

**APLICACIÓN DE LSMA Y OBIA EN IMÁGENES MULTIESPECTRALES
LANDSAT-8 PARA LA OBTENCIÓN DE MAPAS PRELIMINARES DE COBERTURA
EN ZONAS DE ALTA MONTAÑA DEL COMPLEJO DE PÁRAMO JURISDICCIÓN
SANTURBÁN-BERLÍN**



SILVIA RUGGERI

**UNIVERSIDAD CATÓLICA DE MANIZALES
FACULTAD DE INGENIERÍA Y ARQUITECTURA
MANIZALES, COLOMBIA**

2020

**APLICACIÓN DE LSMA Y OBIA EN IMÁGENES MULTIESPECTRALES
LANDSAT-8 PARA LA OBTENCIÓN DE MAPAS PRELIMINARES DE COBERTURA
EN ZONAS DE ALTA MONTAÑA DEL COMPLEJO DE PÁRAMO JURISDICCIÓN
SANTURBÁN-BERLÍN**

SILVIA RUGGERI

BIÓLOGA

Tesis presentada como requisito parcial para optar al título de:

Magister en Teledetección

Director:

VLADIMIR HENAO CÉSPEDES

Codirector:

ALEXANDER DE JESÚS PARRA UZCÁTEGUI

Línea de Investigación:

Tecnologías Geoespaciales

Universidad Católica de Manizales
Facultad de Ingeniería y Arquitectura
Manizales, Colombia
2020

Dedicatoria

*A mi amada familia colombiana, que me ha recibido como una hija,
brindándome su amor y apoyo incondicional, que me hace sentir como en casa,
y que más que nadie, me ha enseñado a sonreírle siempre a la vida, contagiándome
con su buen humor y alegría.*

*Ai miei genitori, da cui ho ereditato la voglia costante di imparare e
la forza per non arrendermi mai, e che, anche se da lontano,
riescono sempre a trasmettermi tutto il loro
amore e affetto.*

Abstract

The main objective of this research is to apply unsupervised classification techniques and object-based image analysis (OBIA) to obtain a preliminary land cover map from multispectral images of the Landsat-8 OLI sensor. The study area is the Santurbán-Berlín Jurisdiction paramo complex (located in the departments of Santander and Norte de Santander, Colombia). This complex is a high mountain ecosystem considered strategic for the supply of environmental services and the conservation of biodiversity. This research applies a proposed approach based on automated endmember extraction for the application of Linear Spectral Mixture Analysis (LSMA) and the assignment of land cover classes to the polygons obtained through segmentation based on the following criteria: abundance, shape, fragmentation, and terrain slope. In consequence, the obtained results contribute to optimize the production of land cover maps using digital image processing techniques, in accordance with the CORINE Land Cover classification scheme adapted for Colombia. Furthermore, the expected outcome of this proposed approach is its applicability to other high mountain tropical ecosystems.

Keywords: paramo, land cover, LSMA, OBIA, remote sensing, optimization, CORINE Land Cover.

Resumen

La presente investigación tiene como objetivo principal determinar la aplicación de técnicas de clasificación no supervisada y de análisis de imagen basada en objetos (OBIA, por su sigla en inglés) para la obtención de un mapa preliminar de cobertura de la tierra a partir de imágenes multiespectrales del sensor OLI de Landsat-8. La zona de estudio es el complejo de páramo Jurisdicción Santurbán-Berlín (departamentos de Santander y Norte de Santander, Colombia), ecosistema de alta montaña considerado estratégico para la provisión de servicios ambientales y para la conservación de la biodiversidad. El enfoque propuesto, se basa en la extracción automatizada de *endmembers* para la aplicación del Análisis Lineal de Mezclas Espectrales (LSMA, por su sigla en inglés), y la asignación de clases de cobertura a los polígonos obtenidos mediante procesos de segmentación, según criterios de abundancia, forma, fragmentación y pendiente del terreno. Por consiguiente, los resultados obtenidos constituyen un aporte para optimizar la producción de mapas de cobertura, mediante técnicas de procesamiento digital de imágenes, de acuerdo con el esquema de clasificación CORINE Land Cover adaptado para Colombia. Adicionalmente, se espera que el enfoque propuesto pueda aplicarse en otros ecosistemas tropicales de alta montaña.

Palabras clave: páramo, cobertura, LSMA, OBIA, teledetección, optimización, CORINE Land Cover.

Agradecimientos

Al Instituto Geográfico Agustín Codazzi y a la Corporación Autónoma Regional para la Defensa de la Meseta de Bucaramanga, que me proporcionaron valiosa información e insumos cartográficos esenciales para el desarrollo de este estudio.

A la Universidad Católica de Manizales, por brindarme la oportunidad de lograr esta importante meta en mi proceso de crecimiento profesional y personal.

A la dirección y docentes de la Maestría en Teledetección, por todo el apoyo brindado y la transferencia de conocimientos.

A mis tutores, el Doctor Vladimir Henao Céspedes y el Doctor Alexander de Jesús Parra Uzcátegui, por todo el apoyo y recomendaciones que han hecho posible el desarrollo de este estudio.

Tabla de contenidos

1. INTRODUCCIÓN	1
1.1. Planteamiento del problema	2
1.2. Justificación	6
1.3. Objetivos.....	9
1.4.1 Objetivo general.....	9
1.4.2 Objetivos específicos	9
1.4. Estructura del documento	10
2. MARCO TEORICO.....	11
2.1. Ecosistemas de alta montaña y páramos	11
2.2. Cobertura de la tierra.....	14
2.3. Teledetección y sistemas sensores	14
2.4. Preprocesamiento de datos de percepción remota	16
2.4.1. Corrección radiométrica	17
2.4.2. Corrección de efectos de relieve	19
2.5. Clasificación digital de imágenes	22
2.5.1. Clasificación no supervisada con ISODATA	22
2.5.2. Análisis lineal de mezclas espectrales (LSMA).....	23
2.5.3. Análisis de imágenes basada en objetos	27
2.6. Esquemas de clasificación	28
2.7. Evaluación de conformidad temática.....	30
3. METODOLOGÍA	34
3.1. Generalidades	36
3.1.1. Delimitación del área de estudio.....	36
3.1.2. Recopilación y selección de insumos.....	38
3.2. Objetivo 1: Preprocesamiento y corrección radiométrica.....	41
3.2.1. Remoción de nubes y anomalías.....	41
3.2.2. Calibración radiométrica y corrección atmosférica	43
3.2.3. Corrección de efectos del relieve	45
3.3. Objetivo 2: extracción de <i>endmembers</i>	49
3.3.1. Enmascaramiento	51
3.3.2. Extracción de <i>endmembers</i> mediante el método combinado MNF y PPI....	51
3.3.3. Extracción de <i>endmembers</i> mediante SMACC	65

3.3.4.	Evaluación del desempeño de los métodos empleados para la extracción de <i>endmembers</i>	68
3.4.	Objetivo 3: Segmentación y clasificación no supervisada	68
3.4.1.	Definición del esquema de clasificación	70
3.4.2.	Clasificación mediante ISODATA	71
3.4.3.	Recorte de las imágenes clasificadas al área de estudio.....	75
3.4.4.	Segmentación de las imágenes.....	75
3.4.5.	Definición de criterios de clasificación y cálculo de estadísticas de clase por segmento	80
3.4.6.	Asignación de clase de cobertura a los polígonos.....	81
3.4.7.	Construcción del mapa de coberturas.....	83
3.4.8.	Validación.....	83
3.4.9.	Evaluación de la aplicabilidad de LSMA y OBIA para la obtención de un mapa de coberturas de la tierra preliminar	88
4.	RESULTADOS Y DISCUSIÓN	89
4.1.	Objetivo 1	89
4.2.	Objetivo 2	106
4.3.	Objetivo 3	117
5.	CONCLUSIONES	127
6.	RECOMENDACIONES	129
7.	BIBLIOGRAFÍA	131
8.	APENDICES	138
	Apéndice 1.Ecuaciones de regresión lineal y parámetros requeridos para la aplicación de la corrección topográfica Corrección C.....	138
	Apéndice 2.Asignación de coberturas a clasificación obtenida con ISODATA.	141
	Apéndice 3.Asignación de endmemebers a clasificación obtenida con SMACC.	153

Lista de tablas

<i>Tabla 1.</i> Límites aproximados de los cinturones altitudinales que conforman las zonas de alta montaña.....	12
<i>Tabla 2.</i> Bandas de la misión Landsat-8.....	15
<i>Tabla 3.</i> Niveles de correspondencia para diferentes valores de Kappa.	32
<i>Tabla 4.</i> Insumos empleados para la investigación.....	39
<i>Tabla 5.</i> Insumos empleados para la investigación (continua).	40
<i>Tabla 6.</i> Estadísticas de anomalías detectadas para la imagen L8 2018 <i>Path 007 Row 055</i>	42
<i>Tabla 7.</i> Estadísticas de anomalías detectadas para la imagen L8 2020 <i>Path 008 Row 054</i>	42
<i>Tabla 8.</i> Metadatos utilizados para la creación del mapa de iluminación.	47
<i>Tabla 9.</i> Valores promedios aplicados para la corrección del coseno mejorada.....	47
<i>Tabla 10.</i> Resultados de la transformación MNF para la imagen con mayor cobertura sobre el área de estudio.	54
<i>Tabla 11.</i> Píxeles puros obtenidos por número de iteraciones.....	58
<i>Tabla 12.</i> <i>Endmembers</i> preseleccionados por clase.	60
<i>Tabla 13.</i> Aplicación de criterios para la selección de <i>endmembers</i> finales.	62
<i>Tabla 14.</i> <i>Endmembers</i> seleccionados.....	64
<i>Tabla 15.</i> Número de <i>endmembers</i> y error cuadrático medio obtenidos con diferentes parámetros de entrada mediante el algoritmo SMACC para la escena <i>Path 007 Row 055</i>	66
<i>Tabla 16.</i> Esquema de clasificación adoptado.	70
<i>Tabla 17.</i> Configuraciones ensayadas para el algoritmo ISODATA.	71
<i>Tabla 18.</i> Número de muestras por unidad de cobertura seleccionadas para la validación de los mapas obtenidos.	86
<i>Tabla 19.</i> Comparación de valores del coeficiente de correlación para diferentes tipos de correcciones e insumos utilizados para el cálculo de $\cos \gamma_i$	105
<i>Tabla 20.</i> Comparación de valores del coeficiente de correlación para diferentes tipos de filtros de paso bajo aplicados al cálculo de $\cos \gamma_i$	105

<i>Tabla 21.</i> Estadísticas por imagen de abundancia y RMSE obtenidos con <i>endmembers</i> extraídos.	107
<i>Tabla 22.</i> Número y porcentaje de píxeles con valores inferiores a 0 o mayores a 1.	109
<i>Tabla 23.</i> Área por clase de cobertura obtenida con los métodos de clasificación aplicados.	

Lista de figuras

<i>Figura 1.</i>	Delimitación aproximada de los cinturones altitudinales de las zonas de alta montaña para el área de estudio.	13
<i>Figura 2.</i>	Comparación de las bandas espectrales de las misiones Landsat.	16
<i>Figura 3.</i>	Ejemplo de la implementación de una matriz de confusión.	32
<i>Figura 4.</i>	Ejemplo de la implementación de una matriz de confusión normalizada MARGFIT.....	33
<i>Figura 5.</i>	Esquema metodológico planteado.....	35
<i>Figura 6.</i>	Localización del área de estudio.	36
<i>Figura 7.</i>	Área de estudio seleccionada.	37
<i>Figura 8.</i>	Algunas áreas de anomalías detectadas (en rojo) por el Anomaly Detection de ENVI 5.3.....	43
<i>Figura 9.</i>	Imagen de insumo con zonas de nubes y anomalías removidas.	44
<i>Figura 10.</i>	Recorte de los mapas de iluminación al área de estudio en PCI Geomatics...48	
<i>Figura 11.</i>	Flujo de actividades realizadas para analizar el desempeño de diferentes métodos de extracción de <i>endmembers</i>	50
<i>Figura 12.</i>	Máscara aplicada para la extracción de <i>endmembers</i>	52
<i>Figura 13.</i>	Área con respuesta espectral homogénea seleccionada.....	53
<i>Figura 14.</i>	Estadísticas de la zona homogénea seleccionada.	53
<i>Figura 15.</i>	Resultados de la transformación MNF. Autovalores.	54
<i>Figura 16.</i>	Resultado de la transformación MNF. Composición RGB.	55
<i>Figura 17.</i>	Visualización de las clases delimitadas en el n-D-Visualizer con componentes MNF.....	56
<i>Figura 18.</i>	Vista de la clase suelo o zonas desprovistas de vegetación sobre imagen de la misión Landsat-8.	56
<i>Figura 19.</i>	Vista de la clase vegetación sobre imagen de la misión Landsat-8.....	57
<i>Figura 20.</i>	Vista de la clase agua y zonas de sombra sobre imagen de la misión Landsat-8.....	57
<i>Figura 21.</i>	Firmas espectrales promedio de las clases seleccionadas a partir de componentes MNF.	58

<i>Figura 22.</i> Cálculo del Índice de Pureza del Pixel en ENVI 5.3.....	59
<i>Figura 23.</i> Firmas espectrales promedio de los endmembers preseleccionados.	60
<i>Figura 24.</i> Tendencia del error máximo relativo con el aumento del número de <i>endmembers</i> para la escena <i>Path 007 Row 055</i>	66
<i>Figura 25.</i> Firmas espectrales de <i>endmembers</i> extraídos mediante SMACC. Escena <i>Path 007 Row 055</i> de 2018.	67
<i>Figura 26.</i> Firmas espectrales de <i>endmembers</i> extraídos mediante SMACC. Escena <i>Path 008 Row 054</i> de 2020.	67
<i>Figura 27.</i> Flujo de actividades realizadas para evaluar la capacidad del análisis lineal de mezclas espectrales para obtener una delimitación preliminar de coberturas.	69
<i>Figura 28.</i> Comparación entre resultados de clasificación obtenidos con el algoritmo ISODATA para la escena <i>path 007 row 055</i>	72
<i>Figura 29.</i> Comparación entre clasificación adoptada para las dos escenas con cubrimiento sobre el área de estudio.	73
<i>Figura 30.</i> Firmas espectrales promedio de las clases obtenidas mediante el algoritmo ISODATA.	74
<i>Figura 31.</i> Imágenes de abundancia recortadas al área de estudio (composición EM1, 2 y 3).....	76
<i>Figura 32.</i> Asignación de coberturas a las clases definidas mediante el algoritmo ISODATA para la escena <i>Path 007 Row 055</i>	77
<i>Figura 33.</i> Asignación de coberturas a las clases definidas mediante el algoritmo ISODATA para la escena <i>Path 008 Row 054</i>	78
<i>Figura 34.</i> Detalle de los resultados de segmentación.....	79
<i>Figura 35.</i> Diagrama de flujo propuesto para semiautomatizar el esquema de clasificación adoptado para UMC de 12.5 Ha.	82
<i>Figura 36.</i> Mapa clasificado obtenido a partir de clasificador ISODATA y segmentación.	84
<i>Figura 37.</i> Mapa clasificado obtenido a partir de clasificador SMACC y segmentación.	85
<i>Figura 38.</i> Distribución espacial de los puntos de muestreo seleccionados para la validación los mapas obtenidos.	87

<i>Figura 39.</i> Comparación de histogramas y estadísticas de las imágenes corregidas con diferentes modelos de transferencia radiativa e insumos.....	91
<i>Figura 40.</i> Comparación de histogramas y estadísticas de las imágenes corregidas con diferentes modelos de transferencia radiativa e insumos (continua).....	92
<i>Figura 41.</i> Comparación visual de las correcciones atmosféricas realizadas con diferentes insumos y modelos de transferencia radiativa.	94
<i>Figura 42.</i> Comparación visual de zonas de artefactos con mapas de iluminación empleados para la corrección con el módulo ATCOR.	95
<i>Figura 43.</i> Comparación de resultados obtenidos mediante la aplicación de corrección atmosférica mediante el uso del modelo digital de elevación de las misiones SRTM (a) y SRTM con filtro promedio de 3x3 (b).	96
<i>Figura 44.</i> Comparación de resultados obtenidos para la corrección del coseno mejorada con diferentes tipos de insumos.	98
<i>Figura 45.</i> Comparación de resultados obtenidos para la corrección C con diferentes tipos de insumos.....	99
<i>Figura 46.</i> Detalle de resultados obtenidos para la corrección C con diferentes tipos de insumos.	100
<i>Figura 47.</i> Presencia de artefactos en imagen corregida con DTM derivado de curvas de nivel del IGAC.	101
<i>Figura 48.</i> Zonas de sombra residuales en imágenes corregidas con corrección C y diferentes tipos de insumos.....	102
<i>Figura 49.</i> Corrección C con aplicación de filtros de paso bajo al mapa de iluminación obtenido a partir del MDE de SRTM.	103
<i>Figura 50.</i> RMSE obtenido con el análisis lineal de mezclas espectrales.	108
<i>Figura 51.</i> Firma espectral de <i>endmembers</i> obtenidos.	112
<i>Figura 52.</i> Ubicación de los <i>endmembers</i> seleccionados con el método MNF+PPI sobre imágenes recientes de alta resolución disponible en Google Earth.....	113
<i>Figura 53.</i> Ubicación de los <i>endmembers</i> seleccionados con el método SMAAC sobre imágenes recientes de resolución mayor a 15m.	114
<i>Figura 54.</i> Ubicación de los <i>endmembers</i> seleccionados con el método SMAAC sobre imágenes recientes de resolución mayor a 15m (continua).	115

<i>Figura 55.</i> Incongruencias encontradas en los <i>endmembers</i> extraídos.....	116
<i>Figura 56.</i> Comparación de los mapas preliminares de cobertura de la tierra obtenidos. 119	
<i>Figura 57.</i> Matriz de confusión obtenida con el método ISODATA y extracción de objetos.....	121
<i>Figura 58.</i> Matriz de confusión obtenida con el método SMACC y extracción de objetos. 121	
<i>Figura 59.</i> Matriz de confusión obtenida con el método ISODATA y extracción de objetos. Clasificación simplificada.....	122
<i>Figura 60.</i> Matriz de confusión obtenida con el método SMACC y extracción de objetos. Clasificación simplificada.....	122
<i>Figura 61.</i> Comparación visual de las clasificaciones obtenidas para una zona de cuerpos de agua.	124
<i>Figura 62.</i> Comparación visual de las clasificaciones obtenidas para una zona urbana discontinua.	125
<i>Figura 63.</i> Análisis comparativo entre el límite de coberturas delimitadas para el área de estudio.....	126
<i>Figura 64.</i> Asignación de clase 1: Aguas continentales (5).....	141
<i>Figura 65.</i> Asignación de clase 2: Vegetación secundaria en transición (32).	142
<i>Figura 66.</i> Asignación de clase 3: Bosque (31).	143
<i>Figura 67.</i> Asignación de clase 4: Vegetación secundaria en transición (32).	144
<i>Figura 68.</i> Asignación de clase 5: Pastos (23).	145
<i>Figura 69.</i> Asignación de clase 6: Tierras desnudas y degradadas (333).....	146
<i>Figura 70.</i> Asignación de clase 7: Pastos (23).	147
<i>Figura 71.</i> Asignación de clase 8: Pastos (23).	148
<i>Figura 72.</i> Asignación de clase 9: Tierras desnudas y degradadas (333).....	149
<i>Figura 73.</i> Asignación de clase 10: Pastos (23).	150
<i>Figura 74.</i> Asignación de clase 11: Tierras desnudas y degradadas (333).....	151
<i>Figura 75.</i> Asignación de clase 12: Territorios artificializados (1).....	152
<i>Figura 76.</i> Asignación de clase al <i>endmember</i> 1: Tierras desnudas y degradadas (333).	153

<i>Figura 77.</i> Asignación de clase al <i>endmember</i> 2: Territorios artificializados (1).	154
<i>Figura 78.</i> Asignación de clase al <i>endmember</i> 3: Vegetación secundaria en transición (32) y cultivos (2).	155
<i>Figura 79.</i> Asignación de clase al <i>endmember</i> 4: Bosques (31) y cultivos (2).	156
<i>Figura 80.</i> Asignación de clase al <i>endmember</i> 5: Aguas continentales (51).	157
<i>Figura 81.</i> Asignación de clase al <i>endmember</i> 6: Pastos (23).	158
<i>Figura 82.</i> Asignación de clase al <i>endmember</i> 7: Tierras desnudas y degradadas (333).	159
<i>Figura 83.</i> Asignación de clase al <i>endmember</i> 8: Zonas húmedas (4).	160
<i>Figura 84.</i> Asignación de clase al <i>endmember</i> 9: Afloramientos rocosos (332).	161

Siglas y abreviaturas

BOA	Bottom of the Atmosphere (de superficie)
CLC	CORINE Land Cover
CPJSB	Complejo de Páramo Jurisdicción Santurbán Berlín
DEM	Digital Elevation Model (modelo digital de elevación)
EM	<i>Endmember</i> o componente puro
ETM+	Enhanced Thematic Mapper
GEOBIA	Análisis geográfico de imágenes basada en objetos
LSMA	Linear Spectral Mixture Analysis (Análisis Lineal de Mezclas Espectrales)
MNF	Minimum Noise Fraction (Mínima Fracción de Ruido)
ND	Niveles digitales
NDVI	Normalized Difference Vegetation Index (Índice de Vegetación de Diferencia Normalizada)
OBIA	Análisis de imágenes basada en objetos
OLI	Operational Land Imager
PPI	Pixel Purity Index (Índice de Pureza del Pixel)
LSU	Linear Spectral Unmixing
SMACC	Sequential Maximum Angle Convex Cone
TM	Thematic Mapper
TOA	Top of the Atmosphere (al techo de la atmósfera)

1. INTRODUCCIÓN

En esta tesis se presenta un caso de aplicación de técnicas de clasificación no supervisada y de análisis de imagen basada en objetos (OBIA, de su sigla en inglés), para la obtención de un mapa preliminar de cobertura de la tierra del complejo de páramo Jurisdicción Santurbán-Berlín (Santander y Norte de Santander), ecosistema de alta montaña considerado estratégico para la provisión de importantes servicios ambientales y para la conservación de la biodiversidad. Para su desarrollo se utilizaron como insumos imágenes multiespectrales del sensor OLI (*Operational Land Imager*) de Landsat-8.

Teniendo en cuenta los principales desafíos en el uso de técnicas de análisis digital de imágenes en zonas de alta montaña, en el estudio se evalúan diferentes métodos e insumos para realizar las correcciones del efecto atmosférico y topográfico sobre los valores de reflectancia. Adicionalmente, se ensayan diferentes métodos para la extracción automatizada de los componentes puros (*endmembers*) requeridos para la clasificación no supervisada mediante Análisis Lineal de Mezclas Espectrales (LSMA, de su sigla en inglés). Finalmente, se realiza la asignación de clases de cobertura a los polígonos obtenidos mediante procesos de segmentación, con base en criterios de abundancia, forma, fragmentación y pendiente del terreno, que permiten aplicar el esquema de clasificación para coberturas CORINE (de su nombre en inglés *Coordination of Information on the Environment*) Land Cover adaptado para Colombia.

Los resultados de este estudio constituyen un aporte para la optimización de la producción de mapas de cobertura de la tierra, mediante técnicas de procesamiento digital de imágenes, de acuerdo con el esquema de clasificación adoptado a nivel nacional. De manera específica, se proporciona un enfoque metodológico alternativo a la interpretación visual, que permite obtener una delimitación preliminar de las unidades de cobertura de manera semi-automatizada, con una intervención mínima por parte del analista y sin requerir el conocimiento previo del área de estudio, gracias al uso de criterios numéricos y espectrales, extraíbles de imágenes de distribución libre, para la asignación de las clases a los polígonos. Se espera que los resultados obtenidos y el enfoque propuesto puedan ser aplicados en otros ecosistemas de alta montaña ubicados en zonas tropicales.

1.1. Planteamiento del problema

Debido a su gran importancia en la prestación de servicios ecosistémicos para la población colombiana, los páramos han sido declarados áreas de especial importancia ecológica y cuentan con protección especial por parte del estado, que reconoce, entre otros aspectos, su gran contribución a la estabilidad de los ciclos hidrológicos y a la regulación de los flujos de agua en cantidad y calidad, lo que hace de estos ecosistemas unas verdaderas “fábricas de agua” (Ministerio de Medio Ambiente y Desarrollo Sostenible, 2018). Sin embargo, se estima que los páramos colombianos han sido transformados entre un 15% y un 25% por el avance hacia áreas naturales, de diversas actividades, tales como, agricultura, ganadería, minería, asentamientos humanos (dispersos y nucleados), vías y embalses (Botía et al., 2018). Para el caso específico del Complejo de Páramo Jurisdicción Santurbán – Berlín (CPJSB), ubicado entre los departamentos de Santander y Norte de Santander, el 35% del área total presenta zonas intervenidas, donde los principales usos están asociados a cultivos y pastizales (Morales et al., 2007). El avance de estas actividades genera cambios en el uso de la tierra, los cuales constituyen, junto al cambio climático, los principales procesos que afectan la estabilidad de los ecosistemas de páramo, considerados de alta fragilidad por su propensión a procesos de degradación, la baja resistencia y capacidad de recuperación del equilibrio de sus suelos, entre otros factores (IDEAM, 2002).

En armonía con este contexto, la cobertura de la tierra es considerada una variable esencial por su capacidad de alterar los beneficios y servicios proporcionados a la sociedad humana (la provisión de alimentos y fibras, oportunidades recreacionales, entre otros), influenciar el clima actuando sobre los intercambios de agua y energía con la atmósfera, y modificar las fuentes y la captura de gases de efecto invernadero (World Meteorological Organization, 2016). Debido a lo anterior, el estudio de esta variable puede considerarse un aspecto de gran importancia para la planeación, la implementación y el seguimiento de acciones orientadas al logro de los Objetivos de Desarrollo Sostenible de las Naciones Unidas (ODS), en especial por sus aportes a la planificación y gestión eficaz en relación al cambio climático (ODS 13), así como a la protección, restablecimiento y promoción del uso sostenible de los ecosistemas terrestres, la gestión de los bosques, la lucha contra la desertificación, la detención e inversión de los procesos de degradación de las tierras y de pérdida de biodiversidad (ODS 15).

En Colombia, los mapas de uso y cobertura constituyen un insumo imprescindible para la realización de estudios básicos y detallados de amenaza, vulnerabilidad y riesgo por remoción en masa (Servicio Geológico Colombiano, 2016). Por otro lado, a nivel internacional, según la WMO (World Meteorological Organization, 2016) la generación de productos de cobertura del suelo ha sido reconocida como una de las prioridades para el estudio del cambio climático a nivel global.

Para la obtención de información asociada a la cobertura del suelo para grandes áreas, y la generación de los productos asociados, la teledetección permite realizar un proceso más económico y viable (Ban et al., 2015). En ese sentido, las metodologías existentes para la producción de mapas de uso y cobertura del suelo se enfocan, por un lado, en la definición de estándares para la elaboración de cartografía temática a partir de la interpretación visual de imágenes de sensores remotos y una rigurosa validación en campo (European Environmental Agency, 1997; IDEAM et al., 2008), y por el otro, en la creciente automatización de los procesos de clasificación de imágenes (Costa et al., 2018; Gábor et al., 2017; Ma et al., 2017).

En relación con los estándares internacionales existentes que regulan la obtención de los mapas de cobertura del suelo, se destaca la iniciativa CORINE Land Cover (CLC), liderado por la Comisión Europea, que pretende unificar la generación de cartografía de uso y cobertura del suelo en los estados miembros, aunque su adopción se ha ido incrementando en los países extra europeos (Taylor et al., 1996), como es el caso de Colombia, en donde ha sido adoptado bajo la metodología “CORINE Land Cover Escala 1:100.000” (IDEAM et al., 2008). Esta metodología se basa en la técnica de interpretación visual de imágenes satelitales, la cual es ampliamente utilizada dado que tiende a generar resultados más confiables que otros métodos (Mas et al., 2017), gracias a la posibilidad de incluir diversos criterios de clasificación, como la textura, la forma, el patrón, la dimensión, la proximidad entre objetos y el conocimiento del área de estudio por parte del intérprete (Mas et al., 2017). Sin embargo, debido al esfuerzo requerido para realizar la clasificación manual de los datos (Wehrmann et al., 2004), tanto en términos de tiempo como de personal altamente especializado (Mas et al., 2017), la automatización de la clasificación de la cobertura del suelo es considerada una prioridad investigativa (World Meteorological Organization, 2016). En ese sentido, el avance tecnológico permitirá superar las deficiencias de los métodos tradicionales de producción de cartografía temática de cobertura de la Tierra, y será

posible minimizar la participación del analista aumentando la objetividad del resultado final de clasificación de la imagen, así como también la eficiencia y replicabilidad (Ban et al., 2015).

Entre las técnicas de procesamiento digital de imágenes que permiten reproducir el proceso de interpretación visual con miras a la automatización, la clasificación basada en objetos (*Object-Based Image Analysis* - OBIA) representa un enfoque que permite obtener la segmentación de la imagen en áreas homogéneas (objetos), con base en el reconocimiento de patrones espaciales y espectrales, proporcionando información adicional sobre la forma, dimensión y relaciones con el entorno (Wehrmann et al., 2004). Siendo sus mayores ventajas la eficiencia en términos de tiempo y la obtención de imágenes con un nivel de detalle comparable a las obtenidas a través de procesos manuales (Gábor et al., 2017).

La técnica OBIA ha sido empleada en combinación con el análisis lineal de mezclas espectrales (LSMA) en imágenes de los sensores TM y ETM+ de Landsat, para clasificar el uso y la cobertura de la tierra en la región amazónica de Brasil (Kawakubo et al., 2013), y más recientemente, con imágenes del sensor OLI de la misión Landsat-8 para la clasificación de diferentes tipos de coberturas terrestres en la provincia de Fujian, en China, obteniendo valores de fiabilidad global superiores al 90% (Liping et al., 2019). En zonas heterogéneas, donde el área del pixel puede ser mayor al área que ocupa una determinada cobertura, los modelos basados en el desmezclado espectral, también denominado clasificación subpixel (Jensen, 2015), como LSMA, pueden proporcionar resultados más confiables que los enfoques tradicionales basados en la clasificación del pixel (Deng et al., 2019). En este sentido, en imágenes multispectrales, la clasificación subpixel puede considerarse un método avanzado para detectar materiales de dimensiones inferiores a la resolución espacial de la imagen (Salih et al., 2017).

Aunque en la literatura científica se encuentren varios estudios orientados al uso de técnicas de procesamiento digital de imágenes ópticas para la construcción automatizada de mapas de uso y cobertura del suelo (Costa et al., 2018; Gábor et al., 2017; Khatami et al., 2016; Ma et al., 2017; Maxwell et al., 2018; Zhai et al., 2018), solo un número limitado de estos se han enfocado en la extracción de las unidades de cobertura definidas por la metodología CLC, adoptada en Colombia. Algunos estudios han intentado generar mapas de manera semiautomática de acuerdo al esquema de la iniciativa CORINE en los Países Bajos, Suecia, Finlandia, Reino Unido (Taylor et al., 1996).

Más recientemente, diferentes autores han explorado la posibilidad de discriminar las unidades definidas por la metodología CLC mediante el uso de técnicas de clasificación supervisada y no supervisada (Paris et al., 2017; Sariyılmaz et al., 2017), o del análisis de imágenes basada en objetos (Gábor et al., 2017; Wehrmann et al., 2004).

En Colombia, investigadores han utilizado técnicas de procesamiento digital de imágenes para la producción de mapas de uso y cobertura del suelo (Clerici et al., 2017; Lizarazo, 2014), sin embargo, las metodologías basadas en la interpretación visual siguen siendo las más utilizadas y aceptadas para la producción de cartografía que responda a los estándares del esquema CLC adoptado en este país. Adicionalmente, la evaluación de las coberturas vegetales en zonas de alta montaña sigue siendo un desafío, principalmente por la presencia de nubes y sombras en las imágenes de satélite, así como por la dificultad para distinguir coberturas naturales abiertas, como las de tipo páramo, de las coberturas de pradera y otras coberturas agropecuarias (IDEAM, 2002). Según Colby (1998) la dificultad para diferenciar tipos de coberturas de la tierra en zonas de alto relieve mediante el uso de datos de percepción remota, radica en la topografía que determina el comportamiento de la respuesta espectral de esas zonas.

En consecuencia, se plantean las siguientes preguntas de conocimiento, a las cuales el presente estudio pretende dar respuesta:

- ¿De qué manera se pueden corregir los efectos atmosféricos y del relieve que interfieren con los procesos de clasificación digital de imágenes en zonas de alta montaña?
- ¿Cómo se puede emplear el análisis lineal de mezclas espectrales en combinación con la extracción de objetos para la producción de mapas preliminares de cobertura de la tierra de acuerdo con el esquema de clasificación adoptado a nivel nacional?

1.2. Justificación

En la actualidad el ordenamiento territorial, la priorización de acciones y la zonificación del régimen de uso de las zonas de páramo, constituyen temas de gran atención, debido a su reconocida importancia para la provisión de servicios ambientales y su alta exposición y vulnerabilidad a los procesos de degradación producidos por la actividad humana que actúan a nivel local y regional alterando el clima, la vegetación, la biodiversidad y los suelos de estos frágiles ecosistemas. Entre las acciones consideradas necesarias para garantizar la sostenibilidad de los páramos colombianos, se incluyen la toma de decisiones para el ordenamiento territorial de estos ecosistemas, el establecimiento de planes de reparación de las zonas degradadas, así como de políticas ambientales usos y manejo de las tierras, metas a corto y largo plazo y un seguimiento riguroso de su cumplimiento (IDEAM, 2002).

Según la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), las montañas son frágiles ecosistemas globalmente importantes como fábricas de agua, hábitats de rica diversidad biológica, lugares para la recreación y el turismo y áreas de un importante valor cultural (Ministerio de Medio Ambiente, 2002). Para el caso de Colombia, las zonas de alta montaña incluyen los pisos bioclimáticos glacial (nieves perpetuas, zonas nevadas o nivales), Páramo y Alto-andino (Ministerio de Medio Ambiente, 2002).

El CPJSB, incluye ocho diferentes áreas de protección (Distritos Regionales de Manejo Integrado, Parques Naturales Regionales, Reservas Forestales Protectoras Nacionales), cuya declaración y manejo es competencia de las dos corporaciones autónomas regionales con jurisdicción en el área de páramo (Corporación Autónoma Regional para la Defensa de la Meseta de Bucaramanga y Corponor) a las cuales se suma la zona de páramo declarada y delimitada por el Ministerio de Medio Ambiente y Desarrollo sostenible (Resolución No. 2090/014 MADS), que se encuentra en proceso de ajuste en su delimitación (Sentencia T-361 de 2017 de la Corte Constitucional). La coexistencia de diferentes figuras de protección y de diferentes entidades de orden gubernamental (corporaciones autónomas regionales) y departamental ha causado la fragmentación de los estudios realizados en el área de interés, que constituye una unidad biogeográfica homogénea (la unidad biogeográfica de páramo), así como también la

desarticulación de los criterios utilizados para el análisis del estado actual y para la formulación de las medidas de manejo. Esta condición genera incongruencias por un lado en términos espaciales, entre los resultados obtenidos para diferentes jurisdicciones territoriales y para diferentes zonas de áreas de conservación, y por otro lado en términos temporales, entre estudios realizados para diferentes fechas, debido a la gran diversidad de insumos y criterios de interpretación utilizados.

El CPJSB cuenta con varios estudios de uso y cobertura del suelo realizados a nivel nacional, en su mayoría realizados como parte los requisitos exigidos por la normatividad colombiana para el ordenamiento y manejo de estos ecosistemas (Duarte et al., 2014; IDEAM, 2002; Morales et al., 2007). Adicionalmente, se han venido realizando estudios de uso y cobertura del suelo por parte de las Corporaciones Autónomas Regionales con jurisdicción en el área de los complejos de Páramo, que muestran gran heterogeneidad en cuanto a los insumos utilizados, alcances, esquemas de clasificación y técnicas de procesamiento adoptadas (CDMB, 2012; CORPONOR, 2009).

Lo anterior justifica la necesidad de realizar un estudio que permita determinar la aplicabilidad de LSMA y de OBIA para la generación de mapas preliminares de cobertura del suelo en zonas de alta montaña, con el fin de minimizar los tiempos y el esfuerzo requeridos para su producción. Para este fin, las imágenes multiespectrales del sensor OLI de Landsat 8, resultan ser el insumo más apropiado debido a que son ampliamente empleadas para la producción de mapas de cobertura de la tierra, son de libre distribución, con alta resolución temporal, espacial y espectral, y con disponibilidad de largas series temporales. Adicionalmente, las imágenes de Landsat 8 han sido utilizadas recientemente por algunos autores para la el uso de enfoques no supervisados de clasificación basados en LSMA y OBIA (Gábor et al., 2017; Liping et al., 2019).

Los resultados obtenidos proporcionarán un nuevo enfoque metodológico para la producción de mapas de cobertura de la tierra en el CPJSB, que constituyen un insumo esencial para la definición del régimen de uso de las zonas de estos ecosistemas estratégicos, en armonía con los lineamientos para la elaboración del plan de manejo ambiental (Botía et al., 2018), así como para evaluar la pertinencia y los impactos de las medidas de manejo implementadas en el pasado y las que se planteen para el futuro. Por otro lado, el presente estudio cuenta con aporte al área de la teledetección y es el uso combinado del análisis lineal de mezclas espectrales y

extracción de objetos para la obtención de mapas de cobertura de la tierra en zonas de alta montaña, de acuerdo al esquema de clasificación CLC. Finalmente, se espera que los resultados constituyan un antecedente metodológico, que pueda aplicarse en otros ecosistemas de alta montaña ubicados en zonas tropicales.

1.3. Objetivos

1.4.1 Objetivo general

Determinar la aplicabilidad del análisis lineal de mezclas espectrales y de la clasificación basada en objetos para la obtención de un mapa preliminar de cobertura de la tierra a partir de imágenes multiespectrales de la misión Landsat 8 en el complejo de páramo jurisdicción Santurbán – Berlín.

1.4.2 Objetivos específicos

- Determinar, a partir del análisis de resultados obtenidos con diferentes modelos de transferencia radiativa y de métodos e insumos para la corrección de los efectos topográficos, el más óptimo para la calibración radiométrica de imágenes satelitales multiespectrales de la misión Landsat 8 de zonas de alta montaña.
- Analizar el desempeño de diferentes métodos de extracción de *endmembers* en imágenes satelitales multiespectrales de la misión Landsat 8 en zonas de alta montaña.
- Evaluar la capacidad del análisis lineal de mezclas espectrales y de la clasificación basada en objetos para obtener una delimitación preliminar de las clases de cobertura existentes en el páramo jurisdicción Santurbán-Berlín.

1.4. Estructura del documento

El documento se estructura de la siguiente manera:

1. Marco teórico: se describen los principales conceptos y categorías de conocimiento requeridas para la correcta interpretación de la metodología empleada y de los resultados obtenidos.
2. Metodología: se describe de manera detallada el proceso metodológico adoptado para la realización del estudio, presentando el desarrollo de las actividades asociadas a cada uno de los objetivos planteados, así como la estrategia de análisis de los resultados obtenidos. En este capítulo se realiza: primero, el preprocesamiento de las imágenes; segundo, la extracción de los *endmembers* con el método combinado MNF-PPI y el algoritmo SMAACC; tercero, la segmentación de las imágenes; cuarto, la asignación de clases de cobertura a los segmentos obtenidos; y por último, la validación de los mapas preliminares de cobertura obtenidos.
3. Resultados y discusión: en esta sección se realiza el análisis e interpretación de los resultados obtenidos durante el estudio, incluida su comparación con resultados obtenidos en otras investigaciones científicas similares. Los análisis realizados en este capítulo son de carácter estadístico y de interpretación visual.
4. Conclusiones: se presentan las conclusiones generales del estudio, asociadas a los objetivos planteados, así como los principales aportes del estudio realizado y las potenciales esferas de aplicación.
5. Recomendaciones: en esta sección se aportan algunas sugerencias orientadas a mejorar los resultados obtenidos, se identifican posibles investigaciones futuras que surgen de los resultados obtenidos.

2. MARCO TEORICO

A continuación, se describen los conceptos y categorías del conocimiento relacionadas con la investigación desarrollada, que dan sustento al problema planteado, así como a la metodología implementada para obtener una solución.

2.1. Ecosistemas de alta montaña y páramos

De acuerdo a la definición adoptada por el Ministerio de Medio Ambiente de Colombia, los ecosistemas de alta montaña agrupan “las culminaciones altitudinales del sistema cordillerano Andino, o áreas de mayor levantamiento orogénico y por lo tanto de mayor energía disponible e inestabilidad real y potencial que se manifiesta en la transferencia de materiales hacia las áreas más bajas, medias y periféricas” (Ministerio de Medio Ambiente, 2002). En el caso específico del territorio nacional, los ecosistemas de alta montaña corresponden a los pisos bioclimáticos Glacial (nieves perpetuas, zonas nevadas o nivales), Páramo y Alto-andino (Ministerio de Ambiente Vivienda y Desarrollo Territorial, 2002).

Por otro lado, de acuerdo a la nomenclatura utilizada por los principales investigadores de la vegetación, el suelo y el clima de la alta montaña colombiana, se consideran como parte de las zonas de alta montaña los siguientes cinturones altitudinales: Páramo, Subpáramo, Páramo, Super páramo y Bosque alto andino (IDEAM, 2002):

Los límites de estas zonas fluctúan entre ciertas alturas y los valores indicados por el IDEAM (2002) son aproximados, y se encuentran registrados en la Tabla 1.

Tabla 1. Límites aproximados de los cinturones altitudinales que conforman las zonas de alta montaña.

Fuente: adaptado de (IDEAM, 2002).

<i>Temperatura y Límite</i>	<i>Descripción</i>
11-12°C y 2800 m.s.n.m.	Límite entre el bosque Andino Bajo y el bosque Andino Alto
7 - 8°C y 3400 m.s.n.m.	Límite entre el bosque Andino Alto y el Bosque Alto Andino
6° y 3750 m.s.n.m.	Límite entre el bosque Alto Andino y el páramo (propriadamente dicho)

Para el caso de la zona de estudio, el CPJSB, en la Figura 1, es posible observar la delimitación aproximada de los cinturones altitudinales de las zonas de alta montaña.

Desde el punto de vista de la localización geográfica de los páramos, varios autores coinciden en considerarlos como ecosistemas de alta montaña, exclusivos del neotrópico, ubicados entre el límite superior del bosque andino y el límite inferior glaciario, cuya distribución espacial depende de las características climáticas en conjunto con aspectos topográficos y altitudinales, exposición a las corrientes eólicas y a la radiación solar, influencia antrópica y a las alturas máximas alcanzadas por las diferentes formaciones montañosas (Botía et al., 2018). La anterior definición está en sintonía con la adoptada por el artículo 3 de la Ley 1930 de 2018 (Congreso de la República de Colombia, 2018).

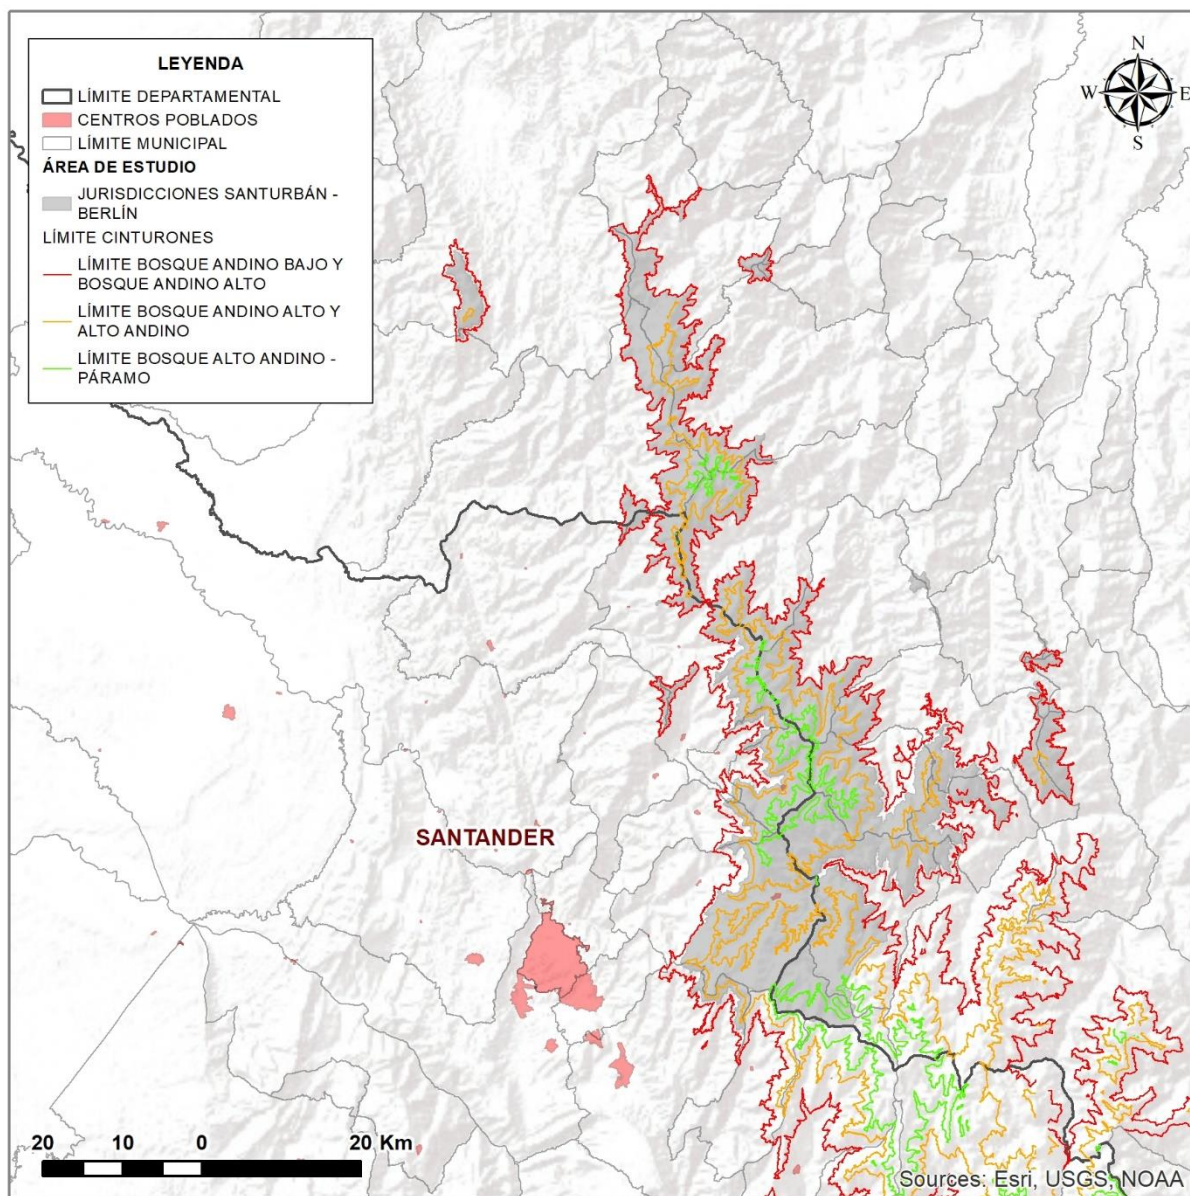


Figura 1. Delimitación aproximada de los cinturones altitudinales de las zonas de alta montaña para el área de estudio.

Fuente: Elaboración propia.

2.2. Cobertura de la tierra

Aunque muchas investigaciones hacen referencia de manera conjunta a la cobertura y al uso de la tierra, su distinción constituye un tema de interés debido a la dificultad de establecer un exacto límite entre los dos términos (Turner II & Meyer, 1991). Con fines de esclarecer la distinción, se puede decir que la “cobertura del suelo” hace referencia a la capa de suelo y biomasa, incluidos la vegetación natural, los cultivos y las estructuras antrópicas que cubren la superficie de la tierra (Verburg et al., 2009), y enfatiza en los atributos físicos de la superficie y de las capas más próximas así como en sus modificaciones en su rugosidad, albedo, emisiones de gas o diversidad biótica (Turner II & Meyer, 1991). Por lo tanto, la cobertura del suelo es directamente observable, tanto en campo como a través de las imágenes obtenidas por sensores remotos (Verburg et al., 2009). Por otra parte, el “uso del suelo” se refiere a los propósitos para los cuales el hombre destina la cobertura del suelo e incluye las prácticas de manejo del territorio (Verburg et al., 2009), como agricultura, ganadería, asentamientos, bosque protector, entre otros. Como consecuencia, el uso del suelo no siempre es fácilmente observable, aunque, en muchos casos, puede inferirse a partir de las actividades o de los elementos estructurales que se evidencian en el paisaje (Turner II & Meyer, 1991).

2.3. Teledetección y sistemas sensores

La teledetección o percepción remota se define como el arte, la ciencia y la tecnología para obtener información confiable de la Tierra, el medio ambiente, objetos físicos y procesos, a partir de imágenes y sistemas de sensores remotos (Lazaridou & Patmio, 2012).

La teledetección, gracias a la mayor disponibilidad y calidad de imágenes satelitales y aéreas, ha determinado su uso en la producción de mapas de cobertura del suelo, siendo económicamente más favorable y eficiente que el muestreo en campo, dado que se pueden cubrir grandes extensiones de territorio (Gábor et al., 2017).

Por otro lado, las imágenes Landsat constituyen actualmente uno de los principales insumos empleados para la producción de mapas de uso y cobertura a nivel global, nacional y regional (Gábor et al., 2017), gracias a su libre distribución, la alta resolución temporal (16 días)

y espacial (de 15 a 30m), y la disponibilidad de largas series temporales (Bullock et al., 2018). El programa Landsat ofrece los registros continuos de información más largos (NASA, 2020), desde el año de 1972 (Jensen, 2015). A la fecha son 8 las misiones del programa Landsat que han sido lanzadas, con diferentes características de sensores, en términos de resolución espectral, radiométrica y espacial.

La última misión, el satélite Landsat-8, fue lanzado el 11 de febrero de 2013, incluye dos instrumentos, el sensor OLI y el TIRS, que proporcionan información multiespectral con resolución espacial de 30 m para el rango visible (VIS), de infrarrojo cercano (NIR), y de infrarrojo medio de onda corta (SWIR); de 100 m para las bandas térmicas; y de 15 m para la banda pancromática (Tabla 2).

Tabla 2. Bandas de la misión Landsat-8.

Fuente: NASA, 2020.

<i>Sensor</i>	<i>Bandas espectrales</i>		<i>Resolución espacial</i>
	<i>N°</i>	<i>Rango espectral [μm]</i>	
OLI	1	0.433–0.453 (costera-aerosoles)	30 m
	2	0.450–0.515 (azul)	30 m
	3	0.525–0.600 (verde)	30 m
	4	0.630–0.680 (rojo)	30 m
	5	0.845–0.885 (IRC)	30 m
	6	1.560–1.660 (SWIR-1)	30 m
	7	2.100–2.300 (SWIR-2)	30 m
	8	0.500–0.680 (PAN)	15 m
	9	1.360–1.390 (cirrus)	30 m
TIRS	10	10.6–11.2 (IRT-1)	100 m
	11	11.5–12.5 (IRT-2)	100 m

Notas: IRC: infrarrojo cercano; SWIR: infrarrojo medio de onda corta; PAN: pancromática; IRT: infrarrojo térmico.

El sensor OLI (*Operational Land Imager*), adquiere la información para las bandas del visible, NIR, SWIR y pancromática, con una resolución radiométrica de 12 bits. Proporciona dos bandas adicionales con respecto al sensor ETM+ de Landsat 7, una banda específica para la detección de zonas costeras y aerosol (banda 1), y una banda para las nubes cirrus (banda 9). El sensor TIRS (*Thermal Instrument*), proporciona información para las dos bandas térmicas. Lo anteriormente descrito se puede observar en la Figura 2.




Figura 2. Comparación de las bandas espectrales de las misiones Landsat.

Fuente: NASA, 2020.

La información espectral y espacial es necesaria para la generación de mapas de uso y cobertura del suelo, dado que dicha información se puede relacionar con diferentes usos y coberturas. Las metodologías existentes para la producción de dichos mapas se enfocan, por un lado, en la definición de estándares para la elaboración de cartografía temática a partir de la interpretación visual de imágenes de sensores remotos y una rigurosa validación en campo (European Environmental Agency, 1997; IDEAM et al., 2008), y por el otro, en la creciente automatización de los procesos de clasificación de imágenes (Costa et al., 2018; Gábor et al., 2017; Ma et al., 2017).

2.4. Preprocesamiento de datos de percepción remota

El preprocesamiento de datos de sensores remotos se refiere a las operaciones requeridas previamente a la extracción de información. De manera ideal, permite obtener imágenes radiométrica y geoméricamente más próximas a las características reales del área de estudio (Jensen, 2015).

2.4.1. Corrección radiométrica

Variaciones en las condiciones de observación, como la iluminación del sol, la dispersión y absorción atmosférica, así como la calibración y desempeño del detector, determinan diferencias en los valores de radiancia no relacionadas con la reflectancia de la cobertura de la superficie terrestre (Rogan & Chen, 2003). La corrección de estos efectos, así como los coeficientes de calibración del sensor, la radiación solar, y los ángulos solares, deben incluirse como parte de los procesos de corrección radiométrica, para convertir los niveles digitales a valores de reflectancia de superficie (Chavez, 1996). La reflectividad o reflectancia hemisférica, constituye una variable física que permite obtener una interpretación más sólida de los resultados, garantiza la compatibilidad multitemporal y el análisis integrado entre imágenes de distintos sensores (Chuvienco Salinero, 1996). Esta es definida como la proporción adimensional entre el flujo radiante reflejado desde una superficie y el flujo radiante incidente sobre ella (Jensen, 2015):

$$\rho_{\lambda} = \frac{\Phi_{r\lambda}}{\Phi_{i\lambda}} \quad (1)$$

Donde:

ρ_{λ} es la reflectancia para la longitud de onda λ

$\Phi_{r\lambda}$ es el flujo radiante reflejado por la superficie para la longitud de onda λ

$\Phi_{i\lambda}$ es el flujo radiante incidente sobre la superficie para la longitud de onda λ

La conversión de los niveles digitales de la imagen de un determinado sensor, a reflectancias de la superficie se realiza en tres etapas, las cuales se describen a continuación (Chuvienco Salinero, 1996):

- 1. Conversión de niveles digitales a valores radiancia.** Se realiza mediante los coeficientes de calibración específicos de cada sensor, de acuerdo con la siguiente ecuación:

$$L_{sen,K} = a_{0,k} + a_{1,k}ND_K \quad (2)$$

Donde:

$L_{sen,K}$ es la radiancia espectral recibida por el sensor en la banda K ($W m^{-2} sr^{-1} \mu m^{-1}$)

$a_{0,k}$ y $a_{1,k}$ son los coeficientes de calibración para la banda K .

ND_K es el nivel digital de la imagen para la banda K .

- 2. Conversión de valores de radiancia a reflectancia al techo de la atmosfera** (*Top of the Atmosphere* - TOA). Asumiendo un comportamiento Lambertiano de la superficie terrestre, lo cual constituye una simplificación, la reflectancia al techo de la atmosfera, puede calcularse de acuerdo con la siguiente ecuación:

$$\rho_k^* = \frac{K\pi L_{sen,K}}{E_{0,k} \cos\theta_i} \quad (3)$$

$$K = \left(1 + 0.0167 \left(\sin \left(\frac{2\pi(D - 93,5)}{365} \right) \right) \right)^2 \quad (4)$$

Donde:

ρ_k^* es la reflectancia aparente para la banda K

K es el factor corrector de la distancia Tierra – Sol.

$L_{sen,K}$ es la radiancia espectral recibida por el sensor en la banda K ($W m^{-2} sr^{-1} \mu m^{-1}$)

$E_{0,k}$ es la irradiancia solar en el techo de la atmósfera.

θ_i es el ángulo cenital del flujo incidente.

D es el día en calendario juliano

Nota: el seno se asume en radianes.

- 3. Conversión de reflectancia TOA a reflectancia de superficie** (*Bottom of the Atmosphere* – BOA). Los componentes líquidos y gaseosos de la atmosfera causan la modificación de la señal procedente de la cubierta (Chuvienco Salinero, 1996), mediante efectos de dispersión y absorción atmosféricas, fenómenos que se conocen, en su conjunto como atenuación atmosférica (Jensen, 2015).

Los métodos de corrección atmosférica pueden clasificarse en dos tipologías principales: absolutos o relativos. Los métodos absolutos tienen como objetivo principal convertir los valores digitales a valores de reflectancia de superficie escalados, que pueden ser comparados o utilizados en conjunto con valores de reflectancia de superficie obtenidos en cualquier otro lugar del planeta. Por otra parte, los métodos relativos, pueden utilizarse cuando no haya disponibilidad de la información requerida para la aplicación de una corrección absoluta, y se requiera normalizar la intensidad de diferentes bandas con una imagen de una sola fecha o con imágenes de diferentes fechas a una escena estándar seleccionada por el analista (Jensen, 2015).

Entre los modelos de transferencia radiativa más comunes, se destacan: primero, el *Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes - FLAASH*¹ incluido en ENVI; y segundo, el *ATmospheric CORrection –ATCOR*² (Jensen, 2015), disponible en PCI Geomatics. Ambos modelos, permiten calcular los valores de reflectancia de superficie y remover los efectos atmosféricos de la imagen de satélite, preparándola para el análisis bajo diferentes condiciones atmosféricas. Como resultado, generan una imagen con valores de reflectancia de superficie corregida de efectos atmosféricos y del terreno, así como productos adicionales de gran utilidad para el preprocesamiento, como las máscaras de nubes (Jensen, 2015).

Ambos modelos, tienen la capacidad de remover los artefactos en los datos corregidos, aplicando algunos ajustes a los datos de reflectancia que hacen que el espectro sea más similar a los materiales reales registrados en campo mediante los equipos de espectroradiometría (Jensen, 2015).

2.4.2. Corrección de efectos de relieve

La iluminación y la radiancia provenientes de elementos ubicados en superficies no perpendiculares a la fuente de irradiación, no representan de manera confiable la respuesta espectral de estos elementos, e introducen una variabilidad espectral “artificial” debido a un efecto topográfico, el cual determina muchos problemas en el análisis digital de los datos, especialmente para la clasificación digital de cobertura del suelo y segmentación de imágenes (Civco, 1989). La magnitud del efecto topográfico, varía en función de la inclinación y del acimut solar, así como de la pendiente y orientación del terreno, y puede producir grandes variaciones en la radiancia asociada con una cobertura uniforme u homogénea (Civco, 1989).

Los métodos de corrección del efecto topográfico requieren de un modelo digital de elevaciones (DEM) del área de estudio, para poder estimar la iluminación recibida por el sol en unas condiciones específicas de pendiente y orientación (Jensen, 2015; Sola, 2015). Entre las características del DEM que pueden afectar al éxito de la corrección topográfica, se destacan: primero, una adecuada resolución espacial, la cual es sugerida como mínimo igual a la del sensor

¹ Desarrollado por el Air Force Philips Laboratory, Hanscom AFB y Spectral Science Inc.

² Desarrollado por el DLR, el Centro Aeroespacial Alemán.

y preferiblemente para imágenes con resolución de 30 m debería ser de 10 m, y segundo la presencia de artefactos. Dichos artefactos se presentan cuando se realizan remuestreos a mayor resolución espacial o se altera la resolución radiométrica de la imagen original (número de bits), estos son transferidos a la imagen corregida topográficamente, para suavizar estos efectos se sugiere la aplicación de un filtro kernel (Sola, 2015).

El primer paso para la corrección de las sombras generadas por la topografía es calcular las condiciones de iluminación IL, aplicando la siguiente ecuación, propuesta por Civco (1989) y Colby (1991) en Hantson (2011):

$$IL = \cos \gamma_i = \cos \theta_s \cos \eta_i + \sin \theta_s \sin \eta_i \cos (\Phi_a - \Phi_o) \quad (5)$$

Donde:

γ_i es el ángulo de incidencia.

θ_s es el ángulo cenital.

η_i es el ángulo de la pendiente.

Φ_a es el ángulo acimutal.

Φ_o es el aspecto.

El parámetro IL o $\cos \gamma_i$, varía entre -1 y +1, e indica la iluminación mínima y máxima, respectivamente (Pimple et al., 2017).

La corrección del coseno mejorado (*Improved Cosine Correction*), introducida por Civco en 1989, es el método Lambertiano más común, donde la reflectancia de superficie es calculada, para todas las bandas, con base en las condiciones promedio de iluminación, de acuerdo a la siguiente ecuación (Civco, 1989; Pimple et al., 2017):

$$\rho_{\lambda,h,i} = \rho_{\lambda,i} + \rho_{\lambda,i} \left(\frac{\cos \bar{\gamma}_i - \cos \gamma_i}{\cos \bar{\gamma}_i} \right) \quad (6)$$

Donde:

$\rho_{\lambda,h,i}$ es la reflectancia normalizada topográficamente del pixel i en el terreno horizontal.

$\rho_{\lambda,i}$ es la reflectancia del pixel i en terreno escabroso.

$\cos \gamma_i$ es el la iluminación escalada a valores entre 0 y 255.

$\cos \bar{\gamma}_i$ es el valor promedio del modelo de iluminación escalado a valores entre 0 y 255.

De acuerdo a Civco (1989), la ecuación anterior permite disminuir el efecto topográfico y mejora de manera general el análisis de imágenes multispectrales y el proceso de clasificación.

Por otro lado, la corrección C (*C- Correction*), propuesta por Teillet (1982), considera la diferencia entre bandas bajo diferentes niveles de irradiación difusa. Por lo tanto, es un método no Lambertiano (Riaño et al., 2003), con enfoque empírico-estadístico, basado en coeficientes de regresión de banda-específicos (Pimple et al., 2017). La ecuación para la corrección topográfica propuesta por Teillet (1982) es la siguiente:

$$\rho_{\lambda,h,i} = \rho_{\lambda,i} \left(\frac{\cos \theta_s + c_\lambda}{\cos \gamma_i + c_\lambda} \right) \quad (7)$$

$$c_\lambda = \frac{b_\lambda}{m_\lambda} \quad (8)$$

$$\rho_{\lambda,i} = b_\lambda + m_\lambda \cos \gamma_i \quad (9)$$

Donde:

$\rho_{\lambda,h,i}$ es la reflectancia del pixel i en el terreno horizontal.

$\rho_{\lambda,i}$ es la reflectancia del pixel i en terreno escabroso.

θ_s es el ángulo cenital

$\cos \gamma_i$ es la iluminación IL.

c_λ es una constante empírica, calculada para cada banda separadamente.

b_λ y m_λ son los coeficientes de regresión entre la iluminación y las reflectancias de las diferentes bandas.

Uno de los métodos más utilizados para validar el desempeño de la remoción del efecto topográfico es la disminución de la dependencia entre la iluminación ($\cos \gamma_i$) y la radiancia o reflectancia de cada banda espectral luego de realizar la corrección del relieve. Esta dependencia es medida a través del coeficiente de correlación, la pendiente de la regresión lineal, o ambos (Hantson & Chuvieco, 2011; Sola, 2015). En regiones montañosas la reflectancia de los pixeles, presenta una alta correlación entre el coseno del ángulo de incidencia, que disminuye o es anulada con la corrección del relieve (Gao et al., 2014).

2.5. Clasificación digital de imágenes

La clasificación digital de imágenes consiste en la categorización de los píxeles de una imagen en un número definido de grupos o clases, con base en los valores de un conjunto de variables o de píxeles de referencia (Vega et al., 2004). Dependiendo de la metodología empleada para definir las estadísticas de entrenamiento, se han dividido los métodos para clasificación de imágenes en supervisados y no supervisados (Chuvienco Salinero, 1996).

En esta sección se presenta brevemente un conjunto de algoritmos y técnicas empleados para la clasificación digital de imágenes, que por sus características, tales como: no requerir conocimiento previo del área de estudio, disponibilidad en software libre, permitir simular la mayoría de los procesos de interpretación visual, y ser utilizadas en imágenes multiespectrales Landsat; se ajustan a la producción de mapas preliminares de cobertura de la tierra a partir de información de imágenes multiespectrales obtenidas mediante percepción remota, y permiten cumplir con los objetivos del presente estudio. Las técnicas en mención son: el algoritmo de clasificación no supervisada ISODATA, y los enfoques LSMA y OBIA.

2.5.1. Clasificación no supervisada con ISODATA

Entre los enfoques que permiten la extracción de información temática a partir de imágenes multiespectrales, la clasificación no supervisada, es una técnica que no requiere de conocimiento a priori de las clases o tipos de coberturas en la escena, y los píxeles con características similares son agrupados de acuerdo a criterios estadísticos (Jensen, 2015). Este tipo de clasificación, realiza una búsqueda automática de los grupos de valores homogéneos dentro de la imagen, por lo tanto no requieren de conocimiento previo del terreno (Chuvienco Salinero, 1996).

Entre los algoritmos más utilizados para la clasificación no supervisada se encuentra el Iterative Self-Organizing Data Analysis Technique o ISODATA, el cual requiere una intervención mínima por parte del usuario y se encuentra disponibles en mayoría de los softwares de procesamiento de imágenes y de sistemas de información geográfica, incluyendo los de libre distribución como Quantum GIS³.

³ <https://www.qgis.org/es/site/>

ISODATA es una modificación del algoritmo de agrupación K-means, que incluye: primero, la fusión de dos grupos si su distancia en el espacio multiespectral es inferior a al rango definido por el usuario; y segundo, la definición de reglas para separar un grupo en dos grupos diferentes (Jensen, 2015).

2.5.2. Análisis lineal de mezclas espectrales (LSMA)

Las imágenes multiespectrales de resolución espacial media, como los datos de las misiones Landsat, son muy utilizadas en aplicaciones geográficas por su capacidad de cubrir amplias áreas y por su corto periodo de repetición (Deng et al., 2019). Sin embargo, en estas imágenes es inevitable encontrar píxeles mixtos, que contienen información de más de una clase de cobertura pura, debido a la amplia cobertura de los píxeles - aproximadamente 900 m² de superficie - y a la fragmentación y diversidad de los diferentes tipos de cobertura existentes (Deng et al., 2019; Du et al., 2014; Liping et al., 2019), entre otros factores. De acuerdo a (Deng et al., 2019), en estos casos, asignar una sola clase a un píxel es inapropiado, ya que implica perder información sobre las otras clases eventualmente presentes. Por tanto, el uso del desmezclado espectral, puede proporcionar resultados más confiables que los enfoques tradicionales basados en la clasificación del píxel (Deng et al., 2019), dado que la existencia de píxeles mixtos puede reducir enormemente la confiabilidad de la clasificación de la imagen, afectando los parámetros cuya estimación se pueda derivar (Liping et al., 2019).

De acuerdo a (Salih et al., 2017), entre las principales ventajas de las técnicas de desmezclado espectral con respecto a las técnicas tradicionales de clasificación se encuentran: la posibilidad de clasificar objetos de tamaño inferior a la resolución espacial del sensor; la identificación de materiales específicos en píxeles mixtos; la creación de firmas espectrales puras; su uso para una gran variedad de aplicaciones; el desarrollo de firmas espectrales transferibles de escena en escena, aunque se hayan tomado en diferentes horarios del día o años; permite la búsqueda de respuestas espectrales específicas en grandes áreas geográficas. El desmezclado espectral es un procedimiento mediante el cual el espectro de un píxel mixto es descompuesto en una colección de componentes, llamados *endmembers*, que corresponden normalmente a elementos macroscópicos con firmas espectrales relativamente constantes como agua, suelo, metales, etc., y en un conjunto de sus fracciones correspondientes, o abundancias, que indican la proporción en la que está presente cada *endmember* en el píxel (Keshava & Mustard, 2002).

El modelo lineal de mezclas espectrales (MLM), es el modelo más sencillo y más utilizado para representar la síntesis de los píxeles mixtos a partir de diferentes *endmembers* (Keshava & Mustard, 2002), y su derivado, el análisis lineal de mezclas espectrales (LSMA) es un método ampliamente utilizado para enfrentarse al problema de los píxeles mixtos (Zurita-Milla et al., 2011).

El MLM se basa en que la mayoría de la variabilidad espectral observada en la escena es consecuencia de los *endmembers* presentes en diferentes proporciones. Si el total de la superficie se considera subdividida en proporciones iguales a las abundancias relativas de cada *endmember*, entonces la radiación reflejada expresará las características de los materiales asociados con las mismas proporciones. En este sentido, existirá una relación lineal entre las abundancias relativas de las sustancias comprendidas en la escena y el espectro de la radiación reflejada. Lo anterior casi nunca se observa en la naturaleza, puesto que los componentes de la superficie están mezclados a una escala espacial muy pequeña para ser percibida por el sensor (Keshava & Mustard, 2002).

Por otro lado, el desmezclado lineal, ha sido ampliamente utilizado debido a su simple base conceptual, la clara significancia física, su fácil implementación y eficiencia (Liping et al., 2019). La siguiente ecuación expresa el modelo matemático empleado para el análisis lineal de mezclas espectrales (Lu et al., 2003):

$$R_i = \sum_{k=1}^n f_k R_{ik} + \varepsilon_i \quad (10)$$

Donde:

$i=1, \dots, m$ es el número de bandas espectrales k ;

$k=1, \dots, n$ es el número de *endmembers*;

R_i es la reflectancia espectral de la banda i para un determinado pixel, que contiene uno o más *endmembers*.

f_k es la proporción del *endmember* k en el pixel;

R_{ik} es la reflectancia espectral del *endmember* k en el pixel i ;

ε_i es el error para la banda i .

Para evaluar el ajuste del modelo, es calculado el error cuadrático medio (RMSE) para todos los píxeles de la imagen. Si el valor del RMSE es alto se considera que existe un mal ajuste

del modelo (Deng et al., 2019; Hostert et al., 2003; Jensen, 2015; Liping et al., 2019; Salih et al., 2017).

De acuerdo a (Keshava et al., 2000) el modelo de desmezclado lineal es una secuencia de tres pasos consecutivos que permiten estimar el espectro de los *endmembers*, y las abundancias relativas asociadas para cada píxel en la escena. Estos pasos son: el primero, opcional, es la reducción de la dimensión de los datos de la escena para reducir el costo computacional; el segundo, es la determinación de los *endmembers* a partir de la estimación de los espectros de los píxeles mixtos; el tercero, es la estimación de las abundancias relativas de cada píxel mixto.

Uno de los pasos críticos para la aplicación del análisis de mezclas espectrales es la definición del número de *endmembers* (Shrivastava et al., 2016). Dado que la calidad de las imágenes de abundancia depende de la adecuada selección y cantidad de *endmembers*, los cuales a su vez definirán la eficiencia con la cual se verán reflejadas las características de la superficie y de reflectancia de los píxeles (Liping et al., 2019). Normalmente, un número de *endmembers* entre 3 y 7 es apropiado para la mayoría de aplicaciones, dependiendo del número de bandas utilizados y de la variabilidad espectral de los componentes de la escena (Mustard & Sunshine, 1999). La ecuación de descomposición del píxel (Ecuación 10), indica que el número de componentes puros o *endmembers* debe ser inferior al número de bandas de la imagen, por lo tanto, para imágenes del sensor OLI de Landsat-8, el número de *endmembers* debe ser inferior a 6 (Liping et al., 2019).

Usualmente, la selección de los *endmembers* puede realizarse, a partir bien sea de los datos de la imagen, o de la nube de puntos de los primeros tres componentes obtenidos con la reducción de la dimensionalidad mediante el método de la Mínima Fracción de Ruido (*Minimum Noise Fraction* –MNF), identificando los píxeles ubicados en los extremos de la nube de puntos (Li et al., 2007).

En los últimos años, el avance en las técnicas de extracción de *endmembers* está evolucionando hacia el uso de algoritmos automatizados de extracción a partir de los datos de la imagen (Shrivastava et al., 2016).

El método basado en el Índice de Pureza del Píxel (PPI), desarrollado por Boardman (1995), permite reducir el esfuerzo requerido para la extracción de *endmembers* e incrementar la fiabilidad de su selección. Este algoritmo, asigna a cada píxel de la imagen un puntaje que

corresponde al número de veces que el pixel es encontrado en una posición extrema en las diferentes proyecciones n-dimensionales de los datos obtenidas mediante un vector aleatorio que atraviesa la nube de datos. Puntajes altos representan mayor pureza, y corresponden a pixeles que ocupan posiciones extremas en la distribución de los datos de manera repetitiva (Li et al., 2007). El algoritmo PPI ha sido empleado ampliamente en imágenes hiperespectrales debido a su difusión y disponibilidad en el software ENVI (Chang & Plaza, 2006). Sin embargo recientemente, varios autores lo han empleado en imágenes multispectrales de la misión Landsat para la creación de mapas de uso y cobertura, en contextos urbanos (Li et al., 2007; Liping et al., 2019) y rurales (Souza et al., 2013).

En el estudio realizado por Li (2007) se presenta el uso combinado de la selección de *endmembers* a partir de la visualización n-dimensional de los componentes obtenidos con MNF y de PPI, en una imagen del sensor ETM+ de Landsat 7, con el fin de evitar la inclusión de pixeles impuros en la selección realizada a través de la visualización n-dimensional de la nube de puntos.

La variabilidad ambiental y atmosférica determina la potencial existencia de muchos *endmembers* o componentes puros por un determinado material (Gruninger et al., 2004b, 2004a). Aunque el espectro de un pixel es único en la escena, no hay una correspondencia única entre el número de materiales de la escena y el número de *endmembers*. Por ejemplo, un pixel puede contener un solo material, o contener un alto porcentaje de un material en combinación con una combinación única de otros materiales. Por otro lado, el uso del algoritmo *Sequential Maximum Angle Convex Cone* (SMACC) de enfoque no supervisado (Niroumand et al., 2012) es uno de los métodos para la extracción de *endmembers* y de sus abundancias en imágenes hiperespectrales (Sharifi et al., 2019). Este algoritmo, desarrollado por Gruninger (2004b), utiliza un modelo de cono convexo, conocido como minimización residual, que permite identificar los *endmembers* de una imagen con base en información espectral (Sharifi et al., 2019). A diferencia de otros métodos no restringe el número de *endmembers* por el número de bandas (Gruninger et al., 2004a). Adicionalmente, permite obtener imágenes de abundancia que proporcionan las fracciones de cada *endmember* que contribuyen a determinar la reflectancia total de cada pixel en la escena (Maselli, 2012). Recientemente, varios autores han empleado el algoritmo SMACC para la extracción de *endmembers* en imágenes multispectrales de los sensores OLI (Milewski et al., 2020; Myachina & Chibilev, 2015), ETM+ (Karoui et al., 2012; Maselli, 2012; Niroumand et al., 2012) y TM

(Maselli, 2012) de Landsat, con el fin de realizar el análisis lineal de mezclas espectrales y lograr, la extracción de clases específicas de coberturas terrestres.

Tanto el algoritmo para la extracción de píxeles puros (PPI), como el algoritmo SMACC se encuentran disponibles en el software ENVI.

2.5.3. Análisis de imágenes basada en objetos

El análisis de imágenes basada en objetos (OBIA o GEOBIA⁴) se ha convertido recientemente en una técnica clave para la clasificación de imágenes y creación de mapas de cobertura de la tierra (Gábor et al., 2017; Liping et al., 2019). Lo anterior dado que los resultados obtenidos con métodos de clasificación basados en el procesamiento de la escena pixel por pixel, no son satisfactorios, sobre todo en zonas espectralmente heterogéneas (Gábor et al., 2017). En zonas de alta montaña, la aplicación de estos métodos genera dificultades en la clasificación de zonas de bosques por su gran variabilidad en términos de reflectancia y la confusión espectral entre especies (Dorren et al., 2003). A diferencia de estos métodos de procesamiento pixel por pixel, OBIA permite descomponer la escena en objetos relativamente homogéneos (denominados parches o segmentos) utilizando procesos de segmentación multiresolución (Jensen, 2015).

Los segmentos creados mediante técnicas de análisis de imagen permiten obtener información espacial sobre los segmentos u objetos (Blaschke, 2010), es decir, no son únicamente considerados los píxeles por separado. Gracias a lo anterior, OBIA permite reproducir en gran parte los procesos de interpretación visual de imágenes, siendo sus mayores ventajas la eficiencia en términos de tiempo y la obtención de imágenes con un nivel de detalle comparable a las obtenidas a través de procesos manuales (Gábor et al., 2017).

El OBIA ha sido empleado en varios estudios para la producción de mapas de coberturas terrestres a partir de imágenes multispectrales de la misión Landsat (Dorren et al., 2003; Geneletti & Gorte, 2003; Kawakubo et al., 2013; Liping et al., 2019; Tewkesbury et al., 2015). En algunos de estos estudios, ha sido utilizado en combinación con el análisis lineal de mezclas espectrales

⁴ Algunos autores, utilizan la expresión Geographic Object Based Image Analysis (GEOBIA) para enfatizar el uso de OBIA en el campo de la teledetección de los Sistemas de Información Geográfica y de las ciencias naturales, excluyendo otros posibles campos de aplicación. Sin embargo, para simplificar, para fines del presente documento se hará referencia únicamente al término OBIA.

(LSMA) en imágenes de los sensores TM y ETM+ de Landsat (Kawakubo et al., 2013), y más recientemente, con imágenes del sensor OLI de la misión Landsat-8 para la clasificación de diferentes tipos de coberturas terrestres en la provincia de Fujian, en China, obteniendo valores de fiabilidad global superiores al 90% (Liping et al., 2019).

Actualmente, existen varios software con capacidad para abordar la clasificación basada en objetos, entre estos se destacan eCognition, Feature Analyst, IDRISI, y ENVI (Jensen, 2015). Entre los softwares de código y uso libre, se destacan SPRING, desarrollado por el INPE⁵, y Orfeo Toolbox⁶.

2.6. Esquemas de clasificación

El esquema de clasificación, según Congalton (2009) es un aspecto fundamental de cualquier proyecto que lleve a la producción de mapas, ya que define las categorías del mapa y permite organizar la información espacial de manera lógica y ordenada, reduciendo el número de elementos existentes a una cantidad razonable. Los principales elementos que lo deben componer son: primero, un conjunto de etiquetas (urbano, residencial, bosques, etc.), segundo, un conjunto de definiciones como puede ser una clave dicotómica para la asignación de las etiquetas, tercero, la definición de una la unidad mínima cartografiable, la cual define el área mínima que debe cumplir cada elemento de las categorías definidas para su delimitación en el mapa. Por otra parte, el nivel de detalle del esquema (definido por el número y la complejidad de las categorías, entre otras características), influencia de manera importante el esfuerzo requerido para la elaboración del mapa y su validación.

De acuerdo a Di Gregorio (2005) en un sentido abstracto e ideal, un sistema de clasificación deberían exhibir las siguientes propiedades:

- Hacer uso de principios de clasificación consistentes, únicos y sistemáticos.
- Adaptarse a describir toda la variedad elementos y de características.
- Ser un sistema completo, que proporcione total cobertura del mundo que describe.

⁵ <http://www.inpe.br/>.

⁶ <https://www.orfeo-toolbox.org>.

- Definir clases únicas, mutuamente exclusivas y precisas.

Entre los esquemas de clasificación más utilizados a nivel internacional, se encuentra el CORINE Land Cover, liderado por la Comisión Europea, una iniciativa que pretende unificar la generación de cartografía de uso y cobertura del suelo en los estados miembros, aunque su adopción se ha ido incrementando en los países extra europeos (Taylor et al., 1996). Este sistema ha sido adaptado al contexto colombiano, dando origen a la “Leyenda Nacional de Uso y Cobertura de la Tierra CORINE Land Cover adaptada para Colombia Escala 1:100.000” (IDEAM et al., 2008), la cual permite unificar los criterios, conceptos y métodos para la creación de mapas de uso y cobertura del suelo en el país a partir de la interpretación visual de imágenes de satélite asistida por computador y la generación de una base de datos geográfica (IDEAM, 2010). La leyenda nacional presenta una estructura jerárquica, donde las unidades de coberturas de la tierra se definen principalmente con base en criterios fisonómicos de altura y densidad, claramente definidos y aplicables a todas las unidades consideradas para un grupo de coberturas del mismo tipo. El concepto de jerarquía se refiere a que las subclases pueden ser combinadas de manera jerárquica en categorías de mayor nivel de manera coherente, lo cual permite generar mapas simplificados cuando se requiera (Jensen, 2015), y a su vez garantiza la posibilidad de incluir nuevas unidades o la definición de nuevos niveles de unidades para estudios más detallados, permitiendo su ubicación y definición rápidamente (IDEAM, 2010).

El esquema de clasificación adoptado se base en los siguientes criterios rectores (IDEAM, 2010):

- Una unidad mínima cartografiable para la escala 1:100.000 es de 25 hectáreas, excepto para los territorios artificializados, donde la unidad mínima es de 5 hectáreas.
- La identificación y delimitación de la unidad de cobertura de la tierra corresponderá a la fecha de toma de la imagen de satélite.
- Los niveles 1 y 2 de la leyenda permanecen iguales a los de la leyenda de CORINE Land Cover de Europa.
- Las unidades de la leyenda para la escala 1:100.000 varían desde el nivel 3 hasta el nivel 6 en los diferentes grupos de coberturas, variación que depende del tipo de cobertura.

2.7. Evaluación de conformidad temática

De acuerdo a la metodología adoptada a nivel nacional para la producción de mapas de cobertura de la tierra, la metodología CORINE Land Cover (CLC) para el territorio colombiano (IDEAM, 2010), la conformidad temática se define como el proceso de revisión y corrección continuo y sistemático que se realiza sobre cada una de las planchas previamente distribuidas a los diferentes intérpretes, con el propósito de evaluar y garantizar la confiabilidad y la exactitud temática del producto (IDEAM, n.d.).

La exactitud temática exigida por la CLC se establece en el 85%, y se refiere a que el polígono interpretado efectivamente corresponda al tipo de cobertura que indica el intérprete y al respectivo código establecido en la Leyenda Nacional (véase el documento de Leyenda Nacional, IDEAM, 2010). La evaluación de la exactitud temática se realiza en formato digital haciendo uso de fotografías aéreas (IDEAM, n.d.). Adicionalmente, se realiza un control en campo para verificar las unidades de cobertura interpretadas que presentan mayor incertidumbre en su identificación y delimitación (IDEAM, n.d.).

En el campo de la teledetección, la conformidad temática se establece mediante la evaluación cuantitativa de la fiabilidad, que permite determinar la calidad del mapa creado a partir de datos de percepción remota, mediante la identificación y medición de los errores del mapa. Su implementación incluye el diseño de muestreo, la recolección de información para cada muestra y el análisis de resultados (Congalton & Green, 2009). Entre los aspectos más importantes a definir para el diseño de muestreo, se destacan: la definición de la unidad de muestreo, el tamaño de la muestra y la modalidad de selección de las muestras. Según Congalton & Green (2009), las evaluaciones de la fiabilidad se pueden realizar utilizando como unidad de muestreo el pixel o el polígono. En cuanto al pixel este constituye una delimitación arbitraria del paisaje que esta escasamente relacionada con el tipo o uso de cobertura terrestre, la ubicación del pixel de referencia no necesariamente igual a la ubicación del pixel en el mapa y raras veces los esquemas de clasificación especifican el tamaño del pixel como unidad mínima cartografiable. En relación con los polígonos estos representan clases homogéneas, y son creados de manera manual, a través de la interpretación visual, o mediante algoritmos de clasificación basados en objetos.

Con respecto al número de muestras Congalton (2009), definen que:

- Para áreas de estudio inferiores a 1 millón de acres ($\cong 4047 \text{ Km}^2$) y un número de clases inferior a 12, se requiere un número 50 muestras por clase.
- Para áreas mayores o con esquemas de clasificación más complejos, deben definirse de 75 a 100 muestras por clase.

Entre los diferentes esquemas selección de muestras, el método aleatorio estratificado se base en la subdivisión del área de estudio en estratos, donde cada estrato es muestreado de manera aleatoria. La mayor ventaja de este método es garantiza la inclusión de todos los estratos en el muestreo, lo cual es especialmente importante cuando se presentan clases poco frecuentes en el área de estudio pero muy importantes (Congalton & Green, 2009).

Con respecto a los datos de referencia a emplear en la validación de los resultados, para los esquemas de clasificación sencillos con un número pequeño de clases, pueden ser verificados mediante la interpretación de imágenes aéreas o videos. A medida que el nivel de detalle aumenta, también debería aumentar la complejidad de recolección de datos (Congalton & Green, 2009). Finalmente, en relación al análisis de resultados, los métodos estadísticos para determinar la fiabilidad cuantitativa incluyen la fiabilidad total, la fiabilidad del usuario, del productor, y el análisis Kappa (Alqurashi & Kumar, 2013).

La determinación de la fiabilidad se deriva de la construcción de la matriz de error o confusión (Chuvieco Salinero, 1996), que consiste en una matriz de números organizados en líneas y columnas que expresan el número de muestras asignadas a una particular categoría en una clasificación, con respecto al número de unidades de muestreo asignadas a una particular categoría en otra clasificación (Congalton & Green, 2009).

Como se ilustra en la Figura 3 la fiabilidad global del mapa es dada por la relación entre el número de puntos correctamente asignados y el total, los residuales en las filas indican tipos de cubierta que no se incluyeron en el mapa (errores de omisión), mientras que los residuales en las columnas indican cubiertas del mapa que no se ajustan a la información de referencia utilizada para la validación (errores de comisión) (Chuvieco Salinero, 1996).

La fiabilidad del productor y del usuario fueron introducidas por Story (1986) y son maneras de representar las fiabilidades individuales de cada categorías en vez de tener en cuenta únicamente la fiabilidad global (Congalton & Green, 2009).

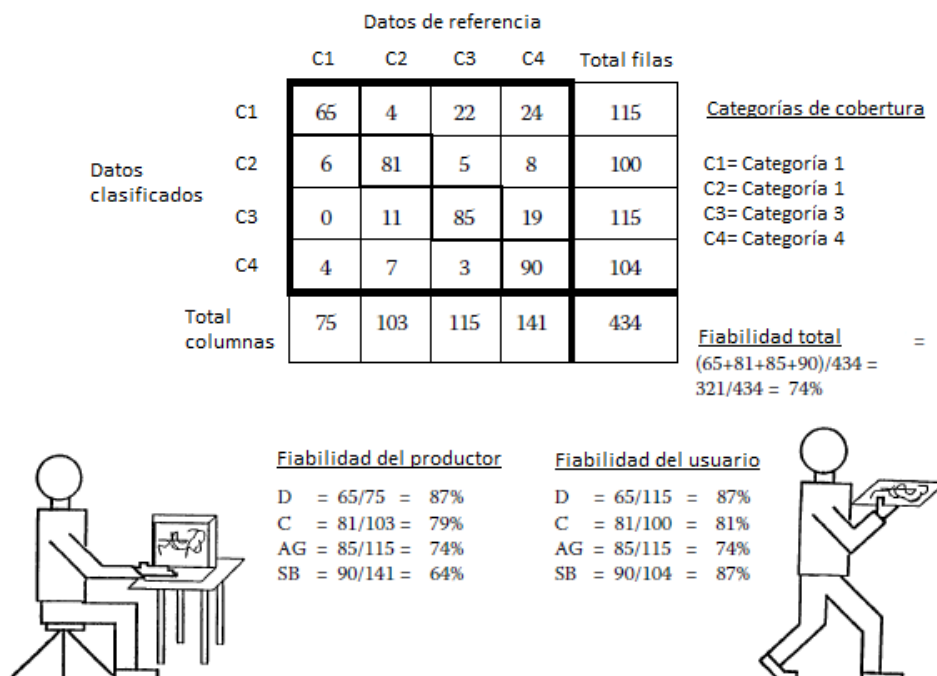


Figura 3. Ejemplo de la implementación de una matriz de confusión.

Fuente: Congalton & Green, 2009.

El análisis Kappa permite obtener una medida de fiabilidad basada en la diferencia entre el nivel de correspondencia reflejado en la diagonal de la matriz de confusión, y la probabilidad de correspondencia indicada en los totales de las líneas y columnas (Congalton & Green, 2009). Su valor puede variar entre -1 y +1, donde valores positivos indican una correlación positiva entre la clasificación y los datos de referencia. Los rangos definidos para la interpretación de los valores de Kappa se indican en la Tabla 3:

Tabla 3. Niveles de correspondencia para diferentes valores de Kappa.

Fuente: Landis & Koch, 1977.

Valor Kappa	Nivel de correspondencia
<0.00	Pobre
0.00-0.20	Leve
0.21-0.40	Suficiente
0.41-0.60	Moderado
0.61-0.80	Sustancial
0.81-1	Casi perfecto

Adicionalmente al análisis Kappa, la técnica MARGFIT puede ser aplicada para normalizar las matrices de confusión para su comparación (Congalton & Green, 2009). MARGFIT, emplea un procedimiento de ajuste proporcional iterativo que obliga que la suma de los valores incluidos en las líneas y columnas de la matriz de confusión coincida con un valor determinado (ver Figura 4). En este proceso de normalización, las diferencias en el tamaño de la muestra son eliminadas y por lo tanto las celdas de la matriz pueden ser comparadas directamente (Congalton & Green, 2009).

		Datos clasificados			
		A	B	C	D
Datos clasificados	A	0.7537	0.0261	0.1300	0.0909
	B	0.1226	0.7735	0.0521	0.0517
	C	0.0090	0.1042	0.7731	0.1133
	D	0.1147	0.0962	0.0448	0.7440
					3.0443

Categorías de cobertura

C1= Categoría 1
 C2= Categoría 2
 C3= Categoría 3
 C4= Categoría 4

Fiabilidad Normalizada =
 $0.7537+0.7735+0.7731+0.7440 =$
 $3.0443/4.0 = 76\%$

Figura 4. Ejemplo de la implementación de una matriz de confusión normalizada MARGFIT.

Fuente: Congalton & Green, 2009.

3. METODOLOGÍA

En el presente capítulo se detallan los aspectos metodológicos del estudio, incluida la definición del área de estudio, los insumos empleados, los procesos adoptados para el logro de los objetivos planteados, así como los criterios adoptados para la evaluación de los resultados obtenidos.

Para determinar la aplicabilidad del análisis lineal de mezclas espectrales (LSMA) en las zonas de alta montaña correspondientes al Complejo de Páramo Jurisdicción Santurbán Berlín mediante el uso de imágenes multiespectrales de la misión Landsat-8, se realizaron las siguientes actividades:

1. Preprocesamiento: incluyó el uso de diferentes métodos e insumos para la corrección radiométrica y atmosférica de las imágenes objeto de análisis, con el fin de evaluar su desempeño en el área de estudio.
2. Extracción de *endmembers*: se emplearon dos métodos de extracción de *endmembers* utilizados recientemente en imágenes multiespectrales de la misión Landsat, con el fin de verificar cual se ajusta más a las necesidades de discriminación de diferentes coberturas de la tierra en el área de estudio: el primero, es el método propuesto por Li (2007), que combina la transformación MNF con el cálculo del Índice de Pureza del Pixel; el segundo, es el propuesto por Gruninger et al. (2004), que emplea un modelo de *endmembers* basado en SMAAC.
3. Clasificación no supervisada: se emplearon dos métodos para la clasificación no supervisada de las coberturas existentes en el área de estudio, basados en LSMA y en el algoritmo ISODATA, con el fin de evaluar su aplicabilidad para la obtención de mapas preliminares mediante análisis digital de imágenes de acuerdo al esquema de clasificación de la Leyenda Nacional de Coberturas de la Tierra (IDEAM, 2010).

En la Figura 1 se presenta el esquema metodológico planteado, que se detallará más adelante. En el esquema es posible visualizar las actividades planteadas relacionadas para dar cumplimiento a los objetivos propuestos en el presente estudio.

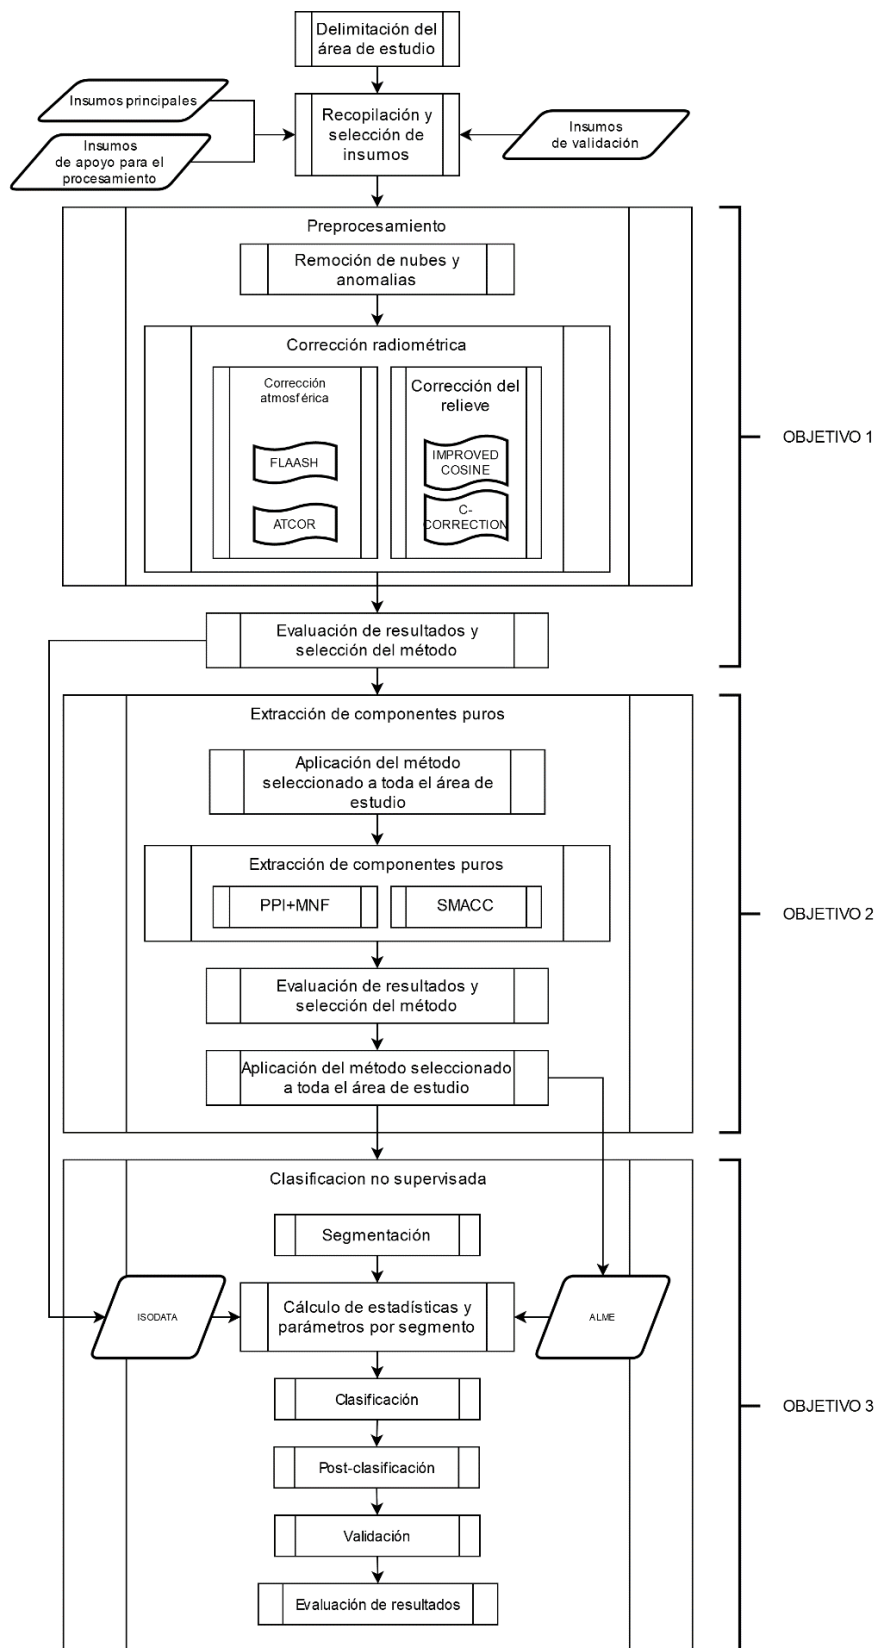


Figura 5. Esquema metodológico planteado.

Fuente: elaboración propia.

3.1. Generalidades

A continuación se tratan de manera detallada algunos aspectos de carácter general inherentes al proceso metodológico adoptado, como son la delimitación del área de estudio y los insumos empleados.

3.1.1. Delimitación del área de estudio

El área de estudio seleccionada es el complejo de páramo Jurisdicción Berlín-Santurbán, ubicado entre los departamentos de Santander y Norte de Santander. Comprende ecosistemas de alta montaña considerados de prioridad nacional e importancia estratégica para la conservación de la biodiversidad del país, por ser indispensables en la provisión del recurso hídrico (Congreso de la República de Colombia, 2018). Tiene una extensión total aproximada 1.426 km² e incluye territorios pertenecientes a 30 municipios de los dos departamentos, siendo Chitagá, Cerrito, Concepción y Silos los más importantes en términos de área. La ubicación del área de estudio y sus límites se muestran en las figuras 6 y 7.

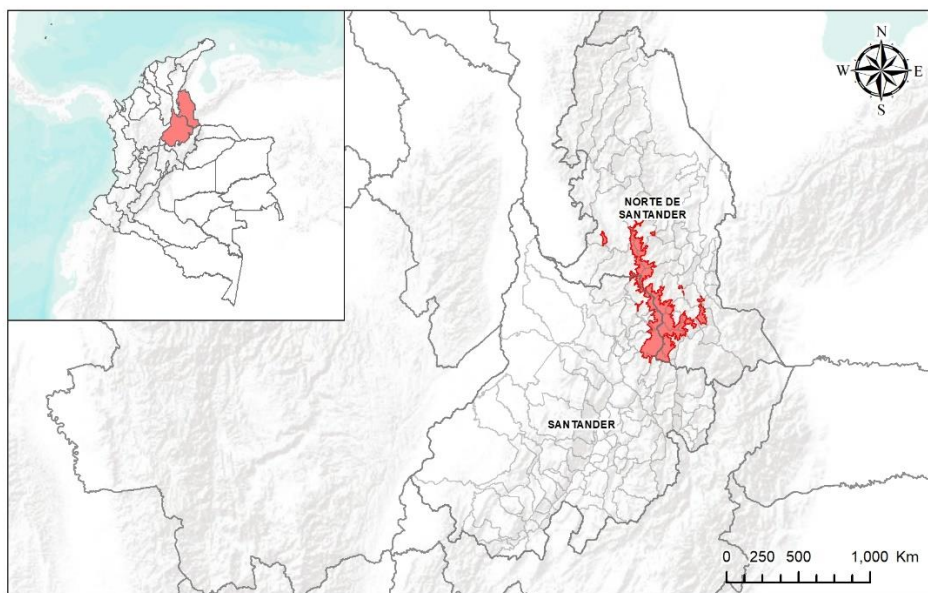


Figura 6. Localización del área de estudio.

Fuente: elaboración propia. Mapa base: Esri, USGS, NOAA.

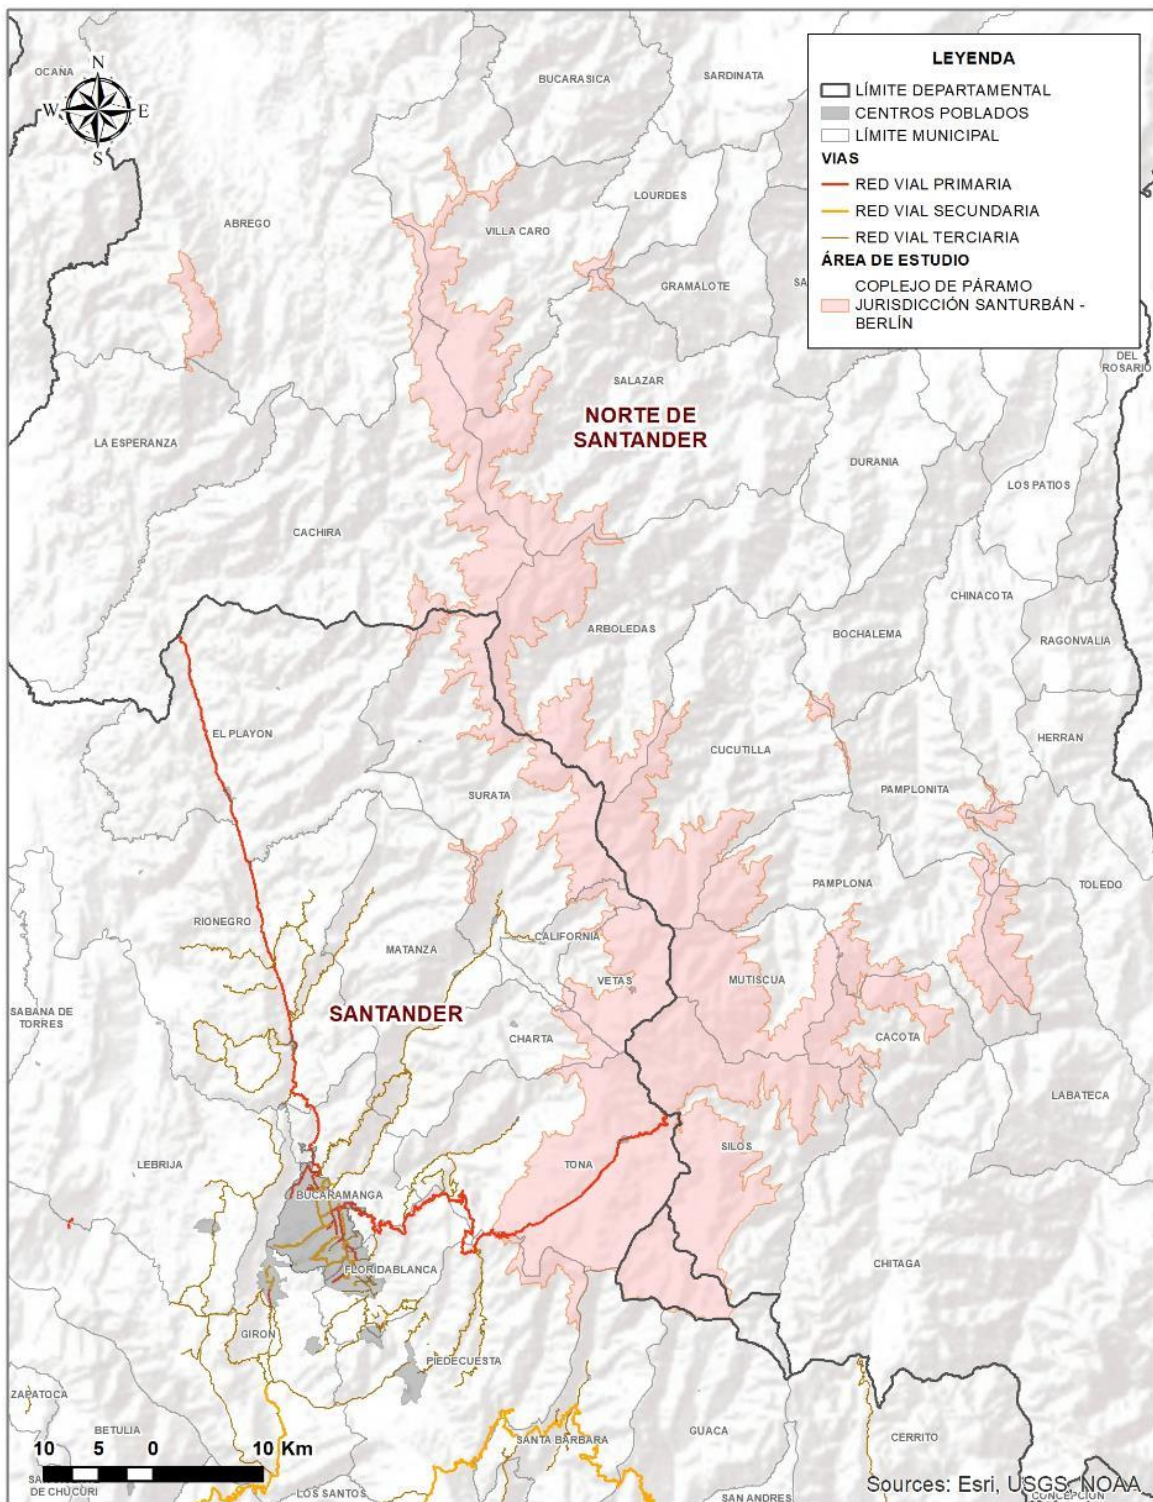


Figura 7. Área de estudio seleccionada.

Fuente: elaboración propia.

3.1.2. Recopilación y selección de insumos

Los insumos utilizados, incluyen tres categorías principales de acuerdo al uso en el presente estudio:

- Insumos principales: incluyen las imágenes ópticas multiespectrales empleadas para el preprocesamiento y las actividades de procesamiento requeridas para la obtención de los mapas clasificados.
- Insumos de apoyo: incluyen los insumos requeridos para el preprocesamiento, como son los modelos digitales de elevación empleados para las correcciones radiométricas, así como también las capas vectoriales de apoyo utilizadas para la delimitación del área de estudio.
- Insumos de validación: incluyen las imágenes ópticas multiespectrales de mayor resolución, así como los geoservicios consultados para realizar la validación de las clasificaciones obtenidas.

En la Tabla 4 se listan los insumos utilizados en la investigación organizados por categoría, incluidas las fuentes de información y los procesos para los cuales se emplearon. La selección de las imágenes de insumo principal se realizó de acuerdo a la fecha de adquisición y nubosidad sobre el área de estudio, priorizando las escenas más recientes, adquiridas en la misma época del año, y con menor porcentaje de nubosidad. Una vez obtenidos los insumos, se procedió a realizar las actividades asociadas a cada uno de los objetivos específicos, lo cual se detalla a continuación.

Tabla 4. Insumos empleados para la investigación.

Fuente: elaboración propia.

<i>Insumos principales: imágenes ópticas multiespectrales</i>						
<i>Código</i>	<i>Sensor</i>	<i>Misión</i>	<i>Res. Especial (m)</i>	<i>Res. espectral</i>	<i>Fecha de adquisición</i>	<i>Fuente</i>
LC08_L1TP_007055_20181223_20190129_01_T1	Operational Land Imager (OLI)	Landsat-8	VIS-NIR: 30 PAN: 15	4 VIS 1 NIR	23/12/2018	Servicio Geológico de Estados Unidos (USGS)
LC08_L1TP_008054_20200102_20200113_01_T1				2 SWIR 1 PAN	02/01/2020	(https://earthexplorer.usgs.gov/)
<i>Insumos de apoyo en formato ráster: modelo digitales de elevación</i>						
<i>Código o referencia</i>	<i>Misión</i>	<i>Res. espacial (m)</i>	<i>Res. espectral</i>	<i>Fecha de creación</i>	<i>Fuente</i>	
SRTMGL1.003_Band1_doy200042_aid0001	Shuttle Radar Topography Mission (SRTM)	30	1	2000	NASA AppEARS (https://lpdaac.usgs.gov/tools/appears/)	
ASTGTM_NC.003_ASTER_GDEM_DEM_doy2000061_aid0001	Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER)	30	1	2000	AppEARS (https://lpdaac.usgs.gov/tools/appears/)	
Imágenes con cubrimiento sobre el área de estudio	ALOS Phased Array type L-band Synthetic Aperture Radar Mission (ALOS PALSAR)	12.5	1	2015	ASF DAAC - JAXA/METI Alaska Satellite Facility Data Search (https://search.asf.alaska.edu/#/)	
gmted2010.pix	GMTED	250	1	2010	Incluido en PCI Geomatics	

Nota: Res: resolución; IAVH: Instituto de Investigación de Recursos Biológicos Alexander Von Humboldt; VIS: bandas en el rango visible del espectro; NIR: bandas en el rango de infrarrojo cercano; SWIR: bandas en el rango del infrarrojo medio de onda corta; PAN: bandas pancromáticas.

Tabla 5. Insumos empleados para la investigación (continua).

Fuente: elaboración propia.

<i>Insumos de apoyo en format vectorial</i>						
<i>Nombre</i>	<i>Escala</i>	<i>Fecha de elaboración</i>	<i>Elaborado por</i>	<i>Fuente</i>		
Delimitación de complejos de páramo	1:100.000	2012	IAVH	SIAC (http://www.siac.gov.co/catalogo-de-mapas)		
Curvas de nivel	1:25.000	2018	IGAC	Instituto Geográfico Agustín Codazzi (IGAC) Datos Abiertos (https://geoportal.igac.gov.co/contenido/datos-abiertos-cartografia-y-geografia)		
<i>Insumos de validación: imágenes ópticas multiespectrales</i>						
<i>Código o referencia</i>	<i>Sensor</i>	<i>Misión</i>	<i>Res. espacial</i>	<i>Res. espectral</i>	<i>Fecha de adquisición</i>	<i>Fuente</i>
Imágenes con cubrimiento sobre el área de estudio	-	Planet Scope	3	3 VIS 1 NIR	2017-2018	Corporación para la Defensa de la Meseta de Bucaramanga (CDBM) Instituto Geográfico Agustín Codazzi (IGAC)
S2A_MSIL1C_20191210T152641_N0208_R025_T18NYP_20191210T170603	MultiSpectral Instrument (MSI)	Sentinel -2	10m	3 VIS 1 NIR	10/12/2019	Agencia Espacial Europea (ESA) (https://scihub.copernicus.eu/dhus/#/home)
S2A_MSIL1C_20200106T151701_N0208_R125_T18NYP_20200106T165842.SAFE					06/01/2020	

Nota: Res: resolución; IAVH: Instituto de Investigación de Recursos Biológicos Alexander Von Humboldt; VIS: bandas en el rango visible del espectro; NIR: bandas en el rango de infrarrojo cercano; SWIR: bandas en el rango del infrarrojo medio de onda corta; PAN: bandas pancromáticas.

3.2. Objetivo 1: Preprocesamiento y corrección radiométrica

3.2.1. Remoción de nubes y anomalías

Previamente al procesamiento de las imágenes seleccionadas para el presente estudio, se procedió a revisar la presencia de píxeles anómalos, cuya información podría resultar alterada debido a diferentes factores que interfieren con la captura de los datos de interés. Para lo anterior, se consultó la información de la banda de calidad proporcionada por el proveedor de los insumos y se analizaron los valores de los píxeles mediante el algoritmo Reed-Xiaoli-Detector (RXD), descrito por Chang (2002).

Con base en esta información se construyó una máscara que se utilizó en varias fases del estudio con el fin de evitar que los píxeles incluidos interfirieran con el procesamiento de datos.

a) Consulta de la información de la banda de calidad

La información de la banda de calidad de las imágenes Landsat seleccionadas fue obtenida mediante el uso la herramienta Decode QA, incluida en el Toolbox de ArcGis Landsat QA ArcGIS. Este toolbox permite clasificar y/o extraer los valores almacenados en bits en la banda de calidad de los productos del nivel 1 de Landsat, haciendo más fácil su interpretación.

b) Detección de anomalías

Para determinar la presencia de píxeles anómalos en los insumos seleccionados, se utilizó la herramienta *Anomaly Detection Workflow* proporcionada por ENVI 5.3, basada en el algoritmo Reed-Xiaoli-Detector (RXD), propuesto por Chang (2002), en el cual es aplicada la siguiente expresión matemática para calcular el valor δ_{RXD} :

$$\delta_{RXD}(r) = (r - \mu)^T K_{L \times L}^{-1} (r - \mu) \quad (11)$$

Donde:

$\delta_{RXD}(r)$ es la distancia de Mahalanobis.

r es el vector de la muestra.

μ es el promedio de la muestra.

$K_{L \times L}$ es la matriz de covarianza de la muestra.

Este algoritmo permite identificar diferencias espectrales entre la región a testear y el conjunto de datos total, y extrae las regiones que son espectralmente distintas con respecto al fondo. Es un algoritmo efectivo cuando las zonas anómalas son suficientemente pequeñas con respecto al resto de la imagen (Harris Geospatial Solutions, 2020a).

El algoritmo permitió identificar un porcentaje de píxeles potencialmente anómalos del 0.01% para cada imagen, calculado con respecto al área de cobertura sobre la zona de interés. El mayor porcentaje de anomalías detectadas por el algoritmo, corresponden a zonas de nubes previamente identificadas mediante el análisis de la banda de calidad. Las zonas restantes detectadas como anomalías para la imagen L8 2018 *Path 007 Row 055* corresponden a zonas de borde de la imagen (ver tablas 6 y 7 y 7 y Figura 8).

Tabla 6. Estadísticas de anomalías detectadas para la imagen L8 2018 *Path 007 Row 055*.

Fuente: elaboración propia.

<i>Estado de los píxeles</i>	<i>Área (km²)</i>	<i>Área (%)</i>
Con anomalías	0.125319504	0.01%
Condiciones óptimas	0.102819504	0.01%
Presencia de nubes o sombra de nubes	0.0225	0.00%
Sin anomalías	1426.139652	99.99%
Condiciones óptimas	1384.497539	97.07%
Presencia de nubes o sombra de nubes	41.64211286	2.92%
Total general	1426.264971	100.00%

Nota: estadísticas elaboradas con base en resultados del Anomaly Detection Workflow de ENVI 5.3.

Tabla 7. Estadísticas de anomalías detectadas para la imagen L8 2020 *Path 008 Row 054*.

Fuente: elaboración propia.

<i>Estado de los píxeles</i>	<i>Área (km²)</i>	<i>Área (%)</i>
Con anomalías	0.0216	0.01%
Presencia de nubes o sombra de nubes	0.0216	0.01%
Sin anomalías	314.1120385	99.99%
Condiciones óptimas	291.9981591	92.95%
Presencia de nubes o sombra de nubes	22.1138794	7.04%
Total general	314.1336385	100.00%

Nota: estadísticas elaboradas con base en resultados del Anomaly Detection Workflow de ENVI 5.3.

a) Remoción de nubes y anomalías

Para realizar la remoción de las zonas de la imagen que pudieran interferir con los posteriores procesos de análisis digital, se seleccionaron todas las áreas con probabilidad de presencia de nubes y sombras identificadas a partir de la banda de calidad de Landsat, y se fusionaron con los píxeles encontrados mediante el proceso de detección de anomalías. Las zonas así delimitadas fueron removidas de las imágenes de insumo recortadas al área de estudio mediante la aplicación de una máscara en ENVI.




Figura 8. Algunas áreas de anomalías detectadas (en rojo) por el Anomaly Detection de ENVI 5.3.

Fuente: elaboración propia.

3.2.2. Calibración radiométrica y corrección atmosférica

Con el fin de realizar la conversión de niveles digitales (ND) a reflectancia BOA mediante modelos de transferencia radiativa y evaluar su desempeño, se aplicaron sobre la imagen con mayor cobertura del área de estudio, los siguientes algoritmos: primero; el Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes - FLAASH desarrollado por el Air Force Philips Laboratory, Hanscom AFB y Spectral Science Inc, e incluido en ENVI, segundo; el ATmospheric CORrection –ATCOR, desarrollado por el DLR, el Centro Aeroespacial Alemán (Jensen, 2015), disponible en el software PCI Geomatics.

La evaluación del desempeño de los diferentes modelos e insumos empleados se realizó mediante la comparación de los histogramas y estadísticas de los valores de reflectancia obtenidos, así como también mediante el análisis visual de las imágenes resultado de las correcciones atmosféricas aplicadas.




Figura 9. Imagen de insumo con zonas de nubes y anomalías removidas.

Fuente: elaboración propia.

3.2.2.1. Corrección atmosférica con FLAASH

Previamente al uso de FLAASH, se requirió realizar la calibración radiométrica a valores de radiancia. Para realizar la corrección, los valores de la fecha y hora de adquisición fueron obtenidos de los metadatos de los insumos seleccionados. Por otro lado, el valor de altitud promedio de la imagen, dato que es requerido por el algoritmo FLAASH, fue obtenido a partir de la información de la misión SRTM de la NASA, teniendo en cuenta los datos de altitud el área de estudio.

3.2.2.2. Corrección atmosférica con ATCOR

A diferencia del módulo FLAASH, que requiere un valor promedio de elevación para definir el parámetro de iluminación de la escena, el módulo ATCOR incluye la opción de incluir un modelo digital de elevación (MDE). De acuerdo con lo anterior fueron ensayados los siguientes insumos para llevar a cabo la corrección atmosférica:

- a. Modelo digital de elevación de la misión NASA, *Shuttle Radar Topography Mission Global* (SRTM) de 30 m de resolución (1 arco de segundo).
- b. Modelo digital de elevación GDEM de ASTER, de 30 m de resolución (1 arco de segundo).
- c. Modelo digital de elevación de la misión SRTM de 30 m de resolución previa aplicación de un filtro de paso bajo con ventana de 3x3 píxeles tipo promedio.
- d. Modelo digital de elevación de la misión ALOS-PALSAR de 12.5 m de resolución, previa aplicación de un filtro de paso bajo con ventana de 3x3 píxeles tipo promedio y remuestreo a 30 m.
- e. Modelo digital de elevación *Global Multi-resolution Terrain Elevation Data 2010* (GMTED 2010) de 250 m de resolución.

3.2.3. Corrección de efectos del relieve

Con el fin de evaluar el desempeño de diferentes métodos e insumos para la corrección de efectos del relieve, se realizaron pruebas con la imagen de mayor cobertura, por un lado, con el método Lambertiano de corrección del coseno mejorado, y por otro lado con el método no

Lambertiano, denominado Corrección C, con los siguientes insumos topográficos para la estimación de las condiciones de iluminación:

- Curvas de nivel escala 1:25.000 del IGAC.
- Modelo digital de elevaciones de la misión SRTM.
- Modelo digital de elevaciones de ASTER.
- Modelo digital de elevaciones de la misión ALOS PALSAR.

Para el método de corrección e insumo que permitió obtener los mejores resultados, fueron realizadas pruebas adicionales mediante la aplicación previa de una ventana móvil de 3x3 y 5x5 tipo promedio y modal al modelo de iluminación obtenido, con el fin de remover eventuales artefactos existentes en el DEM.

Para el caso específico de las curvas de nivel, éstas fueron recortadas al área de interés, convertidas a TIN y a MDT con resolución espacial de 5m y en el sistema de referencia de las imágenes de insumo. Posteriormente se remuestrearon a 30m mediante el módulo RESAMP de PCI Geomatics.

3.2.3.1. Cálculo de la iluminación $\cos \gamma_i$

Para realizar el cálculo del parámetro $\cos \gamma_i$, requerido para la aplicación de las correcciones topográficas, se utilizaron los modelos digitales del terreno recortados y reproyectados al sistema de coordenadas de la imagen de insumo, mediante interpolación bilineal.

Para poder aplicar la corrección del relieve sobre las imágenes de insumo, se creó un mapa de iluminación mediante el algoritmo REL Shaded Relief from Elevation Data del software PCI Geomatica 2016, utilizando los parámetros de acimut y ángulo de elevación solar obtenidos del metadato de la imagen de insumo (Tabla 8). Este algoritmo, permite obtener los valores de iluminación escalados en un rango de 0 a 255.

Los valores del ráster de iluminación obtenido se escalaron entre -1 y +1, con el fin de aplicar la ecuación de corrección C (ecuación 7) propuesta por Teillet (1982).

Tabla 8. Metadatos utilizados para la creación del mapa de iluminación.

Fuente: elaboración propia.

<i>Imagen</i>	<i>Acimut</i>	<i>Ángulo de elevación solar</i>
L8_2018_7055	141.4464258	50.39808553
L8_2018_8054	141.5287169	49.07748802

3.2.3.2. Aplicación de la corrección topográfica del coseno mejorada (Improved Cosine Correction)

Para realizar la corrección topográfica del coseno mejorada, mediante la ecuación propuesta por Civco (1989) (ecuación 6), se requiere extraer el valor promedio de iluminación de la imagen. Para ello fueron calculadas las estadísticas de los diferentes mapas de iluminación generados y recortados al área de estudio mediante el software PCI Geomatics (Figura 10). Los valores promedio obtenidos se muestran en la Tabla 9.

Tabla 9. Valores promedios aplicados para la corrección del coseno mejorada.

<i>Insumo</i>	<i>Valor promedio $\cos \bar{\gamma}_i$</i>
GDEM de ASTER	29.4945
DEM de SRTM	29.5638
DEM de ALOS PALSAR	29.6979
Curvas de nivel IGAC 1:25.000	99.6851

Fuente: elaboración propia.

Una vez determinado el valor promedio de iluminación ($\cos \gamma_i$) para el área de estudio, se aplicó la ecuación propuesta por Civco (Ecuación 6) a todas las bandas mediante la herramienta EASI Modeling del software PCI Geomatics, obteniendo como resultado, las imágenes corregidas topográficamente.

3.2.3.3. Aplicación de la corrección C

Con el fin de aplicar la corrección del relieve propuesta por Teillet (1982), de acuerdo a la ecuación 7 fueron obtenidas las expresiones matemáticas de regresión lineal entre el ráster de iluminación y los valores de reflectancia para cada banda. En el Apéndice 1 se muestran las ecuaciones de regresión lineal obtenidas para cada insumo ensayado, así como los coeficientes m_λ , b_λ y el parámetro c_λ obtenidos. Todos los cálculos requeridos para la aplicación de la corrección se realizaron en el software PCI Geomatics.




Figura 10. Recorte de los mapas de iluminación al área de estudio en PCI Geomatics.

Fuente: elaboración propia.

3.2.3.4. Evaluación del desempeño de diferentes métodos e insumos para la corrección de los efectos topográficos

Para la evaluación del desempeño de los diferentes métodos e insumos para la corrección de los efectos topográficos utilizados, fueron aplicados dos métodos principales: primero, la comparación del coeficiente de correlación entre la iluminación ($\cos \gamma_i$) y la radiancia o reflectancia de cada banda espectral después de la corrección del relieve; segundo, la comparación visual de los resultados obtenidos con la imagen sin corrección del relieve.

Para determinar la correlación entre la iluminación $\cos \gamma_i$ y los valores de reflectancia de superficie para cada banda, se empleó el módulo SPLREG de PCI Geomatics.

3.3. Objetivo 2: extracción de *endmembers*

Con el fin de evaluar el desempeño de diferentes métodos para extracción de *endmembers* en imágenes satelitales multiespectrales de la misión Landsat 8 en zonas de alta montaña, se ensayaron los siguientes procesos, los cuales han sido empleados recientemente en imágenes del sensor OLI:

- **Reducción de la dimensionalidad con MNF e índice de pureza del pixel:** método de selección de *endmembers* propuesto por Li (2007), empleado más recientemente por Liping (2019) y Thayn (2020), que combina el uso de la visualización n-Dimensional de las bandas más representativas de la transformación MNF y filtra los píxeles puros seleccionados mediante el resultado arrojado por el cálculo del Índice de Pureza del Pixel (PPI).
- **Modelo de *endmembers* basado en Sequential Maximum Angle Convex Cone (SMAAC):** método de selección de *endmembers* propuesto por Gruninger (2004b) y aplicado más recientemente en imágenes multiespectrales por Maselli (2012) y Milewski (2020). Los *endmembers* son seleccionados directamente del set de datos de manera secuencial, mediante un modelo de cono convexo para representar los vectores de datos. El algoritmo permite generar de manera directamente las imágenes de abundancia.

En la Figura 11 se resume el flujo de actividades realizadas para la extracción de píxeles puros con los dos métodos ensayados y la evaluación de su desempeño.

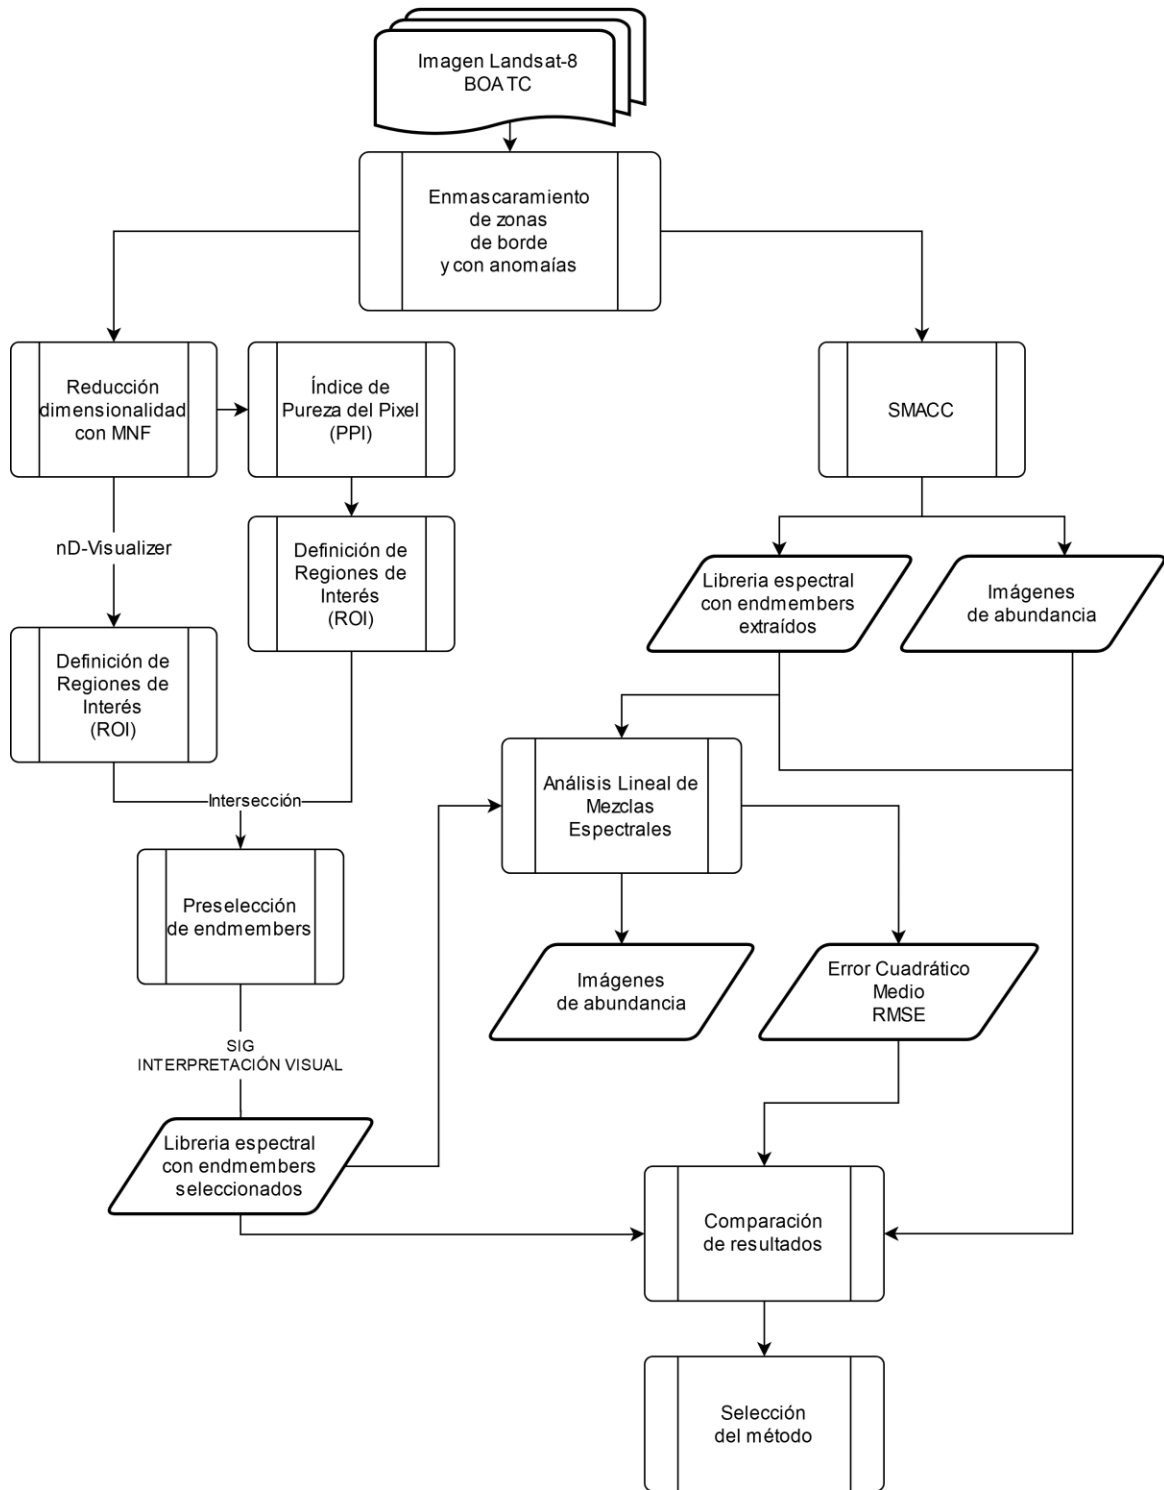


Figura 11. Flujo de actividades realizadas para analizar el desempeño de diferentes métodos de extracción de endmembers.

Fuente: elaboración propia.

3.3.1. Enmascaramiento

Previamente a la aplicación de los algoritmos de extracción de *endmembers* sobre las dos imágenes de insumo, se construyó una máscara con el fin de excluir zonas de borde de la imagen y zonas próximas a nubes y sombras, y evitar que interfirieran con el algoritmo de extracción de *endmembers*. Para lo anterior se tomó como base la máscara de nubes, sombras y anomalías delimitada en el numeral 3.2.1, y se consideró un área de influencia adicional de 500 m del límite de la escena y de 100 m de las zonas de nubes fuera del área de estudio (Figura 12).

3.3.2. Extracción de *endmembers* mediante el método combinado MNF y PPI

La aplicación del método combinado MNF y PPI propuesto Li (2007) incluye las siguientes etapas: a) Reducción de la dimensionalidad mediante MNF. b) Definición de regiones de interés correspondientes a píxeles de suelo, agua y vegetación mediante visualización n-Dimensional de los primeros tres componentes MNF. c) Cálculo del Índice de Pureza del Pixel y definición de una región de interés que contenga los píxeles puros encontrados. d) Intersección entre las regiones de interés definidas mediante MNF y PPI. Estas etapas son explicadas a continuación.

3.3.2.1. Transformación MNF

Para la transformación se empleó la herramienta Estimate Noise Statistics from Data de ENVI Classic 5.3. Con el fin de utilizar un área de referencia suficientemente homogénea para el cálculo de estadísticas de ruido confiables, se seleccionó un área de cuerpo de agua fácilmente identificable en la zona de estudio, de acuerdo a lo recomendado en el manual de la herramienta empleada para el presente análisis (Harris Geospatial Solutions, 2020c). Los datos estadísticos reportados en la Figura 14 obtenida para el área homogénea, evidencian que los valores de desviación estándar son cercanos a 0, lo cual indica que el área es apta para poder ser utilizada como referencia.

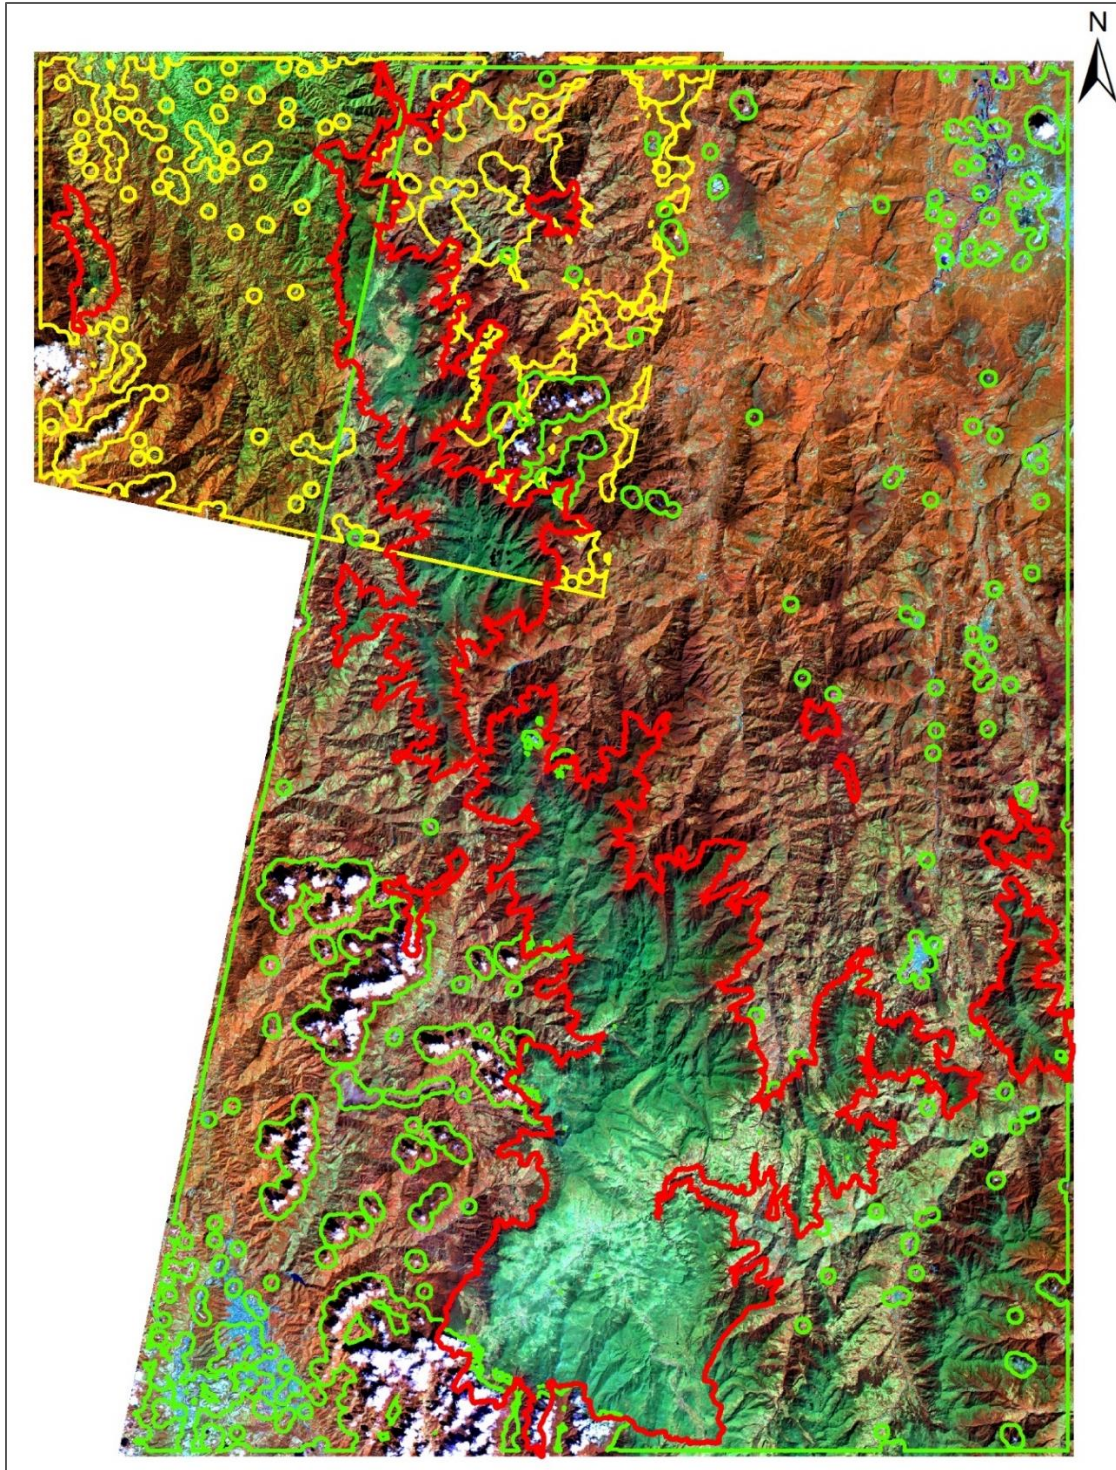


Figura 12. Máscara aplicada para la extracción de *endmembers*.

Fuente: elaboración propia.

Nota: En rojo: límite del área de estudio. En verde: límite de la máscara para la imagen *Path 007 Row 055*. En amarillo: límite de la máscara para la imagen *Path 008 Row 054*.




Figura 13. Área con respuesta espectral homogénea seleccionada.

Fuente: elaboración propia.

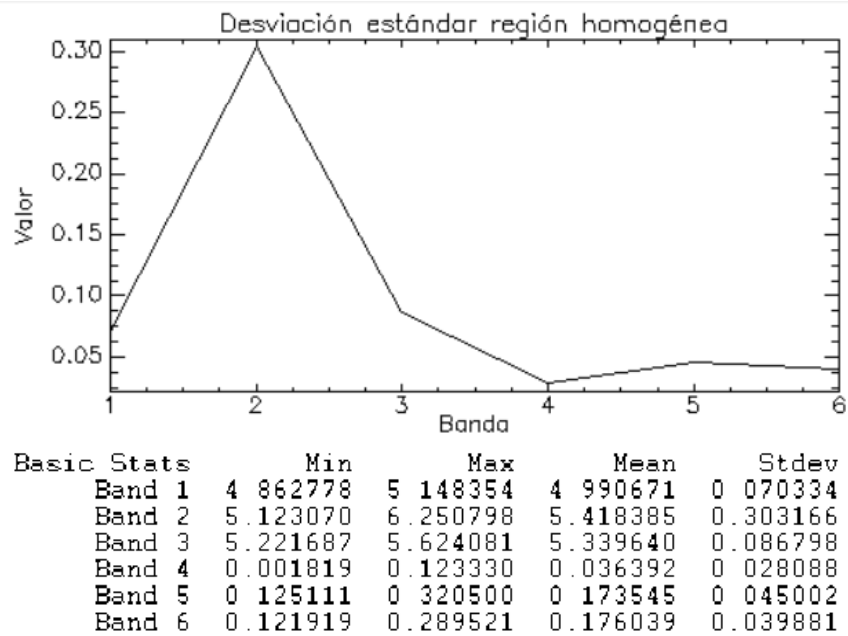


Figura 14. Estadísticas de la zona homogénea seleccionada.

Fuente: elaboración propia.

De acuerdo con las estadísticas obtenidas de la transformación MNF (Tabla 10), se observa que los primeros dos componentes MNF representan el 98.85% de la varianza de la imagen. Lo anterior se puede apreciar fácilmente, comparando las composiciones de bandas obtenidas de los primeros tres componentes MNF, y de los últimos 3 (Figura 16), para la cual se observa una presencia mucho más importante de ruido o efecto sal y pimienta.

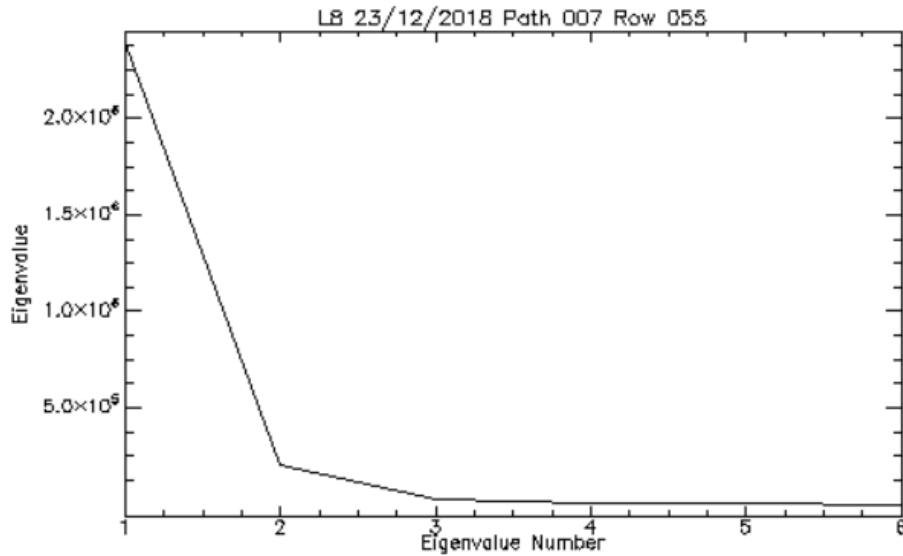


Figura 15. Resultados de la transformación MNF. Autovalores.

Fuente: elaboración propia.

Tabla 10. Resultados de la transformación MNF para la imagen con mayor cobertura sobre el área de estudio.

Fuente: elaboración propia.

<i>Banda</i>	<i>Autovalor</i>	<i>% Varianza total</i>	<i>% Varianza acumulada</i>
MNF-1	2393141.475	91.02	91.02
MNF-2	205880.3997	7.83	98.85
MNF-3	26200.1384	1.00	99.85
MNF-4	3307.902853	0.13	99.97
MNF-5	671.393768	0.03	100.00
MNF-6	7.562067	0.00	100.00




Figura 16. Resultado de la transformación MNF. Composición RGB.

Fuente: elaboración propia.

Nota: a) Composición RGB de los componentes 1,2 y 3. b) Composición RGB de los componentes 4, 5 y 6.

3.3.2.2. Definición de regiones de interés mediante visualización n-dimensional.

De acuerdo con Li (2007), se procedió a definir tres clases principales con base en la visualización n-dimensional de los primeros tres componentes MNF, que contienen más del 95% de la variabilidad de la imagen (Figura 17). Las clases correspondientes a los píxeles agrupados se definieron mediante el análisis visual sobre la imagen de insumo y de la firma espectral promedio, como se muestra en las figuras 18, 19, 20 y 21.




Figura 17. Visualización de las clases delimitadas en el n-D-Visualizer con componentes MNF.

Fuente: elaboración propia.




Figura 18. Vista de la clase suelo o zonas desprovistas de vegetación sobre imagen de la misión Landsat-8.

Fuente: elaboración propia.

Nota: Composición en falso color (5-6-3).




Figura 19. Vista de la clase vegetación sobre imagen de la misión Landsat-8.

Fuente: elaboración propia.

Nota: Composición en falso color (5-6-3).




Figura 20. Vista de la clase agua y zonas de sombra sobre imagen de la misión Landsat-8.

Fuente: elaboración propia.

Nota: Composición en falso color (5-6-3).

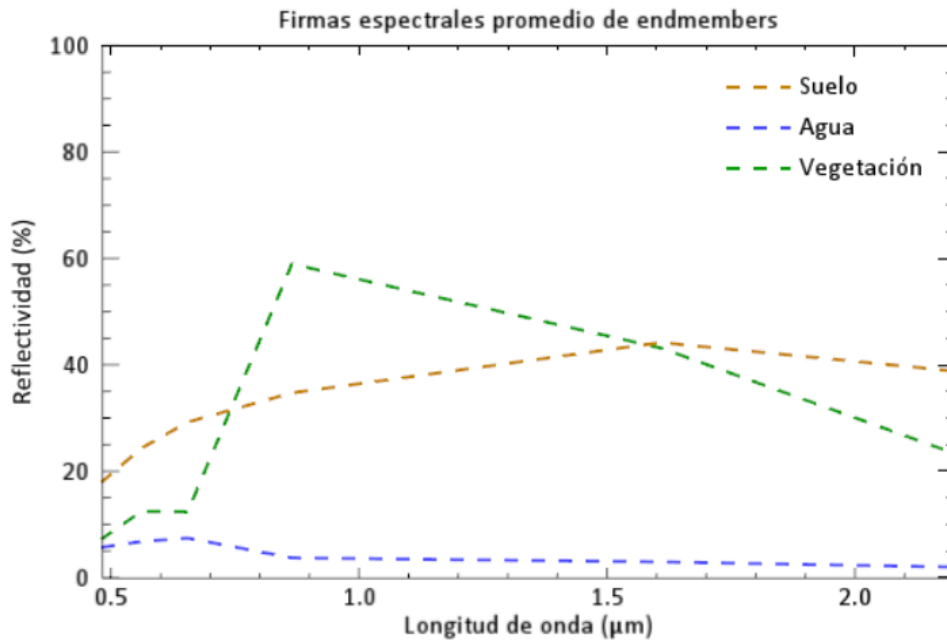


Figura 21. Firmas espectrales promedio de las clases seleccionadas a partir de componentes MNF.

Fuente: elaboración propia.

3.3.2.3. Extracción de píxeles mediante PPI

Para determinar el número de iteraciones y el factor de umbral más adecuado mediante PPI, fueron realizados varios procesamientos, obteniendo los mejores resultados con un número de 5000 iteraciones y un umbral de 2.5 (ver Tabla 10 y Figura 22).

Los píxeles puros así encontrados se clasificaron en una región de interés mediante la herramienta Band Threshold to ROI, aplicando un valor del píxel mayor a 1, es decir se incluyen todos los píxeles que se encuentran ocupando el extremo de la nube de datos al menos en un plano de proyección aleatorio de los dos procesos testeados, incluyendo así 208 píxeles.

Tabla 11. Píxeles puros obtenidos por número de iteraciones.

Fuente: elaboración propia.

<i>Número iteraciones</i>	<i>Umbral</i>	<i># de píxeles puros obtenidos MNF</i>
100	2.5	51
200	2.5	75
1000	2.5	116
1000	3	135
5000	2.5	208

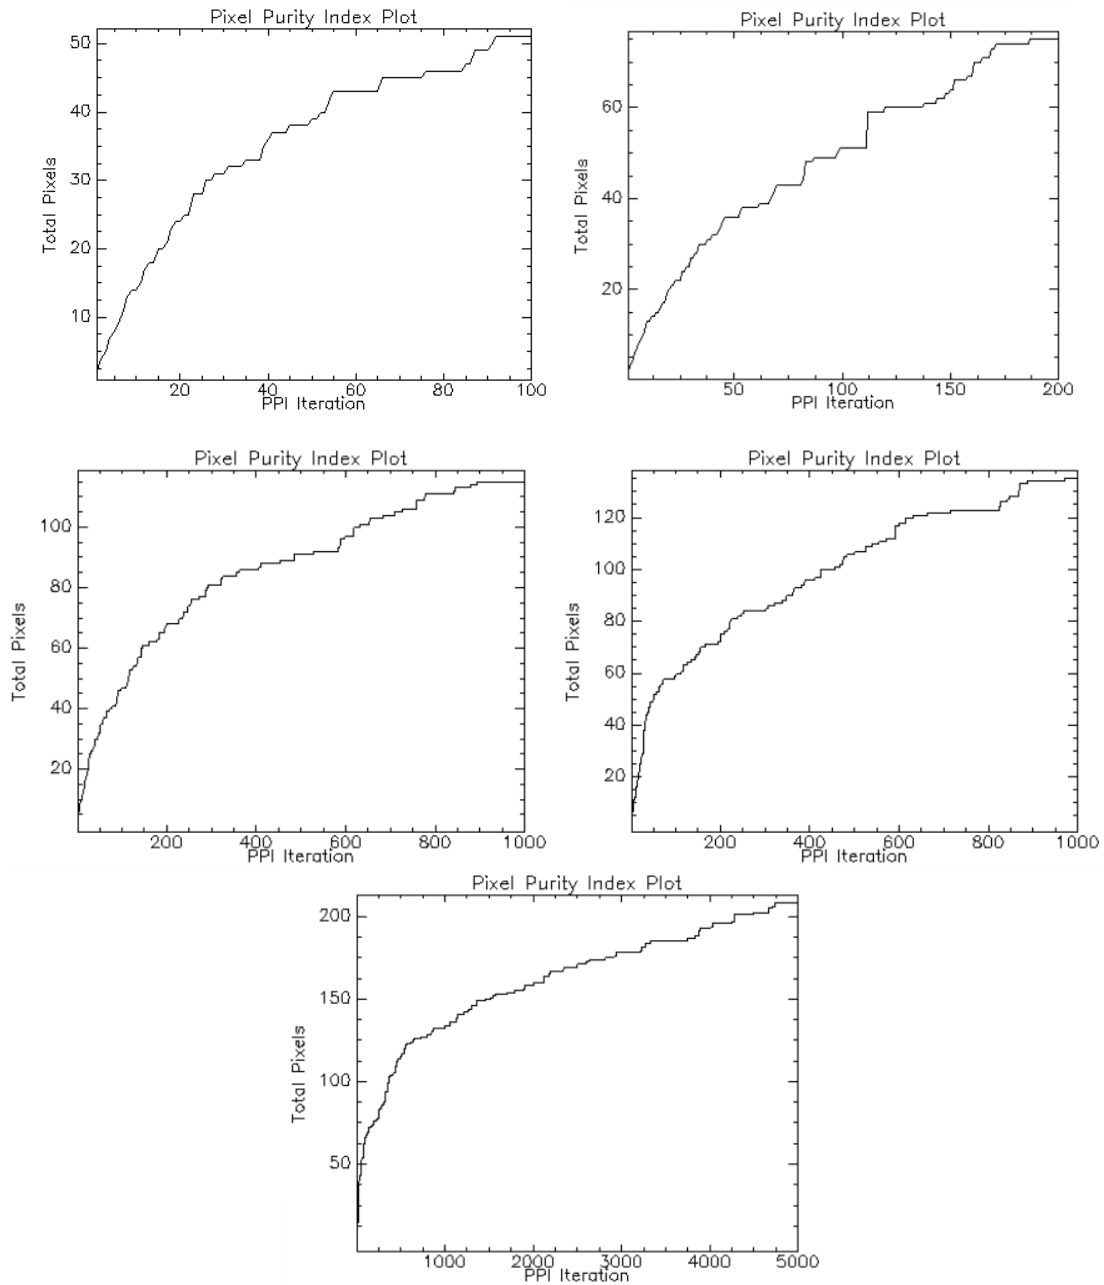


Figura 22. Cálculo del Índice de Pureza del Pixel en ENVI 5.3.

Fuente: elaboración propia.

Nota: a) 100 iteraciones, factor de rango 2.5; b) 200 iteraciones, factor de rango 2.5; c) 1000 iteraciones, factor de rango 2.5; d) 1000 iteraciones, factor de rango 3; e) 5000 iteraciones, factor de rango 2.5.

3.3.2.4. Intersección entre las regiones de interés definidas mediante MNF y PPI

Como resultado de la intersección de las regiones de interés creadas, se obtuvo un total de 97 *endmembers*, distribuidos de la siguiente manera de acuerdo con las clases previamente definidas:

Tabla 12. *Endmembers* preseleccionados por clase.

Fuente: elaboración propia.

<i>Clase</i>	<i>No. Píxeles extraídos n-D Visualizer y MNF</i>	<i>No. píxeles seleccionados por intersección con PPI</i>
Suelo	661	2
Agua y sombras	12768	93
Vegetación	3754	2
Total	17183	97




Figura 23. Firmas espectrales promedio de los endmembers preseleccionados.

Fuente: elaboración propia.

Con el fin de seleccionar un solo *endmember* de cada clase a emplear en el desmezclado espectral, se tuvo en cuenta los siguientes criterios, en orden de importancia:

- Ubicación con respecto al área de estudio (interna o externa): se considera más favorable la ubicación del *endmember* preseleccionado al interior del área de estudio.
- Ubicación relativa con respecto a la clase de cobertura: la ubicación en zonas de borde o en proximidad de zona de nubes, se considera menos favorable frente a la ubicación dentro del área de estudio y lejos de zonas de borde.
- Número de veces (iteraciones) que el píxel ha sido seleccionado como píxel puro por el algoritmo de PPI: se considera más favorable un número mayor de iteraciones por píxel.
- Como criterio adicional, se tuvo en cuenta la desviación de la firma espectral con respecto a la firma promedio: estimada a través del error cuadrático medio del valor de reflectancia para cada banda con respecto al valor promedio de todos los *endmembers* seleccionados por clase mediante el método PPI.

Como resultado de la aplicación de los anteriores criterios, se seleccionaron tres *endmembers*, cuyas firmas espectrales se muestran en la Figura 51. Las características de cada *endmember* de acuerdo a los criterios considerados se reportan en la Tabla 13. Las características de los *endmembers* seleccionados se reportan en la Tabla 14.

Tabla 13. Aplicación de criterios para la selección de *endmembers* finales.

Fuente: elaboración propia.

<i>Endmember</i>	<i>Clase</i>	<i>Ubicación con respecto al área de estudio</i>	<i>Ubicación relativa en la clase de cobertura</i>	<i>N° de iteraciones</i>	<i>Error cuadrático medio</i>
1	Agua	Externa	Óptima	5	3.127
2	Agua	Externa	Óptima	3	2.961
3	Agua	Externa	Borde	25	0.667
4	Agua	Externa	Borde	66	1.483
5	Agua	Externa	Óptima	14	2.538
6	Agua	Externa	Borde	48	2.316
7	Agua	Interna	Borde	80	0.740
8	Vegetación	Externa	Óptima	1	36.044
9	Vegetación	Externa	Óptima	10	35.221
10	Agua	Interna	Borde	2	36.110
11	Agua	Externa	Borde	3	36.700
12	Agua	Externa	Borde	3	1.282
13	Agua	Externa	Borde	3	2.091
14	Agua	Externa	Borde	9	2.451
15	Agua	Interna	Borde	2	2.106
16	Agua	Interna	Borde	1	1.558
17	Agua	Externa	Borde	2	1.024
18	Agua	Interna	Borde	2	2.143
19	Agua	Externa	Borde	1	4.004
20	Agua	Interna	Borde	57	1.115
21	Agua	Interna	Borde	3	1.073
22	Agua	Interna	Borde	1	0.997
23	Agua	Interna	Óptima	8	0.564
24	Agua	Interna	Borde	20	0.690
25	Agua	Interna	Borde	14	0.944
26	Agua	Interna	Borde	1	0.850
27	Agua	Interna	Borde	76	11.558
28	Agua	Interna	Borde	12	0.725
29	Agua	Interna	Borde	4	0.652
30	Agua	Interna	Borde	1	0.751
31	Agua	Interna	Óptima	24	0.641
32	Agua	Interna	Óptima	51	0.763
33	Agua	Interna	Óptima	1	0.673
34	Agua	Interna	Óptima	2	0.675
35	Agua	Interna	Borde	2	0.669
36	Agua	Interna	Borde	2	0.694
37	Agua	Interna	Borde	1	0.930

<i>Endmember</i>	<i>Clase</i>	<i>Ubicación con respecto al área de estudio</i>	<i>Ubicación relativa en la clase de cobertura</i>	<i>N° de iteraciones</i>	<i>Error cuadrático medio</i>
38	Agua	Interna	Borde	18	0.882
39	Agua	Interna	Borde	1	1.078
40	Agua	Interna	Borde	11	0.653
41	Agua	Interna	Borde	7	0.775
42	Agua	Interna	Óptima	16	0.873
43	Agua	Interna	Borde	12	0.864
44	Agua	Interna	Borde	1	0.861
45	Agua	Interna	Borde	2	0.855
46	Agua	Interna	Borde	5	0.903
47	Agua	Interna	Borde	1	0.597
48	Agua	Interna	Borde	6	0.785
49	Agua	Interna	Borde	1	0.793
50	Agua	Interna	Borde	78	1.001
51	Agua	Interna	Borde	4	0.930
52	Agua	Interna	Borde	8	0.895
53	Agua	Interna	Borde	4	0.724
54	Agua	Interna	Borde	15	0.987
55	Agua	Interna	Borde	168	1.174
56	Agua	Externa	Óptima	9	1.058
57	Agua	Externa	Óptima	5	3.300
58	Agua	Externa	Borde	2	0.980
59	Agua	Externa	Óptima	19	1.137
60	Agua	Externa	Óptima	3	0.988
61	Agua	Externa	Óptima	3	1.121
62	Agua	Externa	Óptima	2	1.192
63	Agua	Externa	Óptima	3	1.112
64	Agua	Externa	Óptima	2	1.140
65	Agua	Externa	Borde	1	1.229
66	Agua	Externa	Borde	1	1.130
67	Agua	Externa	Borde	2	2.314
68	Agua	Interna	Óptima	1	1.831
69	Agua	Interna	Borde	2	1.785
70	Agua	Interna	Borde	7	1.605
71	Agua	Interna	Borde	1	0.789
72	Agua	Interna	Óptima	1	0.715
73	Agua	Interna	Óptima	10	0.648
74	Agua	Interna	Borde	255	1.021
75	Agua	Interna	Borde	1	1.115
76	Agua	Interna	Borde	45	0.843
77	Agua	Interna	Borde	92	0.653

<i>Endmember</i>	<i>Clase</i>	<i>Ubicación con respecto al área de estudio</i>	<i>Ubicación relativa en la clase de cobertura</i>	<i>N° de iteraciones</i>	<i>Error cuadrático medio</i>
78	Agua	Interna	Borde	1	1.217
79	Agua	Interna	Borde	2	0.763
80	Agua	Interna	Borde	1	1.981
81	Agua	Interna	Borde	152	0.716
82	Agua	Interna	Borde	24	0.759
83	Agua	Externa	Óptima	31	0.625
84	Agua	Externa	Óptima	3	0.573
85	Agua	Externa	Borde	30	1.932
86	Agua	Externa	Borde	4	1.732
87	Agua	Interna	Borde	1	2.462
88	Agua	Externa	Borde	1	2.138
89	Suelo	Externa	Óptima	2	49.785
90	Suelo	Externa	Óptima	73	49.442
91	Agua	Externa	Borde	1	0.680
92	Agua	Externa	Óptima	56	0.680
93	Agua	Externa	Óptima	52	48.683
94	Agua	Externa	Óptima	2	50.049
95	Agua	Externa	Óptima	7	0.714
96	Agua	Externa	Óptima	1	1.033
97	Agua	Externa	Óptima	1	0.867

Tabla 14. Endmembers seleccionados.

Fuente: elaboración propia.

<i>Endmember</i>	<i>Clase</i>	<i>Ubicación con respecto al área de estudio</i>	<i>Ubicación relativa en la clase de cobertura</i>	<i>N° de iteraciones</i>	<i>Error cuadrático medio</i>
9	Vegetación	Externa	Óptima	10	35.221
32	Agua	Interna	Óptima	51	0.763
90	Suelo	Externa	Óptima	73	49.442

3.3.3. Extracción de *endmembers* mediante SMACC

La extracción de *endmembers* mediante SMACC se realizó con la herramienta homónima disponible en el software ENVI 5.3, utilizando como insumo de entrada, las imágenes fuente corregidas radiométricamente.

Como restricciones para la ejecución del algoritmo, se utilizó la opción de “*Sum unity or less*” la cual impide que la suma de las abundancias para un pixel sea mayor a 1, opción recomendada cuando se quiere realizar una interpretación física estricta de las fracciones obtenidas a partir de los valores de reflectancia. Por otro lado y teniendo en cuenta las recomendaciones incluidas en el manual de la herramienta (Harris Geospatial Solutions, 2020d), se utilizó un valor máximo de RMSE de 1, teniendo en cuenta que en la imagen los valores están escalados de 1 a 100.

La definición del número de *endmembers* y del valor de coalescencia a adoptar para la extracción de los *endmembers*, se realizó mediante el ensayo de varias configuraciones, teniendo en cuenta el error máximo relativo asociado a cada *endmember*, y el error cuadrático medio de las imágenes de abundancia generadas con el algoritmo de Linear Spectral Unmixing (LSU), que permite realizar el LSMA en el software ENVI. Como información espectral de entrada para el algoritmo de LSU, se utilizaron las librerías espectrales generadas a partir de los *endmembers* extraídos con cada opción de configuración ensayada (Maselli, 2012).

Como se muestra en la Figura 24, la tendencia del error máximo relativo obtenido con el aumento del número de *endmembers*, indica que los primeros 5 *endmembers* extraídos son los que más representan la variabilidad espectral de la imagen, sin embargo, los mejores resultados en términos de error cuadrático medio se obtienen con un número mínimo de 9 *endmembers* y una coalescencia de 0.2, para la escena *Path 007 Row 055*, y con un número mínimo de 12 *endmembers* y una coalescencia de 0.15 para la escena *Path 008 Row 054*.

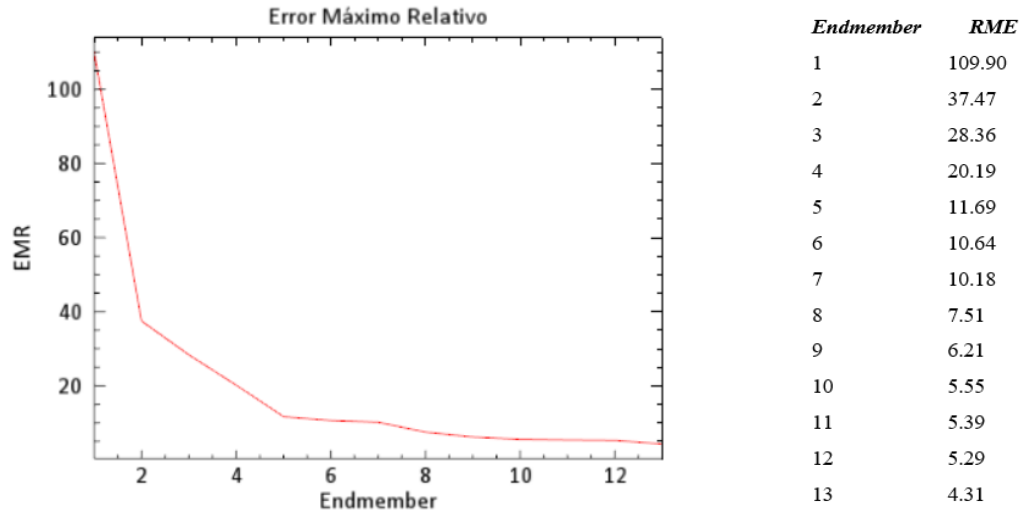


Figura 24. Tendencia del error máximo relativo con el aumento del número de *endmembers* para la escena *Path 007 Row 055*.

Fuente: elaboración propia.

Tabla 15. Número de *endmembers* y error cuadrático medio obtenidos con diferentes parámetros de entrada mediante el algoritmo SMACC para la escena *Path 007 Row 055*.

Fuente: elaboración propia.

<i>Escena Path 007 Row 055</i>					
<i>#Prueba</i>	<i>No. Endmembers definidos</i>	<i>RMSE</i>	<i>Coalescencia</i>	<i>No. Endmembers obtenidos</i>	<i>RMSE Promedio</i>
1	15	1	0.1	13	0.00000118
2	15	1	0.15	11	0.00000187
3	15	1	0.2	9	0.00000039
4	15	1	0.25	8	0.00000085
5	15	1	0.3	8	0.00000073

<i>Escena Path 008 Row 054</i>					
<i>#Prueba</i>	<i>No. Endmembers definidos</i>	<i>RMSE</i>	<i>Coalescencia</i>	<i>No. Endmembers obtenidos</i>	<i>RMSE Promedio</i>
1	15	1	0.1	15	0.00000005
2	15	1	0.15	14	0.00000005
3	15	1	0.2	11	0.00000006
4	15	1	0.25	8	0.00000006
5	15	1	0.3	6	0.00922431

Nota: los valores indicados se refieren al área de estudio.




Figura 25. Firmas espectrales de *endmembers* extraídos mediante SMACC. Escena *Path 007 Row 055* de 2018.

Fuente: elaboración propia.




Figura 26. Firmas espectrales de *endmembers* extraídos mediante SMACC. Escena *Path 008 Row 054* de 2020.

Fuente: elaboración propia.

3.3.4. Evaluación del desempeño de los métodos empleados para la extracción de *endmembers*

Para llevar a cabo la evaluación del desempeño de los métodos empleados, fue realizada una comparación del error cuadrático medio (RMSE) obtenido mediante la aplicación del algoritmo de LSU a partir de la imagen corregida radiométricamente y la librería espectral construida con los *endmembers* extraídos.

Como criterios complementarios, se tuvo en cuenta el número de *endmembers* obtenidos, que se relaciona de manera indirecta con el número de clases de cobertura extraíbles de la imagen de insumo, así como las características de las firmas espectrales de cada *endmember* y su ubicación, factores de los cuales depende la complejidad del proceso de asignación a una clase de cobertura específica.

3.4. Objetivo 3: Segmentación y clasificación no supervisada

Con el fin de evaluar la aplicabilidad del análisis de mezclas espectrales y de la segmentación para la obtención de un mapa de coberturas de la tierra preliminar de acuerdo al esquema de clasificación de la metodología *CORINE Land Cover* adaptada para Colombia, se compararon los resultados obtenidos mediante la aplicación de los siguientes métodos:

1. LSMA y OBIA: clasificación de polígonos obtenidos por segmentación, mediante el uso de criterios numéricos obtenidos con base en las imágenes de abundancia obtenidas con el método de desmezclado espectral seleccionado anteriormente (objetivo 2).
2. ISODATA y OBIA: clasificación de polígonos obtenidos por segmentación, basado el uso de criterios numéricos obtenidos con base en imágenes clasificadas con el algoritmo ISODATA.

En la Figura 27 se muestra el flujo de actividades realizadas, cuyo desarrollo se detalla a continuación.

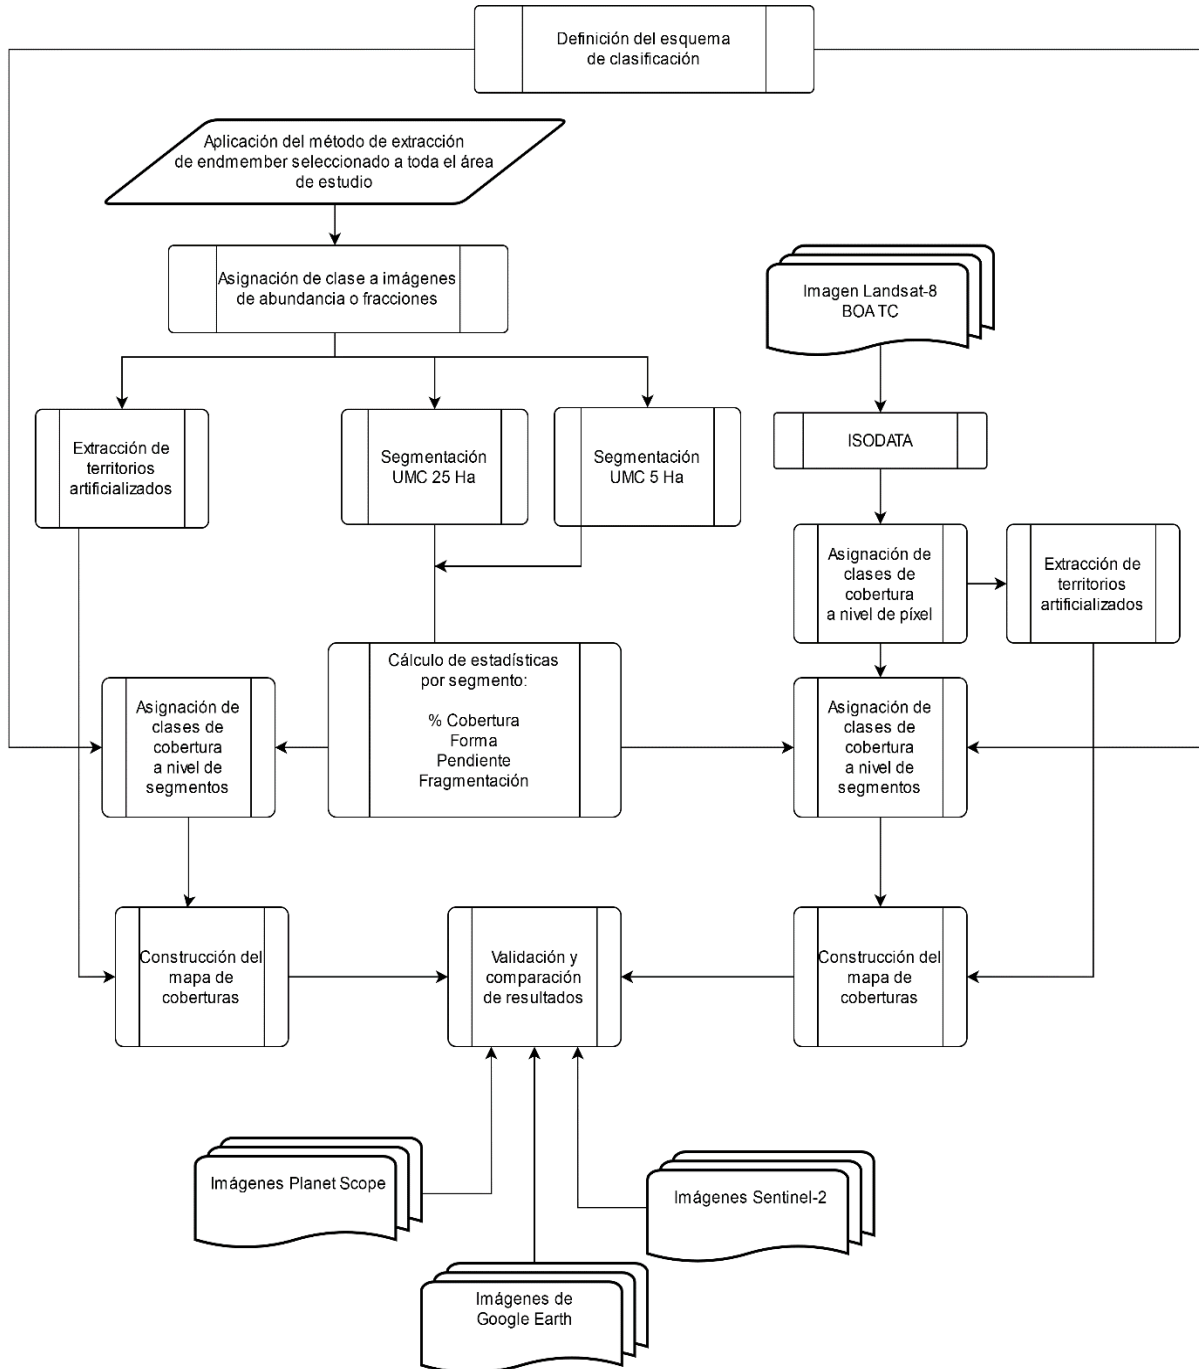


Figura 27. Flujo de actividades realizadas para evaluar la capacidad del análisis lineal de mezclas espectrales para obtener una delimitación preliminar de coberturas.

Fuente: elaboración propia.

3.4.1. Definición del esquema de clasificación

Como primer paso para la aplicación de los métodos propuestos, se definió el esquema de clasificación a adoptar. De acuerdo a los objetivos de la investigación, se seleccionó como esquema el definido en la Leyenda CORINE Land Cover adaptada para Colombia, incluyendo las unidades de cobertura de la tierra hasta el segundo nivel jerárquico.

Para fines de la investigación, se excluyeron aquellas unidades que requieren de verificación en campo o de información de series temporales para su identificación, como son las zonas húmedas y las unidades de cultivos permanentes y transitorios.

Por otra parte, cuando el resultado obtenido con los enfoques de clasificación empleados lo permitió, se incluyeron las unidades de nivel jerárquico 3 correspondientes a tierras desnudas y degradadas (333) y afloramientos rocosos (332).

En la Tabla 16 se muestra el esquema de clasificación adoptado.

Tabla 16. Esquema de clasificación adoptado.

Fuente: elaboración propia.

<i>Nivel jerárquico</i>	<i>Código</i>	<i>Nombre unidad de cobertura</i>
1	1	TERRITORIOS ARTIFICIALIZADOS
2	11	Zonas urbanizadas
2	12	Zonas industriales o comerciales y redes de comunicación
2	14	Zonas verdes artificializadas
1	2	TERRITORIOS AGRÍCOLAS
2	23	Pastos
2	24	Áreas agrícolas heterogéneas
1	3	BOSQUES Y ÁREAS SEMINATURALES
2	31	Bosques
2	32	Áreas con vegetación herbácea y/o arbustiva
2	33	Áreas abiertas, sin o con poca vegetación
3	332	Afloramientos rocosos
3	333	Tierras desnudas y degradadas
1	4	ÁREAS HÚMEDAS
2	41	Áreas húmedas continentales
1	5	SUPERFICIES DE AGUA
2	51	Aguas continentales

Nota: adaptado de IDEAM (2010).

3.4.2. Clasificación mediante ISODATA

La clasificación no supervisada mediante el algoritmo ISODATA se realizó utilizando como insumo de entrada, las imágenes seleccionadas para el área de estudio y corregidas radiométricamente. Para tal fin se utilizó el algoritmo ISODATA disponible en el software ENVI 5.3.

Con el fin de establecer el número adecuado de clases, se ensayaron diferentes configuraciones de clasificación, hasta obtener un número de clases estable en términos de distancia y número de iteraciones.

Para la escena *Path 007 Row 055*, se seleccionó la opción #3 (ver Tabla 17) dado que permite distinguir de mejor manera los cuerpos de agua de zonas de sombra, así como zonas urbanizadas en entornos de suelos desnudos o vegetación escasa (ver Figura 28). Para la escena *Path 008 Row 054*, se seleccionó la clasificación con resultados más similares a los obtenidos en la escena anterior, con base en la comparación visual de las clasificaciones obtenidas en las zonas de solape, correspondiente a la configuración #4 (ver Tabla 17 y Figura 29).

Tabla 17. Configuraciones ensayadas para el algoritmo ISODATA.

Fuente: elaboración propia.

<i>Escena Path 007 Row 055</i>					
<i>#Prueba</i>	<i>#Clases</i>	<i>#Iteraciones</i>	<i>% cambio</i>	<i>Distancia</i>	<i>#Clases obtenidas</i>
1	De 5 a 20	10	5	5	17
2	De 5 a 20	10	5	10	12
3	De 5 a 20	10	5	20	12
4	De 5 a 20	15	5	5	20
5	De 5 a 20	15	5	10	10
6	De 5 a 20	15	5	20	8
<i>Escena Path 008 Row 054</i>					
<i>#Prueba</i>	<i>#Clases</i>	<i>#Iteraciones</i>	<i>% cambio</i>	<i>Distancia</i>	<i>#Clases obtenidas</i>
1	De 5 a 20	10	5	5	9
2	De 5 a 20	10	5	10	5
3	De 5 a 20	10	5	20	5
4	De 5 a 20	15	5	5	9
5	De 5 a 20	15	5	10	6
6	De 5 a 20	15	5	20	6




Figura 28. Comparación entre resultados de clasificación obtenidos con el algoritmo ISODATA para la escena *path 007 row 055*.

Fuente: elaboración propia.

Nota: a) ISODATA con configuración #6; b) ISODATA con configuración #3; c) Imagen original corregida radiométricamente en composición falso color 5-6-3.

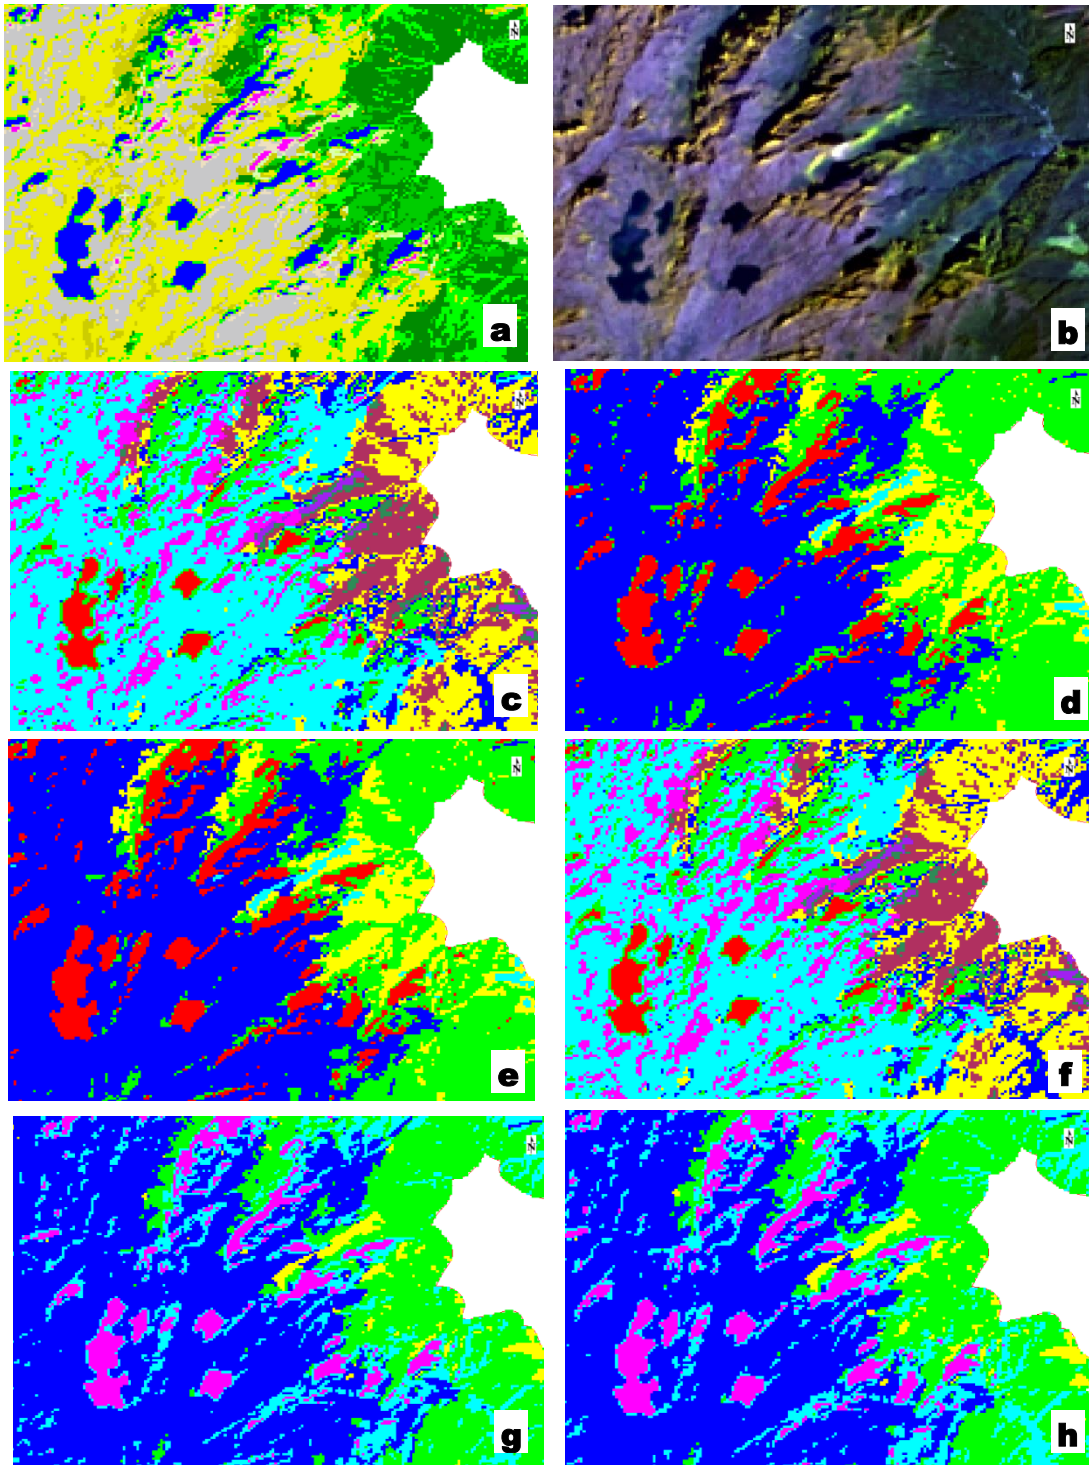


Figura 29. Comparación entre clasificación adoptada para las dos escenas con cubrimiento sobre el área de estudio.

Fuente: elaboración propia.

Nota: a) Clasificación con algoritmo ISODATA seleccionada para el sector sur. b) Imagen corregida radiométricamente en composición en color natural; c) ISODATA con configuración #1. d) ISODATA con configuración #2. e) ISODATA con configuración #3. f) ISODATA con configuración #4. g) ISODATA con configuración #5. h) ISODATA con configuración #6.

Una vez obtenida la clasificación, se procedió a analizar las clases obtenidas con el fin de determinar el tipo de cobertura asociada, mediante la consulta de la imagen original, imágenes de alta resolución disponibles en *Google Earth* y de las firmas espectrales promedio de cada cobertura (ver Figura 30). El detalle de asignación de cada clase se muestra en el Apéndice 2.

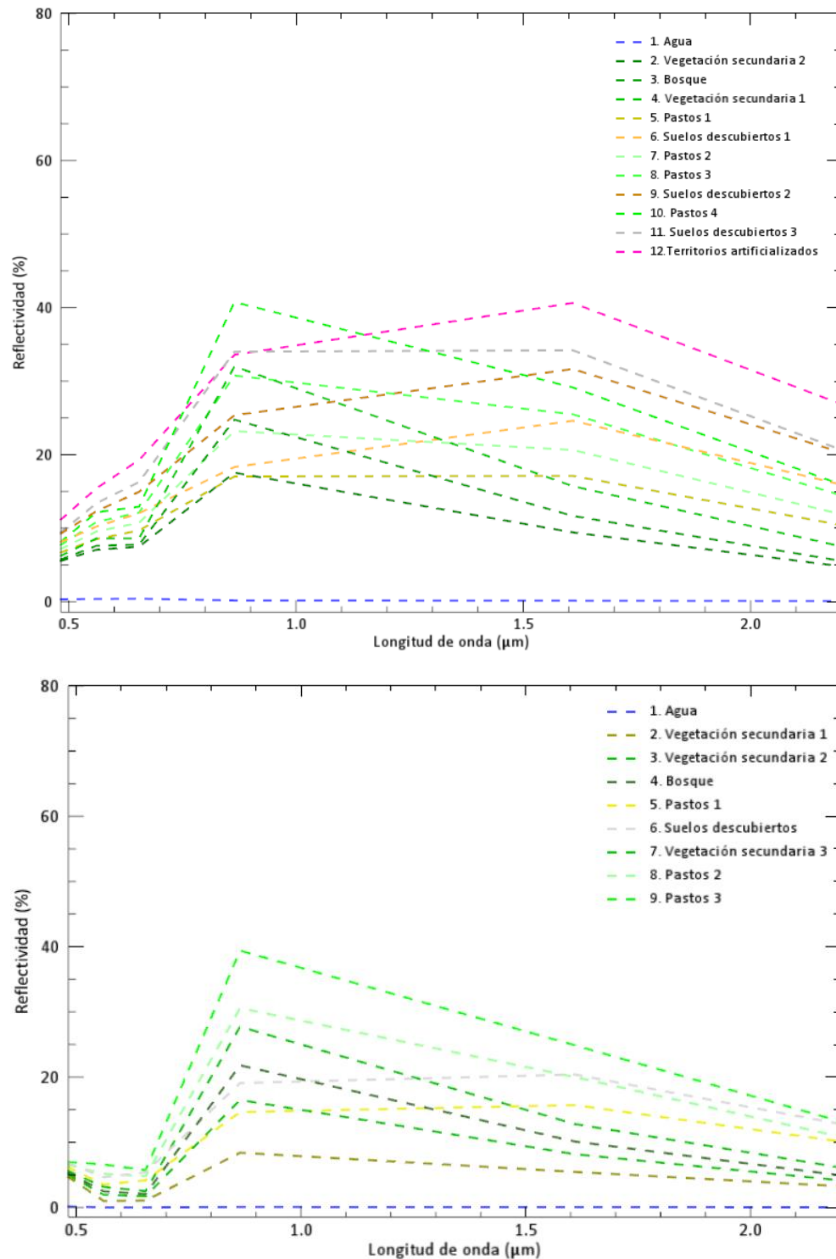


Figura 30. Firmas espectrales promedio de las clases obtenidas mediante el algoritmo ISODATA.

Fuente: elaboración propia.

Nota: a) Escena path 8 row 054; b) Escena path 7 row 55.

3.4.3. Recorte de las imágenes clasificadas al área de estudio

Las imágenes de abundancia obtenidas mediante LSMA, así como las imágenes clasificadas mediante el algoritmo ISODATA fueron recortadas al área de estudio, incluyendo un área de influencia adicional de 100m de radio. En las figuras 31, 32 y 33 se muestran los resultados obtenidos para cada método.

3.4.4. Segmentación de las imágenes

El proceso de segmentación se realizó en el software Spring 5.5.6, utilizando como capa de entrada, las imágenes de abundancia (o fracciones), resmuestreadas a 15 m de resolución espacial y la banda pancromática del sensor OLI, con el fin de obtener un tamaño menor del segmento. El tamaño de los segmentos se estableció de manera proporcional de acuerdo a la unidad mínima cartografiada (UMC) establecida por la CORINE Land Cover adaptada para Colombia, suponiendo una escala de 1:50.000 gracias a la inclusión de la banda pancromática de 15m.

De acuerdo a lo anterior, se adoptó un ancho mínimo de 30m para elementos lineales (2 píxeles de ancho mínimo), un área de 2.5 Ha para territorios artificializados y de 12.5 Ha para las unidades 2 y 3. De acuerdo a la importancia que los cuerpos de agua y zonas húmedas revisten en ecosistemas de páramo, para las unidades 4 y 5 se asumió una UMC de 2.5 Ha.

Teniendo en cuenta que 1 hectáreas corresponden a 10.000 m² y que cada pixel tiene 15x15m, es decir 225 m², el número de píxeles que conforman un segmento se definió como:

- Territorios artificializados y cuerpos de agua: $25.000/15^2 = 112$ píxeles
- Otras unidades: $125.000/15^2 = 555$ píxeles.




Figura 31. Imágenes de abundancia recortadas al área de estudio (composición EM1, 2 y 3).

Fuente: elaboración propia.

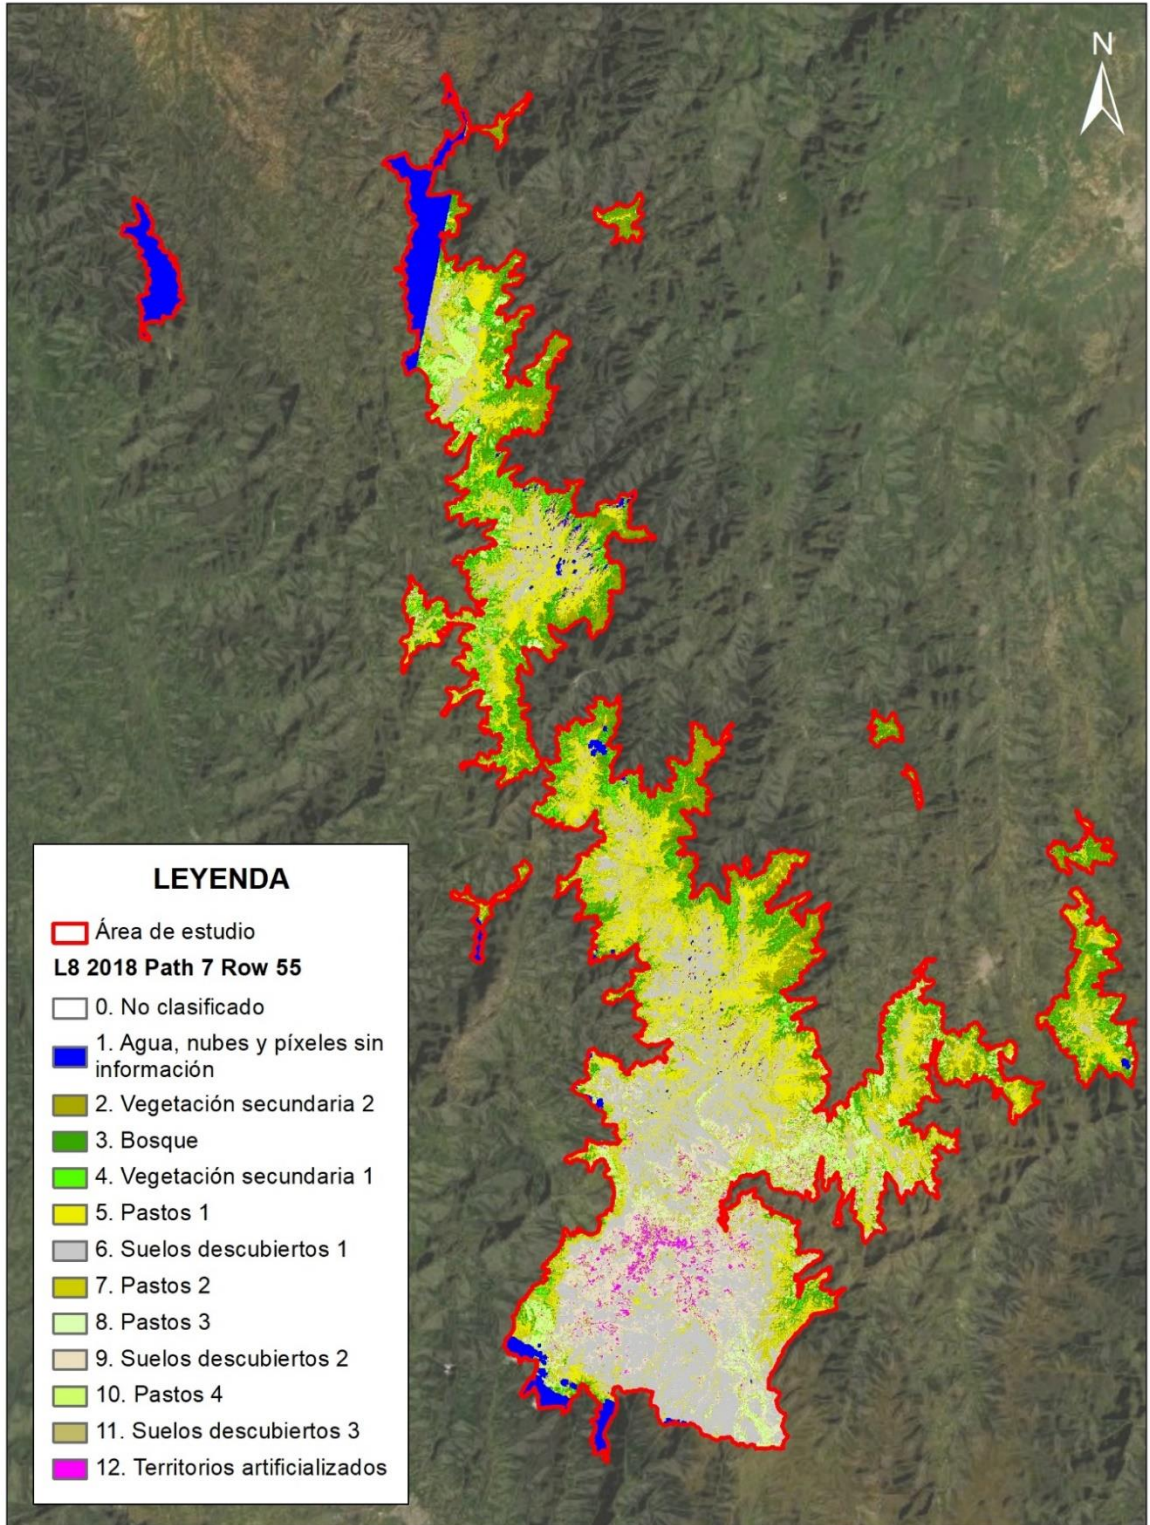


Figura 32. Asignación de coberturas a las clases definidas mediante el algoritmo ISODATA para la escena *Path 007 Row 055*.

Fuente: elaboración propia.

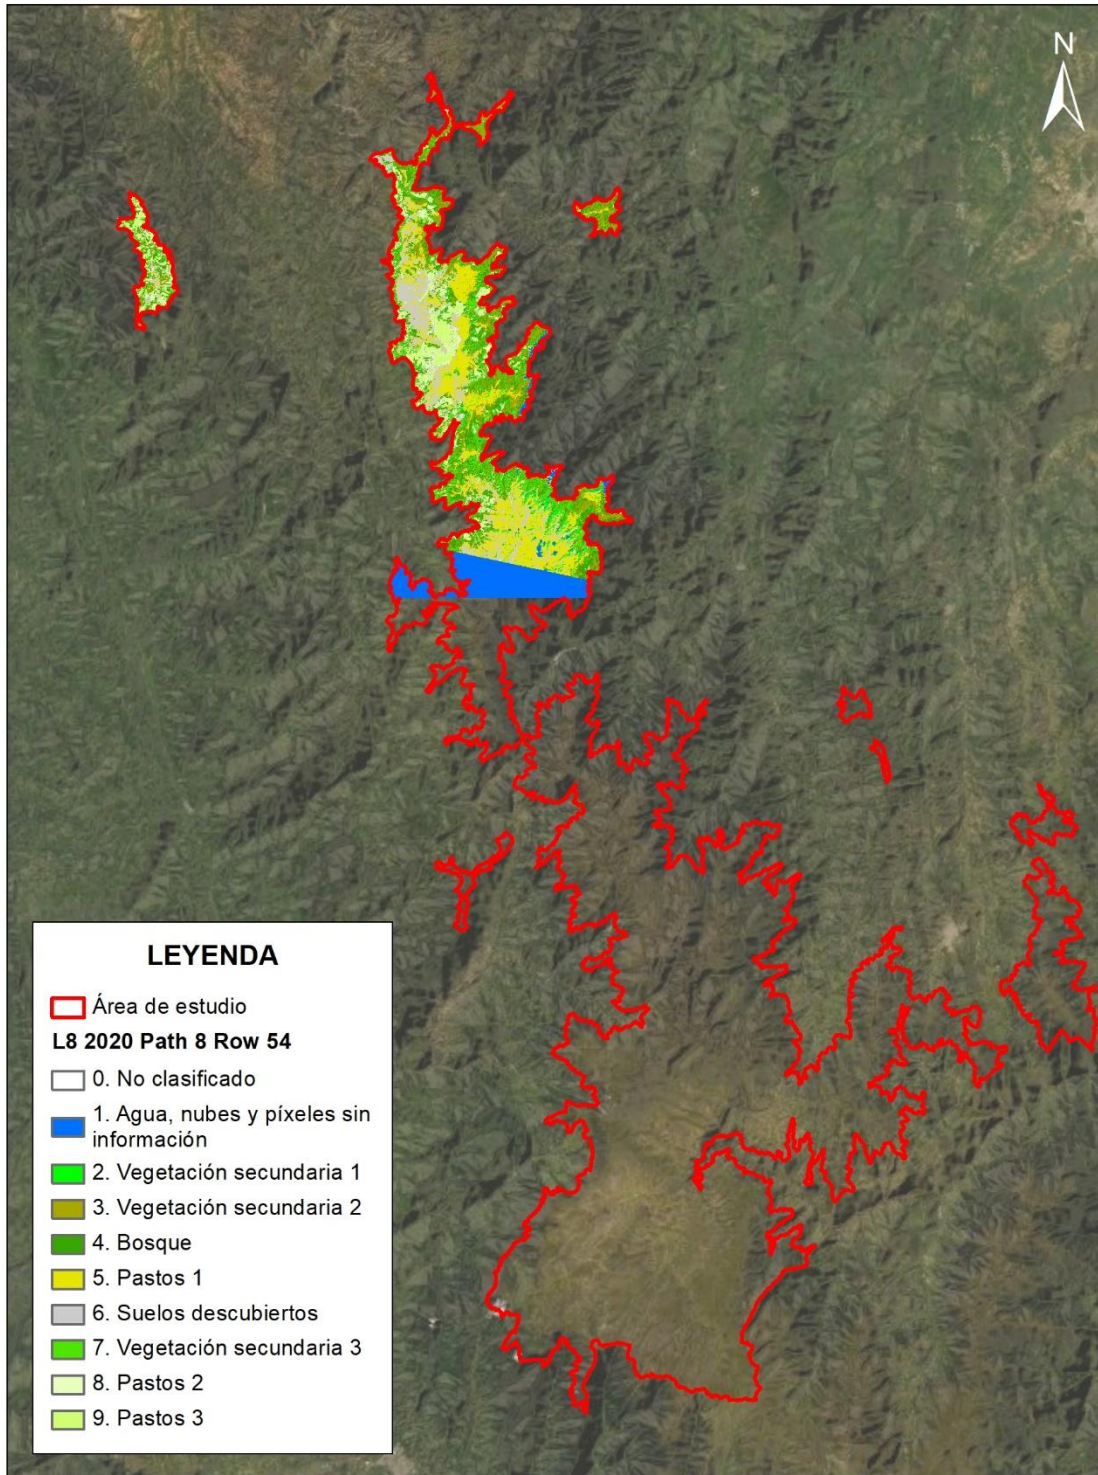


Figura 33. Asignación de coberturas a las clases definidas mediante el algoritmo ISODATA para la escena *Path 008 Row 054*.

Fuente: elaboración propia.

Una vez realizada la segmentación, estas se exportaron en formato vectorial y se incorporaron a una geodatabase de archivo de ArcGIS con el fin de corregir los errores topológicos eventualmente presentes. En la Figura 34 se muestran las segmentaciones obtenidas.




Figura 34. Detalle de los resultados de segmentación.

Fuente: elaboración propia.

Nota: a) Segmentación para UMC de 12.5 Ha. b) Segmentación para UMC de 2.5 Ha.

3.4.5. Definición de criterios de clasificación y cálculo de estadísticas de clase por segmento

Como criterios de clasificación se utilizaron el porcentaje de cobertura de cada clase por segmento, la forma del segmento, la pendiente promedio del terreno incluido en el segmento y medidas de fragmentación. Para poder aplicar los criterios, se realizó el cálculo de las siguientes estadísticas y parámetros para cada segmento obtenido:

1. Moda: indica la clase más representada dentro del segmento, se obtuvo mediante la herramienta Zonal Statistics as Table de ArcMap.
2. Área relativa de la clase: calcula el área de cada clase dentro del segmento (en píxeles), se obtuvo mediante la herramienta Tabulate Area de ArcMap.
3. Pendiente promedio: indica la pendiente promedio del terreno para el segmento, se obtuvo mediante la herramienta Zonal Statistics as Table de ArcMap.
4. Factor de forma: indica el grado de elongación del segmento, su valor es mayor cuanto mayor es la proporción entre longitud y ancho del segmento. Su cálculo se realizó con base en los ejes mayor y menor de cada segmento, calculados mediante la herramienta Zonal Geometry as Table de ArcMap, aplicando una celda de procesamiento de 30m, que corresponde a la resolución de la imagen clasificada.
5. Medidas de fragmentación: con el fin de poder aplicar el mismo indicador para los dos métodos de clasificación empleados, la fragmentación asociada a los segmentos se estimó mediante el cálculo del número de clases de NDVI incluidas, definidas con base en 10 rangos establecidos por intervalos naturales.

Para el caso de la clasificación obtenida mediante el algoritmo ISODATA, se consideró como porcentaje de cobertura, la fracción de los píxeles clasificados como una determinada cobertura con respecto al total de los píxeles incluidos en el segmento. Para el caso de la clasificación obtenida mediante desmezclado espectral con el algoritmo SMACC, se consideró como porcentaje de cobertura, la relación entre la sumatoria de las abundancias asignadas a una misma cobertura para los píxeles incluidos en el segmento considerado, y la suma de las abundancias de todas las coberturas incluidas en un píxel.

La pendiente promedio de cada segmento se calculó en el software ArcMap 10.6, a partir del DEM de la misión SRTM.

3.4.6. Asignación de clase de cobertura a los polígonos

La asignación de las clases a los polígonos de 12.5 Ha, se realizó mediante la aplicación de las reglas establecidas en el diagrama de flujo de la Figura 35, en un intento de semiautomatizar los criterios adoptados por leyenda nacional de coberturas de la tierra CORINE Land Cover adaptada para Colombia (IDEAM, 2010).

La extracción y clasificación de la unidad de territorios artificializados se realizó, para el caso de la clasificación obtenida con el algoritmo ISODATA, mediante la extracción de los píxeles incluidos en la clase correspondiente. En el caso de las fracciones obtenidas con el algoritmo SMACC, los territorios artificializados se extrajeron con base en la fracción correspondiente, utilizando un valor de abundancia mayor a 0.2. Este rango se estableció mediante análisis visual con la imagen de insumo.

Con el fin de dar continuidad a los píxeles adyacentes extraídos, se realizó una expansión utilizando un área de 1 píxel (30m). Como postproceso, se aplicó un filtro mayoritario y un refinado de bordes. Los píxeles extraídos se convirtieron a polígonos y se aplicó un suavizado con tolerancia de 50m. Se eliminaron todos los polígonos con área inferior a 2.5 Ha. Finalmente se asignó la clase 11 a los polígonos con factor de forma mayor o igual a 0.4, y la clase 12 a los polígonos con factor de forma menor a 0.4.

Las zonas verdes urbanizadas (código 14), se obtuvieron de mediante la extracción de los segmentos con presencia de zonas verdes o zonas naturales (códigos 31, 32, 2, 4 y 5) en un porcentaje igual o mayor al 30%, e inmediatamente adyacentes a la selección anterior clasificada como 11), con área mayor a 2.5 Ha y menor a 12.5 Ha.

Las aguas continentales (51) se obtuvieron mediante la extracción de los segmentos con presencia de píxeles asociados a la clase correspondiente, en un porcentaje igual o superior al 70% y con una pendiente menor a 0.3.

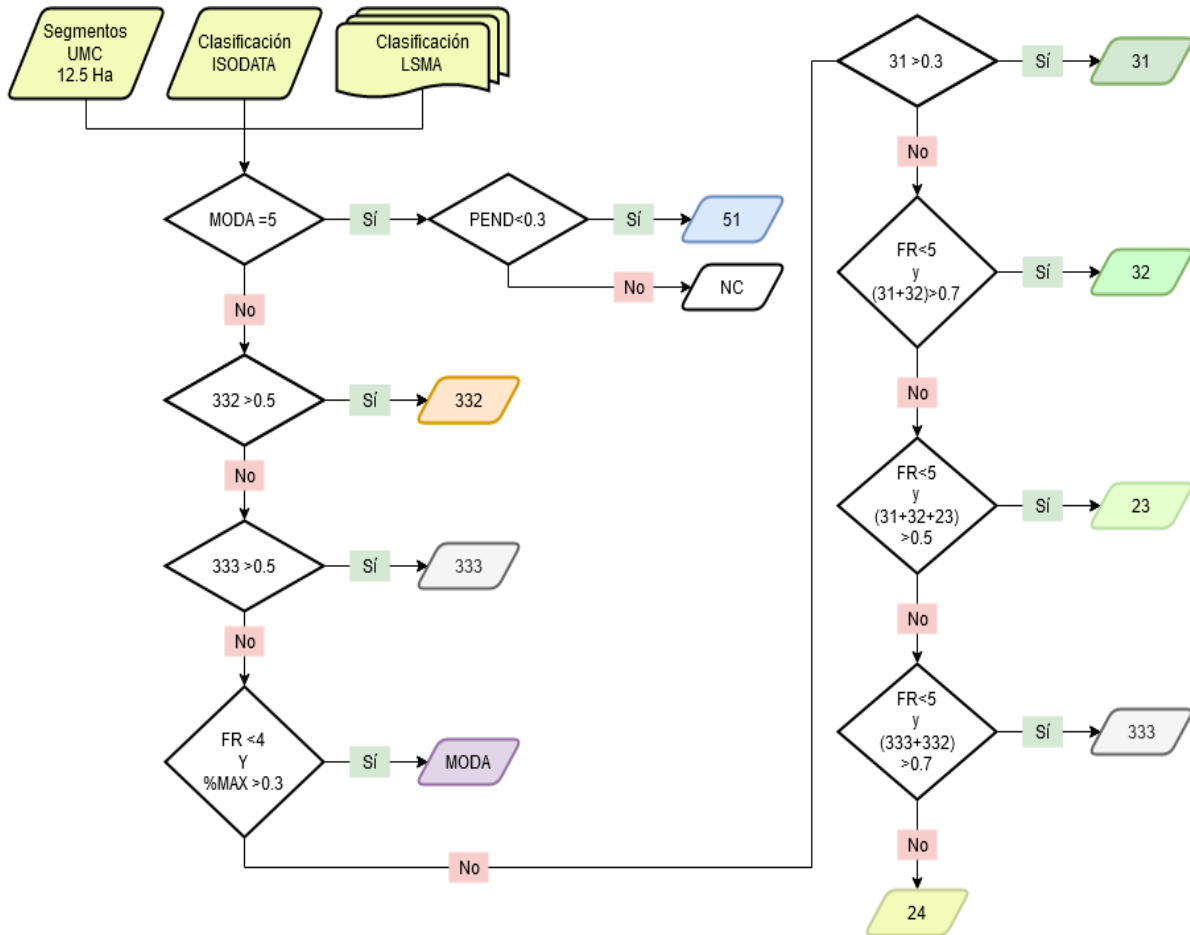


Figura 35. Diagrama de flujo propuesto para semiautomatizar el esquema de clasificación adoptado para UMC de 12.5 Ha.

Fuente: elaboración propia.

Nota: UMC: unidad mínima cartografiable; PEND: Pendiente; NC: no clasificado; FR: factor de fragmentación; %MAX: Abundancia máxima relativa dentro del polígono considerado o abundancia asociada a la moda. MODA: unidad de cobertura de mayor abundancia dentro del polígono. Los valores asociados a los códigos de cobertura se refieren a su abundancia relativa dentro del polígono considerado (ej. $333 > 0.5$ se refiere a que la unidad 333 representa más del 50% del área o de las abundancias de las coberturas presentes en el polígono).

3.4.7. Construcción del mapa de coberturas

Los resultados de la clasificación de las dos imágenes de insumo se incorporaron en una sola capa vectorial, priorizando la imagen con mayor cobertura sobre el área de estudio y con menor cobertura de nube o de píxeles no clasificados.

Los principales procesos llevados a cabo para la obtención del mapa final fueron:

1. Consolidación en una sola capa vectorial los polígonos o segmentos clasificados a partir de diferentes insumos, la cual se tomó como referencia para el proceso de validación (numeral 3.4.8).
2. Fusión de los polígonos pertenecientes a la misma clase.
3. División de entidades multiparte.
4. Fusión de los polígonos con área menor a 2.5 o 12.5 hectáreas según la unidad de pertenencia con el polígono adyacente con mayor borde compartido: este proceso permite eliminar eventuales polígonos que no cumplan con la UMC que se hayan generado en los procesos de fusión anteriores.

En las figuras 36 y 37 se muestran los mapas construidos a partir de los dos métodos de clasificación aplicados.

3.4.8. Validación

Para realizar el proceso de validación, de acuerdo a lo propuesto por Congalton (2009), se estableció el tamaño de la muestra calculando un número de 50 puntos de validación por unidad de cobertura definida. Los puntos se seleccionaron mediante muestreo aleatorio estratificado en el software ArcMap 10.5. Para este fin se excluyeron a priori los polígonos que contienen los *endmembers* utilizados para el proceso de clasificación. En la Tabla 18 se indica el número de muestras utilizadas por clase y por método de clasificación empleado.

Cabe resaltar que la herramienta utilizada para la selección de las muestras de validación ajusta el número de puntos definidos por clase de acuerdo a las dimensiones de cada clase. Por esta razón el tamaño final de la muestra es un poco superior al establecido.

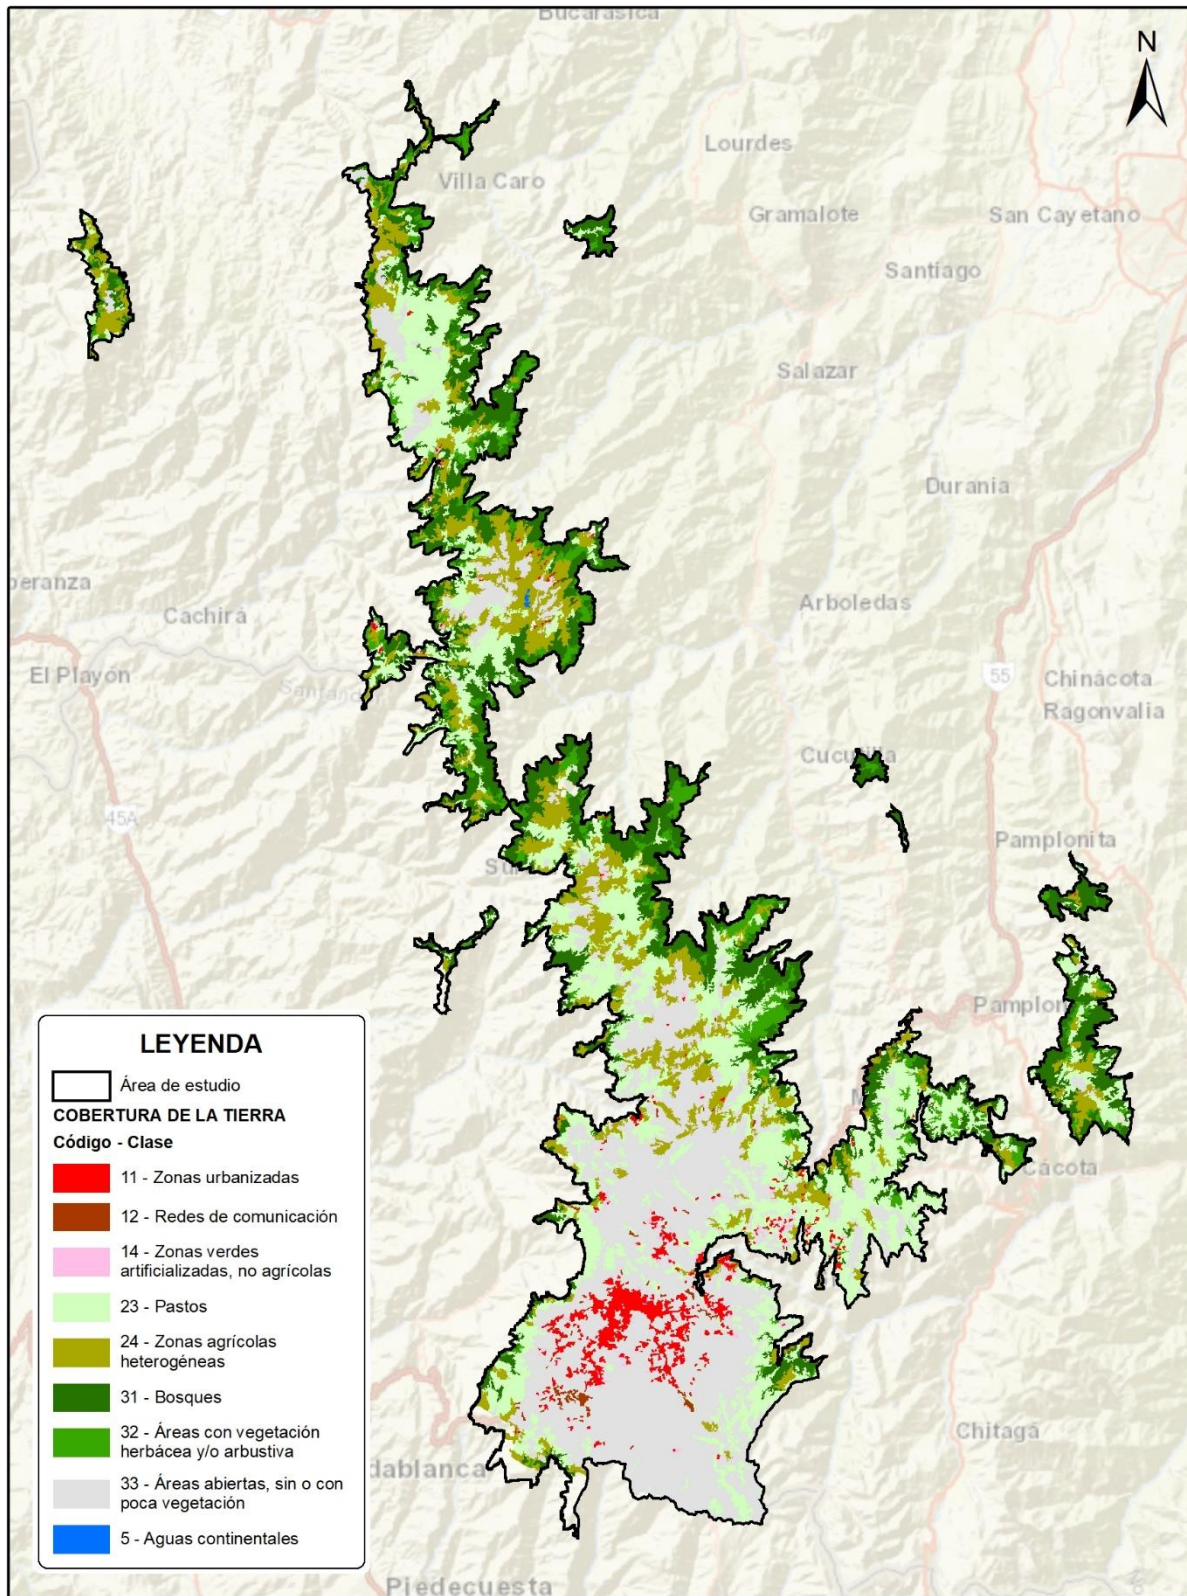


Figura 36. Mapa clasificado obtenido a partir de clasificador ISODATA y segmentación.

Fuente: elaboración propia.

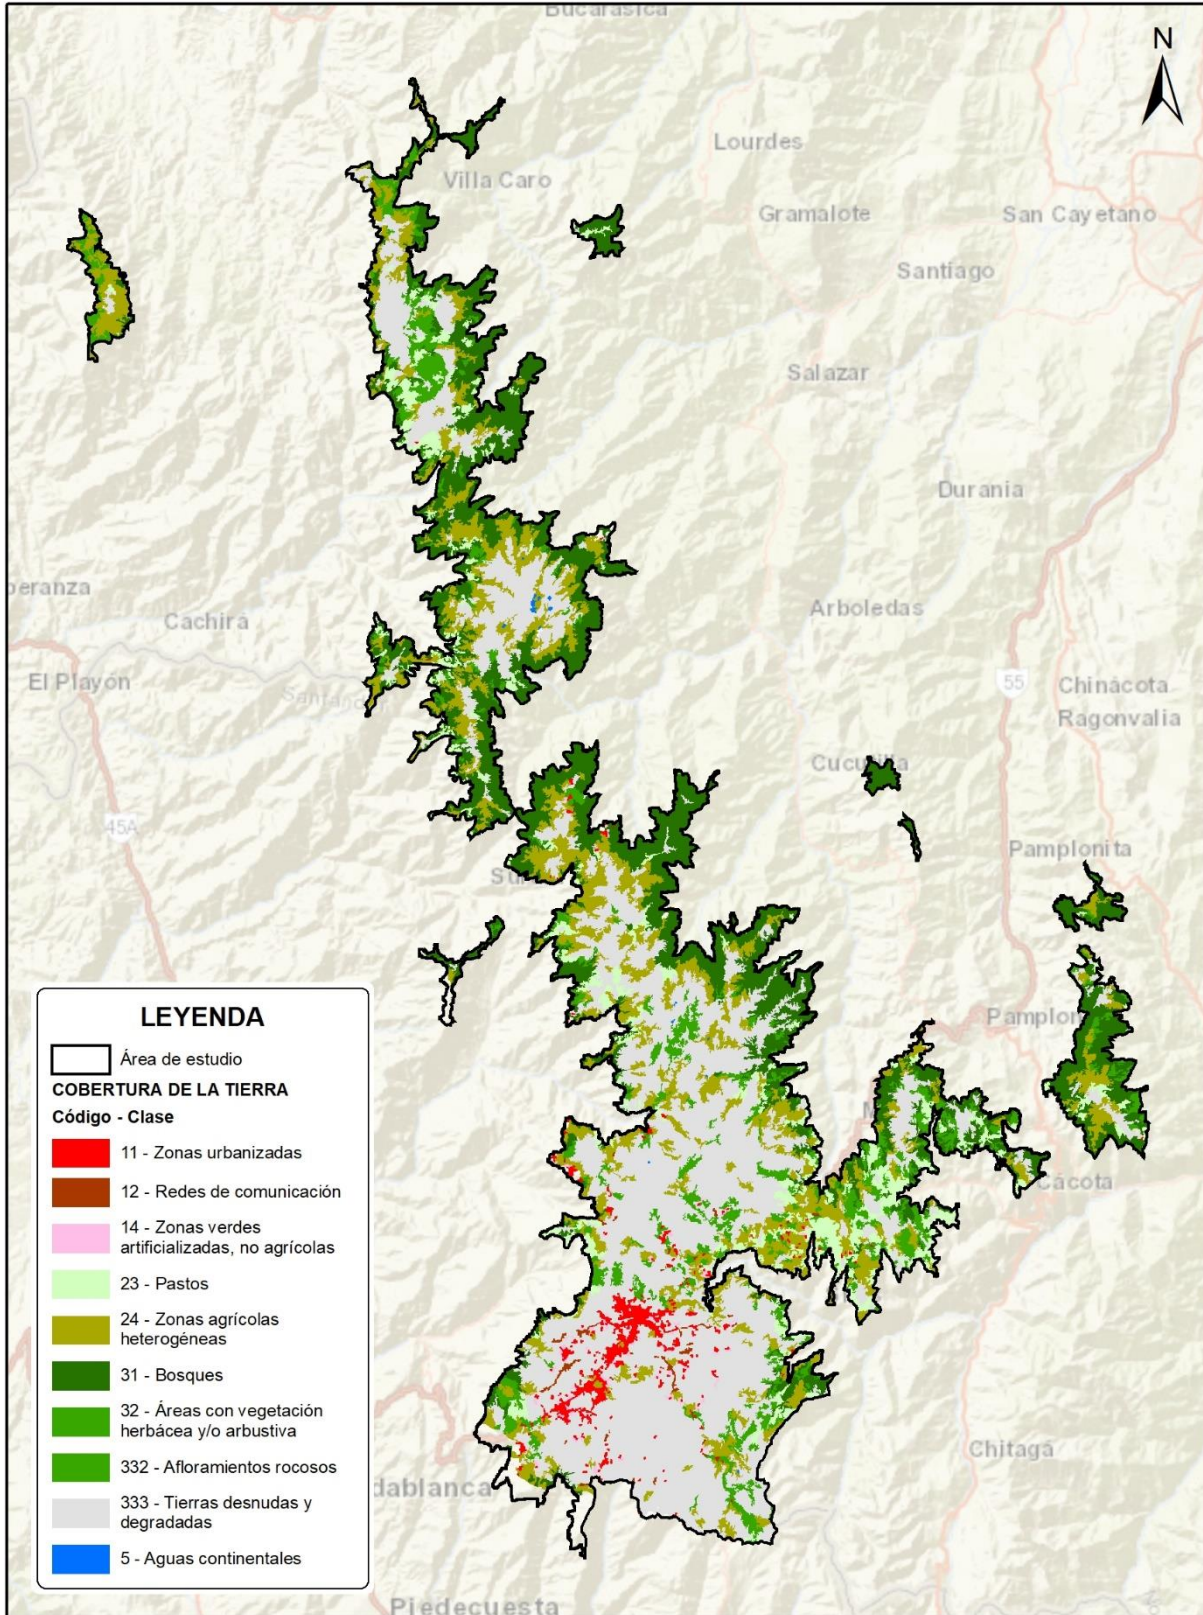


Figura 37. Mapa clasificado obtenido a partir de clasificador SMACC y segmentación.

Fuente: elaboración propia.

Tabla 18. Número de muestras por unidad de cobertura seleccionadas para la validación de los mapas obtenidos.

Fuente: elaboración propia.

<i>Unidad de cobertura de la tierra</i>		<i># Muestras</i>	
<i>Código</i>	<i>Nombre</i>	<i>SMACC</i>	<i>ISODATA</i>
11	Zonas urbanizadas	10	11
12	Zonas industriales o comerciales y redes de comunicación	10	10
14	Zonas verdes artificializadas	10	10
23	Pastos	37	118
24	Áreas agrícolas heterogéneas	90	64
31	Bosques	136	99
32	Áreas con vegetación herbácea y/o arbustiva	41	29
332	Bosques	10	-
333	Áreas con vegetación herbácea y/o arbustiva	182	126
51	Aguas continentales	10	10
TOTAL		536	477

En la Figura 38 se muestra la distribución espacial de los puntos de muestreo seleccionados para realizar la validación de los resultados obtenidos con los métodos utilizados. La validación de la unidad de cobertura en cada punto se realizó con base en la interpretación visual de imágenes de la misión Planet Scope y Sentinel-2 de los años 2017 a 2020. Posteriormente, se obtuvo la matriz de confusión de cada mapa mediante la herramienta Compute Confusion Matrix (Spatial Analyst) del software ArcMap 10.5.

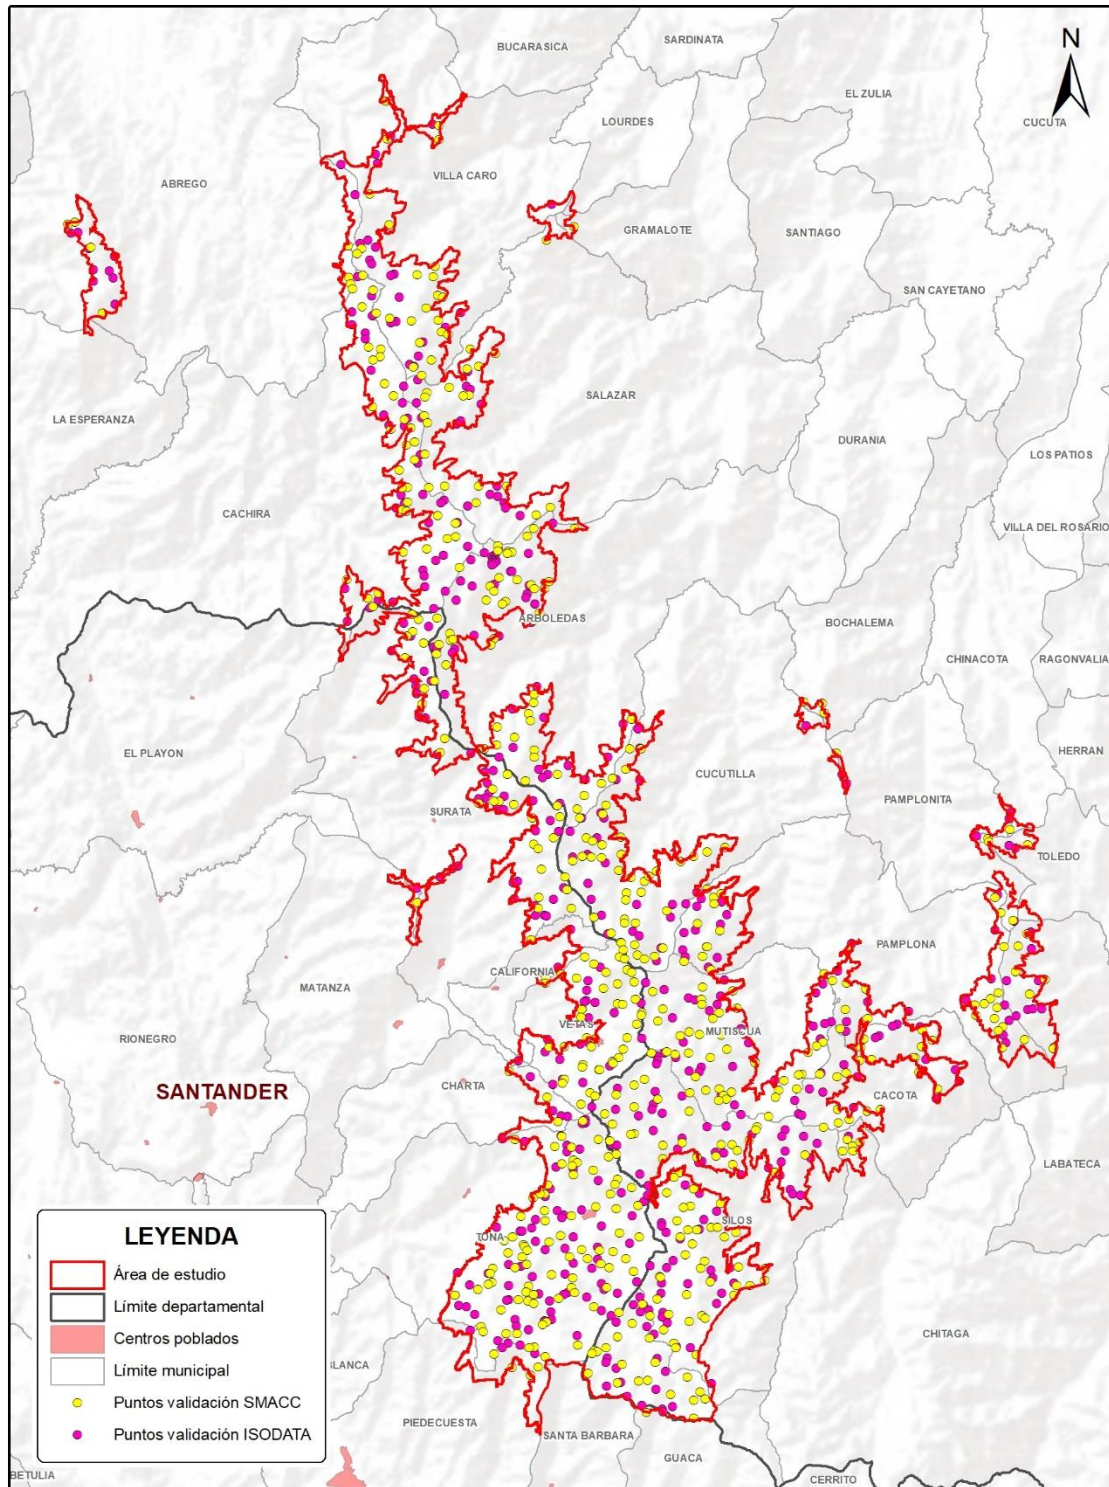


Figura 38. Distribución espacial de los puntos de muestreo seleccionados para la validación los mapas obtenidos.

Fuente: elaboración propia.

3.4.9. Evaluación de la aplicabilidad de LSMA y OBIA para la obtención de un mapa de coberturas de la tierra preliminar

Con el fin de evaluar el desempeño de LSMA y OBIA para la obtención de mapas preliminares de cobertura mediante el esquema de clasificación de la Leyenda CORINE Land Cover adaptada para Colombia, se compararon los resultados obtenidos mediante el enfoque SMACC+OBIA y ISODATA+OBIA en términos de fiabilidad global del mapa final obtenido, número de clases de cobertura discriminadas y detección de elementos de menores dimensiones.

Adicionalmente se comparó el nivel de detalle alcanzado con el enfoque propuesto, con las capas vectoriales de la clasificación oficial de la CORINE Land Cover para Colombia del año 2012.

4. RESULTADOS Y DISCUSIÓN

En esta sección se presentan y discuten, para cada objetivo específico planteado, los resultados obtenidos como parte de la determinación de la aplicabilidad del análisis lineal de mezclas espectrales para la obtención de un mapa preliminar de cobertura de la tierra a partir de imágenes multiespectrales de la misión Landsat-8 en el complejo de páramo jurisdicción Santurbán-Berlín.

4.1. Objetivo 1

En relación al objetivo específico 1 “*Determinar, a partir del análisis de resultados obtenidos con diferentes modelos de transferencia radiativa y de métodos e insumos para la corrección de los efectos topográficos, el más óptimo para la calibración radiométrica de imágenes satelitales multiespectrales de la misión Landsat-8 de zonas de alta montaña*” se obtuvieron los siguientes resultados.

La comparación de los histogramas de las imágenes obtenidas con los modelos de transferencia radiativa FLAASH y ATCOR, y con los diferentes modelos digitales de elevación (SRTM, ASTER, ALOS-PALSAR, GMTED) empleados para la corrección atmosférica (Figura 39), presenta, en todos los casos, la ausencia de desplazamiento en los valores mínimos en los histogramas de las imágenes procesadas, lo cual indica la ausencia de interferencias atmosféricas residuales.

El análisis del histograma de la imagen corregida atmosféricamente con el módulo de FLAASH (Figura 39a), evidencia la presencia de muchos valores de reflectancia por fuera del rango de 0 a 10.000⁷, establecido de acuerdo con la documentación del módulo. Adicionalmente, se observan valores negativos en todas las bandas, los cuales no pueden ser considerados valores físicos admisibles. Por el contrario, los valores de reflectancia de las imágenes corregidas con el módulo ATCOR de PCI Geomatics (Figura 39b, c y d), se encuentran en el rango esperado, de 0

⁷ El software ENVI escala los valores de reflectancia multiplicándolos por 10.000.

a 100^8 , el cual es el esperado con la aplicación de este algoritmo, y no se observan valores negativos.

De acuerdo con lo anterior, los histogramas y estadísticas de las imágenes corregidas atmosféricamente con el módulo ATCOR presentan los mejores resultados.

⁸ El software PCI Geomatics escala los valores de reflectancia multiplicándolos por 100 con el fin de expresarlos en porcentaje.

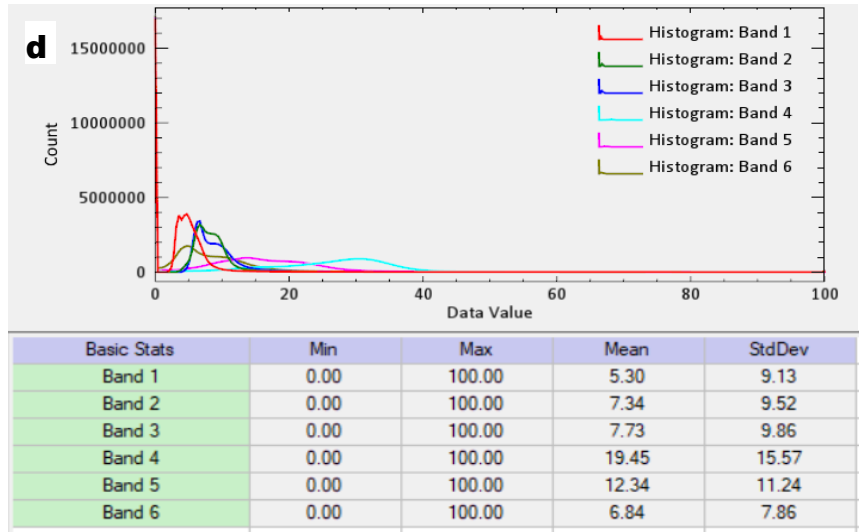





Figura 39. Comparación de histogramas y estadísticas de las imágenes corregidas con diferentes modelos de transferencia radiativa e insumos.

Fuente: elaboración propia.

Notas: a) FLAASH de ENVI; b) ATCOR y MDE de SRTM; c) ATCOR y GDEM de ASTER; d) ATCOR y MDE de SRTM con filtro de paso bajo 3X3.

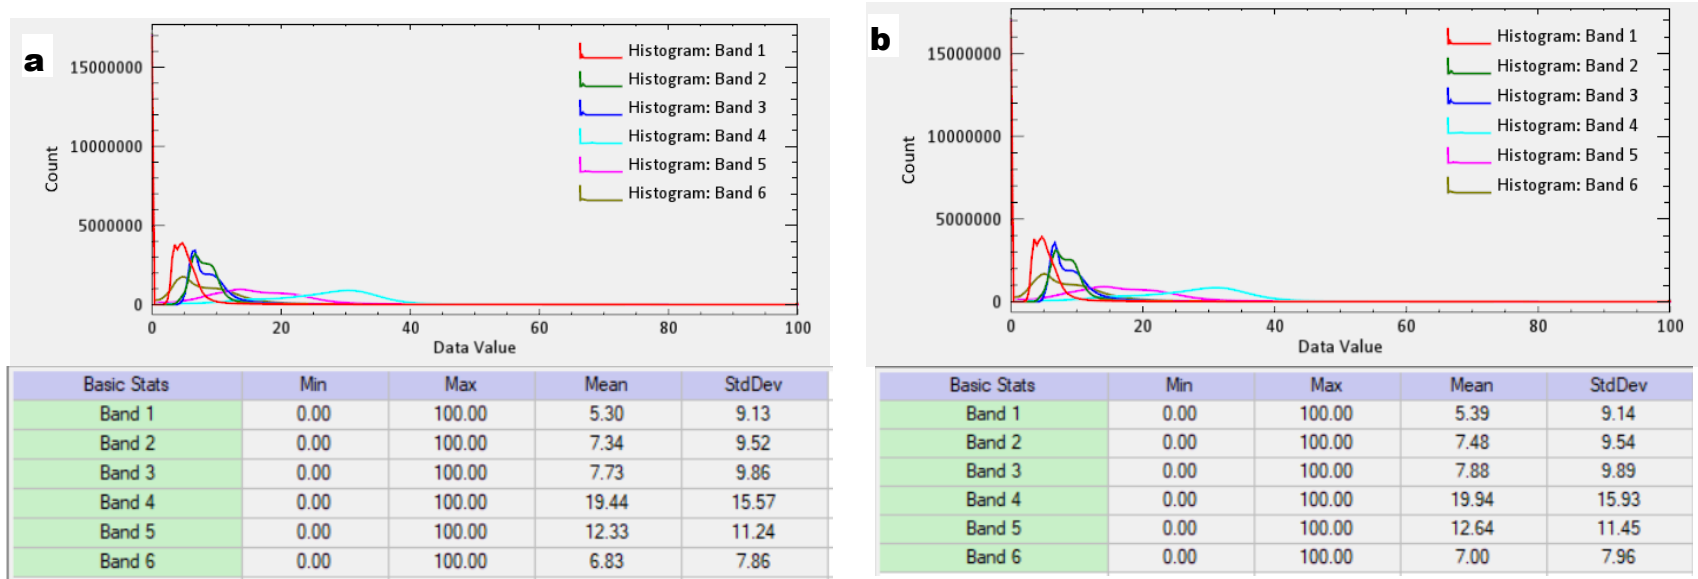


Figura 40. Comparación de histogramas y estadísticas de las imágenes corregidas con diferentes modelos de transferencia radiativa e insumos (continua).

Fuente: elaboración propia.

Notas: a) ATCOR con MDE de ALOS PALSAR; b) ATCOR con GMTED 2010.

Realizada la comparación de los histogramas y los datos estadísticos, se procedió a efectuar el análisis visual de las imágenes obtenidas, observando que la mayoría de imágenes corregidas con el módulo ATCOR evidencian la presencia de grupos de píxeles con valores anómalos en zonas de alta pendiente (ver Figura 41), que aparecen como manchas con alto contraste de color con respecto a las zonas adyacentes. Un análisis más detallado de estas áreas y su comparación con el mapa de iluminación empleado por el modelo de transferencia radiativa, permite deducir que su aparición se debe principalmente al MDE utilizado (ver Figura 42). Lo anterior es confirmado por el hecho de que este efecto se atenúa con la aplicación de un filtro de paso bajo al modelo digital de elevaciones, como se muestra en la Figura 43.

El anterior efecto no se observa en la imagen corregida con el módulo FLAASH, ni en la imagen obtenida con el módulo ATCOR y GMTED 2010, que por lo tanto pueden considerarse las opciones más apropiadas para el área de estudio, desde el punto de vista del análisis visual de los resultados obtenidos.

En conclusión, el análisis comparativo de diferentes modelos e insumos empleados para la corrección atmosférica indica que, para el área de estudio, los mejores resultados se obtienen con el uso del módulo ATCOR y el MDE GMTED 2010.




Figura 41. Comparación visual de las correcciones atmosféricas realizadas con diferentes insumos y modelos de transferencia radiativa.

Fuente: elaboración propia.

Notas: a) Imagen original; b) FLAASH; c) ATCOR y SRTM 30 m; d) ATCOR y SRTM 30m con filtro de paso bajo 3x3; e) ATCOR y ALOS PALSAR 12.5m con filtro de paso bajo 3x3 (promedio) y remuestreado a 30 m; f) ATCOR y GMTED 2010.




Figura 42. Comparación visual de zonas de artefactos con mapas de iluminación empleados para la corrección con el módulo ATCOR.

Fuente: elaboración propia.

Nota: a) Comparación de mapa de iluminación SRTM con imagen corregida b) Comparación de mapa de iluminación ASTER con imagen corregida c) Comparación de mapa de iluminación ALOS PALSAR con imagen corregida.




Figura 43. Comparación de resultados obtenidos mediante la aplicación de corrección atmosférica mediante el uso del modelo digital de elevación de las misiones SRTM (a) y SRTM con filtro promedio de 3x3 (b).

Fuente: elaboración propia.

De acuerdo con Im (2005) y Pimple (2017), en el análisis visual de los resultados obtenidos con la corrección de los efectos topográficos mediante el método del coseno mejorado (Figura 44), se evidencia una corrección exagerada, donde las zonas menos iluminadas en la imagen de insumo, reciben un efecto de iluminación desproporcionado con la aplicación de la corrección del coseno mejorado. Varios autores atribuyen este efecto, a la asunción de una reflectancia de tipo Lambertiano (Colby & Keating, 1998; Gao et al., 2014; Jensen, 2015; Pimple et al., 2017).

Por otra parte, como se evidencia en la Figura 45, la comparación entre las imágenes normalizadas con la corrección C, muestra una reducción del efecto topográfico asociado a la modificación de la pendiente y orientación del terreno. Adicionalmente, se evidencia una menor rugosidad, permanencia de zonas de sombra, así como de zonas de píxeles anómalos o artefactos, con el uso del DEM de SRTM, mientras que con el GDEM de ASTER y de las curvas de nivel del IGAC se evidencia un aumento de estas características (ver figuras 47 y 48).

En la Figura 49 se muestra el efecto de la aplicación de filtros de paso bajo de tipo promedio y modal al mapa de iluminación utilizado para la normalización topográfica. Se evidencia una disminución de la rugosidad de la imagen con los filtros promedio de 3x3 y de 5x5, mientras que los filtros modales generan un aumento de la rugosidad e incluso la formación de artefactos en la imagen normalizada.




Figura 44. Comparación de resultados obtenidos para la corrección del coseno mejorada con diferentes tipos de insumos.

Fuente: elaboración propia.

Nota: a) Imagen en composición color verdadero (4-3-2) del sensor OLI de Landsat 8, con valores de reflectancia de superficie no normalizada topográficamente; b) MDE de la misión ASTER; c) MDE de la misión SRTM.; d) MDT generado a partir de curvas de nivel del IGAC a escala 1:25.000. e) MDE de la misión ALOS PALSAR. Todas las visualizaciones tienen un ajuste del histograma con ecualización.




Figura 45. Comparación de resultados obtenidos para la corrección C con diferentes tipos de insumos.

Fuente: elaboración propia.

Nota: a) Imagen en composición color verdadero (4-3-2) del sensor OLI de Landsat 8, con valores de reflectancia de superficie no normalizada topográficamente. b) MDE de la misión ASTER. c) MDE de la misión SRTM. d) MDT generado a partir de curvas de nivel del IGAC a escala 1:25.000. e) MDE de la misión ALOS PALSAR. Todas las visualizaciones tienen un ajuste del histograma con ecualización.




Figura 46. Detalle de resultados obtenidos para la corrección C con diferentes tipos de insumos.

Fuente: elaboración propia.

Nota: a) Imagen en composición color verdadero (4-3-2) del sensor OLI de Landsat 8, con valores de reflectancia de superficie no normalizada topográficamente. b) MDE de la misión ASTER. c) MDE de la misión SRTM. d) MDT generado a partir de curvas de nivel del IGAC a escala 1:25.000. e) MDE de la misión ALOS PALSAR. Todas las visualizaciones tienen un ajuste del histograma con ecualización.




Figura 47. Presencia de artefactos en imagen corregida con DTM derivado de curvas de nivel del IGAC.

Fuente: elaboración propia.

Nota: a) Imagen corregida con DTM derivado de curvas de nivel del IGAC; b) DTM derivado de las curvas de nivel del IGAC; c) Imagen original; d) Imagen corregida con DEM de SRTM; e) Imagen corregida con GDEM de ASTER.




Figura 48. Zonas de sombra residuales en imágenes corregidas con corrección C y diferentes tipos de insumos.

Fuente: elaboración propia.

Nota: a) Imagen en composición color verdadero (4-3-2) del sensor OLI de Landsat 8, con valores de reflectancia de superficie no normalizada topográficamente; b) Modelo digital de elevaciones de la misión SRTM; c) Modelo digital de elevaciones de la misión ASTER; d) Modelo digital del terreno generado a partir de curvas de nivel del IGAC a escala 1:25.000. Todas las visualizaciones tienen un ajuste del histograma con ecuilización.

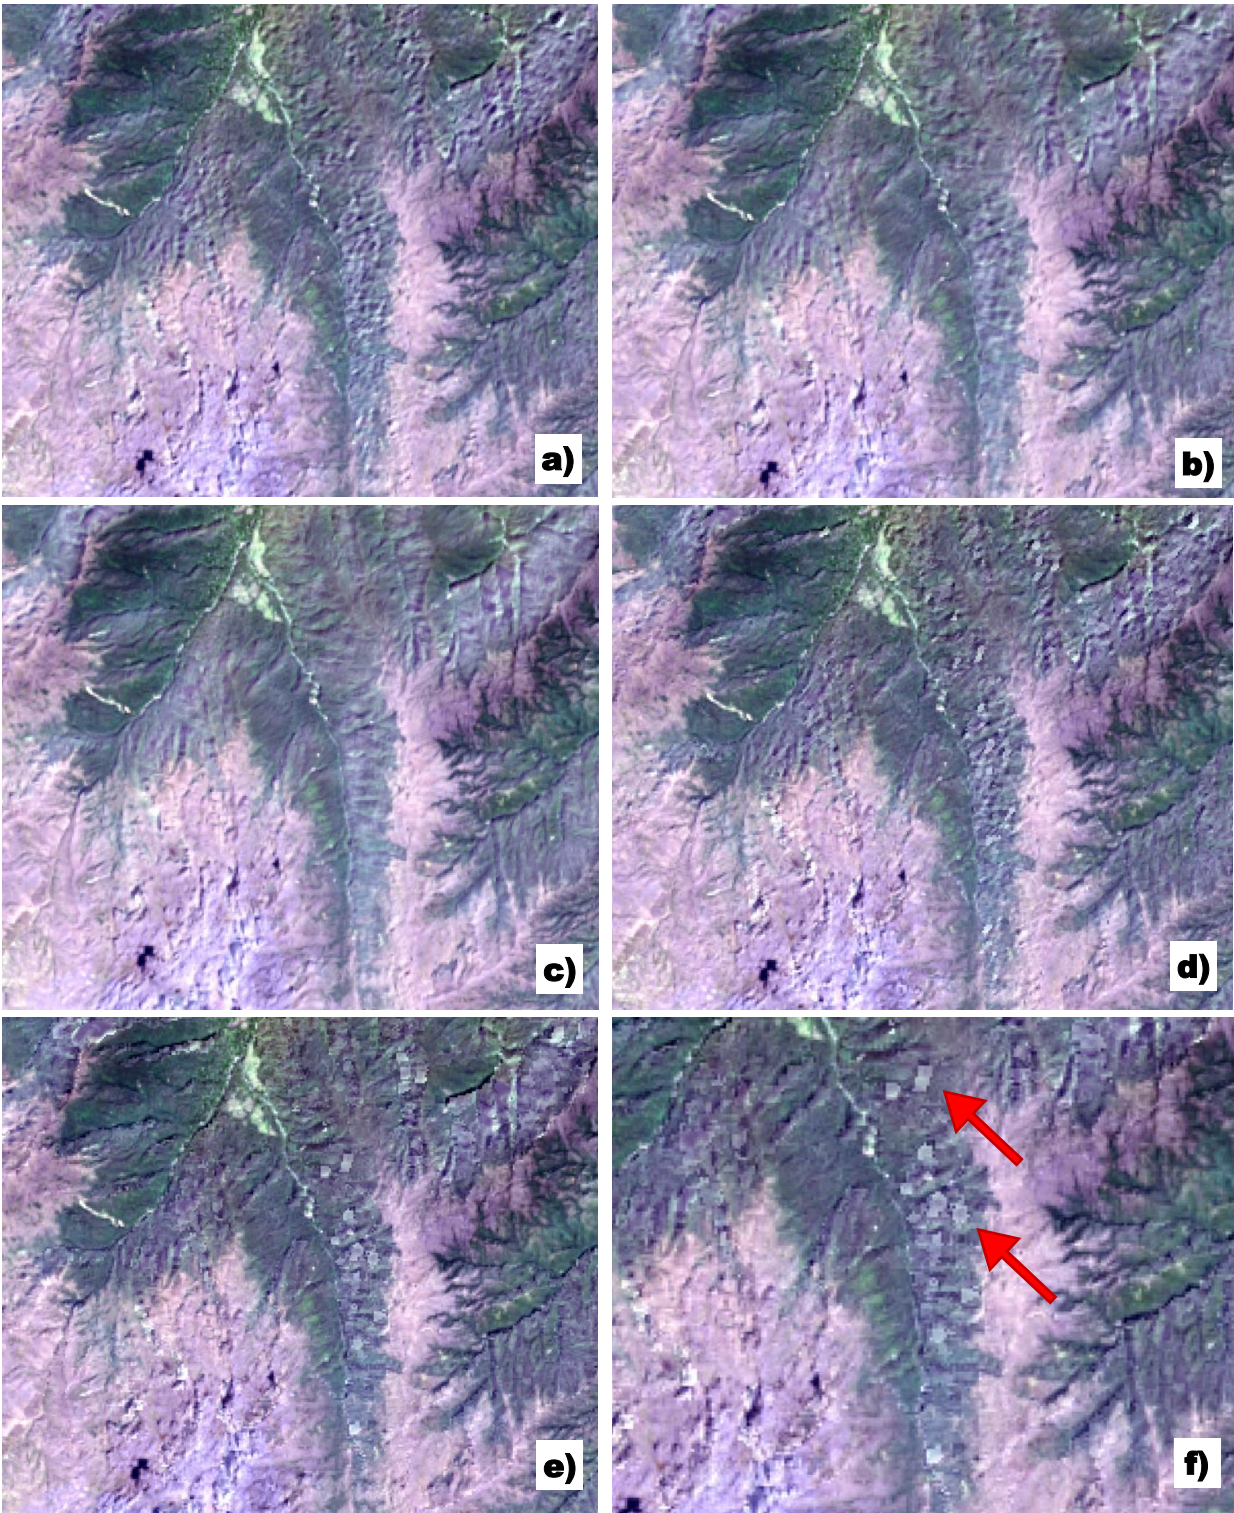


Figura 49. Corrección C con aplicación de filtros de paso bajo al mapa de iluminación obtenido a partir del MDE de SRTM.

Fuente: elaboración propia.

Nota: a) Imagen normalizada sin filtro; b) Filtro promedio de 3x3; c) Filtro promedio de 5x5; d) Filtro modal de 3x3; e) Filtro modal de 5x5; f) Detalle de artefactos producidos por el filtro modal de 5x5.

En la Tabla 19 se comparan el valor promedio de los coeficientes de correlación entre las bandas originales, con los valores de reflectancia de superficie, los valores de reflectancia normalizada topográficamente, y la iluminación calculada a partir de los insumos ensayados en este estudio (GDEM ASTER, SRTM y curvas de nivel del IGAC). Así mismo, se compara el coeficiente de correlación de la banda SWIR1, que es el que presenta el mayor valor para las imágenes no normalizadas y para todos los insumos utilizados para el cálculo de la iluminación. Como se observa de las estadísticas, los mejores resultados en términos de correlaciones promedio para la iluminación, se obtienen con la corrección C calculado a partir del DEM de SRTM. La menor correlación para la banda SWIR1 se observa para la iluminación calculada a partir de las curvas de nivel del IGAC.

Por otra parte, la aplicación del método del coseno mejorado, presenta un incremento de los valores de correlación entre la iluminación y la reflectancia de superficie de las bandas en comparación con los valores de la imagen original, lo cual confirma la presencia del efecto de sobrecorrección ya descrito en el análisis visual de resultados.

Finalmente, la aplicación de los filtros de paso bajo tipo promedio al mapa de iluminación utilizado para la corrección del relieve, muestra una mayor disminución del coeficiente de correlación, obteniendo los mejores resultados con la aplicación de una ventana de 3x3 (Tabla 20).

De acuerdo a lo anterior, los mejores resultados en términos de corrección del efecto del relieve, se obtuvieron con la corrección C y el uso de un filtro de paso bajo tipo promedio con ventana de 3x3 sobre el mapa de iluminación.

Tabla 19. Comparación de valores del coeficiente de correlación para diferentes tipos de correcciones e insumos utilizados para el cálculo de $\cos \gamma_i$.

Fuente: elaboración propia.

<i>Insumo para el cálculo de $\cos \gamma_i$</i>	<i>Valor empleado para la comparación</i>	<i>Valor del coeficiente de correlación</i>		
		<i>Imagen original (BOA)</i>	<i>Corrección C</i>	<i>Corrección del coseno mejorado</i>
DEM	Valor promedio para todas las bandas	0.2138	0.0036	0.5229
SRTM NASA	Valor para la banda 6 SWIR1	0.3371	0.0064	0.5969
GDEM ASTER	Valor promedio para todas las bandas	0.2005	0.0048	0.5171
	Valor para la banda 6 SWIR1	0.3162	0.0084	0.5900
DEM	Valor promedio para todas las bandas	0.2176	0.0364	0.5207
ALOS PALSAR	Valor para la banda 6 SWIR1	0.3415	0.0138	0.5967
MDT curvas de nivel	Valor promedio para todas las bandas	0.3159	0.0045	0.8707
IGAC 1:25.000	Valor para la banda 6 SWIR1	0.5693	0.0047	0.8506

Tabla 20. Comparación de valores del coeficiente de correlación para diferentes tipos de filtros de paso bajo aplicados al cálculo de $\cos \gamma_i$.

Fuente: elaboración propia.

<i>Insumo utilizado para $\cos \gamma_i$</i>	<i>Valor empleado para la comparación</i>	<i>Valor promedio del coeficiente de correlación</i>
$\cos \gamma_i$	Valor promedio para todas las bandas	0.0036
	Valor para la banda 6 SWIR1	0.0064
Filtro promedio Ventana 3x3	Valor promedio para todas las bandas	0.0020
	Valor para la banda 6 SWIR1	0.0033
Filtro promedio Ventana 5x5	Valor promedio para todas las bandas	0.0025
	Valor para la banda 6 SWIR1	0.0037
Filtro modal Ventana 3x3	Valor promedio para todas las bandas	0.0065
	Valor para la banda 6 SWIR1	0.0134
Filtro modal Ventana 5x5	Valor promedio para todas las bandas	0.0054
	Valor para la banda 6 SWIR1	0.0104

Nota: los filtros se aplicaron a la iluminación calculada a partir del DEM de SRTM.

4.2. Objetivo 2

En relación con el objetivo específico 2 “*Analizar el desempeño de diferentes métodos de extracción de endmembers en imágenes satelitales multiespectrales de la misión Landsat-8 en zonas de alta montaña*”, a continuación son relacionados los resultados obtenidos.

La aplicación del análisis lineal de mezclas espectrales mediante el algoritmo LSU con los *endmembers* extraídos mediante MNF y PPI, arrojó un error cuadrático promedio de 0.242, el cual es sensiblemente más alto en comparación con los valores obtenidos en otros estudios que han aplicado este enfoque en imágenes multiespectrales de la misión Landsat (Liping et al., 2019; Wu & Murray, 2003), que obtuvieron valores de RMSE promedio entre 0.0057 y 0.05, siendo 0.02 el valor de referencia apropiado sugerido por (Wu & Murray, 2003). De acuerdo a lo anterior, los resultados obtenidos con la aplicación del método MNF y PPI, indican que la selección del modelo o la selección de los *endmembers* no es apropiada para el área de estudio y los insumos empleados.

Por otra parte, con la aplicación del algoritmo LSU con los *endmembers* extraídos mediante SMACC, se obtuvo un RMSE de 0.00000039. Este valor no solamente es menor que el RMSE obtenido con el método anterior (MNF y PPI), sino que es inferior a los resultados reportados por Liping (2019) y Wu (2003). No obstante, para ambos métodos, según las estadísticas obtenidas de las imágenes y reportadas en la Tabla 22 se observan un importante número de píxeles con valores por debajo y por encima del rango para todas las fracciones o bandas de abundancia, que idealmente deberían estar entre 0 y 1 (Harris Geospatial Solutions, 2020b). De acuerdo al manual del algoritmo LSU, esto podría indicar que uno o más *endmembers* seleccionados para el análisis no están bien caracterizados, o que se requieren *endmembers* adicionales (Harris Geospatial Solutions, 2020b), aunque estudios que han empleado el análisis lineal de mezclas espectrales (Deng et al., 2019; Hostert et al., 2003; Liping et al., 2019; Salih et al., 2017; Wu & Murray, 2003) se basan únicamente en el RMSE para evaluar los resultados obtenidos con el uso de los algoritmos de extracción de *endmembers*.

Para el caso del método MNF+PPI, las áreas que presentaron un mayor RMSE se ubican en las zonas con escasa cobertura de vegetación herbácea, que se extienden en las zonas internas a lo largo de toda el área de estudio (ver Figura 50a).

En el caso del método SMACC, no fue posible apreciar patrones espaciales en la distribución de los valores más elevados de RMSE, que de igual manera se mantienen muy bajos para toda el área de estudio (ver Figura 50b).

Tabla 21. Estadísticas por imagen de abundancia y RMSE obtenidos con *endmembers* extraídos.

Fuente: elaboración propia.

<i>Método MNF+PPI</i>				
<i>Banda</i>	<i>Mínimo</i>	<i>Máximo</i>	<i>Promedio</i>	<i>Desviación estándar</i>
EM1	-19.454	2.605	0.035	0.235
EM2	-0.229	3.574	0.027	0.086
EM3	-1.822	0.94	0.029	0.086
RMSE	-	19.254	0.242	0.4
<i>Método SMACC</i>				
<i>Banda</i>	<i>Mínimo</i>	<i>Máximo</i>	<i>Promedio</i>	<i>Desviación estándar</i>
EM1	(0.260)	1.061	0.013	0.027
EM2	(0.429)	0.489	(0.067)	0.102
EM3	(0.460)	0.671	(0.091)	0.124
EM4	(1.700)	1.443	0.367	0.463
EM5	(1.192)	3.531	0.104	0.162
EM6	(0.614)	0.878	(0.145)	0.192
EM7	(0.463)	1.243	0.265	0.334
EM8	(0.816)	0.911	(0.093)	0.124
EM9	(2.916)	1.626	0.046	0.100
RMSE	-	0.00000790	0.00000039	0.00000057

Nota: RMSE: error cuadrático medio.

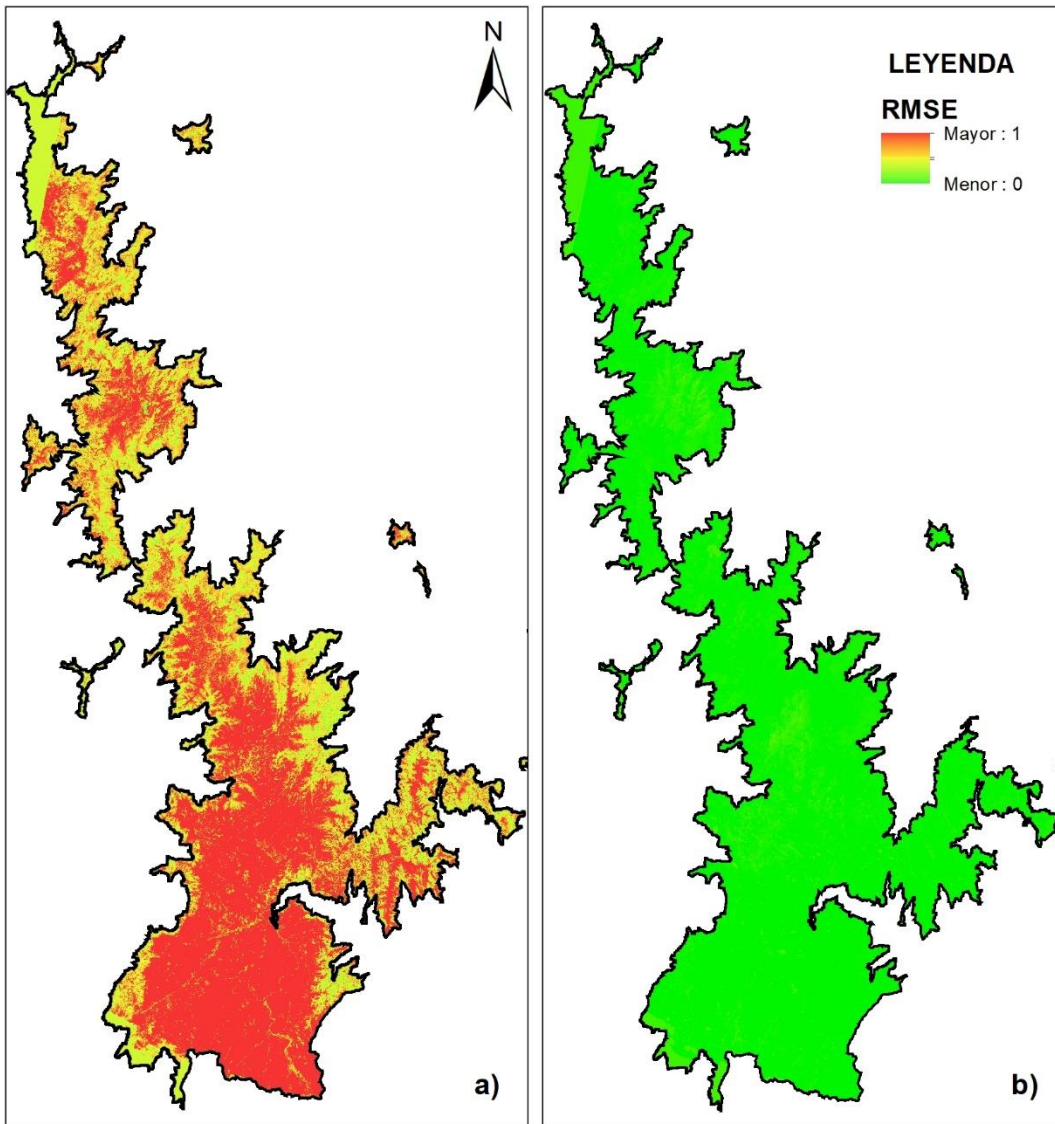


Figura 50. RMSE obtenido con el análisis lineal de mezclas espectrales.

Fuente: elaboración propia.

Nota: a) Método MNF+PPI b) Método SMACC.

Tabla 22. Número y porcentaje de píxeles con valores inferiores a 0 o mayores a 1.

Fuente: elaboración propia.

<i>Método MNF+PPI</i>						
<i>Valor píxel</i>	<i>Agua</i>		<i>Suelo</i>		<i>Vegetación</i>	
	<i>EM1</i>		<i>EM2</i>		<i>EM3</i>	
	<i>No. píxeles</i>	<i>% píxeles</i>	<i>No. píxeles</i>	<i>% píxeles</i>	<i>No. píxeles</i>	<i>% píxeles</i>
<0	6397830	67.35	8227748	86.62	8103360	85.31
De 0 a 1	3068803	32.31	1271296	13.38	1395815	14.69
>1	32542	0.34	131	0	0	-
<0 y >1	6430372	67.69	8227879	86.62	8103360	85.31
<i>Método SMACC</i>						
<i>Valor píxel</i>	<i>Tierras desnudas y degradadas</i>		<i>Suelos artificializados</i>		<i>Vegetación secundaria</i>	
	<i>EM1</i>		<i>EM2</i>		<i>EM3</i>	
	<i>No. píxeles</i>	<i>% píxeles</i>	<i>No. píxeles</i>	<i>% píxeles</i>	<i>No. píxeles</i>	<i>% píxeles</i>
<0	6797932	71.56	9465568	99.65	0	-
De 0 a 1	2701242	28.44	33607	0.35	1.0527E-05	0.00
>1	1	0.00	0	-	514.916082	100.00
<0 y >1	6797933	71.56	9465568	99.65	514.916082	100.00
<i>Valor píxel</i>	<i>Bosques-cultivos</i>		<i>Agua</i>		<i>Pastos</i>	
	<i>EM4</i>		<i>EM5</i>		<i>EM6</i>	
	<i>No. píxeles</i>	<i>% píxeles</i>	<i>No. píxeles</i>	<i>% píxeles</i>	<i>No. píxeles</i>	<i>% píxeles</i>
<0	5716089	60.17	6017539	63.35	9489891	99.90
De 0 a 1	1597905	16.82	3481590	36.65	9283	0.10
>1	2185180	23.00	45	0.00	0	-
<0 y >1	7901269	83.18	6017584	63.35	9489891	99.90
<i>Valor píxel</i>	<i>Tierras desnudas y degradadas</i>		<i>Cuerpos de agua con sedimento y suelos húmedos</i>		<i>Afloramientos rocosos</i>	
	<i>EM7</i>		<i>EM8</i>		<i>EM9</i>	
	<i>No. píxeles</i>	<i>% píxeles</i>	<i>No. píxeles</i>	<i>% píxeles</i>	<i>No. píxeles</i>	<i>% píxeles</i>
<0	5716039	60.17	9435485	99.33	5781760	60.87
De 0 a 1	3783120	39.83	63689	0.67	3717052	39.13
>1	15	0.00	0	-	362	0.00
<0 y >1	5716054	60.17	9435485	99.33	5782122	60.87

Nota: EM: endmember.

Como resultado de la aplicación del método MNF+PPI, propuesto por Li (Li et al., 2007) se obtuvieron 3 endmembers, correspondientes a las coberturas de suelo, agua y vegetación, cuyas firmas espectrales y ubicación se muestran en las figuras 51 y 52 respectivamente. Por otra parte, mediante el método SMACC, se obtuvieron 9 endmembers, asignados de manera preliminar a 7 clases diferentes de cobertura, mediante el análisis de las firmas espectrales y la consulta de imágenes de mayor resolución. Las firmas espectrales y la ubicación de estos, se muestran en las figuras 51, 53 y 54. Para mayor detalle, sobre la asignación de clases a los endmembers obtenidos y su ubicación, remitirse al Apéndice 3.

Es importante destacar que aunque la obtención de un número más elevado de endmembers puede considerarse una ventaja, también constituye un desafío a la hora interpretar la cobertura correspondiente, en especial cuando existan más firmas espectrales afines a una misma tipología de elemento o material, como es el caso de los EM6 y EM8, en la Figura 51b, ambos con un comportamiento espectral asimilable a cuerpos de agua con presencia de sedimento, o cuando se presentan firmas espectrales anómalas como EM1 y EM6, en la Figura 51b, con un alto grado de saturación para una o más bandas espectrales, casos en los cuales ameritaría una verificación en campo.

Adicionalmente, para el caso del algoritmo SMACC, se encontraron algunas incongruencias entre el tipo de cobertura registrada en la ubicación del *endmember*, sus características espectrales y la imagen de abundancia correspondiente, que dificultan el proceso de asignación de clases a cada fracción. A modo de ejemplo, en la Figura 55, se muestra el caso del *endmember* 6, que si bien por su firma espectral y ubicación parece corresponder a una cobertura de vegetación vigorosa, en la imagen de abundancia los mayores valores se encuentran asociados a zonas de pastos.

Teniendo en cuenta los análisis realizados, la ventajas y desventajas evidenciadas en cada método, así como la complejidad de implementación de los métodos ensayados, los mejores resultados se obtuvieron con el uso del algoritmo SMACC, que permite obtener el menor RMSE, el mayor número de clases de coberturas, y resultó ser también el método más simple y menos dispendioso en términos de tiempo requerido para su implementación.

Por otra parte, tanto el RMSE como las estadísticas de los valores de abundancia obtenidos con el método combinado MNF-PPI, indican que este método no presenta un buen desempeño en

el área de estudio. Lo anterior, que está en contradicción con los altos valores de fiabilidad global de la clasificación de coberturas obtenida en áreas urbanas por Li (2007), podría explicarse con el hecho que el área de estudio presenta una variedad de cobertura y de respuestas espectrales muy superior a la que puede encontrarse en zonas urbanas, por ende, se requiere un número mayor de *endmembers* para obtener buenos resultados.

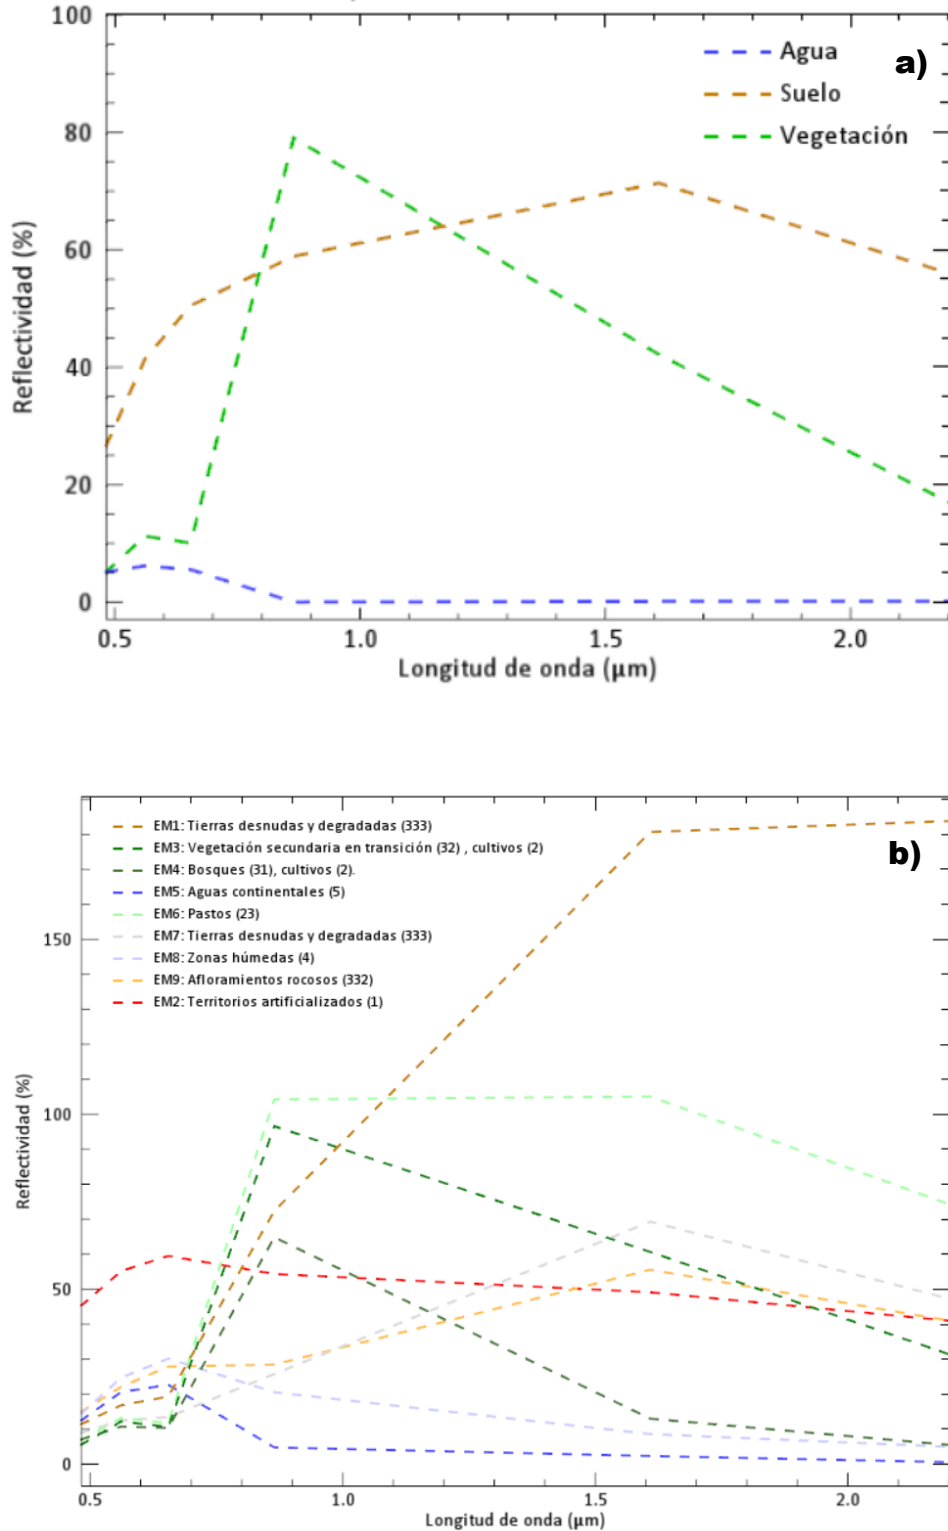


Figura 51. Firma espectral de *endmembers* obtenidos.

Fuente: elaboración propia.

Nota: a) Método MNF+PPI; b) Método SMACC.



Figura 52. Ubicación de los *endmembers* seleccionados con el método MNF+PPI sobre imágenes recientes de alta resolución disponible en Google Earth.

Fuente: elaboración propia.

Notas a) EM1: Agua; b) EM2: Vegetación; c) EM3: Suelos desnudos y/o artificializados.

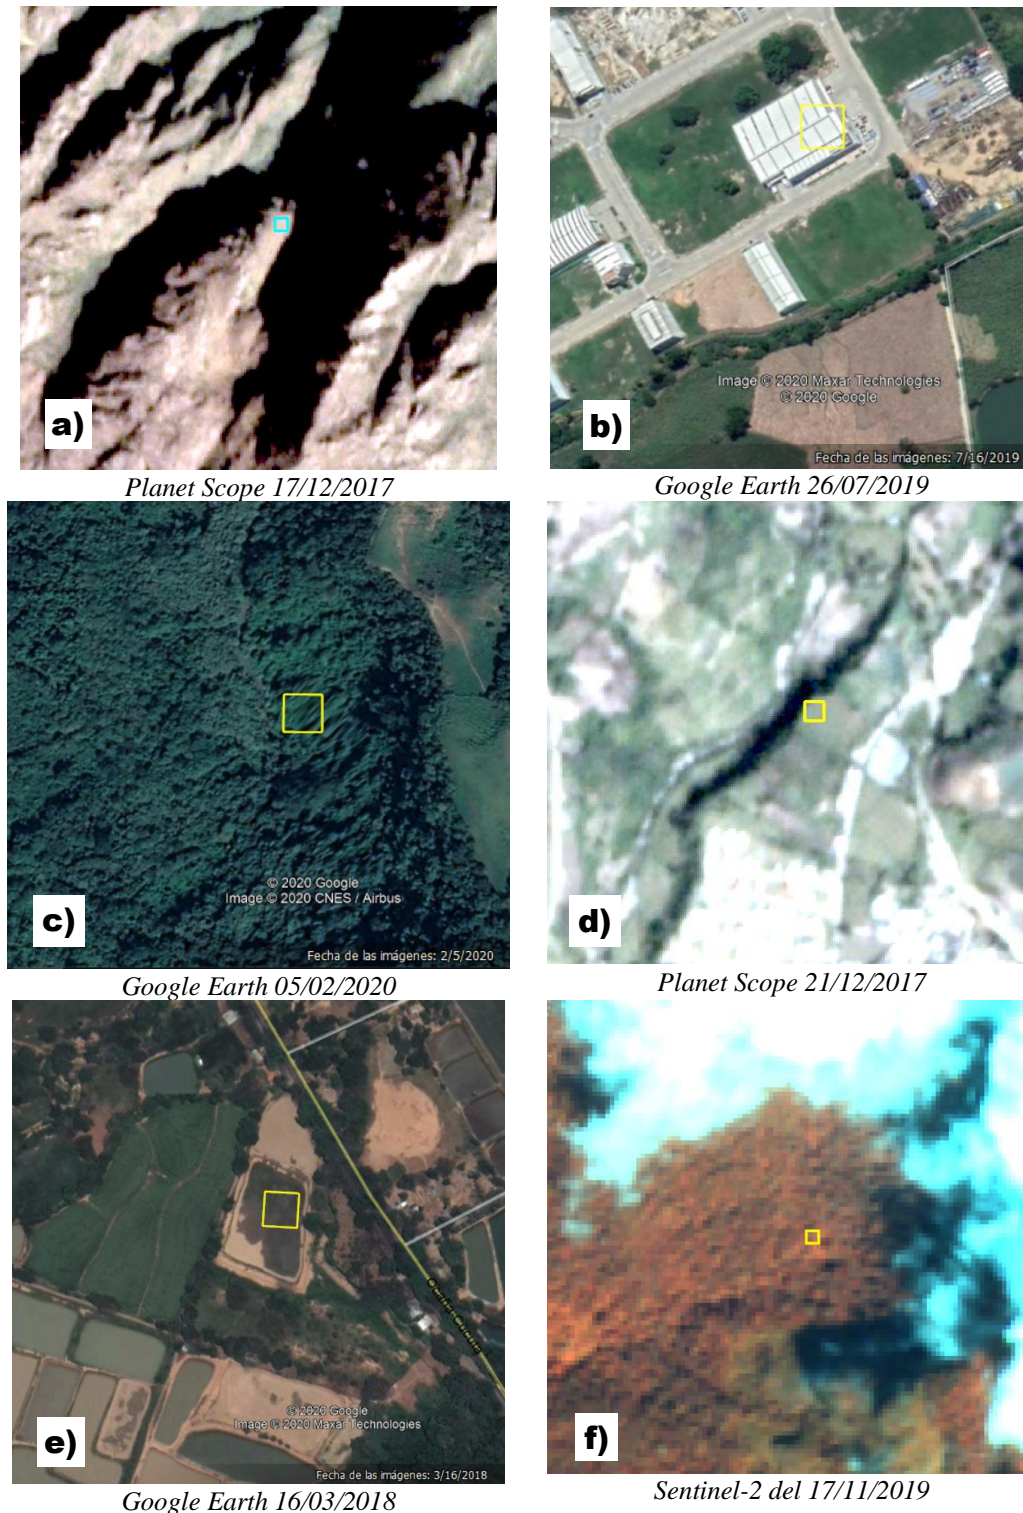


Figura 53. Ubicación de los *endmembers* seleccionados con el método SMAAC sobre imágenes recientes de resolución mayor a 15m.

Fuente: elaboración propia.

Nota: a) EM1: tierras desnudas y degradadas; b) EM2: territorios artificializados; c) EM3: Vegetación secundaria; d) EM4: cultivos y bosques; e) EM5: cuerpos de agua; f) EM6: pastos.




Figura 54. Ubicación de los *endmembers* seleccionados con el método SMAAC sobre imágenes recientes de resolución mayor a 15m (continua).

Fuente: elaboración propia.

Nota: a) EM7: tierras desnudas y degradadas; b) EM8: cuerpos de agua con sedimento y suelos húmedos; c) EM9: Afloramientos rocosos.

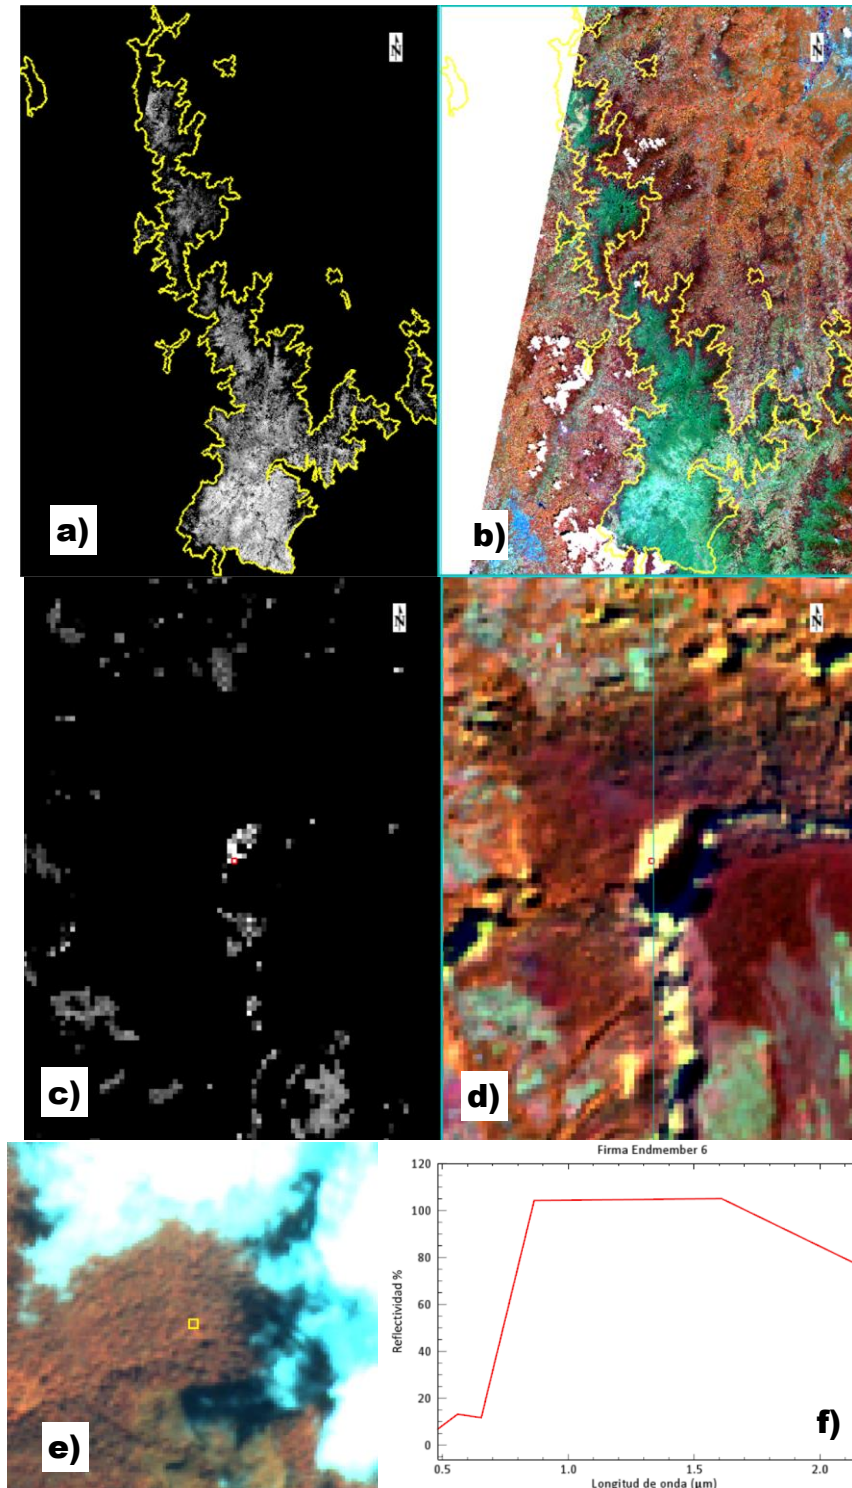


Figura 55. Incongruencias encontradas en los *endmembers* extraídos.

Fuente: elaboración propia.

Nota: a) Imagen de fracción de abundancia; b) Imagen Landsat-8 de referencia en composición falso color (5-6-3); c) Ubicación del EM sobre imagen de abundancia; d) Ubicación del EM sobre imagen Landsat-8 de referencia en composición falso color (5-6-3); e) Ubicación del EM sobre imagen reciente de alta resolución. f) Firma espectral del EM.

4.3. Objetivo 3

A continuación, son presentados los resultados obtenidos durante el desarrollo del objetivo 3 “*Evaluar la capacidad del análisis lineal de mezclas espectrales y de la clasificación basada en objetos para obtener una delimitación preliminar de las clases de cobertura existentes en el páramo jurisdicción Santurbán-Berlín*”.

Los mapas obtenidos como resultado del presente estudio permiten estimar de manera preliminar el área que ocupan las diferentes coberturas vegetales y apreciar sus patrones de distribución en el Complejo de Páramo Jurisdicción Santurbán-Berlín. Sin embargo, como se describe de manera detallada más adelante, las comparaciones realizadas mediante métodos estadísticos y de interpretación visual, muestran que los mejores resultados se obtienen mediante el enfoque basado en LSMA y OBIA.

Como se observa en la Tabla 23, las clasificaciones obtenidas con ambos métodos (ISODATA+OBIA y LSMA+OBIA), evidencian que en el complejo de páramo prevalece la cobertura de tierras desnudas y degradadas. De acuerdo con la metodología de clasificación aplicada, estas áreas corresponden principalmente a zonas de pastizales pobres con una alta influencia del componente de suelo descubierto, que representa más del 50% del píxel.

Las mayores diferencias entre los dos métodos ensayados en términos del área asociada a cada cobertura se observan para los pastos y las tierras desnudas y degradadas, que presentan un desfase del 19% y del 9% aproximadamente.

Con ninguno de los métodos ensayados, fue posible delimitar zonas húmedas, unidad dentro de las cuales se incluyen las turberas, formaciones vegetales comunes en las zonas de páramo.

Para el caso de ISODATA, ninguna de las clases obtenidas mediante el algoritmo pudo asociarse a áreas con altos niveles de humedad del suelo, excepto por los cuerpos de agua que se categorizan en la unidad de aguas continentales.

Por otra parte, en el caso de método basado en LSMA, aunque se haya encontrado correspondencia con la cobertura de suelos húmedos para uno de los *endmembers* extraídos, los

valores de abundancia asociados presentaron un valor máximo del 28% de abundancia relativa para los segmentos, lo que determinó que ningún polígono calificara para ser clasificado como una zona húmeda.

Tabla 23. Área por clase de cobertura obtenida con los métodos de clasificación aplicados.

Fuente: elaboración propia.

<i>Código</i>	<i>Clase de cobertura Descripción</i>	<i>ISODATA</i>		<i>SMACC</i>	
		<i>Ha</i>	<i>%</i>	<i>Ha</i>	<i>%</i>
11	Zonas urbanizadas	3,680.51	2.62	2,479.99	1.77
12	Redes de comunicación	560.51	0.40	455.50	0.32
14	Zonas verdes artificializadas, no agrícolas	603.47	0.43	652.52	0.46
23	Pastos	37,222.30	26.51	9,826.76	7.00
24	Zonas agrícolas heterogéneas	20,195.99	14.38	25,666.35	18.28
31	Bosques	28,241.01	20.11	34,674.52	24.69
32	Áreas con vegetación herbácea y/o arbustiva	8,362.57	5.96	11,443.92	8.15
332	Afloramientos rocosos		-	638.77	0.45
333	Tierras desnudas y degradadas	41,526.25	29.57	54,505.02	38.81
51	Aguas continentales	35.47	0.03	84.75	0.06
Total		140,428.09	99.97	140,428.09	100.00

Observando los mapas preliminares obtenidos (Figura 56), se puede apreciar que la mayoría de coberturas boscosas y vegetación secundaria, se ubican en los límites del Complejo de Páramo, mientras que, por lo general, las zonas más internas, presentan grandes extensiones de tierras desnudas y degradadas, alternadas principalmente con zonas de pastizales y áreas agrícolas heterogéneas. Finalmente, en la porción sur occidental del área de estudio, es posible apreciar la presencia los territorios artificializados correspondientes al centro poblado de Berlín.

A continuación, se discuten algunos aspectos de exactitud temática de los mapas preliminares obtenidos, estimada a través de medidas estadísticas que incluyen el cálculo de la fiabilidad global, la fiabilidad global normalizada y del parámetro kappa, para diferentes niveles jerárquicos de las clasificaciones obtenidas. Adicionalmente se evalúan, mediante comparación visual, las principales diferencias y características relevantes de las clasificaciones obtenidas.

La clasificación con el método combinado ISODATA y OBIA, permitió obtener 9 clases de cobertura, con una fiabilidad global del 65% (Figura 57), muy inferior a la conformidad temática exigida por la metodología CORINE Land Cover adaptada para Colombia (IDEAM, 2010; IDEAM et al., 2008), y valor kappa de 0.56, que indica una correspondencia moderada (Congalton & Green, 2009; Landis & Koch, 1977).

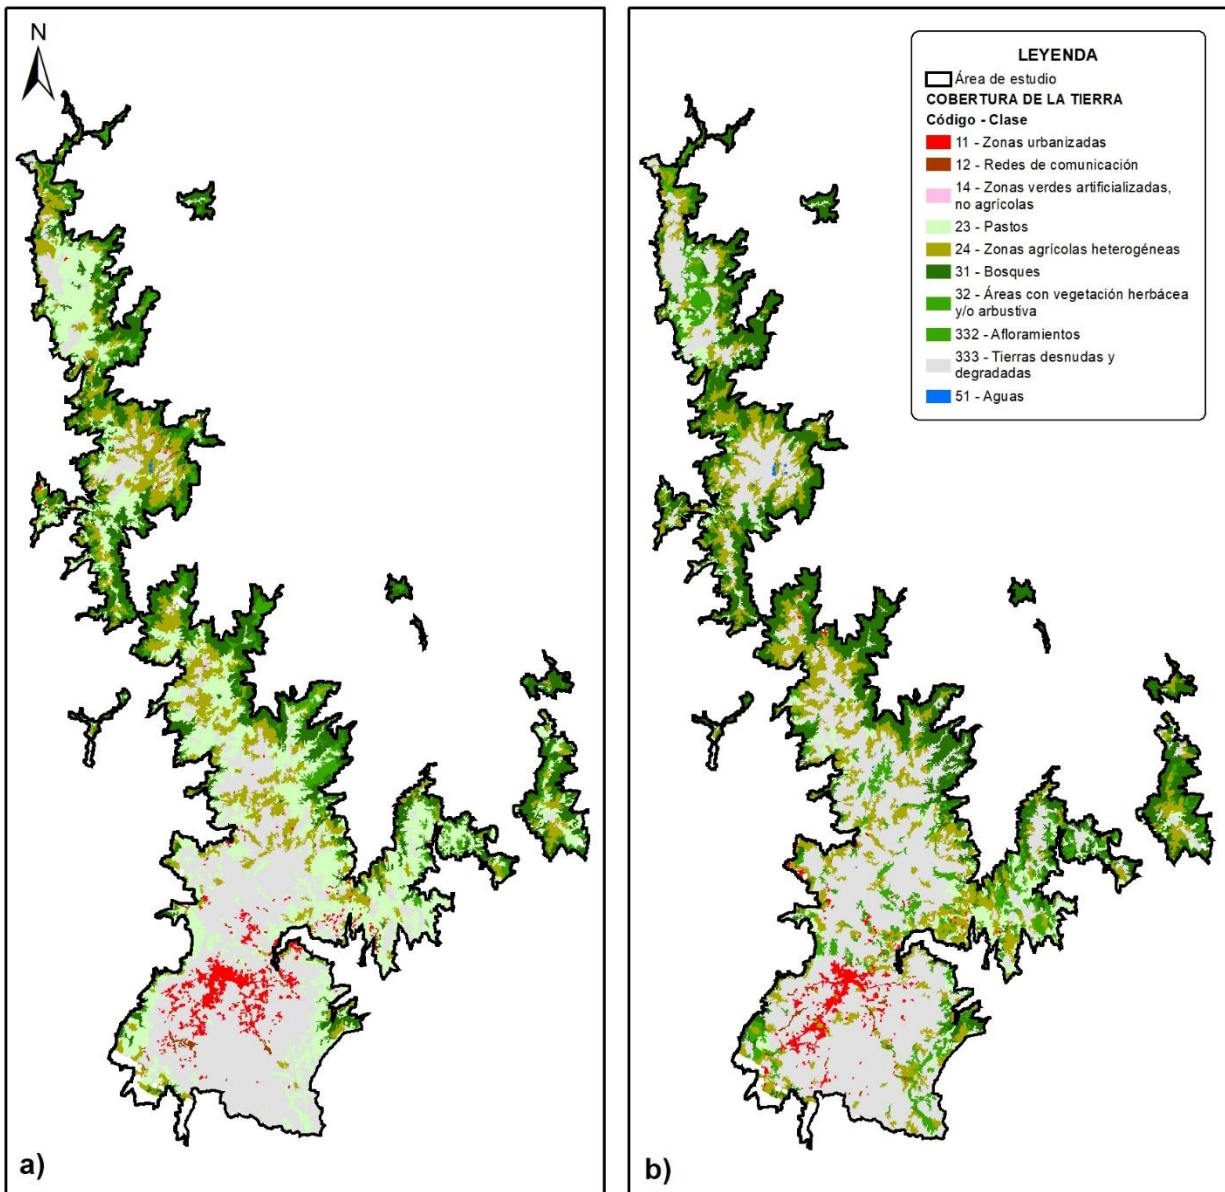


Figura 56. Comparación de los mapas preliminares de cobertura de la tierra obtenidos.

Fuente: elaboración propia.

Por otra parte, la clasificación con desmezclado espectral y OBIA, permitió obtener 10 clases de cobertura, la cual es mejor respecto a la obtenida con el método combinado ISODATA y OBIA, con una fiabilidad global del 84%, y un valor kappa de 0.79 (ver Figura 58), que indica una correspondencia sustancial (Landis & Koch, 1977). El cálculo de la fiabilidad global normalizada (MARGFIT), que permite comparar de manera más adecuada clasificaciones con diferentes tamaños de muestra o número de clases (Congalton & Green, 2009) permitió obtener una fiabilidad global del 68% para el método ISODATA y del 86% para el LSMA.

Observando la fiabilidad del productor obtenida para las diferentes clases con ambos métodos (ver figuras 57 y 58), se evidencia que los menores valores se presentan para las clases de pastos (23), áreas agrícolas heterogéneas (24), y vegetación secundaria (32).

En términos generales, para SMAAC se observan los mayores errores de clasificación entre las clases 23 y 24, y entre 32, 31, 24 y 23. Por otro lado para ISODATA, lo anterior se observa entre las clases entre 23 y 24, 31 y 32, y entre 333, 23, 24.

Los errores entre subcategorías de áreas naturales y seminaturales (unidad 3) podrían atribuirse a una confusión espectral entre coberturas de bosques y vegetación secundaria, cuya distinción tanto en términos espectrales como de interpretación visual puede resultar compleja, sobre todo en presencia de áreas heterogéneas y vegetación con diferentes grados de desarrollo e intervención.

Lo mismo puede aplicarse para errores de clasificación que involucren territorios agrícolas y vegetación secundaria, sobre todo si se tiene en cuenta la afinidad espectral y pictomorfológica que puede existir entre coberturas de pastos enmalezados y vegetación secundaria baja.

Código Clase	51	11	12	14	23	24	31	32	333	Total	F. usuario	Kappa
51	10	-	-	-	-	-	-	-	-	10	1.00	-
11	-	7	1	-	1	1	-	-	1	11	0.64	-
12	-	-	10	-	-	-	-	-	-	10	1.00	-
14	-	-	-	2	5	-	-	3	-	10	0.20	-
23	-	-	-	-	49	40	2	7	20	118	0.42	-
24	-	-	-	-	2	44	3	1	14	64	0.69	-
31	-	-	-	-	-	8	80	10	1	99	0.81	-
32	-	-	-	-	-	2	15	12	-	29	0.41	-
333	-	-	-	-	24	6	1	1	94	126	0.75	-
Total	10	7	11	2	81	101	101	34	130	477	-	-
F.productor	1.00	1.00	0.91	1.00	0.60	0.44	0.79	0.35	0.72	-	0.65	-
Kappa	-	-	-	-	-	-	-	-	-	-	-	0.56

Figura 57. Matriz de confusión obtenida con el método ISODATA y extracción de objetos.

Fuente: elaboración propia.

Código Clase	51	11	12	14	23	24	31	32	332	333	Total	F. usuario	Kappa
51	10	0	0	0	0	0	0	0	0	0	10	1.00	0
11	0	4	0	0	0	0	1	0	0	5	10	0.40	0
12	0	0	8	0	0	1	0	0	0	1	10	0.80	0
14	0	0	0	5	2	0	1	1	0	1	10	0.50	0
23	0	0	0	0	19	12	1	3	0	2	37	0.51	0
24	0	0	0	1	1	68	0	3	0	17	90	0.76	0
31	0	0	0	0	0	4	128	4	0	0	136	0.94	0
32	0	0	0	0	6	9	3	23	0	0	41	0.56	0
332	0	0	0	0	0	0	0	0	10	0	10	1.00	0
333	0	0	0	0	1	7	1	0	0	173	182	0.95	0
Total	10	4	8	6	29	101	135	34	10	199	536	0	0
F.productor	1.00	1.00	1.00	0.83	0.66	0.67	0.95	0.68	1.00	0.87	0.00	0.84	0.00
Kappa	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.79

Figura 58. Matriz de confusión obtenida con el método SMACC y extracción de objetos.

Fuente: elaboración propia.

Finalmente, si se considera un nivel menor de jerarquía y se calcula la fiabilidad global para las clases 1, 2, 3 y 5, se obtiene una fiabilidad global de 0.79 y 0.88, para ISODATA y SMAAC respectivamente (ver figuras 59 y 60).

Código Clase	1	2	3	5	Total	F. usuario	Kappa
1	20	7	4	0	31	0.65	0.00
2	0	135	47	0	182	0.74	0.00
3	0	40	214	0	254	0.84	0.00
5	0	0	0	10	10	1.00	0.00
Total	20	182	265	10	477	0.00	0.00
F.productor	1.00	0.74	0.81	1.00	0.00	0.79	0.00
Kappa	0.00	0.00	0.00	0.00	0.00	0.00	0.63

Figura 59. Matriz de confusión obtenida con el método ISODATA y extracción de objetos. Clasificación simplificada.

Fuente: elaboración propia.

Código Clase	1	2	3	5	Total	F. usuario	Kappa
1	17	3	10	0	30	0.57	0.00
2	1	100	26	0	127	0.79	0.00
3	0	27	342	0	369	0.93	0.00
5	0	0	0	10	10	1.00	0.00
Total	18	130	378	10	536	0.00	0.00
F.productor	0.94	0.77	0.90	1.00	0.00	0.88	0.00
Kappa	0.00	0.00	0.00	0.00	0.00	0.00	0.73

Figura 60. Matriz de confusión obtenida con el método SMACC y extracción de objetos. Clasificación simplificada.

Fuente: elaboración propia.

Como parte de la evaluación de las clasificaciones obtenidas, se evidenciaron diferencias principalmente en términos de capacidad por detallar elementos de menores dimensiones, como cuerpos de agua y territorios artificializados. Como se observa en la Figura 61, varios cuerpos de agua que cumplen con la UMC de 2.5 Ha, no quedaron delimitados en la clasificación realizada a partir de ISODATA, mientras que el método basado en LSMA permitió incluirlos en su totalidad. En la misma figura, se observa también como varias zonas de suelos desnudos con alto albedo, son erróneamente clasificadas como territorios artificializados en la clasificación ISODATA.

Finalmente, se evidencia una diferencia importante en la clasificación de zonas de pastos y áreas agrícolas heterogéneas. Estas diferencias se deben probablemente a que, mientras la clasificación mediante ISODATA asigna de manera estricta una sola clase a cada pixel, y la asignación de una clase a cada polígono se basa principalmente su contribución relativa en términos de área, para el caso del LSMA, se tiene en cuenta la composición de abundancias de

cobertura a nivel de subpixel, lo cual evita la pérdida de información en términos de heterogeneidad de coberturas y puede, por lo tanto, producir resultados muy distintos.

Otra área en donde se presentan diferencias importantes entre las dos clasificaciones es la zona del centro poblado de Berlín, donde se observa una sobreestimación de las zonas urbanizadas, más evidente para el caso del método basado en ISODATA. Este efecto se debe probablemente a que la respuesta espectral de las zonas urbanas es muy afín a la de suelos desnudos, con los cuales tienden a confundirse.

Las capas oficiales más recientes de cobertura de la tierra disponibles para el área de estudio, elaboradas de acuerdo a la Leyenda Nacional CORINE Land Cover adaptada para Colombia, datan del año 2012, mientras que los insumos empleados para el análisis fueron adquiridos entre finales del año 2018 y principios de 2020. De acuerdo a lo anterior no es posible comparar los resultados en términos de áreas o distribución de las coberturas delimitadas.

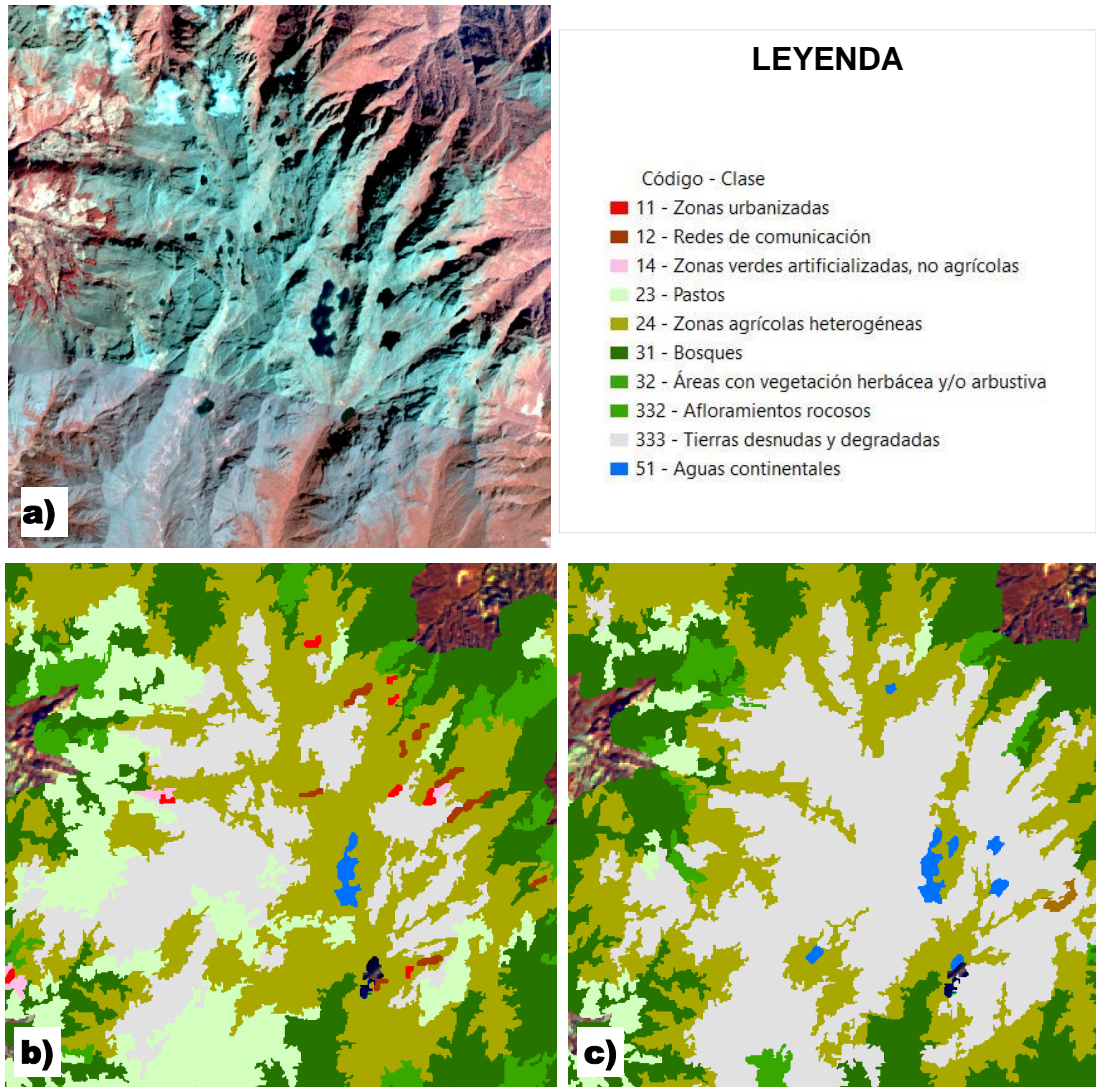


Figura 61. Comparación visual de las clasificaciones obtenidas para una zona de cuerpos de agua.

Fuente: elaboración propia.

Nota: a) Imágenes de la misión Planet Scope; b) Resultados de clasificación con ISODATA y OBIA; c) Resultado de segmentación con LSMA y OBIA.

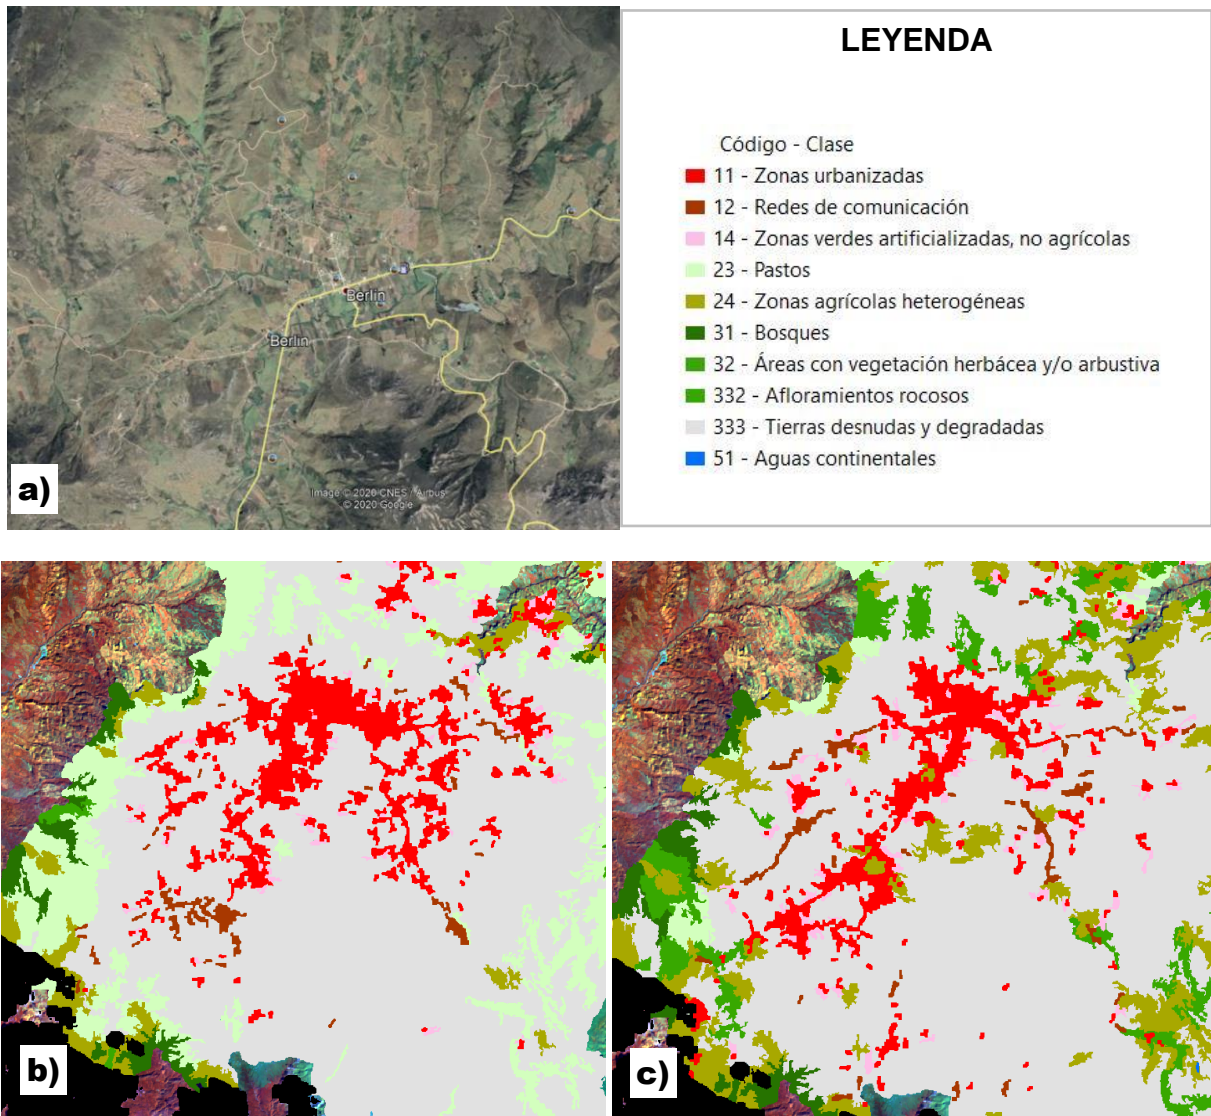


Figura 62. Comparación visual de las clasificaciones obtenidas para una zona urbana discontinua.

Fuente: elaboración propia.

Nota: a) Imágenes de la misión Planet Scope; b) Resultados de clasificación con ISODATA y OBIA; c) Resultado de segmentación con LSMA y OBIA.

No obstante, si se compara la delimitación de los polígonos del mapa de coberturas del año 2012 producido mediante interpretación visual, con los obtenidos mediante los algoritmos de ISODATA y con el LSMA combinado con extracción de objetos, es posible observar, un alto nivel de correspondencia en toda el área de estudio, como se muestra en la Figura 63.

Adicionalmente, es importante destacar que, aunque los insumos utilizados en la elaboración del mapa de coberturas del año 2012 tengan las mismas o mejores características en

términos de resolución espectral y espacial, debido a que incluyeron imágenes multispectrales del sensor ETM+ de Landsat 7 y del sensor RapidEye, con resolución espacial 30 m y de 6.5 m respectivamente, el uso segmentación a partir de las bandas de abundancia generadas con LSMA permite alcanzar un mayor nivel de detalle en términos de UMC, utilizando únicamente procesos de análisis digital de imagen y sistemas de información geográfica.

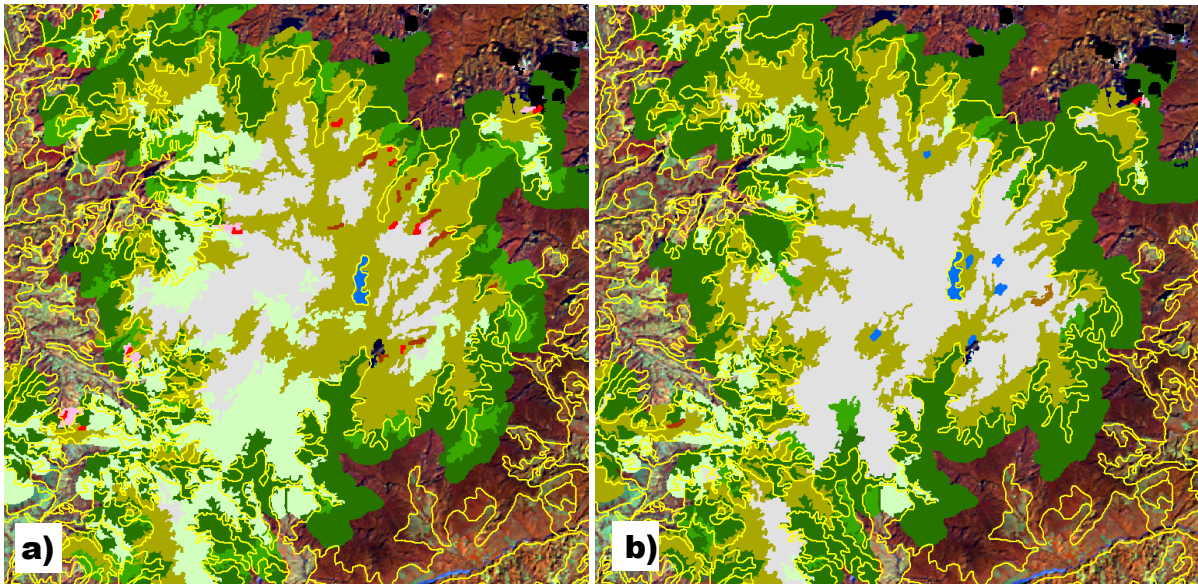


Figura 63. Análisis comparativo entre el límite de coberturas delimitadas para el área de estudio.

Fuente: elaboración propia.

Nota: a) Límite de coberturas de la tierra del año 2012 (IDEAM) sobre mapa de coberturas obtenido con el algoritmo ISODATA y OBIA. c) Límite de coberturas de la tierra del año 2012 (IDEAM) sobre mapa de coberturas obtenido con el algoritmo SMACC y OBIA.

Finalmente, teniendo en cuenta los valores de fiabilidad global y normalizada obtenidos para los diferentes niveles jerárquicos de la clasificación, la comparación de la distribución espacial y el nivel de detalle obtenido en términos de delimitación de las unidades cartografiadas, se puede concluir que el uso combinado del análisis lineal de mezclas espectrales y OBIA constituye un método efectivo para la obtención de mapas preliminares de uso y cobertura en el en zonas de alta montaña, como en este caso de estudio, el área de complejo de páramo jurisdicción Santurbán Berlín, mediante el uso de clasificación no supervisada. Así mismo, el uso de LSMA permite obtener mejores resultados en términos de conformidad temática en comparación con el algoritmo ISODATA, utilizado tradicionalmente para llevar a cabo procesos de clasificación digital no supervisada.

5. CONCLUSIONES

Fue posible obtener un mapa preliminar de coberturas de la tierra para zonas de alta montaña, caso de estudio el Complejo de Páramo Jurisdicción Santurbán-Berlín, a partir de la aplicación del análisis lineal de mezclas espectrales en combinación con la clasificación basada en objetos en imágenes multiespectrales del sensor OLI de Landsat-8.

El mapa obtenido, permite estimar el área y apreciar la distribución de las clases de cobertura definidas de acuerdo al esquema de clasificación adoptado por la Leyenda Nacional de Coberturas de la Tierra CORINE Land Cover adaptada para Colombia, con una fiabilidad global del 84% para el nivel jerárquico 2 y del 88% para el nivel jerárquico 1.

De acuerdo a lo anterior, el uso del análisis lineal de mezclas espectrales en combinación con la clasificación basada en objetos constituye una alternativa viable para optimizar y disminuir los tiempos requeridos para los procesos de mapeo de coberturas de la tierra en la zona de estudio, según el esquema de clasificación adoptado a nivel nacional.

En relación con los modelos de transferencia radiativa ensayados para la corrección atmosférica de las imágenes multiespectrales de la misión Landsat-8 (sensor OLI), en la zona del CPJSB, los mejores resultados se observaron con el uso combinado del módulo de ATCOR de PCI y el modelo digital del terreno GMTED 2010, que permitieron obtener valores de reflectancia dentro del rango establecido y sin evidencia de grupos de píxeles anómalos en las imágenes corregidas atmosféricamente.

Con respecto a los métodos de corrección del relieve, los mejores resultados se obtuvieron mediante el uso de la Corrección C, que presentó los menores valores de correlación entre la iluminación y los valores de reflectancia obtenidos después de la corrección.

Por otra parte, entre los insumos ensayados para el cálculo de la iluminación, se obtuvieron los mejores resultados mediante el uso del modelo digital de elevaciones de la misión SRTM, con aplicación de un filtro promedio con ventana móvil de 3x3.

La evaluación de los métodos de extracción de píxeles propuestos por Li (2007), y basado en el algoritmo SMAACC, evidenció un mejor desempeño de este último, obteniendo un RMSE

inferior a 0.02, valor de referencia reportado en la literatura. No obstante, a lo anterior, las estadísticas de los valores de abundancia de los píxeles obtenidos con ambos métodos indican que la selección de uno o varios *endmembers* podría ser inadecuada. En el caso del algoritmo de extracción basado en SMACC, este resultado podría relacionarse con la inclusión de algunos píxeles que presentan una firma espectral anómala, con saturación para una o más bandas, como es el caso de los *endmembers* 1 y 6.

Por otra parte, tanto el RMSE como las estadísticas de los valores de abundancia obtenidos con el método combinado MNF-PPI, indican que este método no tiene buen desempeño en el área de estudio.

Finalmente, el análisis comparativo entre la clasificación no supervisada basada en LSMA y la clasificación obtenida con el algoritmo ISODATA, evidenció que el primer método permite obtener mejores resultados en términos de fiabilidad global normalizada (con un desfase del 18% entre los dos métodos), así como una mayor capacidad para incluir cuerpos de agua y una menor confusión entre zonas de suelos desnudos y territorios artificializados.

6. RECOMENDACIONES

Como recomendación de carácter general, se sugiere realizar mayores investigaciones orientadas a mejorar la fiabilidad global del mapa de coberturas de la tierra obtenido y el nivel de detalle alcanzado con el enfoque propuesto.

Aunque el algoritmo de extracción de *endmembers* basado en SMAAC, permitió obtener buenos resultados en términos de RMSE y de clases de cobertura de la tierra identificadas, para trabajos futuros, se recomienda explorar otros algoritmos y métodos para la extracción de *endmembers* en imágenes multiespectrales, con el fin de obtener mejores resultados que se reflejen en las estadísticas de los valores de los píxeles obtenidos para cada fracción de abundancia.

Así mismo, se recomienda realizar mejoras al proceso adoptado para la asignación de clases de cobertura a los segmentos, orientadas principalmente a discriminar un mayor número de clases y mejorar su forma de ejecución, mediante la construcción de algoritmos específicamente desarrollados para tal fin.

En la mayoría de los procesos realizados tanto a nivel de preprocesamiento como de extracción de *endmembers* y clasificación, la remoción de zonas de nubes y píxeles anómalos presentes en las imágenes utilizadas como insumo principal, reviste una gran importancia para poder obtener buenos resultados en términos de corrección atmosférica, del relieve, de extracción de *endmembers* y por ende, en la clasificación final. Por lo tanto se recomienda realizar una remoción rigurosa de estos elementos antes de proceder a realizar cualquier proceso de análisis digital de la imagen.

El estudio realizado, sienta las bases para la investigación de nuevos métodos de procesamiento digital de imágenes multiespectrales para la producción de mapas temáticos de coberturas de la tierra en zonas tropicales, basados en el análisis lineal de mezclas espectrales. De acuerdo a lo anterior, se recomienda realizar estudios de aplicación del enfoque propuesto en otros ecosistemas tropicales y con imágenes de diferentes sensores y características, con el fin de evaluar su desempeño y poder plantear, en un futuro, su uso para la producción de mapas de cobertura de la tierra para el nivel regional y nacional.

El enfoque propuesto en este estudio representa una alternativa para optimizar la producción de mapas de uso y cobertura de acuerdo con el esquema de clasificación adoptado a nivel nacional en el Complejo de Páramo Jurisdicción Santurbán-Berlín. De acuerdo a lo anterior, constituye una válida herramienta para las entidades territoriales y nacionales encargadas de realizar el seguimiento del estado y del uso del territorio de este ecosistema estratégico.

7. BIBLIOGRAFÍA

- Alqurashi, A. F., & Kumar, L. (2013). Investigating the Use of Remote Sensing and GIS Techniques to Detect Land Use and Land Cover Change: A Review. *Advances in Remote Sensing*, 02(02), 193–204. <https://doi.org/10.4236/ars.2013.22022>
- Ban, Y., Gong, P., & Giri, C. (2015). Global land cover mapping using Earth observation satellite data: Recent progresses and challenges. *ISPRS Journal of Photogrammetry and Remote Sensing*, 103(February 2020), 1–6. <https://doi.org/10.1016/j.isprsjprs.2015.01.001>
- Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1), 2–16. <https://doi.org/10.1016/j.isprsjprs.2009.06.004>
- Boardman, J. W., Kruse, F. A., & Green, R. O. (1995). Mapping target signatures via partial unmixing of AVIRIS data: in summaries. *Fifth JPL Airborne Earth Science Workshop*, 95(1)(1), 23–26.
- Botía, A., Oliveros, A., Avella, C., Sarmiento, C., Rey, C., Ruales, D., Rubio, F., Hernández, L. H., Carrión, G. A., Berrío, G. A., Murcia Rodríguez, C. E., Insuasty, J., Galvis, M., Ramírez, N., & Cortés, V. (2018). *Documento de lineamientos para la elaboración del Plan de Manejo Ambiental y la zonificación y régimen de usos aplicable a páramos delimitados*.
- Bullock, E. L., Woodcock, C. E., & Olofsson, P. (2018). Monitoring tropical forest degradation using spectral unmixing and Landsat time series analysis. *Remote Sensing of Environment*, April, 0–1. <https://doi.org/10.1016/j.rse.2018.11.011>
- CDMB. (2012). *Estudio Páramo Santurbán*.
- Chang, C. I., & Chiang, S. S. (2002). Anomaly detection and classification for hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 40(6), 1314–1325. <https://doi.org/10.1109/TGRS.2002.800280>
- Chang, C. I., & Plaza, A. (2006). A fast iterative algorithm for implementation of pixel purity index. *IEEE Geoscience and Remote Sensing Letters*, 3(1), 63–67. <https://doi.org/10.1109/LGRS.2005.856701>
- Chavez, P. S. (1996). Image-based atmospheric corrections - Revisited and improved. *Photogrammetric Engineering and Remote Sensing*, 62(9), 1025–1036.
- Chuvieco Salinero, E. (1996). *Fundamentos de Teledetección Espacial* (3rd ed.). Ediciones Rialp S.A.
- Civco, D. L. (1989). Topographic normalization of Landsat Thematic Mapper digital imagery. *Photogrammetric Engineering & Remote Sensing*, 55(9), 1303–1309.
- Clerici, N., Valbuena Calderón, C. A., & Posada, J. M. (2017). Fusion of Sentinel-1A and Sentinel-2A data for land cover mapping: a case study in the lower Magdalena region, Colombia. *Journal of Maps*, 13(2), 718–726. <https://doi.org/10.1080/17445647.2017.1372316>

- Colby, J. D., & Keating, P. L. (1998). Land cover classification using Landsat TM imagery in the tropical highlands: The influence of anisotropic reflectance. *International Journal of Remote Sensing*, 19(8), 1479–1500. <https://doi.org/10.1080/014311698215306>
- Congalton, R. G., & Green, K. (2009). Assessing the Accuracy of Remotely Sensed Data: Principles and Practices. In *The Photogrammetric Record* (Second Edi). CRC Press. https://doi.org/10.1111/j.1477-9730.2010.00574_2.x
- Congreso de la República de Colombia. (2018). *Ley 1931 de 2018*. 19. https://www.minambiente.gov.co/images/cambioclimatico/pdf/LEY_1931_DEL_27_DE_JULIO_DE_2018_LEY_DE_CAMBIO_CLIMÁTICO.pdf
- CORPONOR. (2009). *Estado actual del páramo región nororiental unidad biogeográfica Santurbán - departamento Norte de Santander municipios de Villacaro, Chitaga, Cachira, Salazar, Arboledas, Cucutilla, Pamplona, Mutiscua, Cécota y Silos. Capítulo I. Presentación*.
- Costa, H., Foody, G. M., & Boyd, D. S. (2018). Supervised methods of image segmentation accuracy assessment in land cover mapping. *Remote Sensing of Environment*, 205, 338–351. <https://doi.org/10.1016/j.rse.2017.11.024>
- Deng, Y., Chen, R., & Wu, C. (2019). Examining the deep belief network for subpixel unmixing with medium spatial resolution multispectral imagery in urban environments. *Remote Sensing*, 11(13). <https://doi.org/10.3390/rs11131566>
- Di Gregorio, A. (2005). Land Cover Classification System. Software version 3. In *October* (Issue October). <https://doi.org/10.1080/01431161.2012.674230>
- Dorren, L. K. A., Maier, B., & Seijmonsbergen, A. C. (2003). Improved Landsat-based forest mapping in steep mountainous terrain using object-based classification. *Forest Ecology and Management*, 183(1–3), 31–46. [https://doi.org/10.1016/S0378-1127\(03\)00113-0](https://doi.org/10.1016/S0378-1127(03)00113-0)
- Du, P., Liu, S., Liu, P., Tan, K., & Cheng, L. (2014). Sub-pixel change detection for urban land-cover analysis via multi-temporal remote sensing images. *Geo-Spatial Information Science*, 17(1), 26–38. <https://doi.org/10.1080/10095020.2014.889268>
- Duarte, B., Ciontescu, N., Ávila, Y., & Márin, C. (2014). *Estudio sobre la sostenibilidad de los medios de vida de las poblaciones locales que habitan o utilizan directamente los páramos y su relación la sostenibilidad del uso de estos ecosistemas Proyecto Páramos y Sistemas de Vida (PPSV). Caracterización Ecoló.*
- European Environmental Agency. (1997). *CORINE Land Cover - Technical guide*. European Environmental Agency. http://image2000.jrc.ec.europa.eu/reports/technical_guide.pdf
- Gábor, M., Karlík, L., Faltan, V., & Petrovič, F. (2017). Implementation of semi-automated object-based image land cover classification methods: A case study of the Male Karpaty Mts. (Slovakia). *Geograficky Casopis*, 69(2), 113–128.
- Gao, M. L., Zhao, W. J., Gong, Z. N., Gong, H. L., Chen, Z., & Tang, X. M. (2014). Topographic correction of ZY-3 satellite images and its effects on estimation of shrub leaf biomass in mountainous areas. *Remote Sensing*, 6(4), 2745–2764. <https://doi.org/10.3390/rs6042745>
- Geneletti, D., & Gorte, B. G. H. (2003). A method for object-oriented land cover classification

- combining Landsat TM data and aerial photographs. *International Journal of Remote Sensing*, 24(6), 1273–1286. <https://doi.org/10.1080/01431160210144499>
- Gruninger, J. H., Ratkowski, A. J., & Hoke, M. L. (2004a). The extension of endmember extraction to multispectral scenes. *Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery X*, 5425, 15. <https://doi.org/10.1117/12.543798>
- Gruninger, J. H., Ratkowski, A. J., & Hoke, M. L. (2004b). The sequential maximum angle convex cone (SMACC) endmember model. *Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery X*, 5425, 1. <https://doi.org/10.1117/12.543794>
- Hantson, S., & Chuvieco, E. (2011). Evaluation of different topographic correction methods for landsat imagery. *International Journal of Applied Earth Observation and Geoinformation*, 13(5), 691–700. <https://doi.org/10.1016/j.jag.2011.05.001>
- Harris Geospatial Solutions. (2020a). *RX Anomaly Detection*. <https://www.harrisgeospatial.com/docs/RXAnomalyDetection.html>
- Harris Geospatial Solutions, I. (2020b). *Linear Spectral Unmixing*. <https://www.harrisgeospatial.com/docs/linearspectralunmixing.html>
- Harris Geospatial Solutions, I. (2020c). *Minimum Noise Fraction Transform*. <https://www.harrisgeospatial.com/docs/MinimumNoiseFractionTransform.html>
- Harris Geospatial Solutions, I. (2020d). *SMACC*. <https://www.harrisgeospatial.com/docs/SMACC.html>
- Hostert, P., Röder, A., & Hill, J. (2003). Coupling spectral unmixing and trend analysis for monitoring of long-term vegetation dynamics in Mediterranean rangelands. *Remote Sensing of Environment*, 87(2–3), 183–197. [https://doi.org/10.1016/s0034-4257\(03\)00145-7](https://doi.org/10.1016/s0034-4257(03)00145-7)
- IDEAM. (n.d.). www.ideam.gov.co. *Manual de Control de Calidad Para El Procedimiento de Cobertura de La Tierra*, 2.
- IDEAM. (2002). *Páramos y Ecosistemas Alto Andinos de Colombia en Condición HotSpot & Global Climatic Tensor*.
- IDEAM. (2010). *Leyenda nacional de coberturas de la tierra. Metodología CORINE Land Cover Adaptada para Colombia Escala 1:100.000*.
- IDEAM, IGAC, & CORMAGDALENA. (2008). *Mapa de Cobertura de la Tierra Cuenca Magdalena-Cauca: Metodología CORINE Land Cover adaptada para Colombia a escala 1:100.000*. <http://documentacion.ideam.gov.co/openbiblio/bvirtual/021521/LIBROCORINEFINAL.pdf>
- Im, J., & Jensen, J. R. (2005). A change detection model based on neighborhood correlation image analysis and decision tree classification. *Remote Sensing of Environment*, 99(3), 326–340. <https://doi.org/10.1016/j.rse.2005.09.008>
- Jensen, J. R. (2015). *Introductory digital image processing. A remote sensing perspective* (4th ed.). Pearson Education, Inc.
- Karoui, M. S., Deville, Y., Hosseini, S., & Ouamri, A. (2012). Blind spatial unmixing of

- multispectral images: New methods combining sparse component analysis, clustering and non-negativity constraints. *Pattern Recognition*, 45(12), 4263–4278. <https://doi.org/10.1016/j.patcog.2012.05.008>
- Kawakubo, F. S., Morato, R. G., & Luchiari, A. (2013). Use of fraction imagery, segmentation and masking techniques to classify land-use and land-cover types in the Brazilian Amazon. *International Journal of Remote Sensing*, 34(15), 5452–5467. <https://doi.org/10.1080/01431161.2013.791758>
- Keshava, N., Kerekes, J. P., Manolakis, D. G., & Shaw, G. A. (2000). Algorithm taxonomy for hyperspectral unmixing. *Algorithms for Multispectral, Hyperspectral, and Ultraspectral Imagery VI*, 4049(781), 42. <https://doi.org/10.1117/12.410362>
- Keshava, N., & Mustard, J. F. (2002). Nirmal Keshava and John F. Mustard. *Ieee Signal Processing Magazine*, January, 44–57.
- Khatami, R., Mountrakis, G., & Stehman, S. V. (2016). A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes: General guidelines for practitioners and future research. *Remote Sensing of Environment*, 177, 89–100. <https://doi.org/10.1016/j.rse.2016.02.028>
- Landis, J. R., & Koch, G. G. (1977). Landis and Koch 1977 agreement of categorical data. *Biometrics*, 33(1), 159–174. <https://doi.org/10.2307/2529310>
- Lazaridou, M. A., & Patmio, E. N. (2012). Photogrammetry - Remote Sensing and Geoinformation. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XXXIX-B6(September), 69–71. <https://doi.org/10.5194/isprsarchives-xxxix-b6-69-2012>
- Li, S., Li, W., Zhou, J., & Zhuang, D. (2007). Novel urban land use/cover mapping approach based on the combination of fraction image and MNF image using decision tree method. *MIPPR 2007: Remote Sensing and GIS Data Processing and Applications; and Innovative Multispectral Technology and Applications*, 6790(86), 67903M. <https://doi.org/10.1117/12.752008>
- Liping, C., Saeed, S., & Yujun, S. (2019). Image classification based on the linear unmixing and GEOBIA. *Environmental Monitoring and Assessment*, 191(11). <https://doi.org/10.1007/s10661-019-7837-x>
- Lizarazo, I. (2014). Accuracy assessment of object-based image classification: another STEP. *International Journal of Remote Sensing*, 35(16), 6135–6156. <https://doi.org/10.1080/01431161.2014.943328>
- Lu, D., Moran, E., & Batistella, M. (2003). Linear mixture model applied to Amazonian vegetation classification. *Remote Sensing of Environment*, 87(4), 456–469. <https://doi.org/10.1016/j.rse.2002.06.001>
- Ma, L., Li, M., Ma, X., Cheng, L., Du, P., & Liu, Y. (2017). A review of supervised object-based land-cover image classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 277–293. <https://doi.org/10.1016/j.isprsjprs.2017.06.001>
- Mas, J., Lemoine-rodríguez, R., González-lópez, R., Piña-garduño, A., & Herrera-flores, E.

- (2017). Land use / land cover change detection combining automatic processing and visual interpretation. *European Journal of Remote Sensing*, 50(1), 626–635. <https://doi.org/10.1080/22797254.2017.1387505>
- Maselli, F. (2012). A method to improve the spatial features of NDVI data series. *European Journal of Remote Sensing*, 45(1), 407–420. <https://doi.org/10.5721/EuJRS20124534>
- Maxwell, A. E., Warner, T. A., & Fang, F. (2018). Implementation of machine-learning classification in remote sensing: an applied review. *International Journal of Remote Sensing*, 39(9), 2784–2817. <https://doi.org/10.1080/01431161.2018.1433343>
- Milewski, R., Chabrillat, S., & Bookhagen, B. (2020). Analyses of namibian seasonal salt pan crust dynamics and climatic drivers using landsat 8 time-series and ground data. *Remote Sensing*, 12(3), 1–24. <https://doi.org/10.3390/rs12030474>
- Ministerio de Ambiente Vivienda y Desarrollo Territorial. (2002). *Resolución 0769 (agosto, 5). Por la cual se dictan disposiciones para contribuir a la protección, conservación y sostenibilidad de los páramos. 0769, 6.* http://www.minambiente.gov.co/images/BosquesBiodiversidadyServiciosEcosistemicos/pdf/Paramos/res_0769_050802.pdf
- Ministerio de Medio Ambiente. (2002). Programa nacional para el manejo sostenible y restauración de ecosistemas de alta montaña colombiana: páramos. In *Congreso mundial de páramos- Memorias Tomo I*. <https://doi.org/10.1111/j.1748-0361.1995.tb00413.x>
- Ministerio de Medio Ambiente y Desarrollo Sostenible. (2018). *Resolucion 886 (mayo,18). Por la cual se adoptan los lineamientos para la zonificación y régimen de usos en las áreas de páramos delimitados y se establecen las directrices para diseñar, capacitar y poner en marcha programas de sustitución y reconversión .*
- Morales, M., Otero, J., Van der Hammen, T., Torres, A., Cadena, C., Pedraza, C., Rodríguez, N., Franco, C., Betancourth, J. C., Olaya, E., Posada, E., & Cárdenas, L. (2007). *Atlas de páramos de Colombia. Instituto de Investigación de Recursos Biológicos Alexander von Humboldt.*
- Mustard, J. F., & Sunshine, J. M. (1999). Spectral Analysis for Earth Science: Investigations Using Remote Sensing Data. In *Remote Sensing for the Earth Sciences* (Vol. 3).
- Myachina, K. V., & Chibilev, A. A. (2015). *Use of Satellite Data to Identify Steppe Lands of the Orenburg Trans-Volga Region Disturbed by Oil Development.* 36(4), 383–388. <https://doi.org/10.1134/S1875372815040095>
- NASA. (2020). *Landsat science*. <https://landsat.gsfc.nasa.gov>
- Niroumand, J. M., Safdarinezhad, A. R., Sahebi, M. R., & Mokhtarzade, M. (2012). A novel approach to super resolution mapping of multispectral imagery based on pixel swapping technique. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 1(September), 159–164. <https://doi.org/10.5194/isprsannals-I-7-159-2012>
- Paris, C., Bruzzone, L., & Fernández-Prieto, D. (2017). A novel automatic approach to the update of land-cover maps by unsupervised classification of remote sensing images. *2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2207–2210.

- Pimple, U., Sitthi, A., Simonetti, D., Pungkul, S., Leadprathom, K., & Chidthaisong, A. (2017). Topographic correction of Landsat TM-5 and Landsat OLI-8 imagery to improve the performance of forest classification in the mountainous terrain of Northeast Thailand. *Sustainability (Switzerland)*, *9*(2), 1–26. <https://doi.org/10.3390/su9020258>
- Riaño, D., Chuvieco, E., Salas, J., & Aguado, I. (2003). Assessment of Different Topographic Corrections in Landsat-TM Data for Mapping Vegetation Types. *IEEE Transactions on Geoscience and Remote Sensing*, *41*(5), 1056.
- Rogan, J., & Chen, D. (2003). Remote sensing technology for mapping and monitoring land-cover and land-use change. *Progress in Planning*, *61*(61), 301–325. [https://doi.org/10.1016/S0305-9006\(03\)00066-7](https://doi.org/10.1016/S0305-9006(03)00066-7)
- Salih, A. A. M., Ganawa, E. T., & Elmahl, A. A. (2017). Spectral mixture analysis (SMA) and change vector analysis (CVA) methods for monitoring and mapping land degradation/desertification in arid and semiarid areas (Sudan), using Landsat imagery. *Egyptian Journal of Remote Sensing and Space Science*, *20*, S21–S29. <https://doi.org/10.1016/j.ejrs.2016.12.008>
- Sarıymaza, F. B., Musaoğlua, N., & Uluğtekin, N. (2017). Producing information for CORINE database by using classification method: a case study of Sazlıdere basin, Istanbul. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, *IV*(4), 357–362.
- Servicio Geológico Colombiano. (2016). *Guía Metodológica para estudios de amenaza, vulnerabilidad y riesgo por movimientos en masa. Escala detallada* (1st ed.). Imprenta Nacional de Colombia.
- Sharifi, A., Hosseingholizadeh, M., & Angle, S. M. (2019). *Validation of extracted endmembers from hyperspectral images*. *XLII*(October), 12–14.
- Shrivastava, D., Kumar, V., & Sharma, R. U. (2016). Automated endmember extraction for subpixel classification of multispectral and hyperspectral data. *Multispectral, Hyperspectral, and Ultraspectral Remote Sensing Technology, Techniques and Applications VI*, 9880, 988012. <https://doi.org/10.1117/12.2228045>
- Sola, I. (2015). *Evaluation of Topographic Correction Algorithms on Satellite Images*. November.
- Souza, C. M., Siqueira, J. V., Sales, M. H., Fonseca, A. V., Ribeiro, J. G., Numata, I., Cochrane, M. A., Barber, C. P., Roberts, D. A., & Barlow, J. (2013). Ten-year landsat classification of deforestation and forest degradation in the brazilian amazon. *Remote Sensing*, *5*(11), 5493–5513. <https://doi.org/10.3390/rs5115493>
- Story, M., & Congalton, R. G. (1986). Remote Sensing Brief Accuracy Assessment: A User's Perspective. *Photogrammetric Engineering and Remote Sensing*, *52*(3), 397–399.
- Taylor, P., Fuller, R., & Brown, N. (1996). A CORINE map of Great Britain by automated means . Techniques for automatic generalization of the Land Cover Map of Great Britain . *International Journal of Geographical Information Systems*, *10*, 937–953. <https://doi.org/10.1080/02693799608902118>
- Teillet, P. M., Guindon, B., & Goodenough, D. G. (1982). On the slope-aspect correction of

- multispectral scanner data. *Canadian Journal of Remote Sensing*, 8(2), 84–106. <https://doi.org/10.1080/07038992.1982.10855028>
- Tewkesbury, A. P., Comber, A. J., Tate, N. J., Lamb, A., & Fisher, P. F. (2015). A critical synthesis of remotely sensed optical image change detection techniques. *Remote Sensing of Environment*, 160, 1–14. <https://doi.org/10.1016/j.rse.2015.01.006>
- Thayn, J. B. (2020). Monitoring Narrow Mangrove Stands in Baja California Sur, Mexico using Linear Spectral Unmixing. *Marine Geodesy*, 0(0), 1–12. <https://doi.org/10.1080/01490419.2020.1751753>
- Turner II, B. L., & Meyer, W. B. (1991). Land use and land cover in global environmental change: considerations for study. *ISSJ*, 130, 669–679.
- Vega, M., Gil, J., Ronvert-Delisle, D., García, E., & Sánchez, R. (2004). Enfoques para la clasificación digital de imágenes mono y multiespectral y su implementación en el software cubano TN Estudio V2.0. *Revista de Teledetección: Revista de La Asociación Española de Teledetección*, 20, 35–52.
- Verburg, P. H., van de Steeg, J., Veldkamp, A., & Willemsen, L. (2009). From land cover change to land function dynamics: A major challenge to improve land characterization. *Journal of Environmental Management*, 90(3), 1327–1335. <https://doi.org/10.1016/j.jenvman.2008.08.005>
- Wehrmann, T., Dech, S., & Glaser, R. (2004). An automated object-based classification approach for Updating Corine Land Cover data. *Proceedings of SPIE - The International Society for Optical Engineering*, 5574, 100–110. <https://doi.org/10.1117/12.565234>
- World Meteorological Organization. (2016). *The global observing system for climate: implementation needs* (1st ed.). World Meteorological Organization.
- Wu, C., & Murray, A. T. (2003). Estimating impervious surface distribution by spectral mixture analysis. *Remote Sensing of Environment*, 30(84), 493–505.
- Zhai, Y., Qu, Z., & Hao, L. (2018). Land cover classification using integrated spectral, temporal, and spatial features derived from remotely sensed images. *Remote Sensing*, 10(3). <https://doi.org/10.3390/rs10030383>
- Zurita-Milla, R., Gómez-Chova, L., Guanter, L., Clevers, J. G. P. W., & Camps-Valls, G. (2011). Multitemporal unmixing of medium-spatial-resolution satellite images: A case study using MERIS images for land-cover mapping. *IEEE Transactions on Geoscience and Remote Sensing*, 49(11 PART 1), 4308–4317. <https://doi.org/10.1109/TGRS.2011.2158320>

8. APENDICES

*Apéndice 1. Ecuaciones de regresión lineal y parámetros requeridos para la aplicación de la corrección topográfica Corrección C**Ecuaciones de regresión lineal entre valores de reflectancia de superficie y la iluminación calculada a partir del GDEM de ASTER*

<i>Banda</i>	<i>Ecuación</i>	m_λ	b_λ	$c_\lambda = b_\lambda/m_\lambda$
2- Blue	$Y = 4.555383 + 1.017206 * X$	1.017206	4.555383	4.478328873
3- Green	$Y = 6.343224 + 1.789168 * X$	1.789168	6.343224	3.545348452
4- Red	$Y = 6.670705 + 1.806512 * X$	1.806512	6.670705	3.692588258
5- NIR	$Y = 17.190720 + 8.877278 * X$	8.877278	17.190720	1.936485486
6- SWIR1	$Y = 9.819950 + 6.944162 * X$	6.944162	9.819950	1.414130316
7- SWIR2	$Y = 5.169813 + 3.951365 * X$	3.951365	5.169813	1.308361288

Ecuaciones de regresión lineal entre valores de reflectancia de superficie y la iluminación calculada a partir del DEM de SRTM

<i>Banda</i>	<i>Ecuación</i>	m_λ	b_λ	$c_\lambda = b_\lambda/m_\lambda$
2- Blue	$Y = 4.526057 + 1.084849 * X$	1.084849	4.526057	4.172061734
3- Green	$Y = 6.290219 + 1.911984 * X$	1.911984	6.290219	3.289891024
4- Red	$Y = 6.620504 + 1.921568 * X$	1.921568	6.620504	3.445365452
5- NIR	$Y = 16.889488 + 9.589824 * X$	9.589824	16.889488	1.761188527
6- SWIR1	$Y = 9.609547 + 7.433464 * X$	7.433464	9.609547	1.292741446
7- SWIR2	$Y = 5.057484 + 4.209836 * X$	4.209836	5.057484	1.201349411

Ecuaciones de regresión lineal entre valores de reflectancia de superficie y la iluminación calculada a partir del DEM de ALOS PALSAR

<i>Banda</i>	<i>Ecuación</i>	m_λ	b_λ	$c_\lambda = b_\lambda/m_\lambda$
2- Blue	$Y = 4.506956 + 1.130072 * X$	1.130072	4.506956	3.988202522
3- Green	$Y = 6.266503 + 1.964997 * X$	1.964997	6.266503	3.18906492
4- Red	$Y = 6.593957 + 1.982123 * X$	1.982123	6.593957	3.326714336
5- NIR	$Y = 16.847844 + 9.648287 * X$	9.648287	16.847844	1.746200543
6- SWIR1	$Y = 9.557111 + 7.532863 * X$	7.532863	9.557111	1.268722264
7- SWIR2	$Y = 5.021396 + 4.283277 * X$	4.283277	5.021396	1.172325768

Ecuaciones de regresión lineal entre valores de reflectancia de superficie y la iluminación calculada a partir del DEM generado con las curvas de nivel del IGAC 1:25.000

<i>Banda</i>	<i>Ecuación</i>	m_λ	b_λ	$c_\lambda = b_\lambda/m_\lambda$
2- Blue	$Y = 6.058045 + 1.212236 * X$	1.212236	6.058045	4.99741387
3- Green	$Y = 7.869771 + 2.044704 * X$	2.044704	7.869771	3.848855874
4- Red	$Y = 8.474025 + 2.330030 * X$	2.330030	8.474025	3.636873774
5- NIR	$Y = 8.474025 + 2.330030 * X$	2.330030	8.474025	3.636873774
6- SWIR1	$Y = 12.339953 + 9.305785 * X$	9.305785	12.339953	1.326051805
7- SWIR2	$Y = 6.337087 + 0.782745 * X$	0.782745	6.337087	8.095978895

Ecuaciones de regresión lineal entre valores de reflectancia de superficie y la iluminación calculada a partir del DEM de SRTM con filtro de paso bajo tipo promedio de ventana 3x3

<i>Banda</i>	<i>Ecuación</i>	m_λ	b_λ	$c_\lambda = b_\lambda/m_\lambda$
2- Blue	$Y = 4.496880 + 1.175604 * X$	1.175604	4.496880	3.825165617
3- Green	$Y = 6.240469 + 2.067373 * X$	2.067373	6.240469	3.018550112
4- Red	$Y = 6.567558 + 2.085770 * X$	2.085770	6.567558	3.148745068
5- NIR	$Y = 16.672572 + 10.280303 * X$	10.280303	16.672572	1.621797723
6- SWIR1	$Y = 9.421052 + 8.024170 * X$	8.024170	9.421052	1.174084298
7- SWIR2	$Y = 4.946177 + 4.556791 * X$	4.556791	4.946177	1.085451801

Ecuaciones de regresión lineal entre valores de reflectancia de superficie y la iluminación calculada a partir del DEM de SRTM con filtro de paso bajo tipo promedio de ventana 5x5

<i>Banda</i>	<i>Ecuación</i>	m_λ	b_λ	$c_\lambda = b_\lambda/m_\lambda$
2- Blue	$Y = 4.469429 + 1.250397 * X$	1.250397	4.469429	3.574407968
3- Green	$Y = 6.193889 + 2.194284 * X$	2.194284	6.193889	2.822738078
4- Red	$Y = 6.517080 + 2.223304 * X$	2.223304	6.517080	2.931259063
5- NIR	$Y = 16.476029 + 10.815745 * X$	10.815745	16.476029	1.523337412
6- SWIR1	$Y = 9.237669 + 8.523810 * X$	8.523810	9.237669	1.083748817
7- SWIR2	$Y = 4.835172 + 4.859241 * X$	4.859241	4.835172	0.995046757

Ecuaciones de regresión lineal entre valores de reflectancia de superficie y la iluminación calculada a partir del DEM de SRTM con filtro de paso bajo modal de ventana 3x3

<i>Banda</i>	<i>Ecuación</i>	m_λ	b_λ	$c_\lambda = b_\lambda/m_\lambda$
2- Blue	$Y = 4.546216 + 1.035568 * X$	1.035568	4.546216	4.390069991
3- Green	$Y = 6.324879 + 1.827487 * X$	1.827487	6.324879	3.460970721
4- Red	$Y = 6.655239 + 1.836913 * X$	1.836913	6.655239	3.623056182
5- NIR	$Y = 17.061532 + 9.170894 * X$	9.170894	17.061532	1.860400087
6- SWIR1	$Y = 9.742919 + 7.108695 * X$	7.108695	9.742919	1.370563655
7- SWIR2	$Y = 5.133035 + 4.025860 * X$	4.025860	5.133035	1.275015773

Ecuaciones de regresión lineal entre valores de reflectancia de superficie y la iluminación calculada a partir del DEM de SRTM con filtro de paso bajo modal de ventana 5x5

<i>Banda</i>	<i>Ecuación</i>	m_λ	b_λ	$c_\lambda = b_\lambda/m_\lambda$
2- Blue	$Y = 4.579372 + 0.909679 * X$	0.909679	4.579372	5.034052671
3- Green	$Y = 6.372541 + 1.633624 * X$	1.633624	6.372541	3.90086152
4- Red	$Y = 6.708663 + 1.627663 * X$	1.627663	6.708663	4.121653561
5- NIR	$Y = 17.191407 + 8.483138 * X$	8.483138	17.191407	2.026538646
6- SWIR1	$Y = 9.869823 + 6.507166 * X$	6.507166	9.869823	1.516762136
7- SWIR2	$Y = 5.209845 + 3.672309 * X$	3.672309	5.209845	1.418683722

Apéndice 2. Asignación de coberturas a clasificación obtenida con ISODATA.

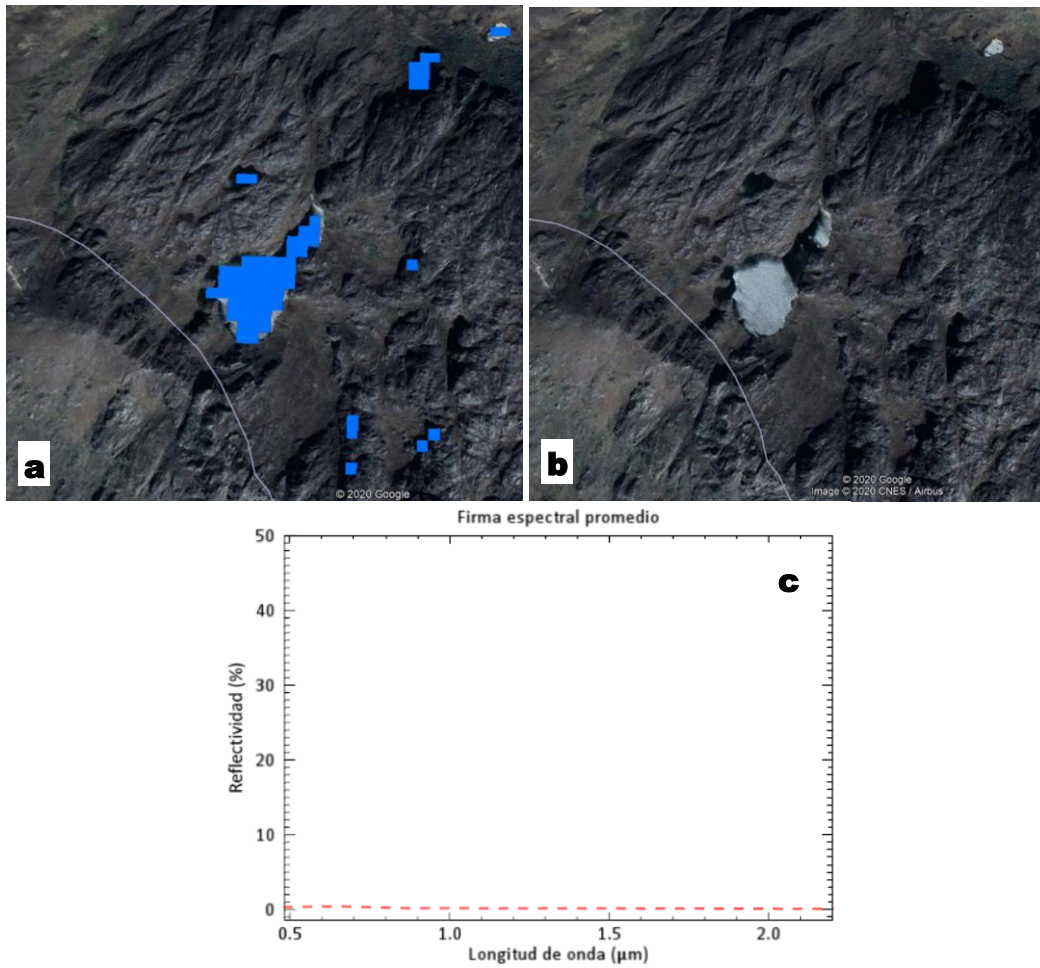


Figura 64. Asignación de clase 1: Aguas continentales (5).

Fuente: elaboración propia.

Nota: a) Vista de la clase en imagen Google Earth; b) Imagen de Google Earth; c) Firma espectral promedio de la clase extraída de la imagen.




Figura 65. Asignación de clase 2: Vegetación secundaria en transición (32).

Fuente: elaboración propia.

Nota: a) Vista de la clase en imagen Google Earth; b) Imagen de Google Earth; c) Firma espectral promedio de la clase extraída de la imagen.

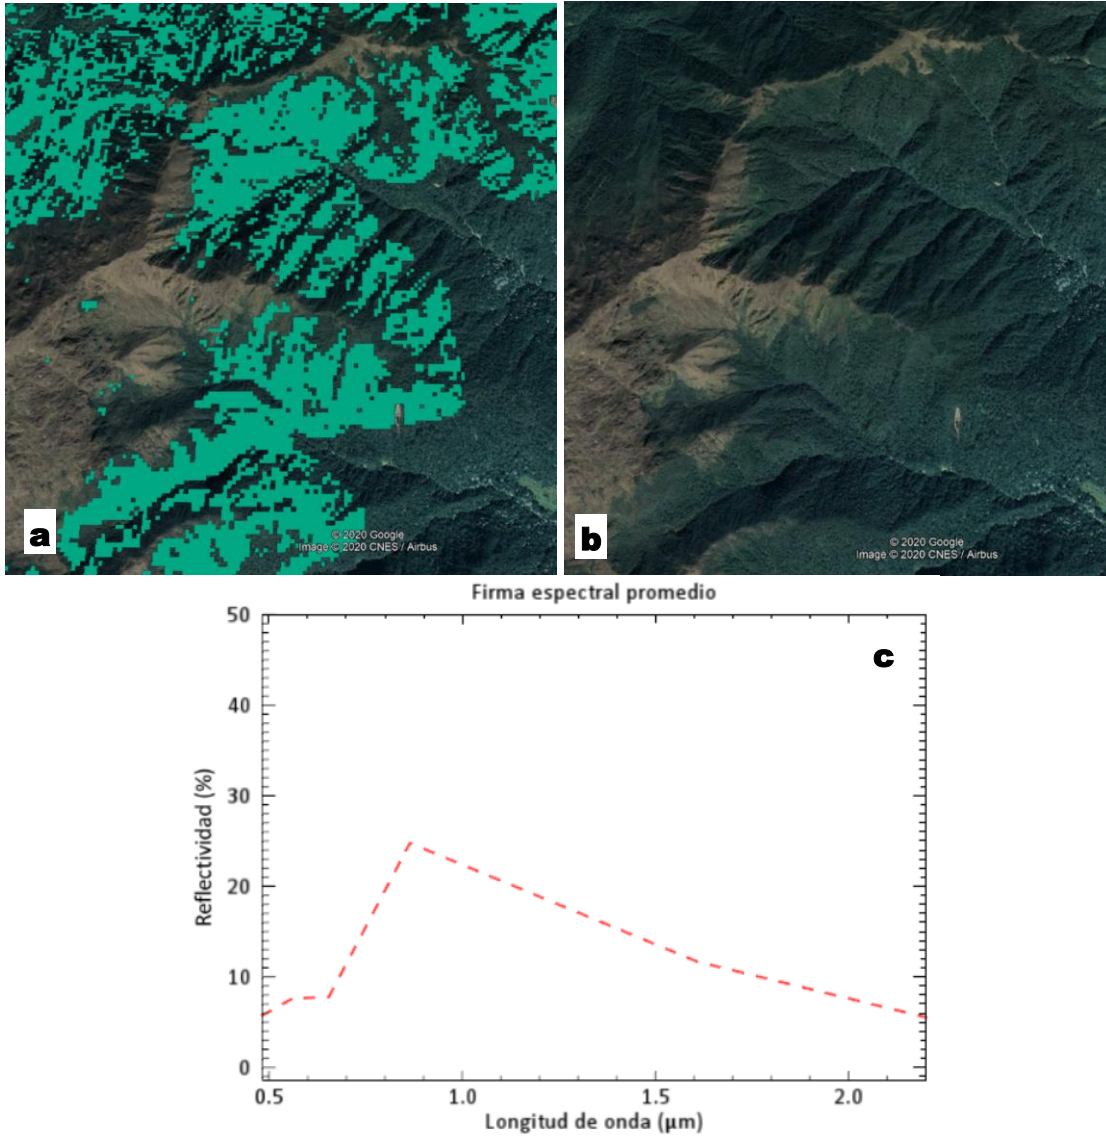


Figura 66. Asignación de clase 3: Bosque (31).

Fuente: elaboración propia.

Nota: a) Vista de la clase en imagen Google Earth; b) Imagen de Google Earth; c) Firma espectral promedio de la clase extraída de la imagen.





Figura 67. Asignación de clase 4: Vegetación secundaria en transición (32).

Fuente: elaboración propia.

Nota: a) Vista de la clase en imagen Google Earth; b) Imagen de Google Earth; c) Firma espectral promedio de la clase extraída de la imagen.

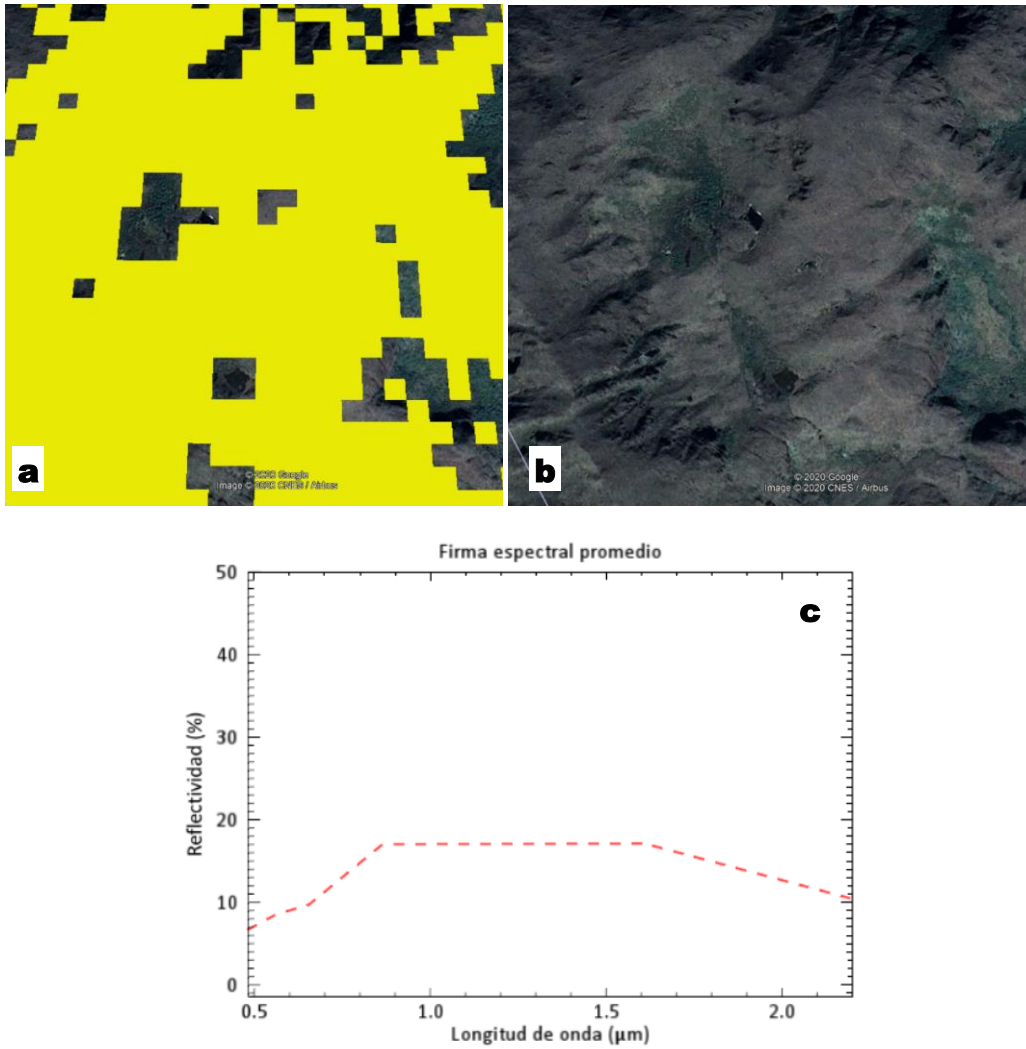


Figura 68. Asignación de clase 5: Pastos (23).

Fuente: elaboración propia.

Nota: a) Vista de la clase en imagen Google Earth; b) Imagen de Google Earth; c) Firma espectral promedio de la clase extraída de la imagen.




Figura 69. Asignación de clase 6: Tierras desnudas y degradadas (333).

Fuente: elaboración propia.

Nota: a) Vista de la clase en imagen Google Earth; b) Imagen de Google Earth; c) Firma espectral promedio de la clase extraída de la imagen.

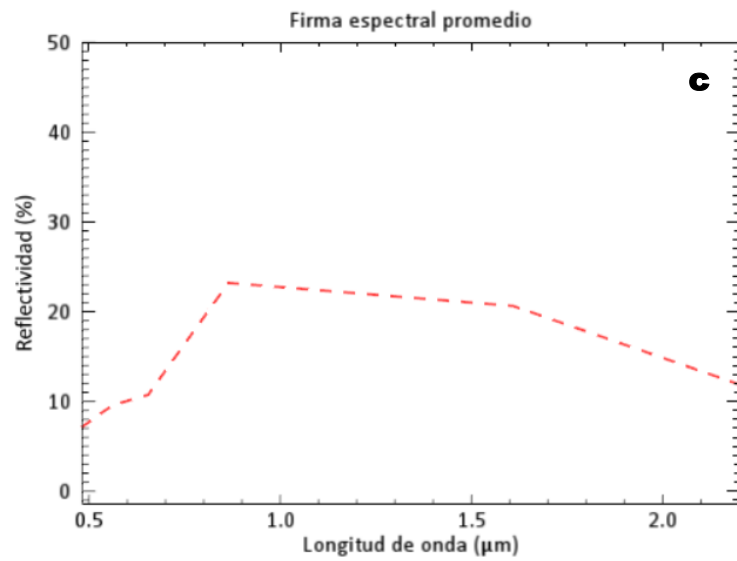



Figura 70. Asignación de clase 7: Pastos (23).

Fuente: elaboración propia.

Nota: a) Vista de la clase en imagen Google Earth; b) Imagen de Google Earth; c) Firma espectral promedio de la clase extraída de la imagen.

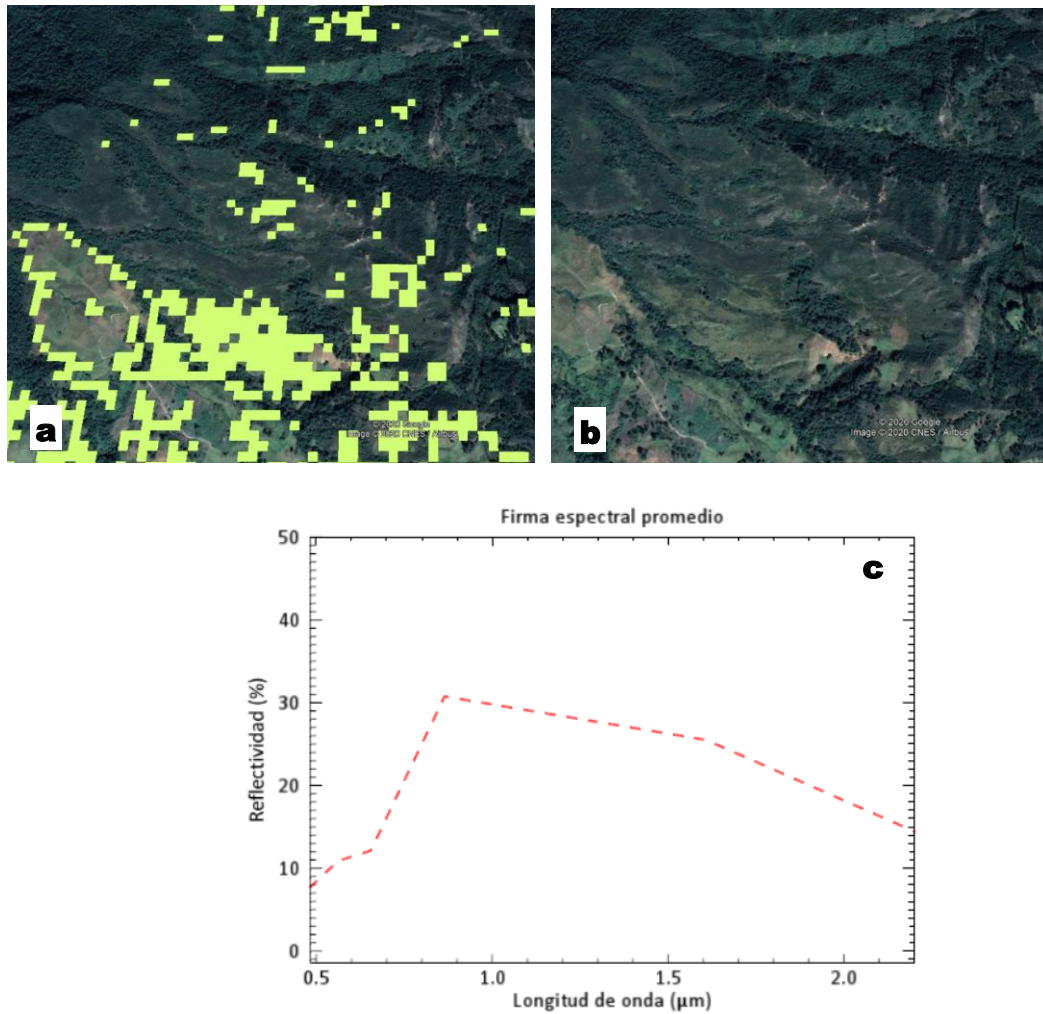


Figura 71. Asignación de clase 8: Pastos (23).

Fuente: elaboración propia.

Nota: a) Vista de la clase en imagen Google Earth; b) Imagen de Google Earth; c) Firma espectral promedio de la clase extraída de la imagen.

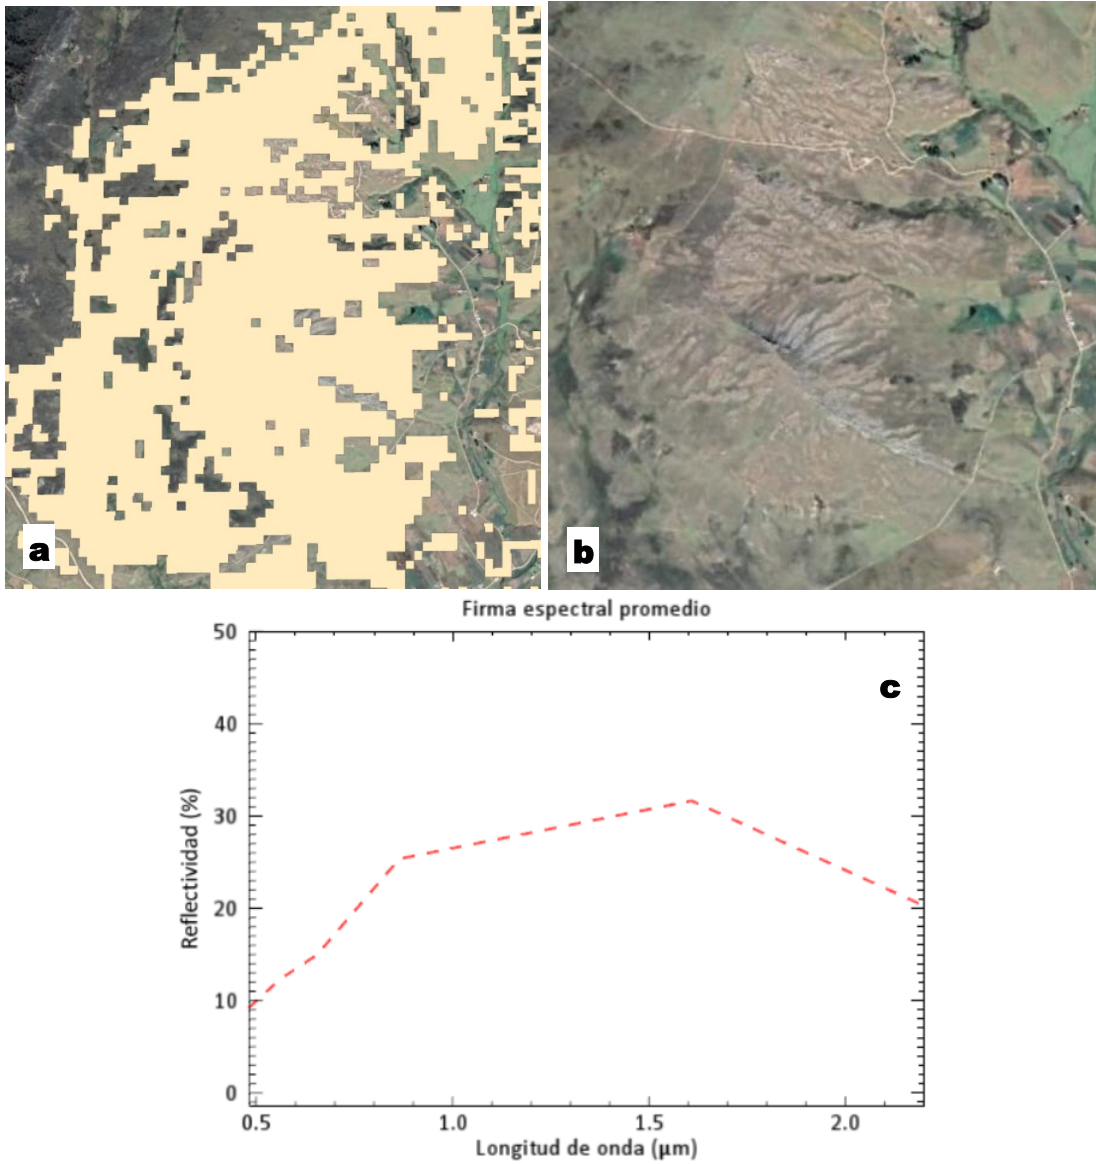


Figura 72. Asignación de clase 9: Tierras desnudas y degradadas (333).

Fuente: elaboración propia.

Nota: a) Vista de la clase en imagen Google Earth; b) Imagen de Google Earth; c) Firma espectral promedio de la clase extraída de la imagen.

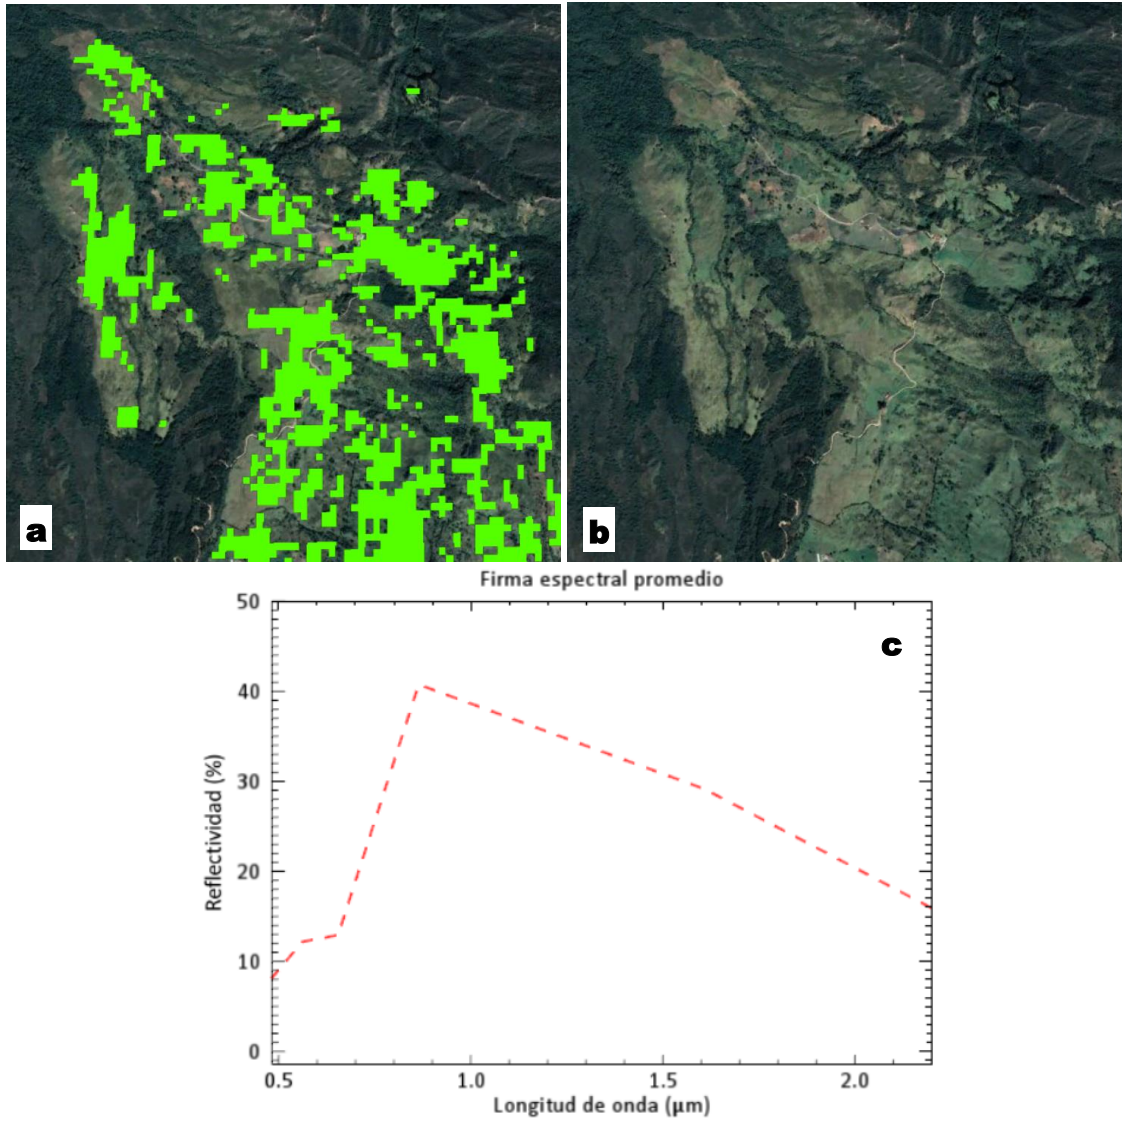


Figura 73. Asignación de clase 10: Pastos (23).

Fuente: elaboración propia.

Nota: a) Vista de la clase en imagen Google Earth; b) Imagen de Google Earth; c) Firma espectral promedio de la clase extraída de la imagen.





Figura 74. Asignación de clase 11: Tierras desnudas y degradadas (333).

Fuente: elaboración propia.

Nota: a) Vista de la clase en imagen Google Earth; b) Imagen de Google Earth; c) Firma espectral promedio de la clase extraída de la imagen.

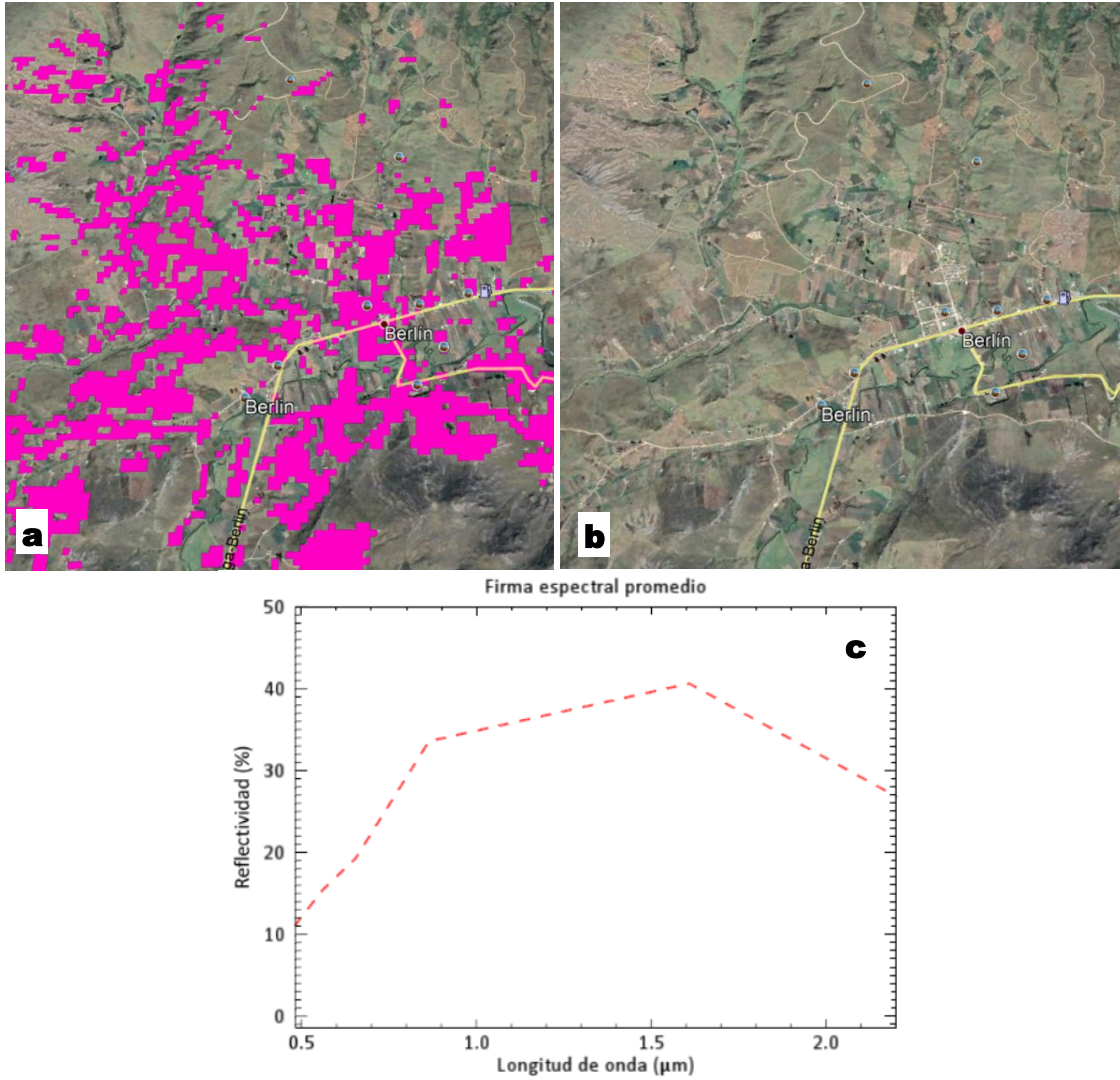


Figura 75. Asignación de clase 12: Territorios artificializados (1).

Fuente: elaboración propia.

Nota: a) Vista de la clase en imagen Google Earth; b) Imagen de Google Earth; c) Firma espectral promedio de la clase extraída de la imagen.

Apéndice 3. Asignación de endmembers a clasificación obtenida con SMACC.

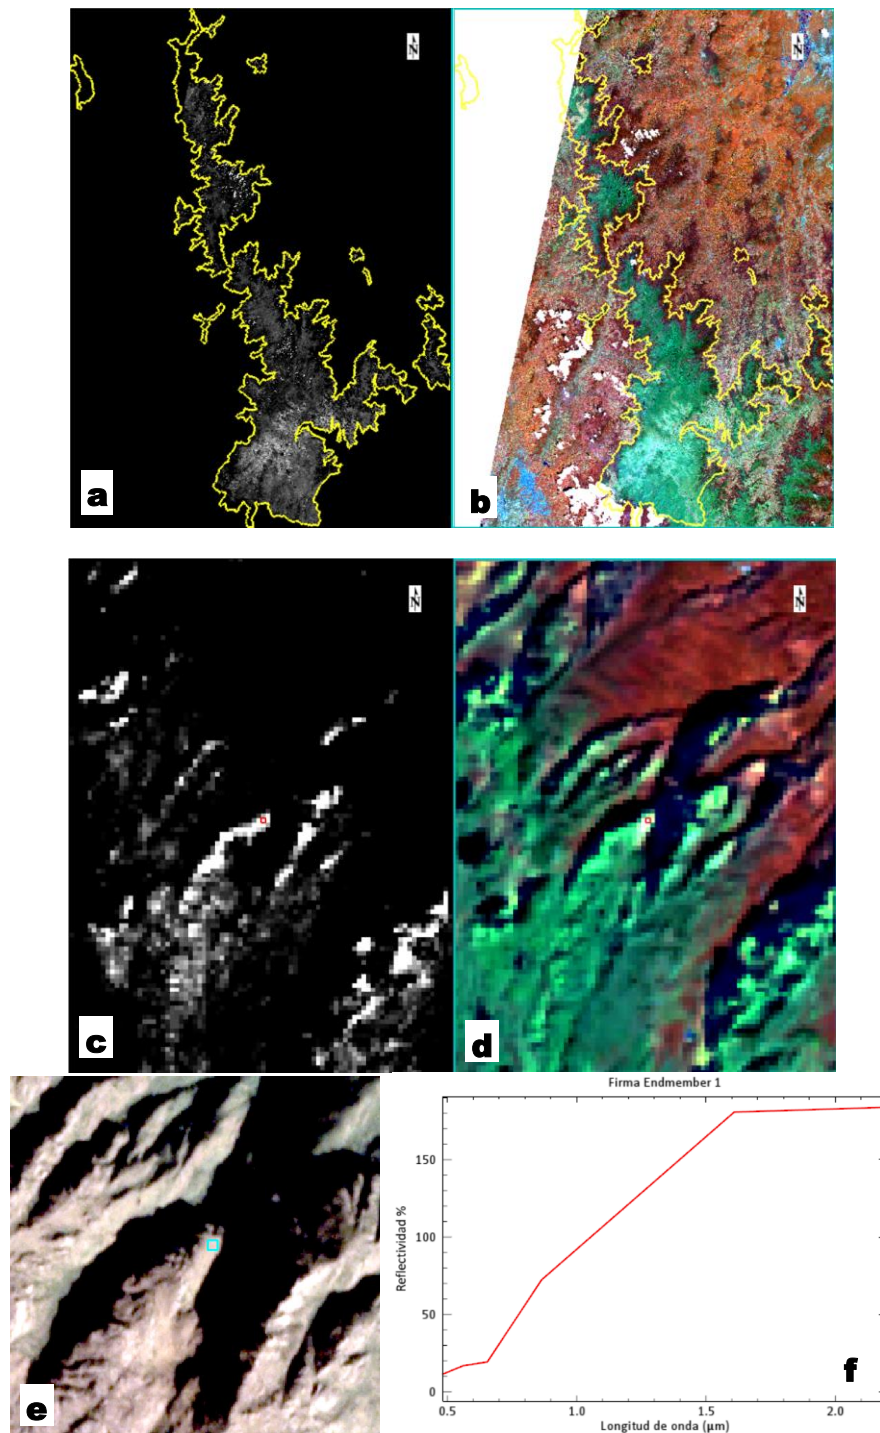


Figura 76. Asignación de clase al endmember 1: Tierras desnudas y degradadas (333).

Fuente: elaboración propia.

Nota: a) Imagen de la fracción de abundancia del *endmember*; b) Imagen original en composición falso color 5-6-3; c) Comparación a nivel de detalle de la imagen original y de la fracción de abundancia del *endmember*; d) Vista *endmember* en la imagen Planet Scope del 17/12/2017. e) Firma espectral del *endmember* extraída de la imagen.

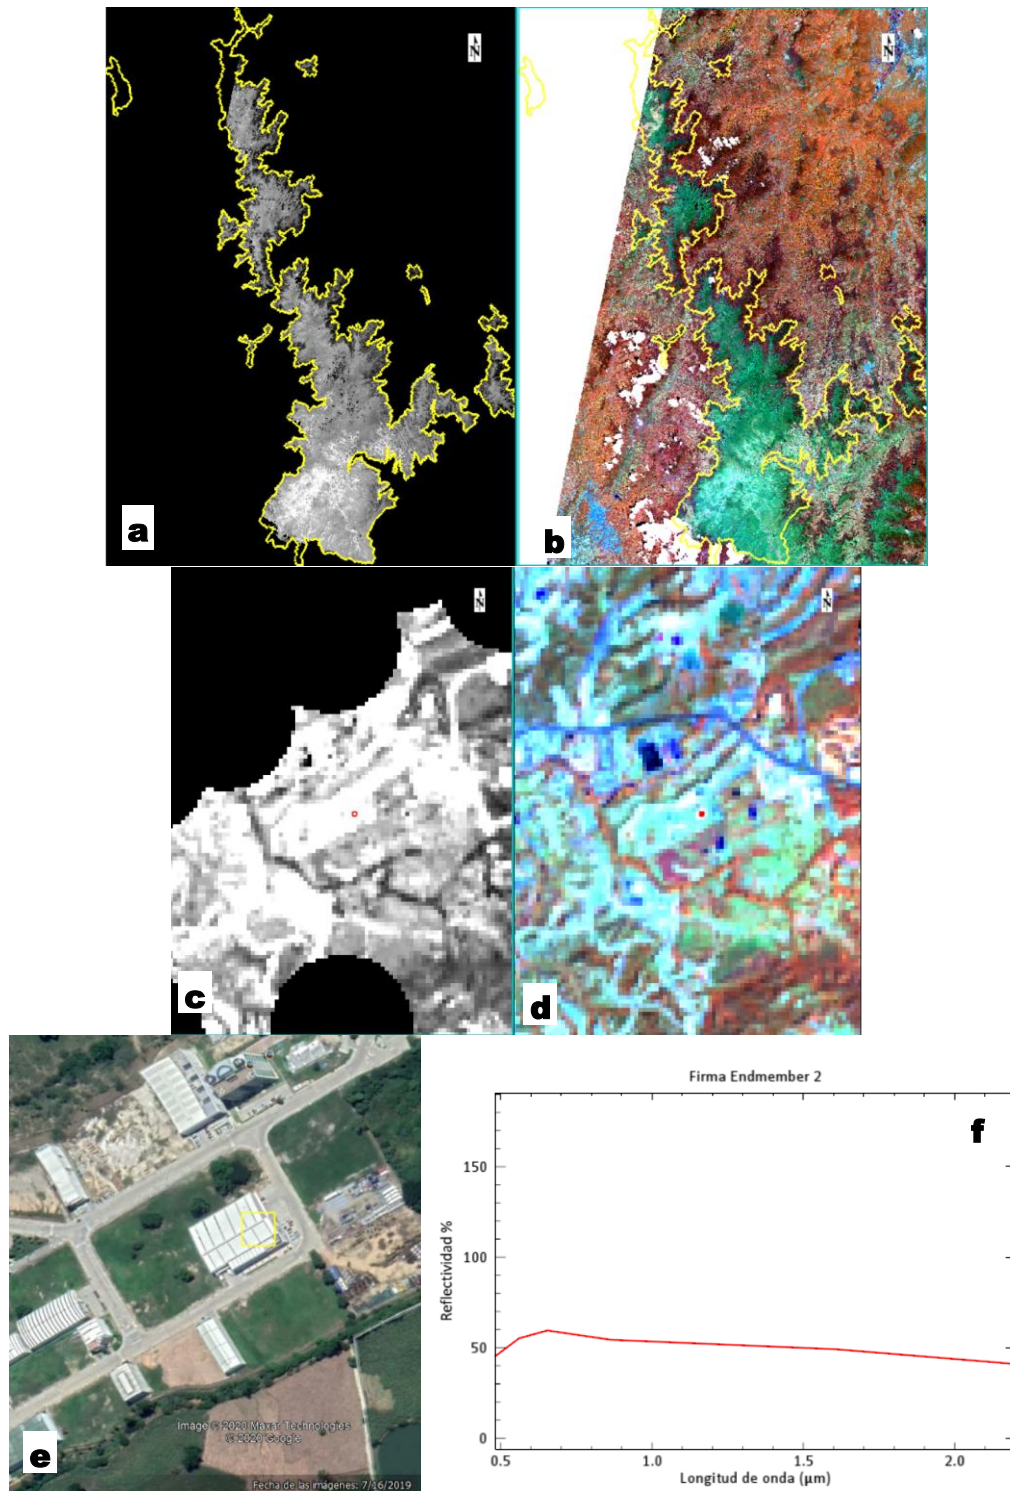


Figura 77. Asignación de clase al *endmember 2*: Territorios artificializados (1).

Fuente: elaboración propia.

Nota: a) Imagen de la fracción de abundancia del *endmember*; b) Imagen original en composición falso color 5-6-3; c) Comparación a nivel de detalle de la imagen original y de la fracción de abundancia del *endmember*; d) Vista *endmember* en la imagen Google Earth del 16/07/2019. e) Firma espectral del *endmember* extraída de la imagen.

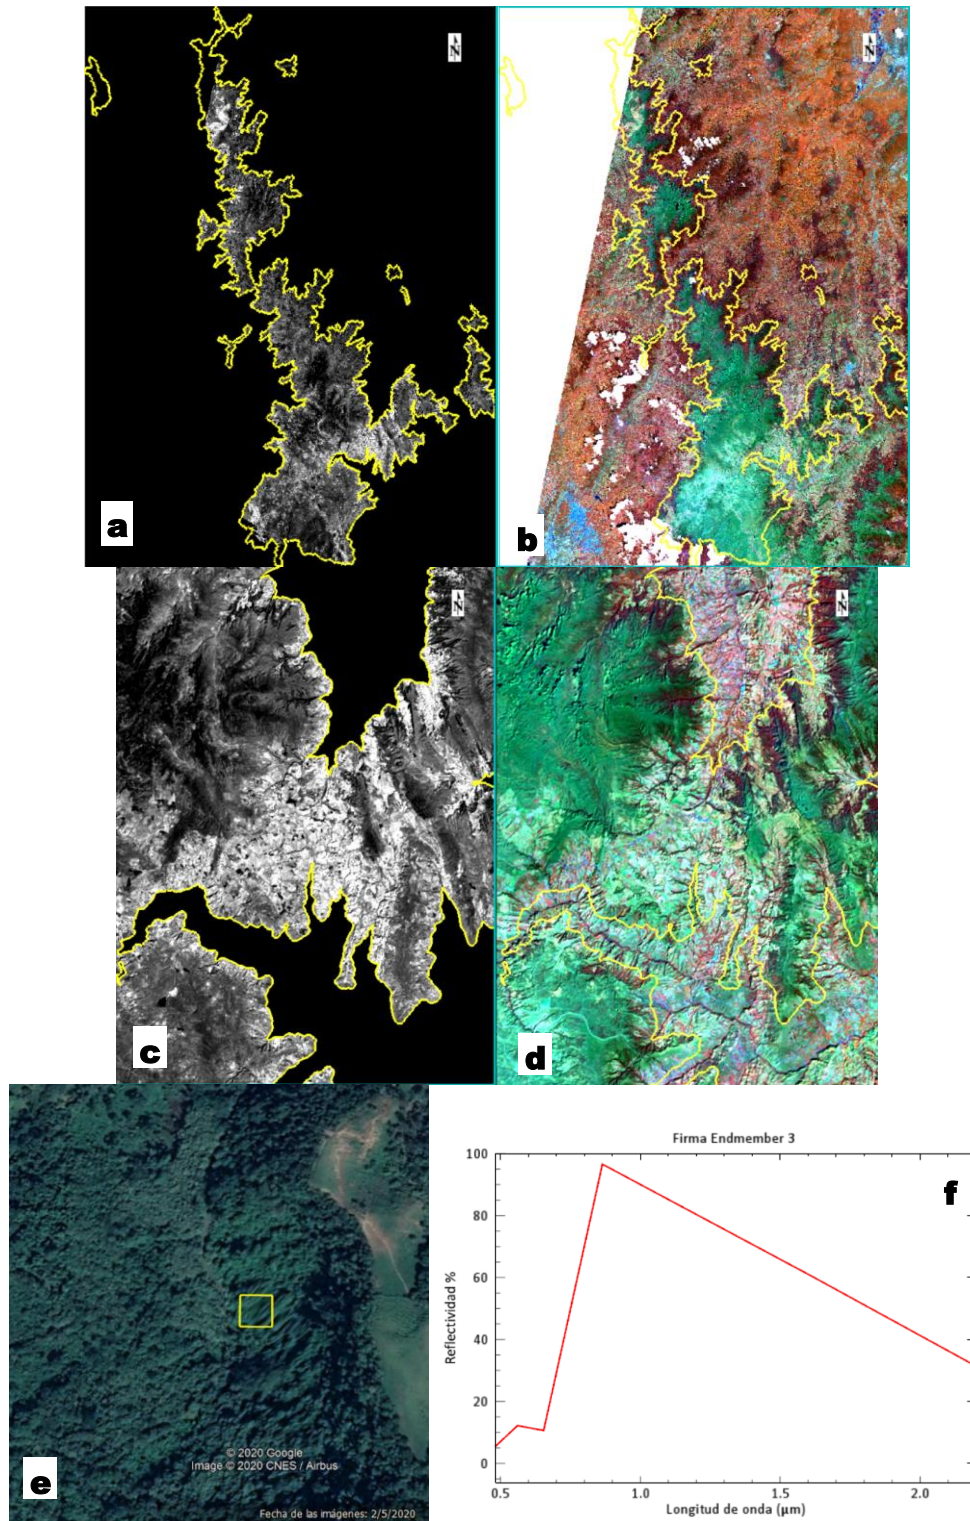


Figura 78. Asignación de clase al *endmember 3*: Vegetación secundaria en transición (32) y cultivos (2).

Fuente: elaboración propia.

Nota: a) Imagen de la fracción de abundancia del *endmember*; b) Imagen original en composición falso color 5-6-3; c) Comparación a nivel de detalle de la imagen original y de la fracción de abundancia del *endmember*; d) Vista *endmember* en la imagen Google Earth del 05/02/2020. e) Firma espectral del *endmember* extraída de la imagen.

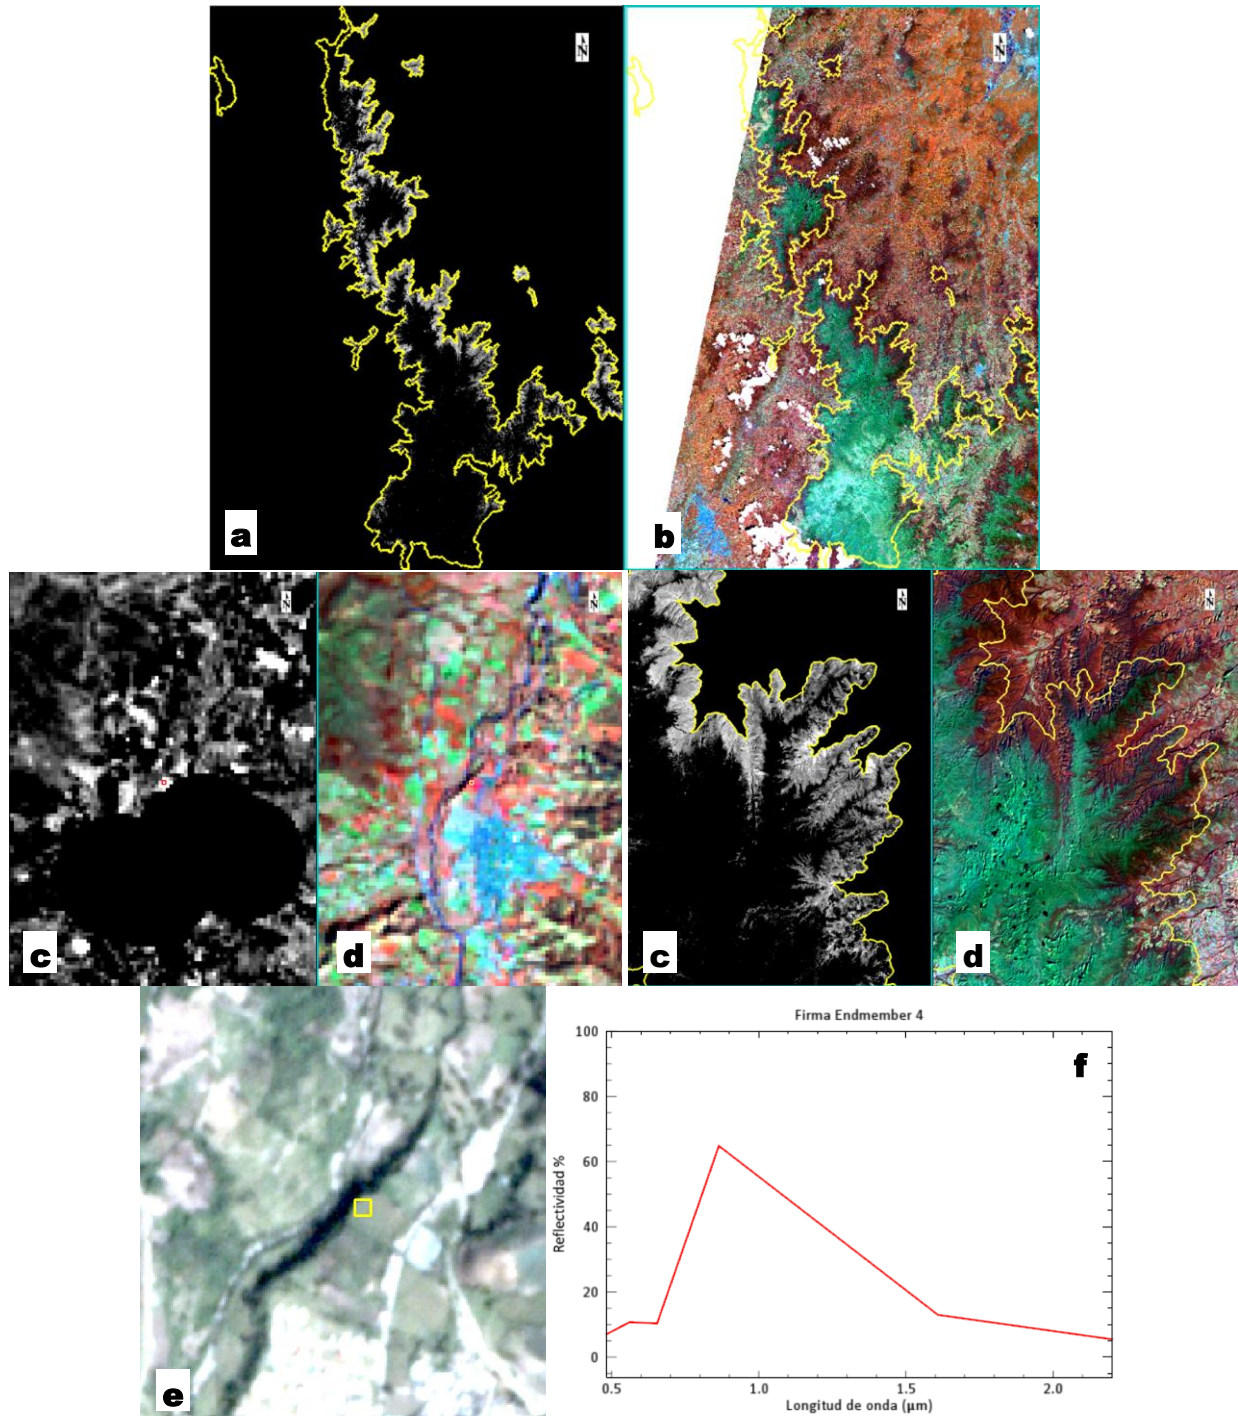


Figura 79. Asignación de clase al *endmember* 4: Bosques (31) y cultivos (2).

Fuente: elaboración propia.

Nota: a) Imagen de la fracción de abundancia del *endmember*; b) Imagen original en composición falso color 5-6-3; c) Comparación a nivel de detalle de la imagen original y de la fracción de abundancia del *endmember*; d) Vista *endmember* en la imagen Planet Scope del 21/12/2017. e) Firma espectral del *endmember* extraída de la imagen.

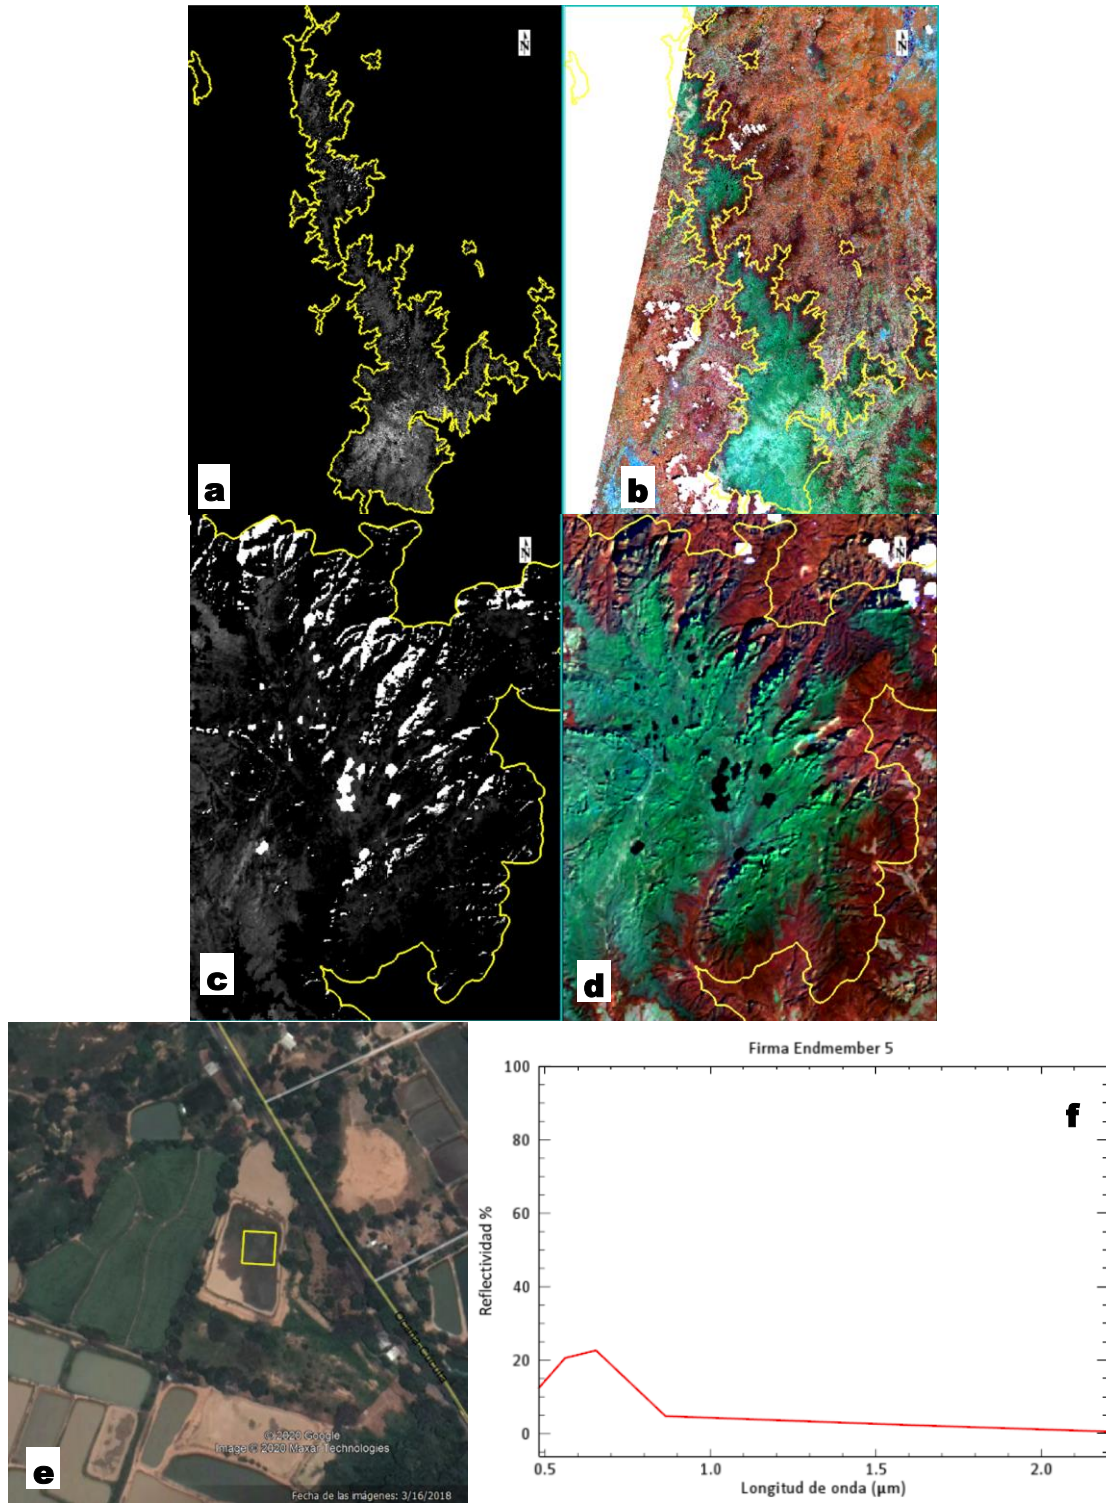


Figura 80. Asignación de clase al *endmember* 5: Aguas continentales (51).

Fuente: elaboración propia.

Nota: a) Imagen de la fracción de abundancia del *endmember*; b) Imagen original en composición falso color 5-6-3; c) Comparación a nivel de detalle de la imagen original y de la fracción de abundancia del *endmember*; d) Vista *endmember* en la imagen Google Earth del 16/08/2018. e) Firma espectral del *endmember* extraída de la imagen.

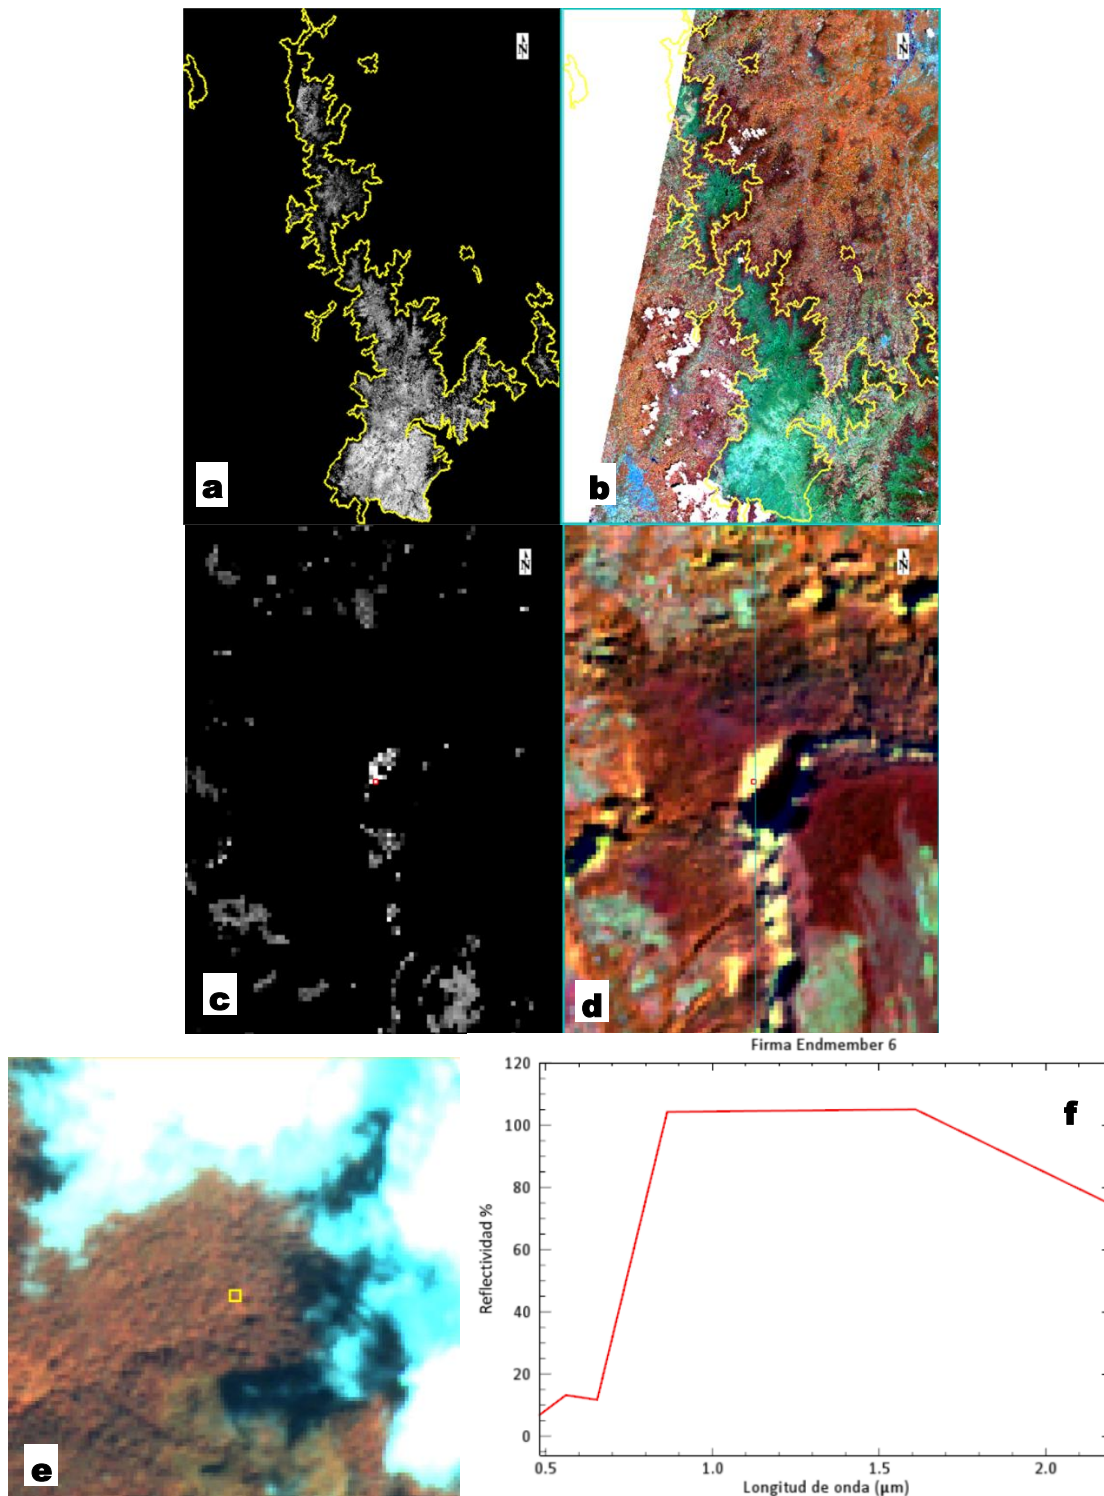


Figura 81. Asignación de clase al *endmember* 6: Pastors (23).

Fuente: elaboración propia.

Nota: a) Imagen de la fracción de abundancia del *endmember*; b) Imagen original en composición falso color 5-6-3; c) Comparación a nivel de detalle de la imagen original y de la fracción de abundancia del *endmember*; d) Vista *endmember* en la imagen Sentinel 2 del 17/11/2019. e) Firma espectral del *endmember* extraída de la imagen.

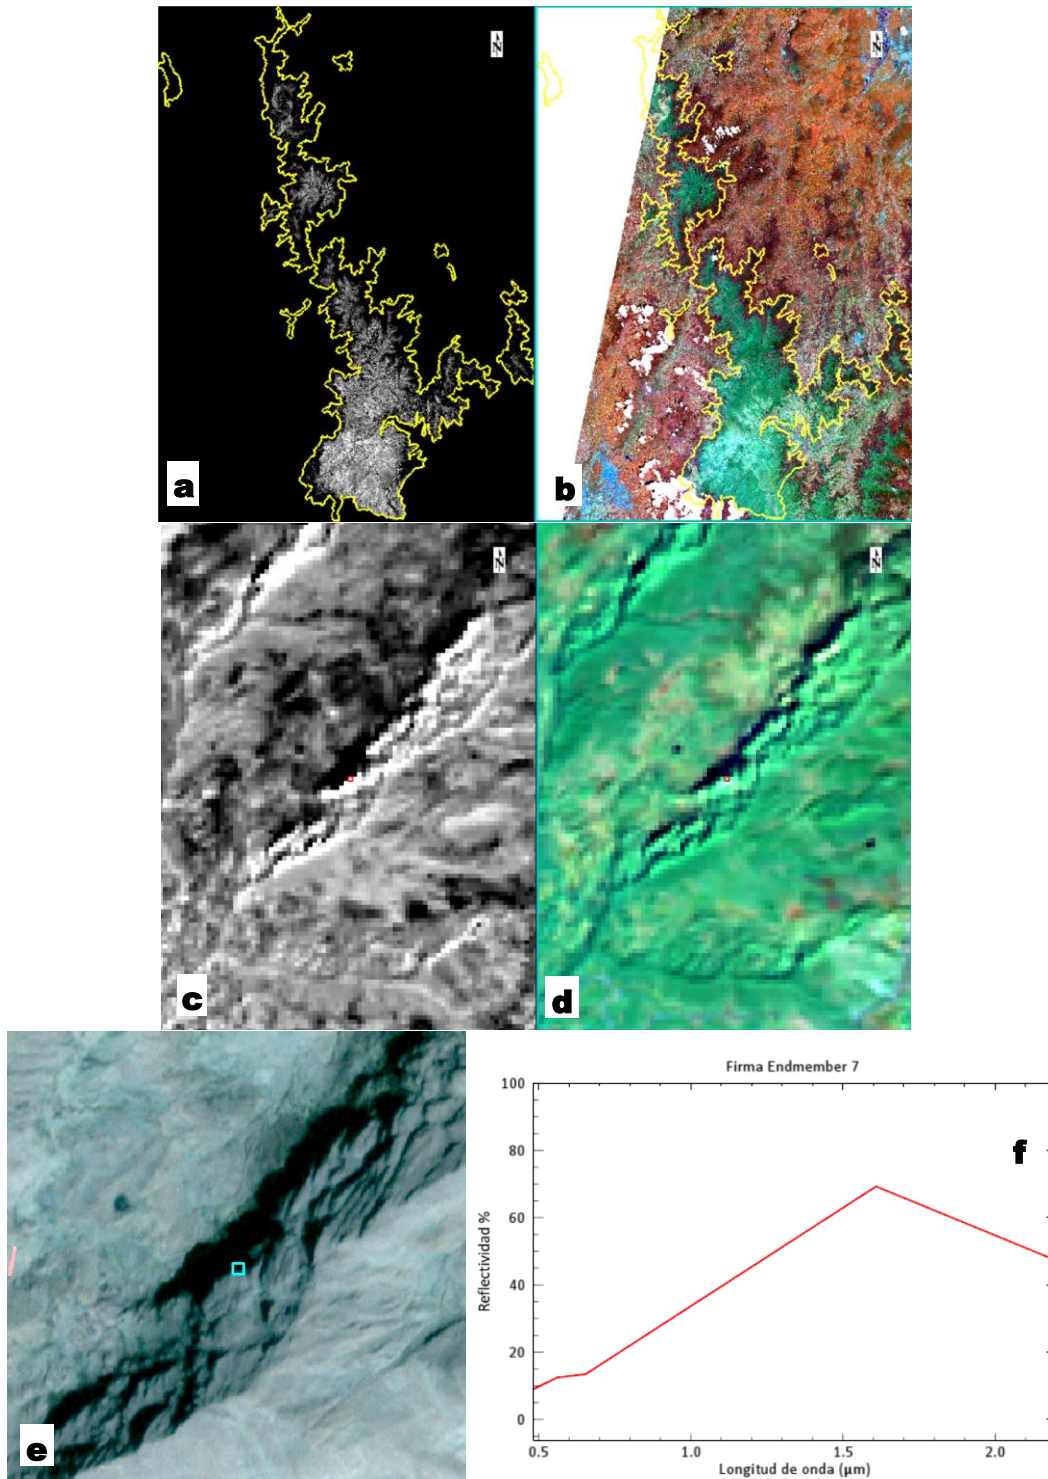


Figura 82. Asignación de clase al *endmember* 7: Tierras desnudas y degradadas (333).

Fuente: elaboración propia.

Nota: a) Imagen de la fracción de abundancia del *endmember*; b) Imagen original en composición falso color 5-6-3; c) Comparación a nivel de detalle de la imagen original y de la fracción de abundancia del *endmember*; d) Vista *endmember* en la imagen Planet Scope 21/12/2017; e) Firma espectral del *endmember* extraída de la imagen.

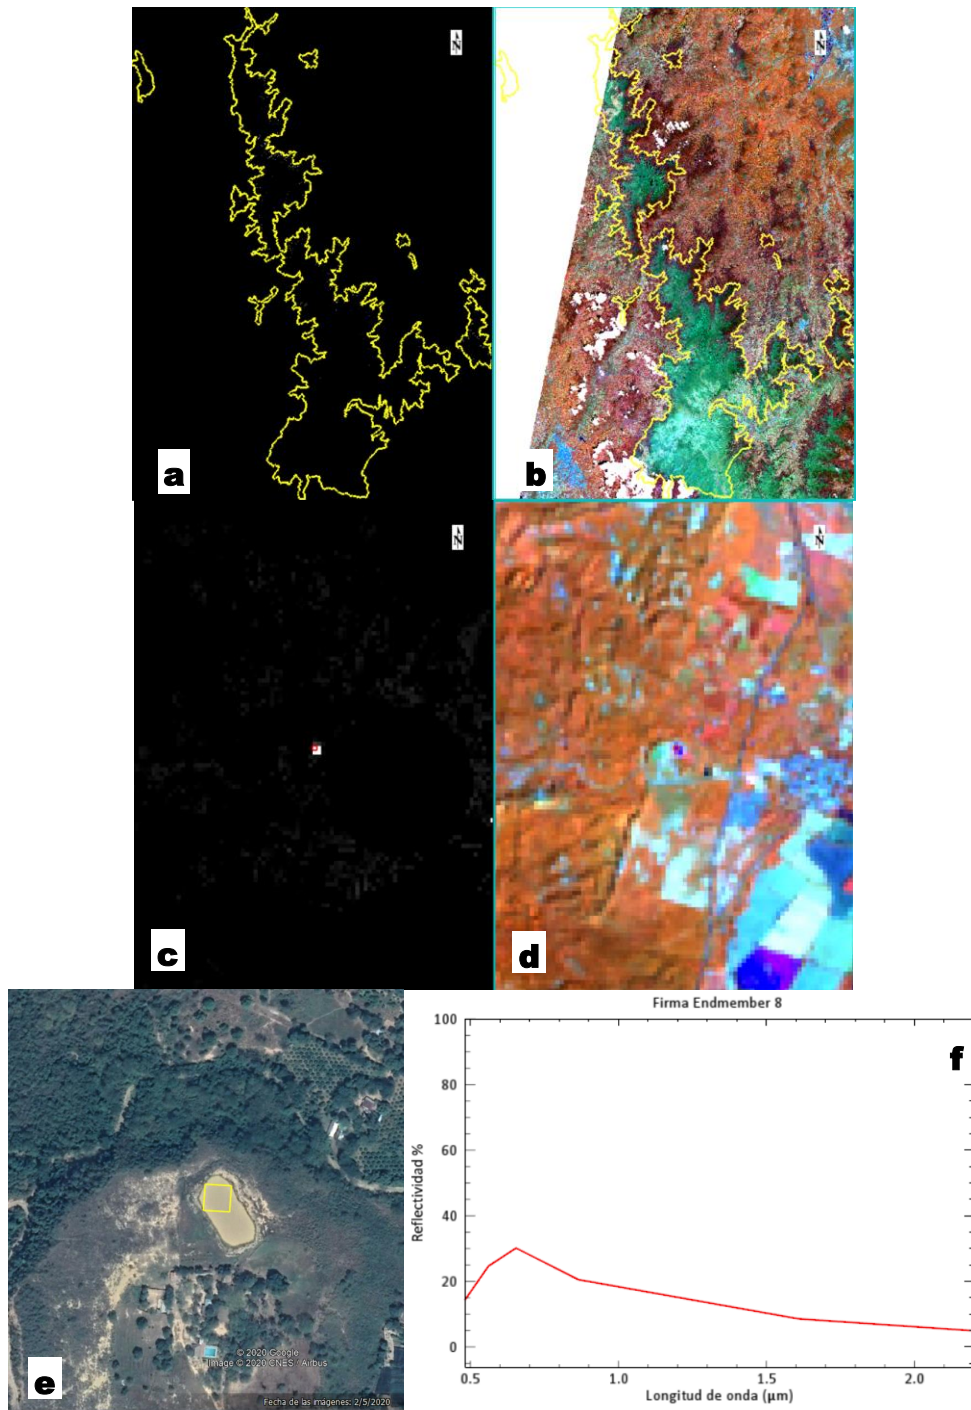


Figura 83. Asignación de clase al *endmember 8*: Zonas húmedas (4).

Fuente: elaboración propia.

Nota: a) Imagen de la fracción de abundancia del *endmember*; b) Imagen original en composición falso color 5-6-3; c) Comparación a nivel de detalle de la imagen original y de la fracción de abundancia del *endmember*; d) Vista *endmember* en la imagen Google Earth 05/02/2020; e) Firma espectral del *endmember* extraída de la imagen.

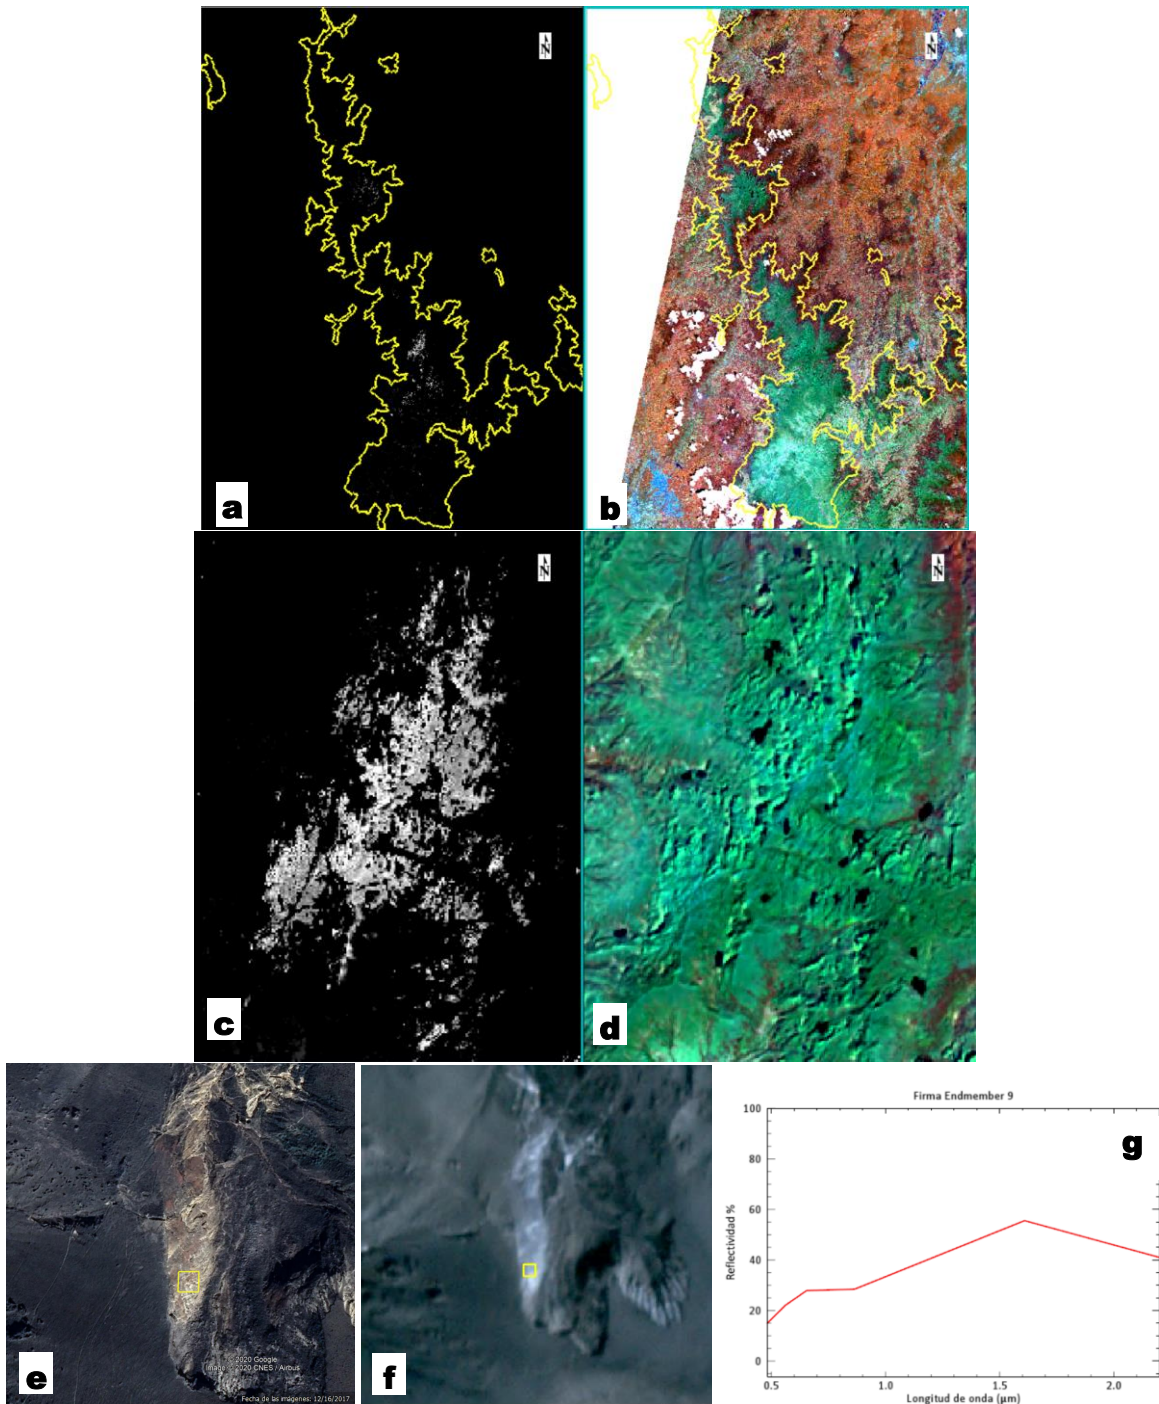


Figura 84. Asignación de clase al *endmember 9*: Afloramientos rocosos (332).

Fuente: elaboración propia.

Nota: a) Imagen de la fracción de abundancia del *endmember*; b) Imagen original en composición falso color 5-6-3; c) Comparación a nivel de detalle de la imagen original y de la fracción de abundancia del *endmember*; d) Vista *endmember* en la imagen Google Earth 12/16/2017; e) Vista *endmember* en la imagen Planet Scope 21/12/2017; f) Firma espectral del *endmember* extraída de la imagen.