxima verosimilitud como criterio de desempate, usando las bandas espectrales junto con las de textura, las cuales se crearon con una relación espacial (1,0) y una matriz móvil de 25x25, generadas de la banda de infrarrojo cercano.

Clase	0	1	2	3	4	5	6	7	8	9	Total
0	**0**	6	1	0	1	1	2	4	1	2	18
1	0	**51**	4	3	2	3	2	1	1	2	69
2	0	3	**23**	0	0	0	5	2	9	1	43
3	0	5	0	**22**	0	0	0	0	0	6	33
4	0	0	0	0	**8**	0	0	0	0	0	8
5	0	0	0	0	0	**164**	7	3	0	1	175
6	0	0	0	0	0	10	**286**	3	5	0	304
7	0	3	0	1	0	12	55	**242**	40	5	358
8	0	0	0	0	0	0	16	6	**280**	0	302
9	0	3	1	1	0	0	0	1	0	**34**	40
Total	0	71	29	27	11	190	373	262	336	51	**1350**

Tabla 4. 4 Matriz de confusión de la clasificación supervisada por el algoritmo de paralelepípedo.[10]

[10] **Leyenda. 1:** Zonas Urbanizadas, **2:** Invernaderos, **3:** Zonas de extracción minera y escombrera, **4:** Cuerpos de agua, **5:** Pastos, **6:** Herbazales, **7:** Cultivos Transitorios, **8:** Bosques, **9:** Tierras sin o con poca vegetación.

La **Tabla 4. 4** muestra la matriz de confusión generada al evaluar la clasificación. Se puede detallar que la mayoría de puntos se encuentran en las clases correspondientes a la vegetación porque son las que predominan, en extensión, en la zona de estudio y porque era el objetivo central del proyecto.

4.2.4 EXACTITUD DEL PRODUCTOR

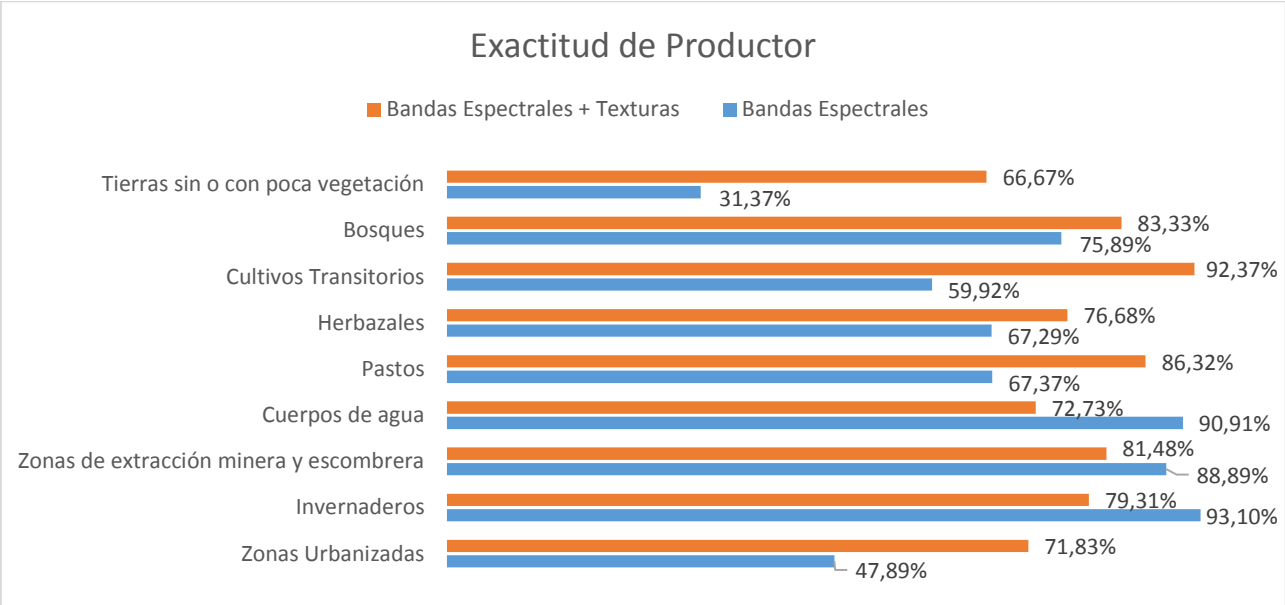


Figura 4. 3 *Exactitud del productor de la clasificación supervisada por el algoritmo de paralelepípedo de las bandas espectrales junto con las de textura.*

En la **Figura 4. 3** se pueden observar las diferencias de exactitud del productor que tuvo cada una de las coberturas. Las coberturas que tuvieron menos porcentaje de exactitud al incorporar las bandas de textura fueron zonas de extracción minera y escombrera, invernaderos y cuerpos de agua. Entre las demás coberturas siempre hubo un porcentaje igual o mayor al incorporarse las medidas.

4.2.5 EXACTITUD DEL USUARIO

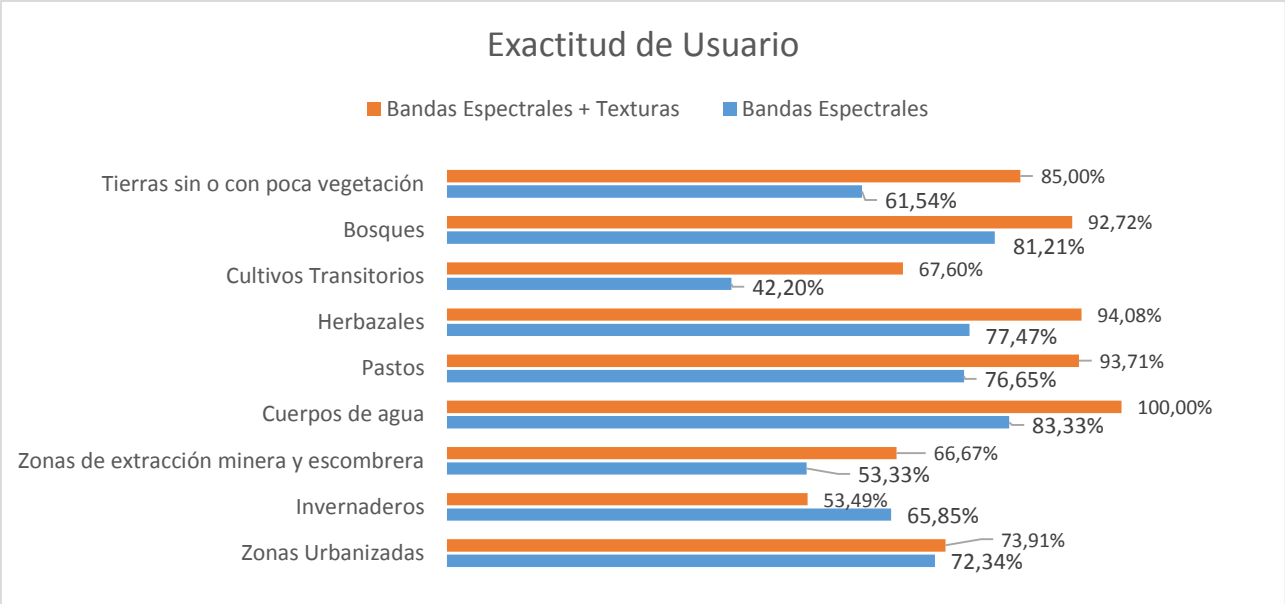


Figura 4. 4 Exactitud del usuario de la clasificación supervisada por el algoritmo de paralelepípedo de las bandas espectrales junto con las de textura.

En la **Figura 4. 4** se encuentran los porcentajes de exactitud del usuario que tuvo cada una de las coberturas. La única cobertura que tuvo menos porcentaje al incorporar las medidas de texturas fue la de invernaderos. Lo anterior se dio por las características espectrales y de textura que dicha clase tenía, generando confusión con las demás coberturas no vegetales.

Entre las demás coberturas siempre hubo un porcentaje o mayor al incorporarse las medidas de textura.

4.2.6 COEFICIENTE KAPPA

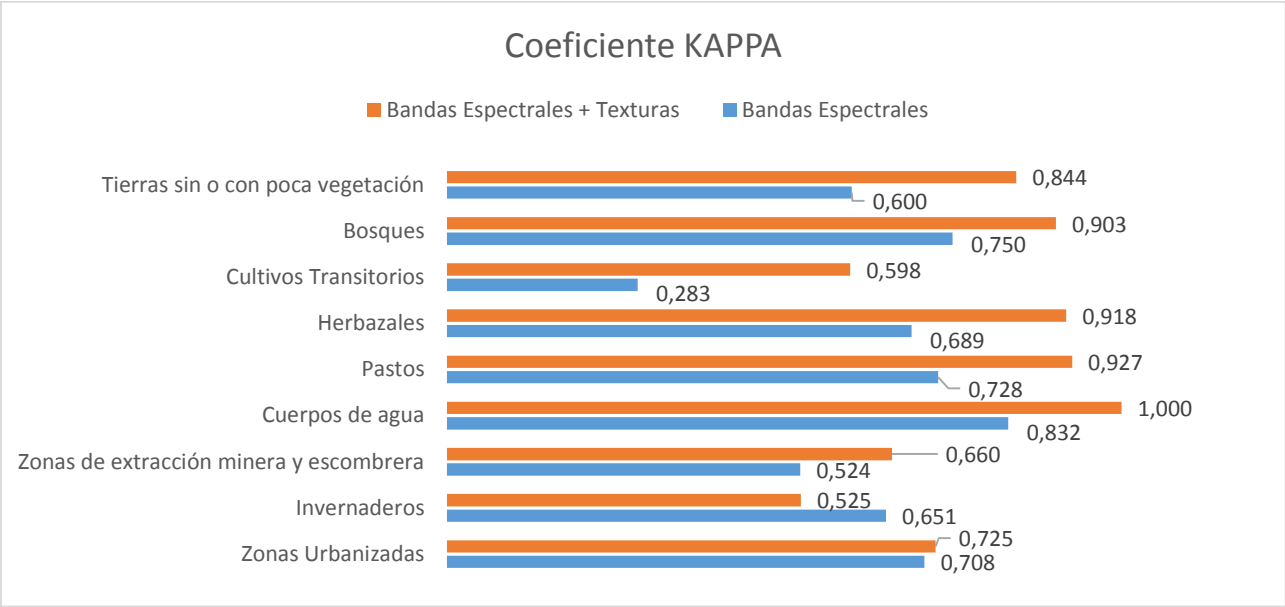


Figura 4. 5 Coeficiente KAPPA de la clasificación supervisada por el algoritmo de paralelepípedo de las bandas espectrales junto con las de textura.

En la **Figura 4. 5** se encuentran las diferencias del coeficiente KAPPA que tuvo cada una de las coberturas. La única cobertura que tuvo menos coeficiente cuando se incorporaron las bandas de textura fue la de invernaderos. Entre las demás coberturas siempre hubo un valor igual o mayor al incorporarse las medidas de textura.

DISCUSIÓN

A continuación se describen todos los puntos que se consideran importantes exponer acerca de los procesos y resultados obtenidos a lo largo del desarrollo del proyecto; cada uno de éstos se especifica por proceso general realizado.

ORTORECTIFICACIÓN

El certificado de calibración de la cámara adquirido no contenía todos los datos necesarios para ser ingresados en el programa utilizado; así que se asumió que la cámara “no tenía errores” de distorsión de la lente y distorsión radial (los datos ingresados tenían un valor de cero), y aun así, el resultado del proceso fue mejor que el esperado (**Tabla 3. 11** y **Tabla 3. 12**).

Aunque se utilizó Google Earth para obtener las coordenadas de los puntos de control, dicha fuente puede arrojar grados variables de confianza, ya que no todas las imágenes contenidas allí son de alta resolución espacial, generando que en algunos casos, los errores finales sean más altos.

El modelo digital de elevación fue fundamental para obtener los resultados positivos del proceso de ortorectificación; y aunque éste fue sometido a una interpolación, aumentando su resolución significativamente, no generó disparidad notable a la realidad ya que la zona de estudio no tiene cambios topográficos abruptos cada 30 metros (**Figura 3. 3**), que era la resolución original del modelo utilizado.

Como el proceso de toma de puntos de control fue realizado rigurosamente, fue suficiente con calcular automáticamente los puntos de amarre entre todas las imágenes utilizadas. De igual forma, se verificaron los errores medios cuadráticos de dicho proceso, y se ajustaban fácilmente al rango permitido (**Tabla 3. 12**).

El proceso de ortorectificación, que si bien no obtuvo la exactitud que un proceso general de estos conlleva, se consiguió un error medio cuadrático bajo, teniendo en cuenta la

finalidad y los datos disponibles para llevar a cabo el proyecto. Los únicos datos privados usados en todo el proyecto fueron las aerofotografías.

PARÁMETROS DE HARALICK

Los análisis de textura, en procesos de clasificación de imágenes de alta resolución espacial, proporcionan información espacial valiosa, ya que al poder manipular diferentes parámetros, en el cálculo de la matriz de co-ocurrencia de niveles de grises, se pueden crear múltiples bandas de textura, las cuales están basadas en la información del vecindario, que, junto a las bandas espectrales, asegura un mejor porcentaje de clasificación en zonas donde se evidencia homogeneidad espectral en distintas coberturas.

Al aumentar las dimensiones de la ventana móvil, se incorpora, proporcionalmente, información espacial; dando como resultado, mejoras en los porcentajes de clasificación de la cobertura del suelo. Sin embargo, hay un punto donde la precisión empieza a disminuir. Esto se da cuando la ventana móvil tiene dimensiones altas, generando que la información contenida se distorsione por la gran cantidad de píxeles vecinos que se incluyen en los cálculos de las nuevas bandas de textura.

Existen diferentes parámetros que se deben fijar para calcular bandas de textura por el método de matriz de co-ocurrencia propuesto por (Haralick, 1973) (Haralick & Shanmugam, 1974). La mayoría de dichos parámetros no afectó en gran medida el resultado de la nueva banda de textura cuando son originadas a partir de las bandas espectrales de alta resolución espacial. El parámetro, dependiendo de su valor asignado, que genera diferentes y notorios resultados, es el tamaño de la matriz o ventana móvil.

La gran mayoría de medidas de textura están correlacionadas entre sí en un alto grado; por esto, se descartaron más de la mitad de ellas, para no generar redundancia en las bandas que entraron en el proceso de clasificación de cobertura del suelo.

Al momento de crear nuevas bandas de textura a partir de la matriz de co-ocurrencia, se deben tener consideraciones entre los parámetros a elegir. Esto es; si se desea utilizar

una distancia de pixel alta, en referencia a la ventana móvil, se debe tener en cuenta que generará que muchos píxeles no tengan información, por el parámetro ingresado, dando un resultado que carece de datos espaciales. Dando como resultado, bandas de textura con información ambigua.

Así como expresa (Maillard, 2003). Dentro de las medidas recomendadas, **el segundo momento angular**, **el contraste** y **la correlación**, son de las medidas sobresalientes en todo el grupo propuesto por Haralick, por su baja correlación con las demás y por la información que proveen. Por otro lado no se incluye la **homogeneidad**; sin embargo se encontró que ésta es una medida que aporta información útil al momento de realizar clasificaciones de cobertura del suelo.

En todas las pruebas y análisis de correlación entre las medidas de texturas seleccionadas, la medida **contraste** es la que más variabilidad genera al cambiar alguno de los parámetros. Lo anterior se da por la ecuación que se utiliza para el cálculo de la misma, que puede ser consultada en la **Tabla 2. 2**.

Aunque se utilizaron ordenadores de tipo medio-alto, dentro de un rango de usuarios comunes, las características de espacio en disco duro, velocidad en procesador y cantidad de memoria, fueron fundamentales para el cálculo de las bandas de textura en términos de tiempos de respuesta y espacio de almacenamiento, porque son procesos que consumen recursos considerables dentro del tipo de máquinas señaladas.

CLASIFICACIÓN DE COBERTURA DEL SUELO

El sistema de clasificación adoptado fue diseñado para escalas 1:100.000 (modificación de Corine Land Cover Nivel 2) (**Tabla 3. 7**), y aunque las aerofotografías tienen una alta resolución espacial (0.3 metros), se eligió dicho sistema ya que de haber seleccionado uno para una escala menor, como Corine Land Cover Nivel 3, hubiera sido necesario la incorporación de conocimientos y/o profesionales de otros perfiles académicos como Ingenieros Forestales, Ingenieros Ambientales, entre otros, para poder identificar y evaluar correctamente las coberturas que estuvieran fuera del alcance de la formación académica de los integrantes del proyecto. De igual forma, el sistema en adoptado

caracterizó las coberturas que eran necesarias para aplicar los objetivos propuestos de manera satisfactoria.

En los procesos de toma de datos en campo, polígonos de entrenamiento y evaluación de exactitud temática, se encuentra un grado considerable de subjetividad, ya que la información proveniente del análisis interpretativo visual de los integrantes del proyecto es alta. Lo anterior fue necesario porque entre la toma de imágenes y la verificación en campo, hay una diferencia de más de 5 años; por ende, gran parte de las coberturas no podían entrar en los datos de validación por la susceptibilidad de cambio a través del tiempo que tenían.

Para realizar las clasificaciones de cobertura del suelo se descartó el método de clasificación no supervisada ya que este método requiere necesariamente de procesos de post-clasificación puntuales para cada una de las clasificaciones, generando desigualdad en los resultados, desde el punto de vista de una única metodología usada; y con esto, se hubiera perdido el punto parcial para la validación de las exactitudes de clasificación.

VALIDACIÓN

Creando bandas de textura con un valor de dimensiones de ventana móvil bajo (5x5 para el caso del proyecto), el aumento de nueva información es casi nulo ya que la información espacial, la cual es la ventaja de la técnica de texturas, se minimiza por la poca información que puede incluir las matrices de dicho tipo, y más aún en imágenes de alta resolución donde cada cobertura contiene gran cantidad de píxeles.

Al aumentar en gran proporción la ventana móvil (51x51 para el caso del proyecto) el problema de bordes entre clases crece de manera proporcional ya que cada pixel de estudio estará relacionado con una cantidad considerable de píxeles que lo rodean, y al llegar el momento del cálculo los datos limítrofes entre clases, se presentan problemas para definir correctamente a qué clase corresponden. Por esto, es necesario, dependiendo de las características del estudio, encontrar un valor de ventana móvil intermedio en el cual pueda incorporar información espacial suficiente para el objetivo a cumplir sin provocar problemas notorios entre los límites de las clases clasificadas.

El porcentaje de clasificación correcta más alto obtenido fue de 82.22 %, haciendo uso del algoritmo de paralelepípedo con máxima verosimilitud como criterio de desempate (**Anexo G**), con el grupo que comprende las bandas espectrales y de texturas calculadas con una ventana móvil de 25x25, lo cual es un resultado bueno, teniendo en cuenta que la zona de estudio que se eligió cumplía con las características de presencia de diferentes coberturas vegetales. El resultado no pudo ser más alto, ya que en los resultados de clasificación hubo confusión entre las clases de zona de extracción minera y escombrera, zonas sin o con poca vegetación presente e invernaderos, por sus características espectrales y de textura. Además, no se realizaron post-procesos adicionales al filtro de moda, para conservar un punto de comparación.

La incorporación de bandas de textura, usando cualquier algoritmo de clasificación supervisada, aumentó la exactitud de clasificación correcta general, y sobre todo de las coberturas vegetales. Pero el grado de aumento de exactitud se vio reflejado en la variación del parámetro de dimensión de ventana móvil para el cálculo de las bandas de textura, para el cual, siendo bajo, la información adicional fue insignificante; y, siendo alto, se detallaron grandes problemas de bordes entre clases. El punto medio se encontró con una ventana móvil de 25x25.

Las sombras que generaban los distintos objetos presentes en la zona de estudio generaron errores en algunas coberturas, sobre todo en las no vegetales, que tendían a confundirse con las coberturas de cuerpos de agua.

CONCLUSIONES

Se comprobó que al combinar las bandas de textura con la información espectral, en procesos de clasificación de cobertura del suelo, en zonas donde se dificulta diferenciar clases que tienen semejanzas espectrales, las precisiones de clasificación aumentan considerablemente (**Figura 4. 1**).

De los diferentes parámetros que se deben seleccionar para la creación de las bandas de textura, la dimensión de la ventana móvil es el que genera mayor impacto a la hora de la creación de las bandas. Pero así mismo, se debe tener en cuenta la elección de los parámetros en su conjunto. Por ejemplo, un valor de distancia de pixel grande, respecto a la ventana móvil, generará resultados no deseados, ya que se está perdiendo información espacial porque gran cantidad de píxeles no entrarían en el cálculo de la medida por los parámetros iniciales.

El porcentaje de clasificación correcta por los métodos convencionales utilizando el algoritmo de paralelepípedo con máxima verosimilitud como criterio de desempate, en el mejor de los casos, fue del 66.82%. Al incorporar las imágenes de textura, con tamaño de ventana móvil de 25x25 y relación espacial (1,0), la precisión fue de 82.22%; es decir, hubo un aumento del 15.40 %.

Para crear las bandas de textura se deben utilizar, en lo posible, ventanas móviles medianas-grandes, lo cual está sujeto a la resolución espacial de la imagen y a la unidad mínima cartografiable, ya que cuando se hace uso de ventanas con pequeñas dimensiones, la información espacial, que es el fuerte de ésta técnica, es mínima; lo que generaría un aumento nulo o insignificante en el uso de texturas. Sin embargo, si el tamaño de dicha ventana es exageradamente grande, los resultados se verían afectados por los problemas de bordes entre las coberturas clasificadas.

Muchas de las medidas de textura propuesta por (Haralick, 1973) (Haralick & Shanmugam, 1974) están altamente correlacionadas entre sí, generando redundancia si se utilizan conjuntamente.

Implementar la técnica de texturas no genera un aumento no justificado de recursos y sus resultados pueden llegar a ser significativamente superiores respecto al uso de las bandas espectrales únicamente.

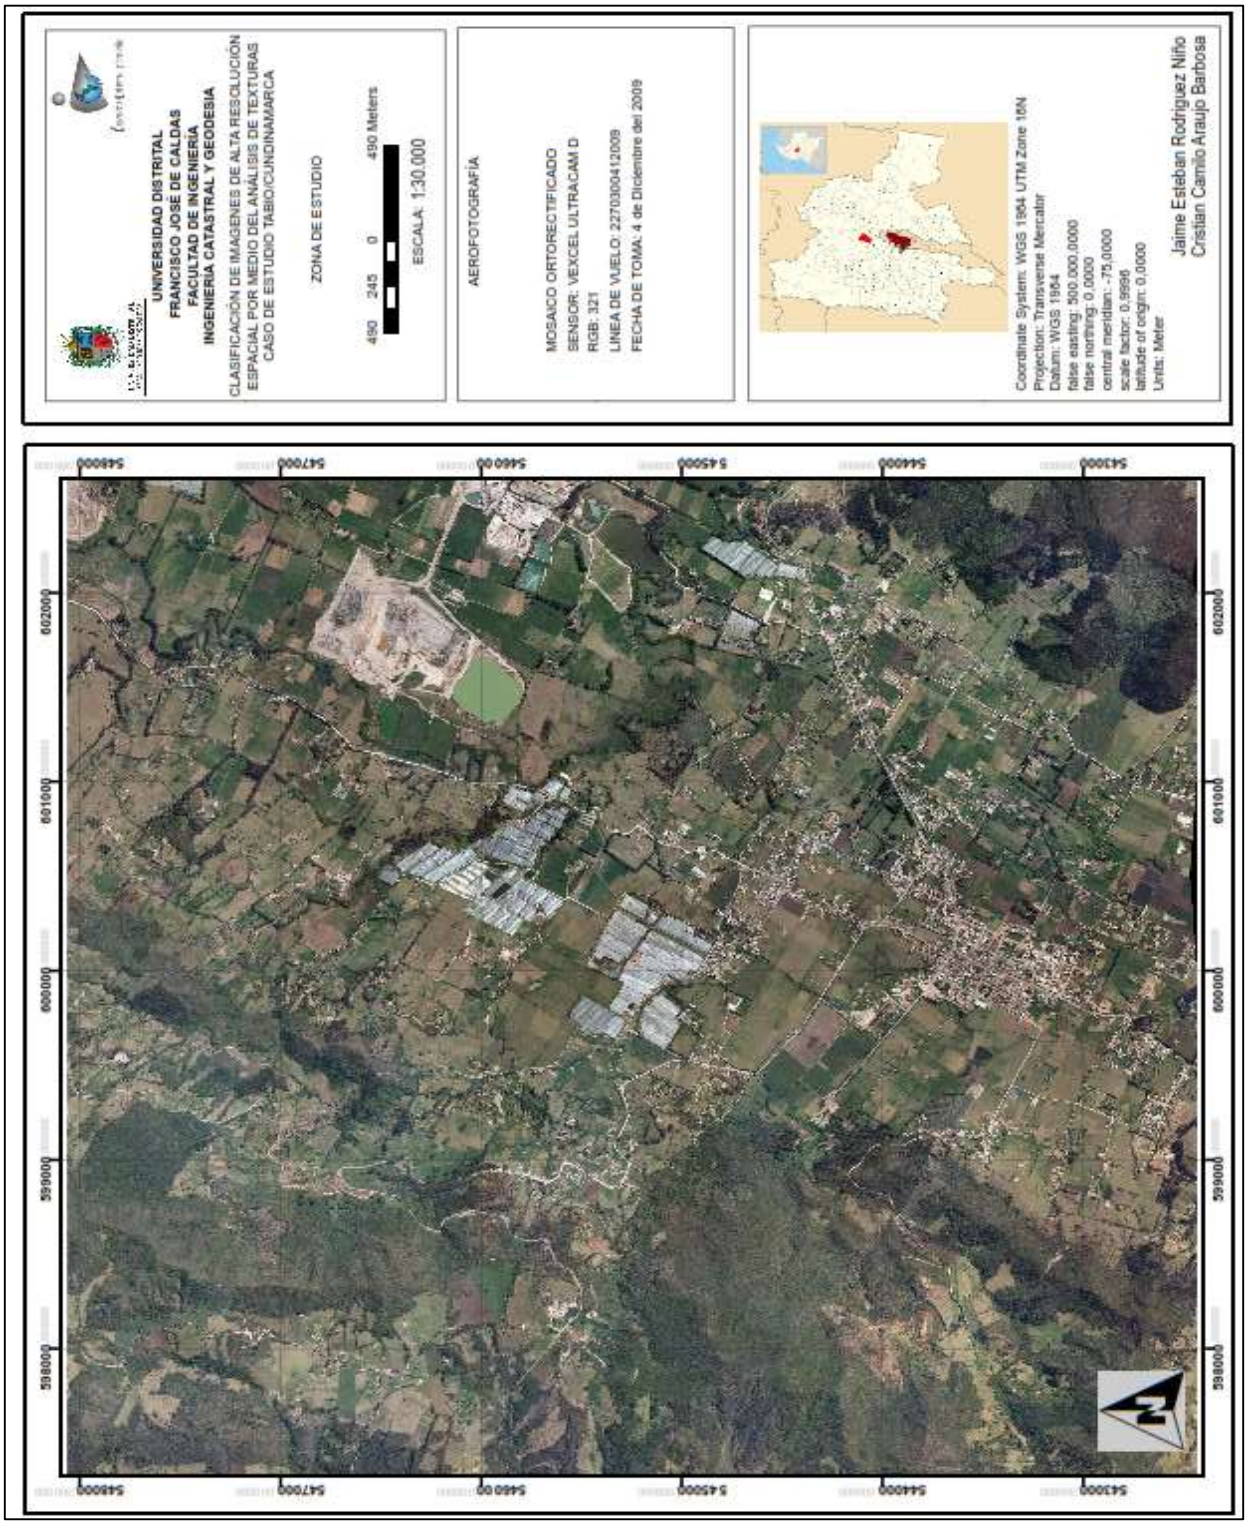
La respuesta espectral del pixel continúa siendo la información principal, ya que a partir de allí es que se crean las bandas de textura. Además, al realizar una clasificación supervisada, haciendo uso de la información de texturas solamente, los resultados son pobres.

Aunque a medida que avanza la tecnología, el espacio en disco ha venido aumentando, se debe tener en cuenta que el uso de la técnica de textura requiere una cantidad considerable del mismo, ya que cada banda puede llegar a ocupar el mismo o incluso más espacio que cada banda de la imagen multiespectral que se vaya a procesar.

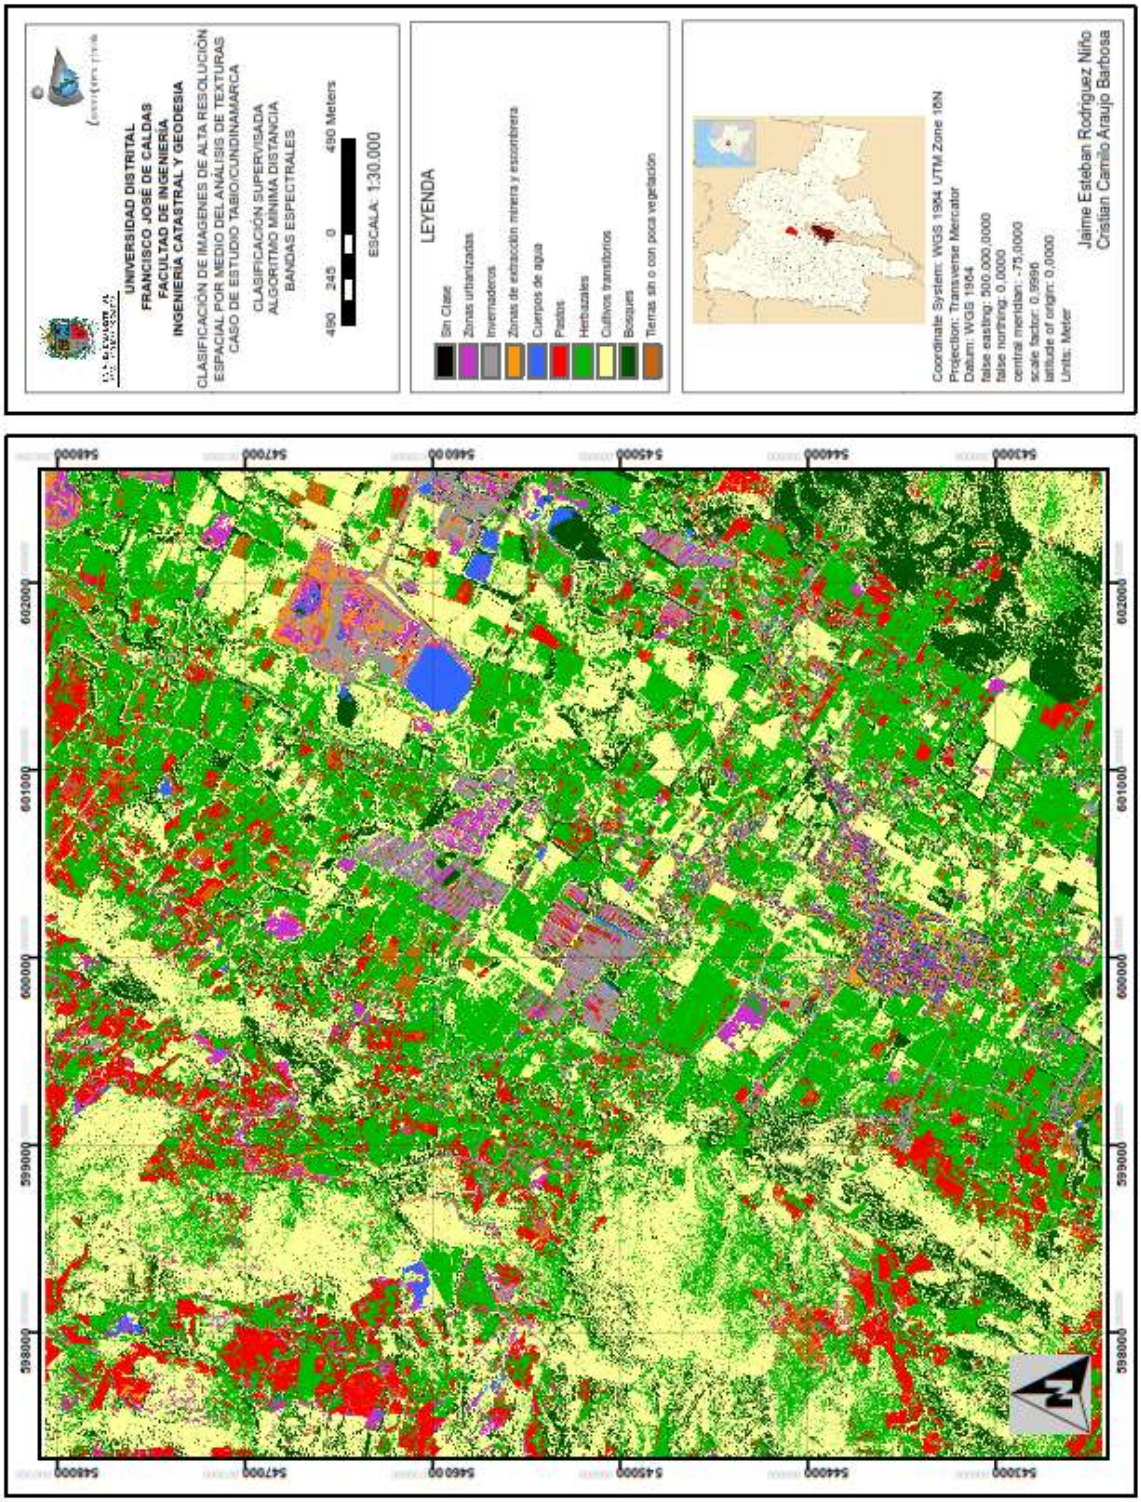
Se pueden realizar ortorectificaciones con precisiones aceptables, dependiendo del objetivo final, sin necesidad de datos privados; exceptuando las imágenes digitales, si es el caso. Sin embargo, se debe tener en cuenta que el procedimiento se podría llevar a cabo en algunos casos. La ortorectificación realizada se trabajó con imágenes de alta resolución espacial, y las coordenadas de los puntos de control fueron tomadas de Google Earth, los cuales se adaptaron correctamente al proceso ya que las imágenes allí contenidas, correspondientes a la zona de estudio, también eran de alta resolución espacial, por lo que cada punto era plenamente identificable. Como dicho visualizador está compuesto por imágenes de diferentes resoluciones espaciales, puede que no sea viable aplicar la metodología planteada en zonas donde las imágenes sean de baja resolución espacial.

ANEXOS

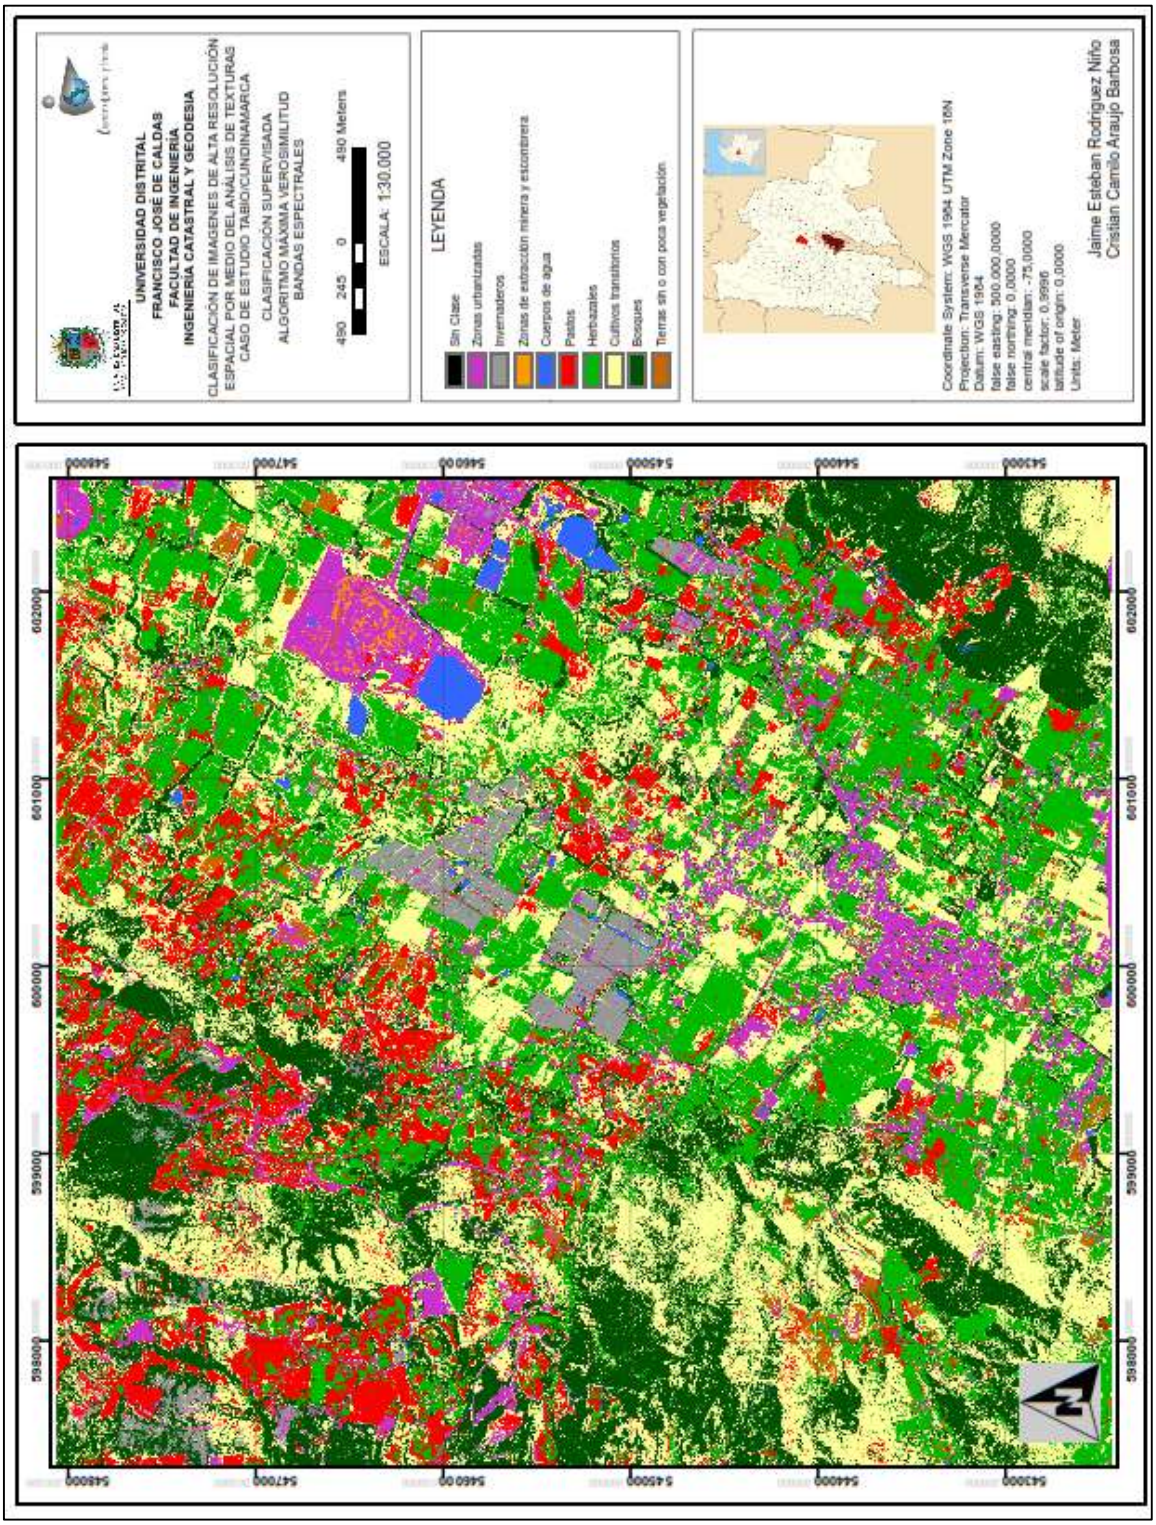
A. Mapa de zona de estudio en imagen multiespectral combinación RGB (321).



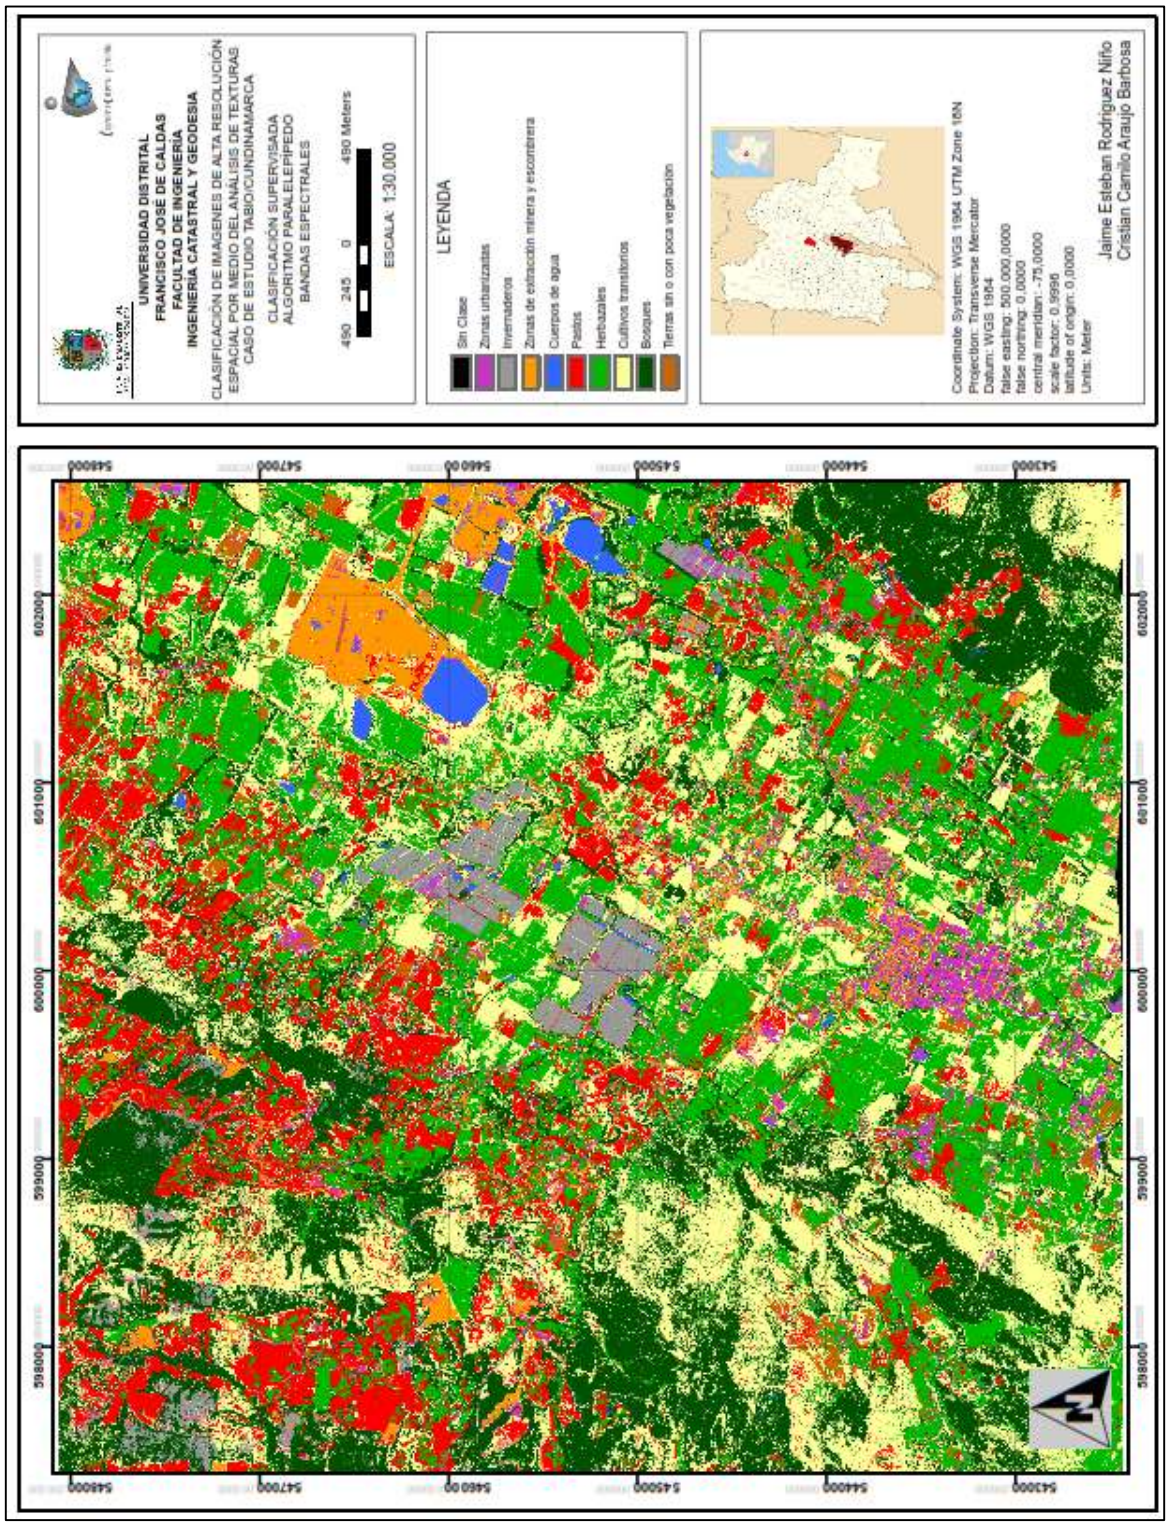
B. Mapa de Clasificación Supervisada por el algoritmo de Mínima Distancia con bandas espectrales.



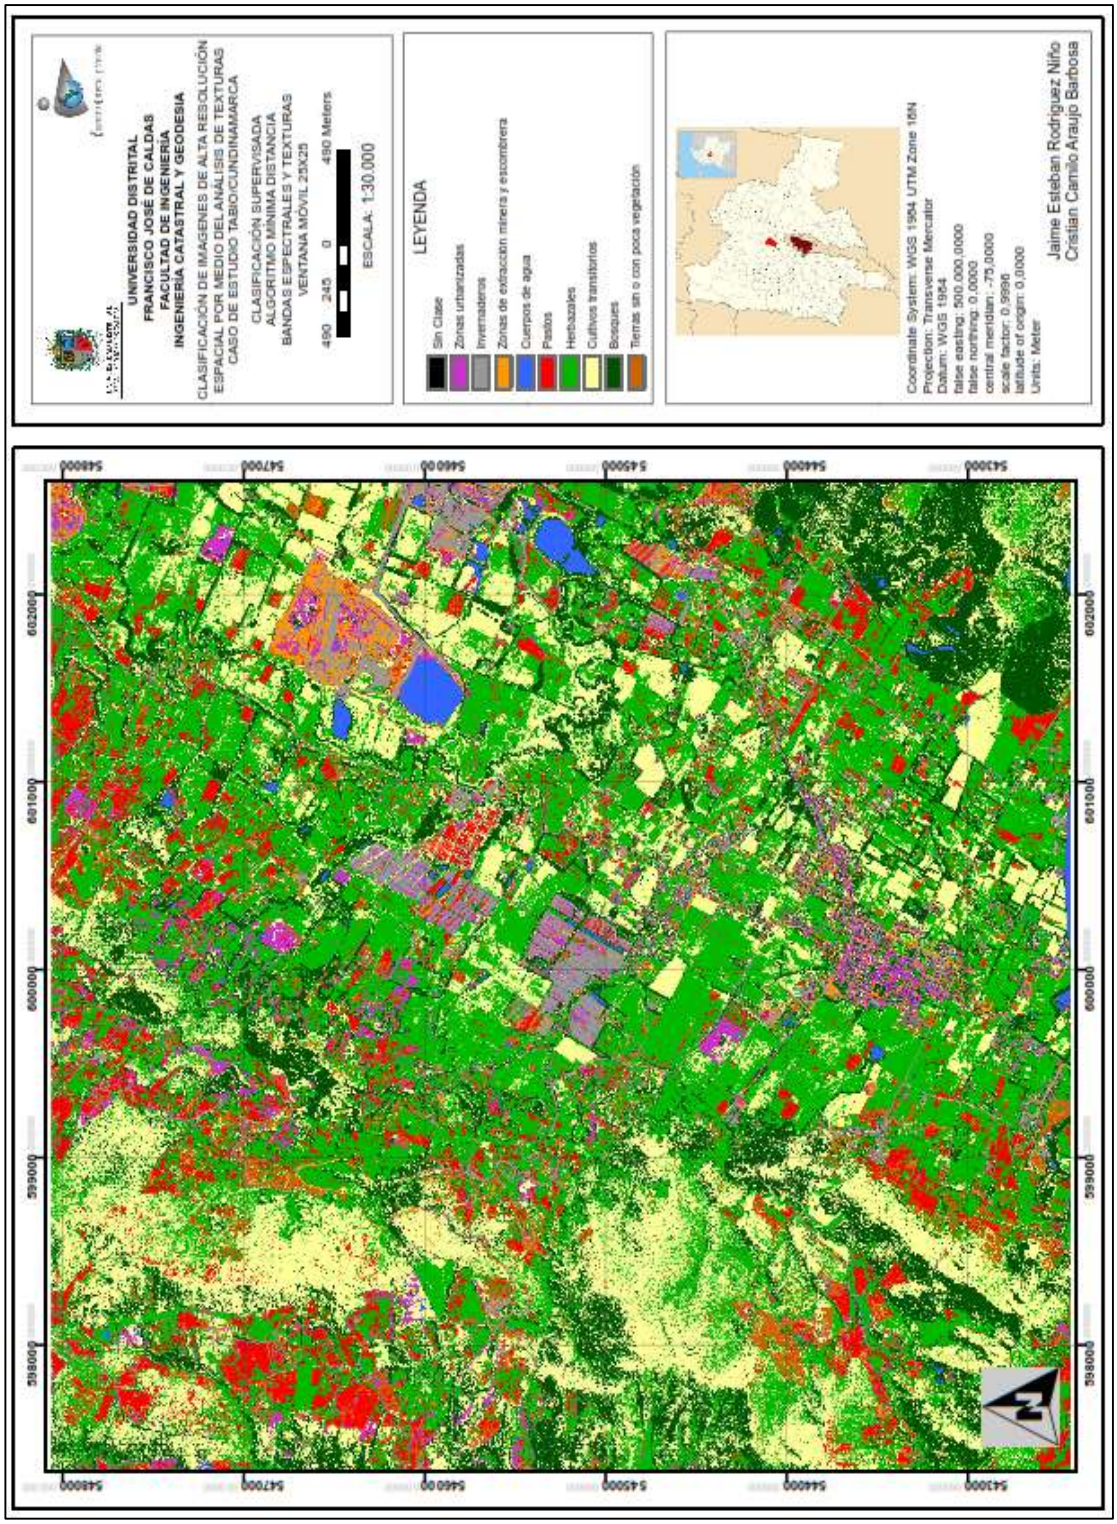
C. Mapa de Clasificación Supervisada por el algoritmo de Máxima Verosimilitud con bandas espectrales.



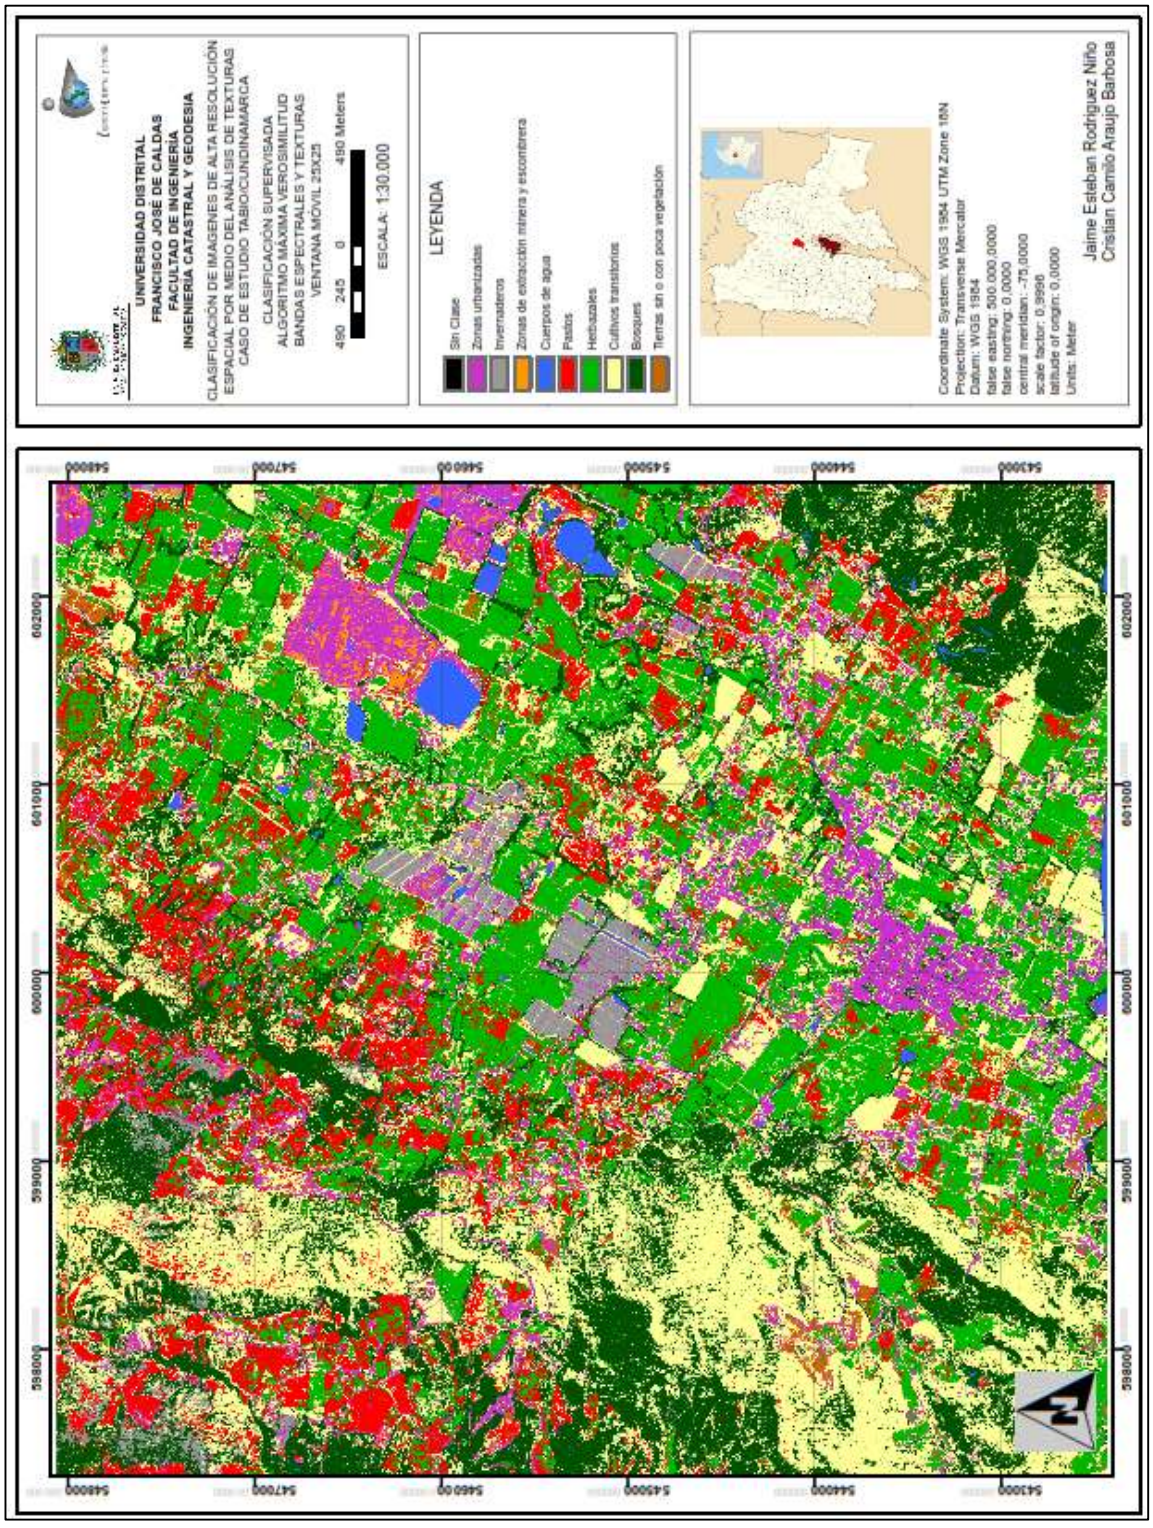
D. Mapa de Clasificación Supervisada por el algoritmo de Paralelepípedo con Máxima Verosimilitud como criterio de desempate con bandas espectrales.



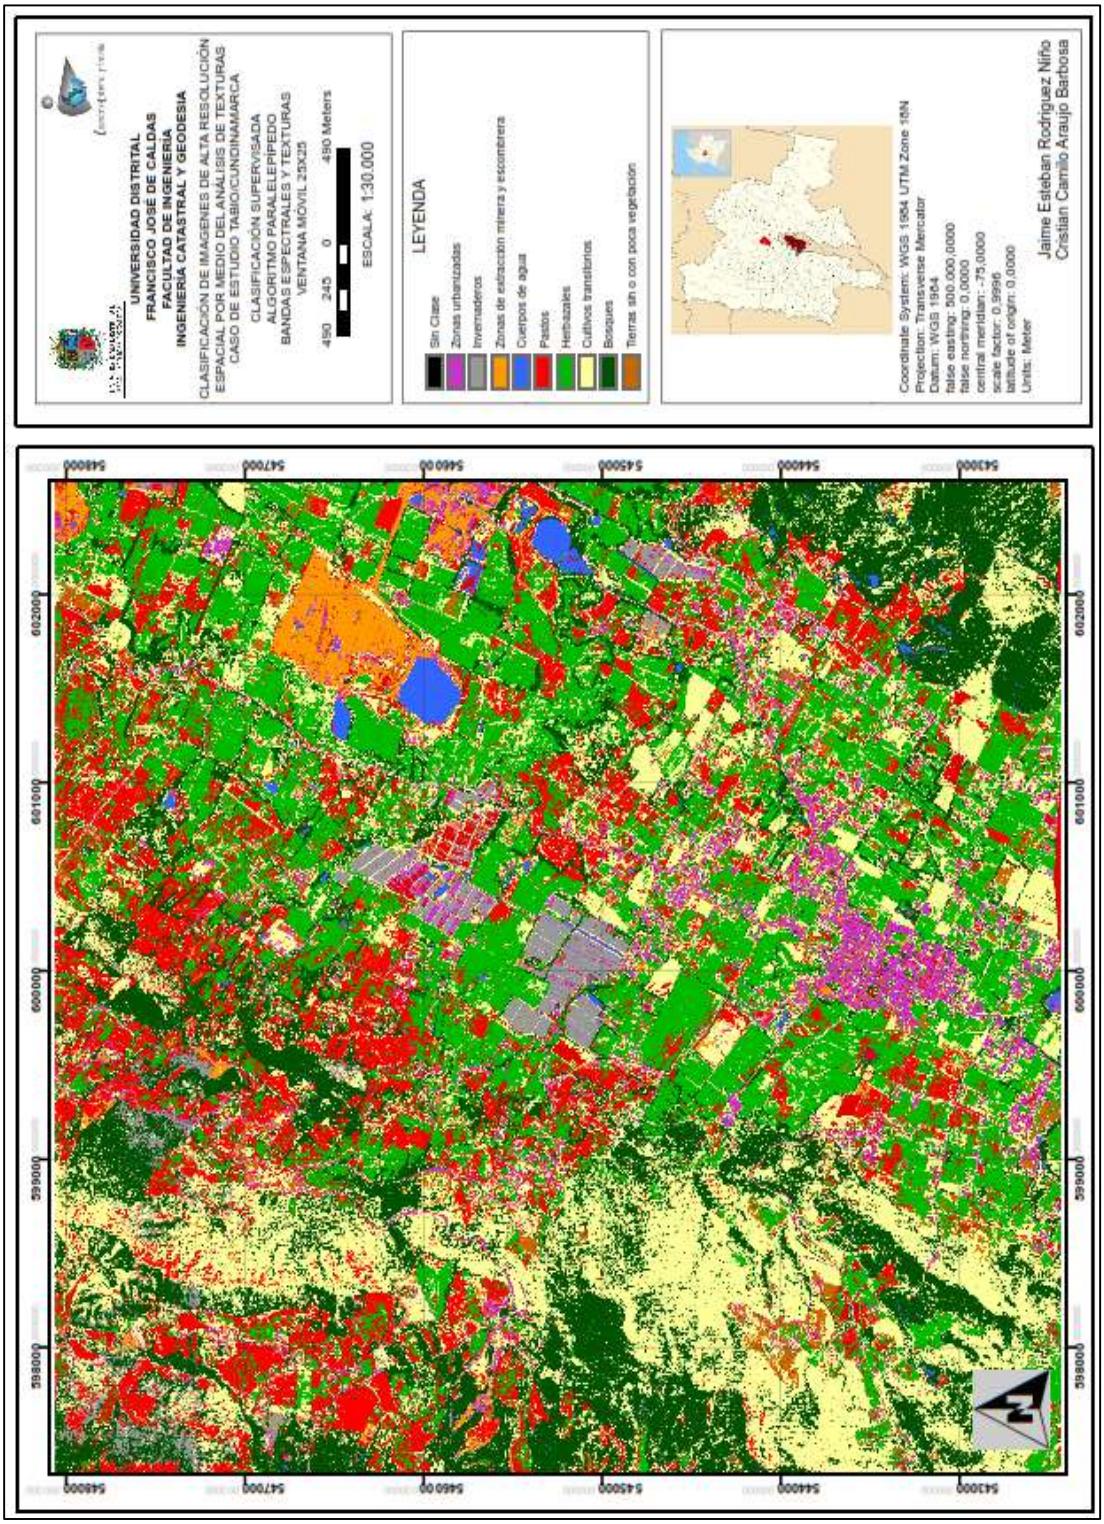
E. Mapa de Clasificación Supervisada por el algoritmo de Mínima Distancia con bandas espectrales y texturas con ventana móvil de 25x25.



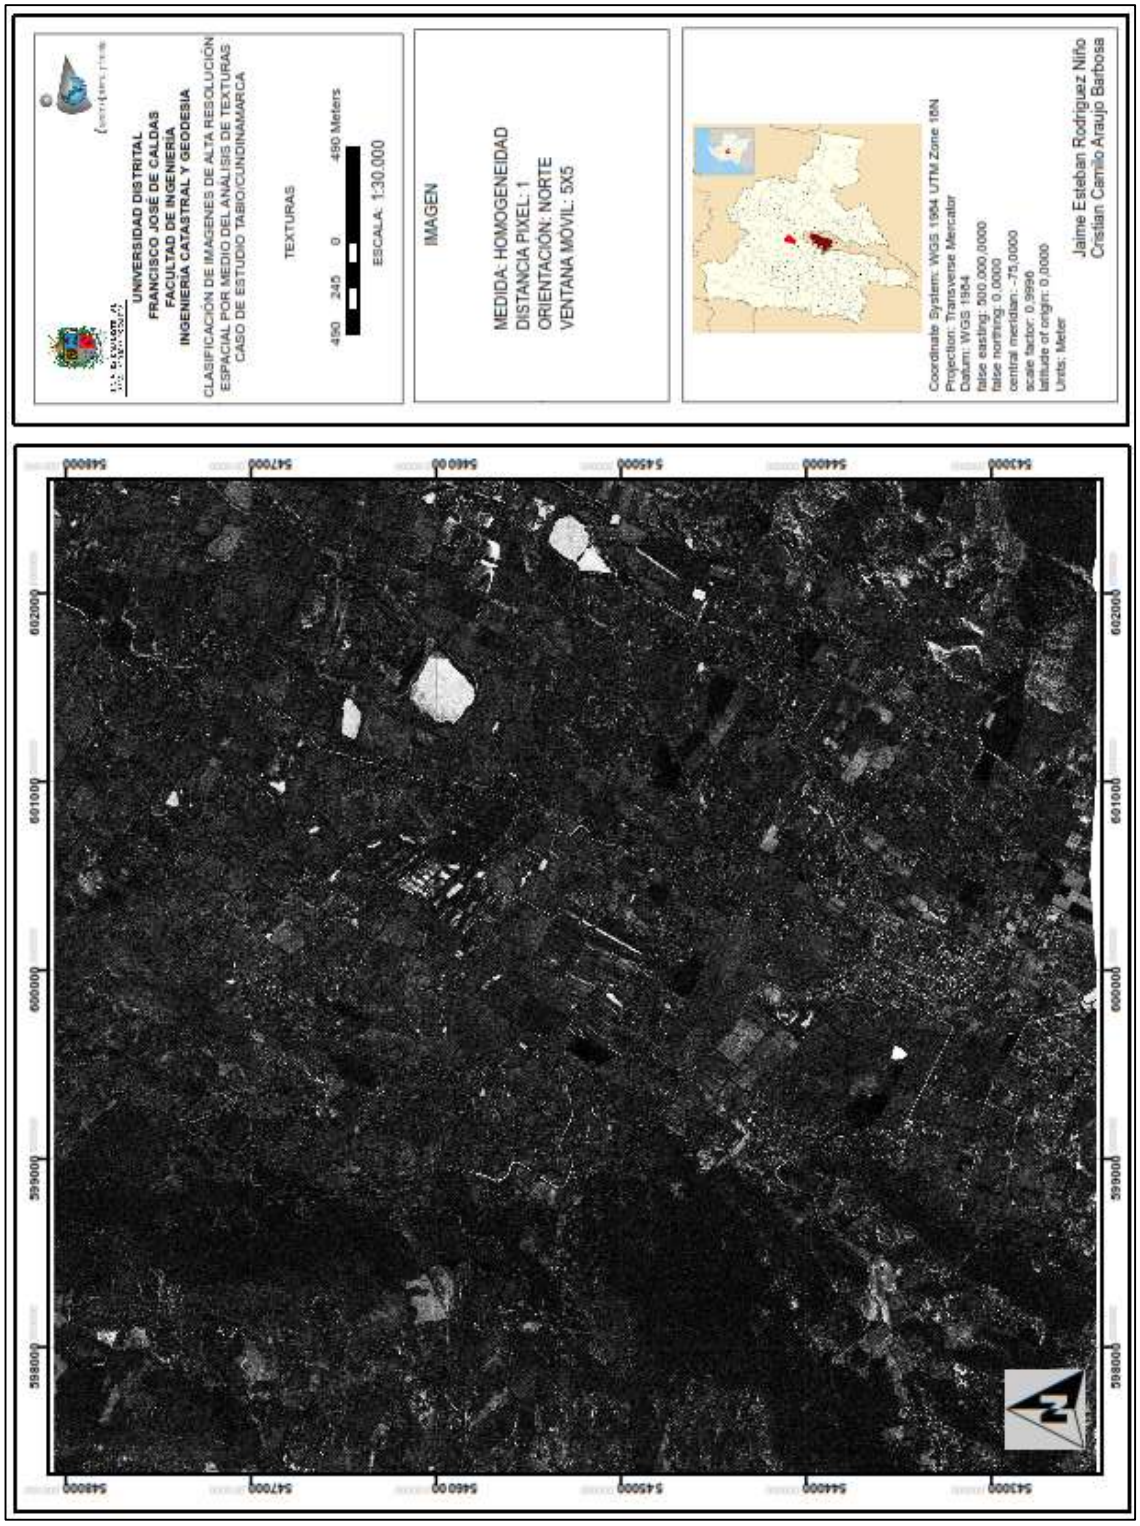
F. Mapa de Clasificación Supervisada por el algoritmo de Máxima Verosimilitud con bandas espectrales y texturas con ventana móvil de 25x25.



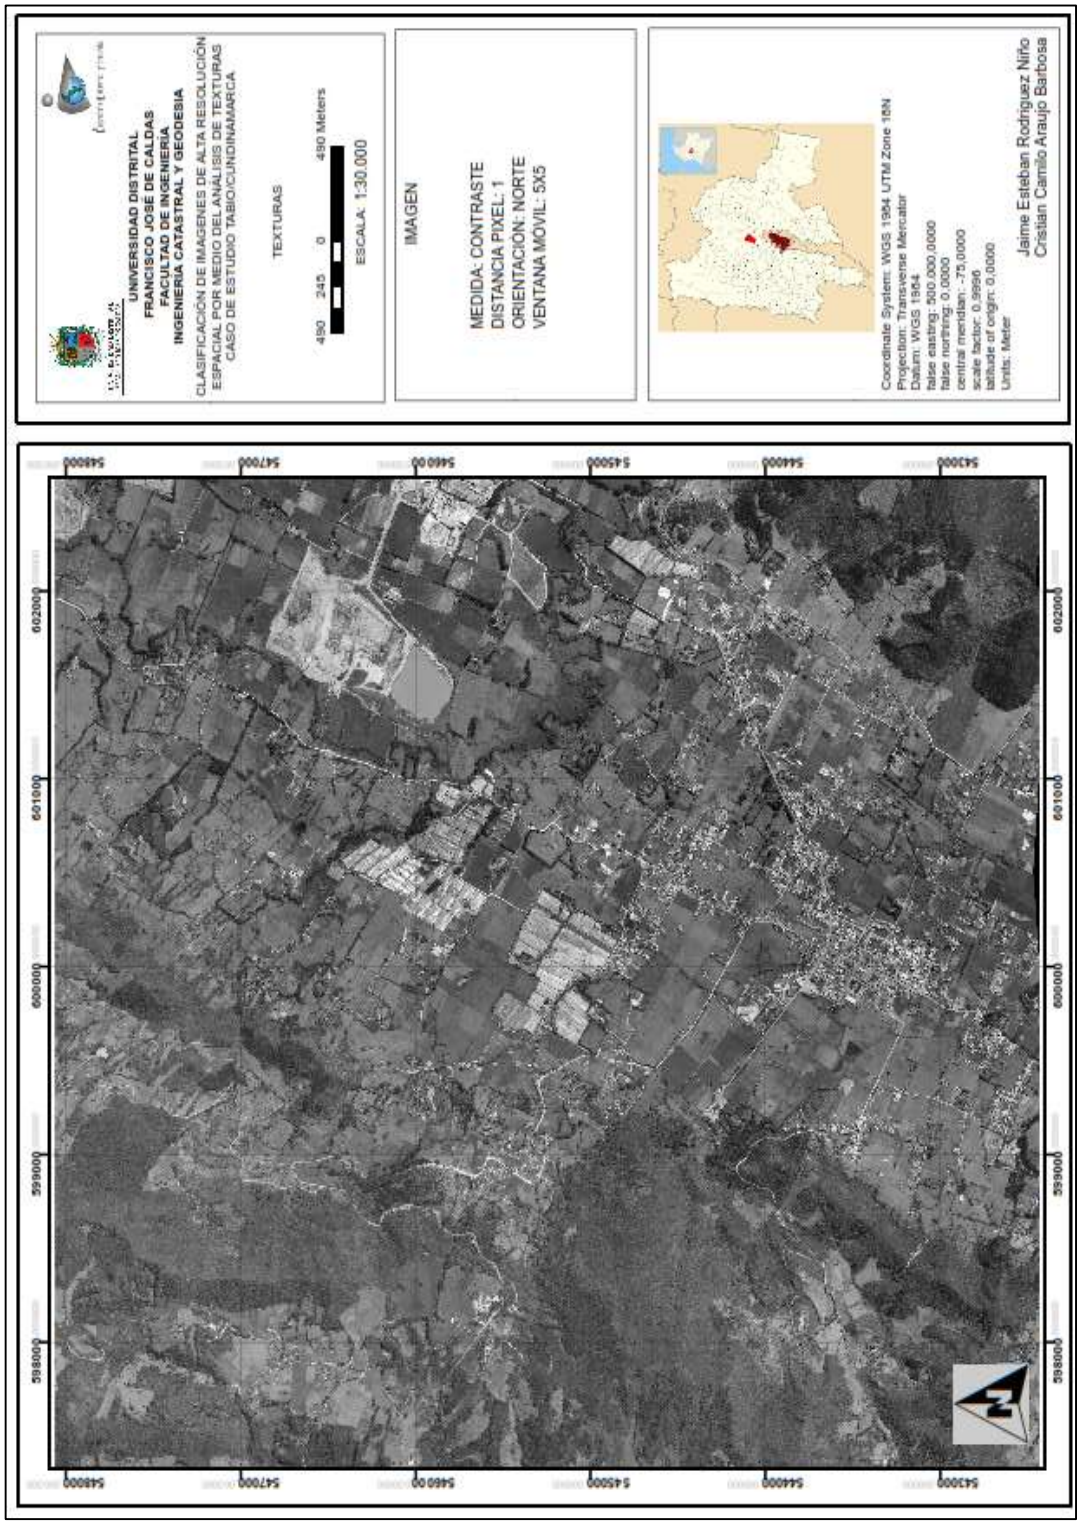
G. Mapa de Clasificación Supervisada por el algoritmo de Paralelepípedo con Máxima Verosimilitud como criterio de desempate con bandas espectrales y texturas con ventana móvil de 25x25.



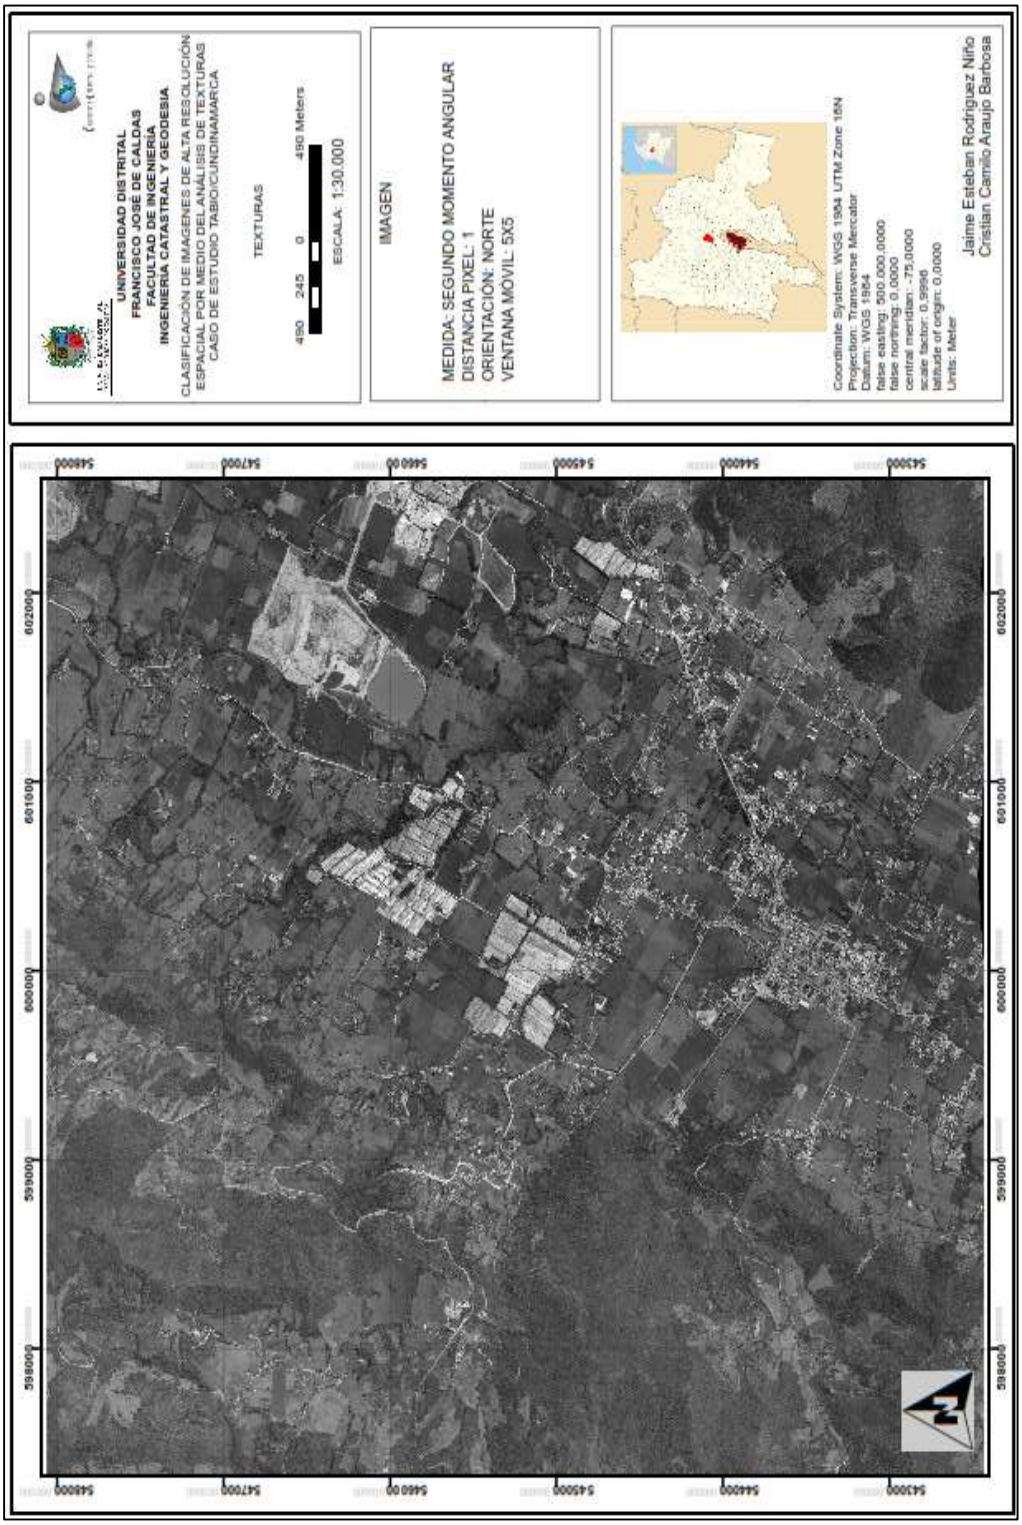
H. Mapa de Banda de Textura de Homogeneidad con relación espacial (0,1) y ventana móvil de 25x25.



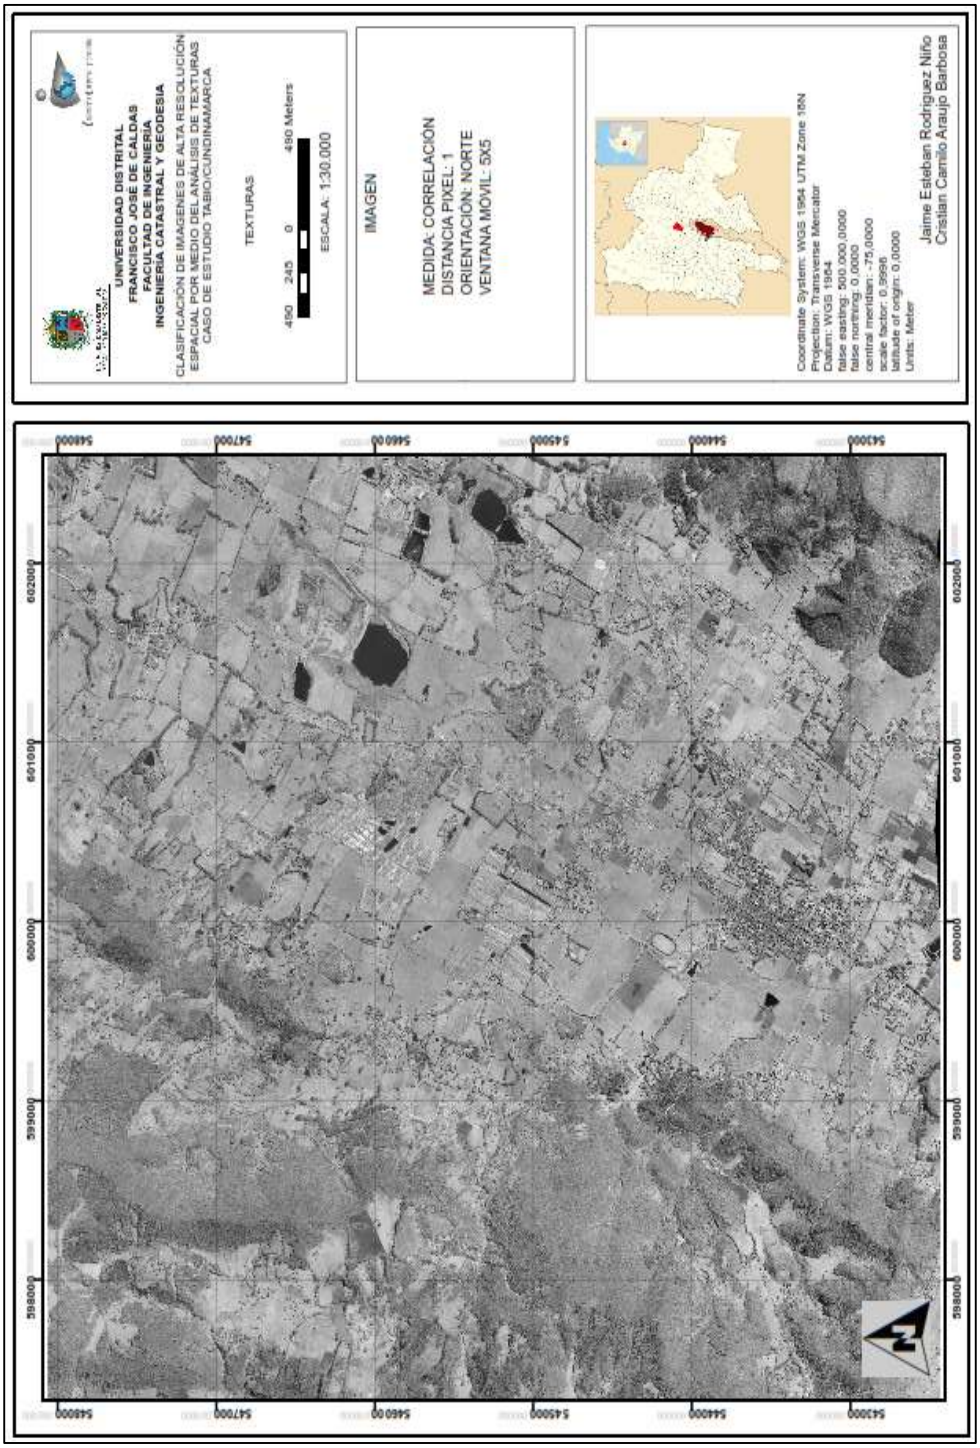
I. Mapa de Banda de Textura de Contraste con relación espacial (0,1) y ventana móvil de 25x25.



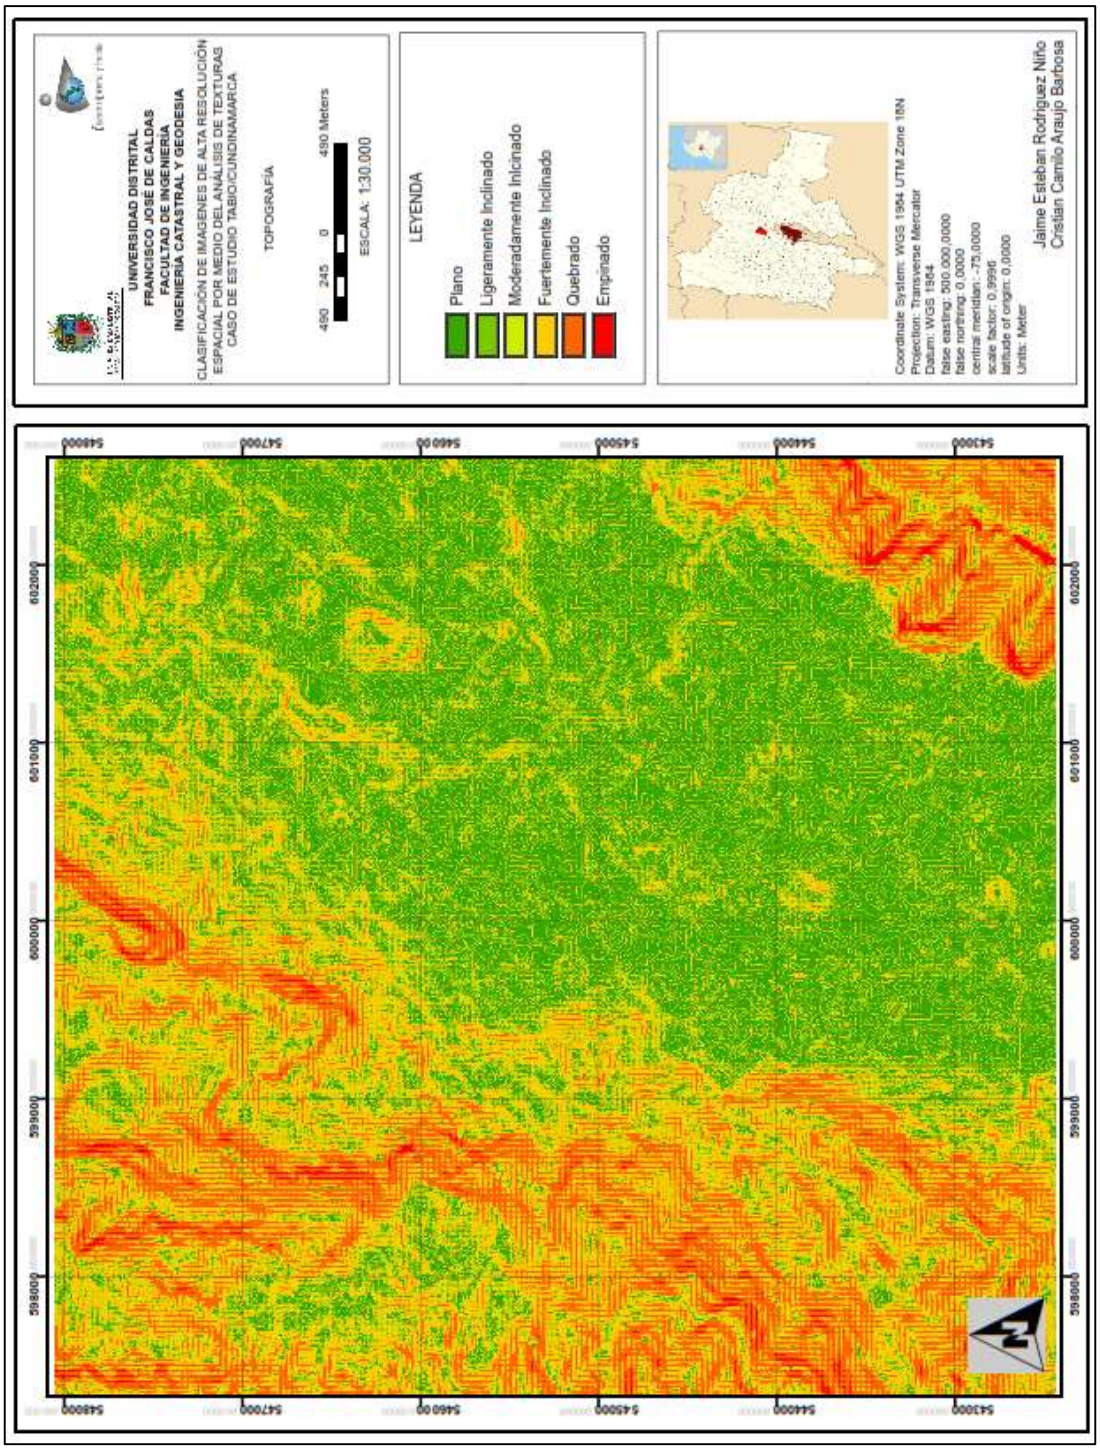
J. Mapa de Banda de Textura de Segundo Momento Angular con relación espacial (0,1) y ventana móvil de 25x25.



K. *Mapa de Banda de Textura de Correlación con relación espacial (0,1) y ventana móvil de 25x25.*



I. Mapa de Topografía de la zona de estudio



BIBLIOGRAFÍA

Aldana, R. C., Orozco, H. N., & Barreto, M. S. (2014). Identificacion de lesiones cerebrales de esclerosis multiple en imagenes de resonancia magnetica mediante análisis de textura. *Revista Tecnura*, 89-101.

Alperín, M. I., Borges, V. G., & Sarandón, R. (2007). Caracterización Espacial de los Tipos de Cobertura de Suelo usando Técnicas Geoestadísticas a partir de Información Satelital. *Gabinete de Ecometría, Cátedra de Estadística; Facultad de Ciencias Naturales y Museo*.

Anaya, A. A., Duque, L. R., & Valencia, H. G. (2006). Análisis de textura en imágenes de satélite en el ámbito de la biodiversidad y la estructura en un bosque de los andes colombianos. *Universidad de Medellín*.

Anaya, A. J., Duque, L. R., & Valencia, H. G. (2008). Análisis de textura en imágenes de satélite en el ambito de la biodiversidad y la estructura en un bosque de los Andes Colombianos.

Asner, G. P., Bustamante, M. M., & Townsend, A. R. (2003). Scale Dependence of Biophysical Structure in Deforested Areas Bordering the Tapajós National Forest, Central Amazon. *Remote Sensing of Enviroment, Volume 87*.

Backes, A. R., Casanova, D., & Bruno, O. M. (2013). Texture analysis and classification: A complex network-based approach. *Sciverse ScienceDirect*.

Bedoya, J. L. (2005). Comparación de modelos de clasificación automática de patrones texturales de minerales presentes en los carbones colombianos. *Dyna, año 72, nro. 146*, 115-124.

Betancur, J., Mora, J., & Viera, J. (2010). Detección de bordes utilizando la matriz de coocurrencia: aplicación a la segmentación de imágenes de frutos de café. *Dyna, Año 77, Nro. 164*, 240-250.

BNI. (2015). *Banco Nacional de Imagenes*. Obtenido de http://www.bni.gov.co/portal/public/classic/

Camacho, J. J. (2008). Plan integral único. *Plan Integral Único* .

Chen, Y. Q., Nixon, M. S., & Thomas, D. W. (1995). Statistical geometrical features for texture classification. *Pattern Recognition*.

Chowdhury, P. R., Deshmukh, B., & Goswami, A. (2007). Machine Extraction of Landforms from Multispectral Images Using Texture and Neural Methods. *Proceedings of the International Conference on Computing: Theory and Applications*.

Chuvieco, E. (1996). *Fundamentos de teledetección espacial.* Madrid: Rialp.

Ciriza, R., González, M., Audícana, & Albiuza, L. (2012). Procedimiento simplificado para la caracterización del cultivo del frutal a nivel parcela mediante los parámetros de Haralick. *Asociación Espaoñla de Teledetección*.

Congalton, R. G., & Green, K. (2009). *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices.* Florida: CRC Press.

Demirci, S., Yazgan, B., & Ersoy, 0. (2005). Multispectral Target Detection by Statistical Methods. *IEEE*.

Di Bella, C., Posse, M., Beget, M., Fischer, N. M., & Veron, &. (2008). La teledetección como herramienta para la prevención, seguimiento y evaluación de incendios e inundaciones. *Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET). Argentina*.

Díaz, J. J. (2006). Modelos digitales de elevación para el continuo de elevaciones mexicano. *INEGI Departamento de Producción de Modelos Digitales de Elevación*.

Fdez. Sarría, A. R. (2003). Análisis de imágenes mediante texturas: aplicación a la clasificación de unidades de vegetación. *Departamento de Ingeniería Cartográfica, Geodesia y Fotogrametría*.

Fernandez, L. R., Recio, J. R., & Sarrìa, A. F. (2005). Clasificaciòn de entornos forestales mediterraneos mediante tècnicas de anàlisis de texturas. *Cuad. Soc. Esp. Cienc. For. 19: 187 - 192*, 188.

Gonzalez, R. C., & Woods, R. E. (1993). *Digital image processing.* Knoxville: Prentice Hall.

Haralick. (1973). Textural feauters for image classification. *IEEE*.

Haralick, R. M., & Shanmugam, K. S. (1974). Combined spectral and spatial processing or ERTS imagery data. *Remote Sensing of Environment*.

Hermosilla, T., Bermejo, E., Balaguer, A., & Ruiz, L. (2006). Detección de bordes con precisión subpixel en imágenes digitales: Interpolación lineal frente a esquemas de tipo no lineal. *Jornadas de matemáticas aplicadas*.

Herold, M., Liu, X., & Clarke, K. C. (2003). Spatial metrics and image texture for mapping urban land use. *Photogrammetric Engineering & Remote Sensing*.

IDEAM. (2010). Leyenda Nacional de Coberturas de la Tierra. Metodología Corine Land Cover adaptada para Colombia Escala 1:100.000. Instituo de Hidrología, Metereología y Estudios Ambientales. Bogotá, D.C.: IDEAM.

Jenicka, A., & Suruliandi, A. (2014). A textural approach for land cover classification of remotely sensed image. *International Journal of Computer Applications*.

Jensen, J. R. (2004). *Introductory Digital Image Processing.* Columbia: Pretince Hall.

Keys, R. G. (1981). Cubic convolution interpolation for digital image processing. *IEEE*.

Kidnera, D. B. (2003). Higher-order interpolation of regular grid digital elevation models. *International Journal of Remote Sensing*, 2981-2987.

La Serna, P. N., Contreras, W., & Ruiz, M. E. (2010). Procesamiento Digital de textura: Técnicas utilizadas en aplicaciones actuales de CBIR. *Revista de Ingeniería de Sistemas e Informática vol. 7, N.º 1*.

Lu, S., Tian, J., Qiu, D., Du, M., & Shi, R. (2009). Sub-classification of farmland in high resolution rs images based on textural and spectral features. *IGARRS*.

Maillard, P. (2003). Comparing texture analysis methods through classification. *Photogrammetric Engineering & Remote Sensing* .

Manterola, H. L. (2003). Extracción de objetos en imágenes médicas tridimensionales basada en características texturales. *Congreso Argentino de Informatica y Salud*, 162-178.

Martínez, S. A. (2010). Método para identificación de cultivos de arroz (Oryza sativa L.) con base en imágenes de satélite. *Agronomía Colombiana 28*, 281-290.

Mhangara, P., & Odindi, J. (2012). Potencial of texture-based classification in urban landscapes using multispectral aerial photos. *Sotuh African Journal of Science*.

Mikós, P. (2007). Comparison of convolution based interpolation techniques in digital images processing. *International Symposium on Intelligent Systems and Informatics*.

Morales, D. I., Moctezuma, M., & Parmiggiani, F. (2003). Urban and Non Urban Area Classification by Texture Characteristics and Data Fusion. *IEEE*.

Moran, E. F. (2010). Land cover classification in a complex urban-rural landscape with Quickbird imagery. *Photogramm End Remote Sensing*.

Odindi, P. M. (2012). Potential of texture-based classification in urban landscapes using multispectral aerial photos. *Texture-based classification using multispectral aerial photos*.

Ortiz, Z. L. (2007). Caracterización de café cereza empleando técnicas de visión artificial. *Rev.Fac.Nal.Agr.Medellín.Vol.60,No.2*, 4105-4127.

Panniggiani, A. B. (1995). An Investigation of the Textural Characteristics Associated with Gray Level Cooccurrence Matrix Statistical Parameters. *IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING, VOL. 33, NO. 2*.

Paruelo, G. P. (2009). Cambios en el uso de la tierra en Argentina y Uruguay: marcos conceptuales para su análisis. *Laboratorio de análisis regional y teledetección – ifeva – facultad de agronomía. Universidad de Buenos Aires*.

Perea, M. A., Meroño, D. L., & Aguilera, U. M. (2009). Clasificación orientada a objetos en fotografías aéreas digitales para la discriminación de usos del suelo. *INTERCIENCIA VOL. 34 Nº 9*.

Presutti, M. (2004). La matriz de co-ocurrencia en la clasificación multiespectral: Tutorial para la enseñanza de medidas texturales en cursos de grado universitarios. *4º Jornada de Educação em Sensoriamento Remoto no Âmbito do Mercosul*.

Priego, d. l., & Porres, d. l. (2001). La triangulación de Delaunay aplicada a los modelos digitales del terreno. *Departamento de ingeniería cartográfica, geodesia y fotogrametría*.

R. Ciriza, M. G.-A. (1988). Procedimiento simplificado para la caracterización de la textura del cultivo del frutal a nivel de parcela mediante los parámetros de Haralick. *Revista de Teledetección 37*, 57-66.

Rees, W. (2000). The Accuracy of Digital Elevations Models Interpolated to Higher Resolutions. *International Journal of Remote Sensing, Volume 21*.

Rees, W. G. (2000). The accuracy of Digital Elevation Models interpolated to higher resolutions. *International Journal of Remote Sensing*, 7-20.

Richards, J. A., & Jia, X. (2006). *Remote Sensing Digital Image Analysis, An Introduction.* Germany: Springer.

Rico, E. C., Gil, D. M., González, J. A., & Sanmartín, T. R. (2006). La escala cartográfica de la imagen de satélite. Caso particular de las imágenes Ikonos y QuickBird. *Revista de Teledetección 26*, 18-24.

Ríos-Díaz, J., Martínez-Payá, J. J., & Aledo, M. E. (2009). El análisis textural mediante las matrices de co-ocurrencia (GLCM) sobre imagen ecográfica del tendón rotuliano es de utilidad para la detección cambios histológicos tras un entrenamiento con plataforma de vibración. *CCD 11 I AÑO 5 I VOLUMEN 5*, 91-102.

Ruíz, Acosta, Sarría, Porres, & Pardo. (2001). Mejora de la eficiencia de la segmentación de imágenes por texturas mediante filtros de energía. *Teledetección, Medio Ambiente y Cambio Climático*, 477-480.

Ruíz, F. L., Recio, R. J., & Fernández, S. A. (2005). Clasificación mediante entornos forestales mediterráneos mediante técnicas de análisis de texturas. *Dpto. Ingeniería Geográfica, Geodésica y Fotogramétrica. Univ. Politénica de Valencia.*

Ruiz, L. A., Fdez.-Sarría, A., Pardo, J. E., Porres, M. J., & Recio, M. J. (2002). Integración de datos geoespaciales para la caracterización de la vegetación: Una herramienta potencial para estimar las variaciones microclimáticas. *3ª Asemblea Hispano Portuguesa de Geodesia y Geofisica*.

Santamaría, M. y. (2014). Enfoque estadístico de análisis de textura: su aplicación a la clasificación de un ortofotomosaico del valle de inundación del Arroyo Naposta Grande. *GeoFocus nº 14*, 55-67.

Sarría, A. F., Recio, J., & Ruiz, L. (2005). Determinación de la resolucón espacial óptima en imágenes pancormáticas para su clasificación por texturas. *XI Congreso Nacional de Teledetección.* Puerto de la Cruz.

Sarría, A., Recio, J. A., & Ruíz, L. A. (2005). Determinación de la resolución espacial óptima en imágenes pancromáticas para su clasificación por texturas. *XI Congreso Nacioanl de Teledetección*.

Sisodia, P. S., Tiwari, V., & Kumar, A. (2014). A comparative analysis of remote sensing image classification techniques. *Computer Science and Technology*.

Srinivasan, G. N., & Shobha, G. (2008). Statistical texture analysis. *Proceedings of Worl Academy of Science, Engieenering and Technology*.

Suruliandi, S. J. (2014). A textural approach for land cover classification of remotely. *Computer Society Of India CSIT*, 1-9.

Thiele, A., Schulz, K., Thoennessen, U., & Cadario, E. (2006). Orthorectification as pleliminary step for the fusion data from active and passive sensor systems. *IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems*.

Universidad Distrital, F. J. (25 de 06 de 2015). *Ingeniería Catastral y Geodesia: Universidad Distrital Francisco José de Caldas*. Obtenido de Sitio Web de la Universidad Distrital Francisco José de Caldas: www.udistrital.edu.co

Ursani, A. A., Kpalma, K., Lelong, C. C., & Ronsin, J. (2012). Fusion of Textural and Spectral Information for Tree Crop and Other Agricultural Cover Mapping With Very-High Resolution Satellite Images. *IEEE JOURNAL OF SELECTED TOPICS IN APPLIED EARTH OBSERVATIONS AND REMOTE SENSING, VOL. 5, NO. 1*.

USGS, D. o. (2010). USGS quality assurance plan for digital aerial imagery. *Certification Report for the Microsoft Vexcel Ultracam D, Ultracam X, Ultracam Xp and Ultracam XP WA models*.

USGS, U. G., NGA, N. G.-I., & NASA, N. A. (2000). Shuttle Radar Topography Mission 1 Arc-Second Global: SRTM1N04W075V3. *Elevation data in raster format*.

Valdez-Lazalde, J. R. (2007). Estimación de cobertura arbórea mediante imágenes satelitales multiespectrales de alta resolución. *Programa forestal. Campus montecillo. Colegio de postgraduados*.

Wang, C. H. (2002). Urban land cover classification from high resolution multi-spectral ikonos imagery. *IEEE*.

Wilches, M., & Hernando, L. (2005). *Interpretación visual de imágenes de sensores remotos y su aplicación al levantamiento y uso de la tierra.* Bogotá D.C.: Instituto Geográfico Agustín Codazzi, Centro de Investigación y Desarrollo en Informática Geográfica.

Yang, H., Du, Q., & Ma, B. (2010). Weighted decision fusion for supervised and unsupervised hyperspectral image classification. *IGARSS*.

Zheng, X., Liu, W., Qian, L., & Liang, X. (2010). Research on pattern recognition methods of tm remote sensing images. *Seventh International Conference on Fuzzy Systems and Knowledge Discovery*.