



UNIVERSIDAD  
**NACIONAL**  
DE COLOMBIA

# **Metodología para el análisis automático de imágenes de sensores remotos de alta resolución basada en líneas**

**Jaime López Carvajal**

Universidad Nacional de Colombia  
Facultad de Minas  
Departamento de Ciencias de la Computación y de la Decisión  
Medellín, Colombia  
2016



# **Metodología para el análisis automático de imágenes de sensores remotos de alta resolución basada en líneas**

**Jaime López Carvajal**

Tesis o trabajo de investigación presentada(o) como requisito parcial para optar al título de:

**Doctor en Ingeniería – Sistemas e Informática**

Director:

John Willian Branch Bedoya, PhD.

Línea de Investigación:

Inteligencia Artificial

Grupo de Investigación:

Grupo de Investigación y Desarrollo en Inteligencia Artificial  
(GIDIA)

Universidad Nacional de Colombia

Facultad de Minas

Departamento de Ciencias de la Computación y de la Decisión

Medellín, Colombia

2016



*A mis padres, Jaime y Ana  
...que me enseñaron el camino.*

*A mis hermanas, Victoria y Sandra  
...que me acompañaron en el camino.*

*A mis hijas, Sarah y Laura  
...para enseñarles el camino.*



## **Agradecimientos**

Agradezco a la Universidad del Tolima, por concederme la posibilidad de realizar mis estudios de doctorado durante el cual aprendí nuevos conceptos científicos y metodologías de investigación, para elevar mi capacidad investigativa.

Agradezco al Profesor John Willian Branch, PhD. Director de mi tesis, por su orientación y acompañamiento durante el desarrollo de la presente investigación, por ayudarme a mejorar significativamente la calidad del trabajo, por brindarme la posibilidad de asistir a eventos académicos de primer nivel, y por permitirme compartir con los miembros de su grupo de investigación sobre inteligencia artificial y procesamiento de imágenes de la Facultad de Minas de la Universidad Nacional de Colombia , sede Medellín.

Agradezco al Profesor Gang Chen, PhD., Director del Laboratorio de Sensores Remotos del Departamento de Geografía de la Universidad de Charlotte (USA), por invitarme a realizar una pasantía en su grupo de investigación y participar en un proyecto de investigación sobre utilización de los sensores remotos en la evaluación del impacto de los bosques en el entorno urbano.





## Resumen

Las imágenes de sensores remotos de muy alta resolución contienen información muy detallada sobre los objetos que se encuentran sobre la superficie de la tierra, lo que permite visibilizar patrones adicionales, pero cuya extracción eficiente usando técnicas de procesamiento automático se torna muy compleja, por lo que se hace necesario desarrollar nuevas técnicas que permitan detectarlos y clasificarlos.

Esta investigación aborda una nueva aproximación basada en líneas, que permiten extraer la información requerida para determinar de forma automática la escala de la imagen, el proceso de segmentación, y finalmente, la clasificación de los objetos; conformando una metodología integrada, que utiliza solamente la información inherente a la escena bajo estudio, permitiendo determinar los parámetros requeridos para las técnicas utilizadas. Teniendo en cuenta lo anterior, se propuso como objetivo principal de esta investigación, proponer una metodología para el procesamiento automático de las imágenes de sensores remotos de alta resolución extrayendo la información requerida a partir de la línea seleccionada para la escena bajo estudio.

Los resultados alcanzados demuestran que los métodos desarrollados para la determinación de la escala en la imagen, la segmentación y la clasificación, basados en la aproximación en líneas, logró rendimientos competitivos frente a los métodos vigentes, que usualmente requieren la participación de un experto o usuario, quien es el encargado de seleccionar los parámetros de acuerdo a su conocimiento o experiencia.

Se puede concluir que la metodología basada en líneas desarrollada en esta investigación, que enlaza secuencialmente tres fases fundamentales en el procesamiento y análisis de imágenes de sensores remotos, ha demostrado un buen rendimiento, lo que permite vislumbrar un alto potencial a futuro.

**Palabras clave: VHRS, Sensores Remotos, Procesamiento de Imágenes, Aprendizaje de Máquinas, Metodología.**

## Abstract

The high resolution remote sensing images contain very detailed information about objects on earth's surface, showing additional patterns, but whose efficient extraction using automatic processing techniques becomes very complex, making it necessary to develop new techniques to detect and classify them.

This research presents a new approach based on lines, that allows to extract automatically the information required to determine the image scale, to guide the image segmentation process, and finally, to classify objects; conforming an integrated methodology, which uses only the information inherent to the scene under study, allowing to determine the parameters required for the techniques used. Taking this into account, it was proposed as this research's main objective, to propose a methodology for automatic processing of remote sensing images with very high resolution extracting the required information from the line previously selected for the scene under study.

The results shows these developed methods for image's scale determination, segmentation and classification, based on line approach, giving competitive returns against current methods, which usually require experto/user participation to choose the appropriate parameter setting according to their knowledge or experience.

It can be concluded that the line-based methodology developed in this research, which integrates three fundamental stages on processing and analysis of remote sensing images, has demonstrated good performance and envisions a high potential for the future.

**Keywords: VHSR, Remote sensing, Image processing, Machine learning, Methodology**

# Contenido

	Pág.
<b>Resumen</b>	IX
<b>Lista de figuras</b>	XIII
<b>Lista de tablas</b>	XV
<b>Lista de algoritmos</b>	XVI
<b>1. INTRODUCCION .....</b>	<b>17</b>
1.1 Motivación .....	18
1.2 Trabajos previos.....	19
1.3 Descripción del problema .....	20
1.4 Objetivos .....	21
1.4.1 General.....	21
1.4.2 Específicos .....	21
1.5 Contribuciones .....	22
1.6 Estructura.....	22
<b>2. MARCO TEÓRICO .....</b>	<b>25</b>
2.1 Introducción.....	25
2.2 Procesamiento y análisis de imágenes de sensores remotos.....	27
2.3 Paradigmas existentes .....	28
2.4 Aproximación basada en líneas.....	29
2.5 Objetos geográficos .....	30
<b>3. MÉTODO PARA LA DETERMINACION DE LA ESCALA EN LAS IMÁGENES DE SENSORES REMOTOS BASADO EN LA ENTROPIA .....</b>	<b>33</b>
3.1 Concepto de la escala.....	34
3.2 Métodos existentes .....	35
3.3 Entropía .....	36
3.4 Metodología .....	38
3.4.1 Selección de imágenes.....	38
3.4.2 Cálculo de la entropía.....	40
3.4.3 Determinación de la escala.....	41
3.5 Resultados .....	44
3.6 Conclusiones.....	48
<b>4. MÉTODO PARA LA SEGMENTACIÓN AUTOMÁTICA DE IMÁGENES DE SENSORES REMOTOS BASADO EN CRECIMIENTO DE REGIONES .....</b>	<b>51</b>

---

4.1	Crecimiento de regiones .....	53
4.2	Metodología .....	54
4.2.1	Preprocesamiento de la imagen .....	55
4.2.2	Definición de parámetros de segmentación .....	55
4.2.3	Crecimiento de regiones .....	56
4.3	Resultados .....	57
4.3.1	Evaluación cualitativa .....	58
4.3.2	Evaluación cuantitativa .....	60
4.4	Conclusiones .....	65
<b>5.</b>	<b>METODO PARA LA CLASIFICACIÓN NO SUPERVISADA DE IMÁGENES DE SENSORES REMOTOS BASADA EN AGRUPAMIENTO JERÁRQUICO .....</b>	<b>67</b>
5.1	Clasificación no supervisada Jerárquica Aglomerativa .....	69
5.2	Atributos .....	70
5.2.1	Información espectral .....	71
5.2.2	Textura .....	71
5.2.3	Vecindad .....	72
5.3	Metodología .....	73
5.3.1	Numero de clusters .....	73
5.3.2	Clasificación jerárquica aglomerativa .....	74
5.3.3	Dendrogramas .....	74
5.4	Resultados .....	75
5.5	Conclusiones .....	80
<b>6.</b>	<b>DISCUSION DE RESULTADOS SOBRE LA METODOLOGIA EN LINEAS .....</b>	<b>81</b>
<b>7.</b>	<b>Conclusiones y recomendaciones .....</b>	<b>86</b>
7.1	Conclusiones .....	86
7.2	Recomendaciones .....	87
	<b>BIBLIOGRAFIA .....</b>	<b>91</b>

## Lista de figuras

<b>Figura 1.1.1.</b> Estructura de la tesis .....	23
<b>Figura 2.1.1.</b> Representación de una imagen a color con 3 canales espectrales correspondientes al rojo, verde y azul. ....	26
<b>Figura 2.2.</b> Macrocomponentes del procesamiento y análisis de imágenes de sensores remotos .....	27
<b>Figura 2.3.</b> Representación gráfica de un objeto de acuerdo a la unidad básica de procesamiento.....	29
<b>Figura 2.4.</b> Imagen de sensor remoto (izquierda) junto con los objetos geográficos delimitados (derecha), arboles, suelo desnudo y lecho seco de un río. ....	30
<b>Figura 3.1.</b> Incremento del valor de la entropía a medida que aumenta la cantidad de niveles gris diferentes en el vector.....	37
<b>Figura 3.2.</b> Imágenes VSHR (arriba) y HSR (abajo) correspondientes a las ciudades de Madrid, Tokio, Charlotte, Barcelona (dos) y Seattle.....	39
<b>Figura 3.3.</b> Fragmento de imagen ilustrando las direcciones utilizadas para el trazado de las líneas (no se han trazado el total de 1360 líneas usadas para no ocultar la imagen de fondo).....	40
<b>Figura 3.4.</b> Gráfica que ilustra el punto de inflexión [12, 110] para la curva. ....	42
<b>Figura 3.5.</b> Trazado de las líneas que poseen con el valor de entropía más alto para cada una de las imágenes utilizadas. ....	45
<b>Figura 3.6.</b> Ilustración manual (cuadro rojo) de los objetos identificables en cada imagen de acuerdo a la escala determinada por el método propuesto.....	48
<b>Figura 4.1.</b> Diagrama de flujo del método de segmentación automático propuesto. ....	54
<b>Figura 4.2.</b> Imágenes VHRS utilizadas para evaluar el desempeño del método de segmentación.....	57
<b>Figura 4.3.</b> Comparación visual de la segmentación (borde rojo) bajo los tres métodos sobre diferentes objetos geográficos. ....	59
<b>Figura 4.4.</b> Traslape de la segmentación (borde rojo) sobre las imágenes VHRS en escala de grises bajo los tres métodos utilizados. ....	63
<b>Figura 4.5.</b> a) Precisión (%) y b) Sobre-segmentación de los tres métodos .....	64
<b>Figura 5.1.</b> Tipos de clasificación de imágenes: a) Clasificación no supervisada, que utiliza solo atributos (x) de las instancias, b) Clasificación supervisada, que utiliza atributos y clases (x,y) del conjunto de datos. ....	67
<b>Figura 5.2.</b> Dendrograma invertido que ilustra la estructura típica de un agrupamiento. 69	

<b>Figura 5.3.</b> Clasificación de las imágenes VHRS obtenidas con diferentes combinaciones de los atributos.....	76
<b>Figura 5.4.</b> Dendrogramas correspondientes a la agrupación jerárquica aglomerativa para cada imagen VHRS. ....	77
<b>Figura 5.5.</b> Reclasificación de cada imagen con ayuda del dendrograma. ....	78
<b>Figura 6.1.</b> Diagrama de flujo de la metodología basada en líneas, indicando los procesos y los subprocesos (azul medio y azul claro respectivamente), mientras los productos finales se indican con azul oscuro. ....	83

## Lista de tablas

<b>Tabla 2.1.</b> Sub-componentes de las fases de procesamiento y análisis. ....	27
<b>Tabla 3.1.</b> Características de las imágenes utilizadas. ....	39
<b>Tabla 3.2.</b> Valor de escala obtenido con los diferentes métodos, junto con los promedios discriminados por tipo de imagen (VHSR y HSR). ....	46
<b>Tabla 4.1.</b> Métricas utilizadas para evaluar la segmentación. ....	58
<b>Tabla 4.2.</b> Valores de las métricas de evaluación para los tres métodos utilizados. ....	61
<b>Tabla 5.1.</b> Atributos extraídos de la matriz de coocurrencia. ....	72
<b>Tabla 5.2.</b> Métricas de evaluación de la clasificación no supervisada. ....	79
<b>Tabla 6.1.</b> Tiempos de ejecución para cada uno de los procesos involucrados para tres imágenes VHSR. ....	84

## Lista de Algoritmos

<b>Algoritmo 3.1.</b> Conteo de objetos geográficos y llenado de vectores.....	41
<b>Algoritmo 3.2.</b> Suavizamiento del vector para obtencion de etiquetas .....	43
<b>Algoritmo 4.1.</b> Descripción del algoritmo de crecimiento de regiones.....	57
<b>Algoritmo 5.1.</b> Clasificación jerárquica aglomerativa.....	74



# 1.INTRODUCCION

Actualmente, existe una gran variedad de plataformas y sensores que capturan constantemente imágenes de la superficie terrestre con resolución espacial submétrica (GSD Ground Sample Distance en inglés), denominadas imágenes VHRS (*Very High Spatial Resolution* en inglés), las cuales se prevé que tendrán un alto impacto sobre un amplio espectro de aplicaciones, tanto en la ingeniería como en el medio ambiente, pero al mismo tiempo, estas imágenes representan un reto importante debido al incremento significativo en el volumen de datos, así como en la complejidad de los algoritmos para su análisis e interpretación.

Las imágenes de sensores remotos VHRS brindan información muy detallada sobre los objetos presentes en la superficie terrestre, haciendo visibles patrones complejos, cuya identificación y extracción eficiente utilizando técnicas de clasificación automáticas se torna muy compleja, porque se debe lidiar con la alta heterogeneidad espectral al interior de los objetos, y simultáneamente con la similaridad espectral entre diferentes objetos, la alta variabilidad espacial y naturaleza multiescala de los objetos de interés, por lo que se requiere desarrollar técnicas que permitan detectarlos y reconocerlos apropiadamente.

El procesamiento y análisis automático de imágenes VHRS se considera una aproximación con un alto potencial para igualar o superar las habilidades de expertos humanos, aunque no está exento de dificultades por superar. Se considera de especial importancia el estudio de los patrones espaciales de los objetos geográficos presentes en las imágenes, profundizando en su naturaleza y propiedades intrínsecas, para la construcción de modelos que incorporen la información contextual, en forma de conocimiento a priori sobre la escena, que permita avanzar paso a paso hacia el reconocimiento automático de los datos y aportar elementos que permitan su reusabilidad y transferibilidad.

## 1.1 Motivación

El procesamiento y análisis automático de las imágenes de sensores remotos presenta un enorme potencial debido a la existencia de gran cantidad de sensores (aéreos o satelitales) que continuamente están capturando imágenes de la superficie terrestre, conteniendo información detallada de las características de los objetos que componen la escena.

Estos objetos presentes en las imágenes de sensores remotos, se denominan objetos geográficos, dado que su naturaleza ligada a la geografía física del terreno sobre el cual se encuentran, siendo condicionados por la topografía, el clima, las características de suelo, y por supuesto, por la población asentada en la zona.

Esta información que contienen las imágenes sobre los objetos geográficos, se torna muy valiosa para la toma de decisiones que involucran la conservación y manejo del medio ambiente, el desarrollo de proyectos de infraestructura, la planificación y gestión del ordenamiento territorial, el apoyo para la prevención y atención de desastres ambientales, la gestión del territorio para las comunidades asentadas en la región, el monitoreo y control de cultivos, el estudio del comportamiento de los cuerpos de agua (ríos o embalses), entre muchas otras aplicaciones (militar, negocios, turismo, etc.).

Para la extracción, selección, procesamiento y análisis de esta información contenida en las imágenes se requiere la ejecución de un proceso generalmente de tipo secuencial, que aborda diferentes etapas, conocidas como pre-procesamiento, procesamiento y post-procesamiento. Este proceso parte de un conjunto de datos (imágenes), que son sometidos a diferentes tratamientos y técnicas, para obtener un producto final, que puede ser un mapa, una imagen o un archivo, dependiendo del tipo de proyecto o entidad que requiere el procesamiento de esta información.

Este es un proceso fundamentalmente dependiente del factor humano, porque son los expertos, científicos, ingenieros o usuarios los encargados de tomar las decisiones en todas las fases del mismo; desde seleccionar las imágenes, pasando por las técnicas apropiadas, hasta la validación del producto final; lo que lo convierte en un proceso subjetivo, poco eficiente, costoso y difícilmente transferible.

Por tal motivo, se requiere el desarrollo de métodos automáticos para el procesamiento y análisis de las imágenes de sensores remotos, que permitan la extracción de información de una forma eficiente, reproducible, objetiva, continua y transferible que permita la generación y actualización de bases de datos sobre el medio ambiente y el componente social.

## 1.2 Trabajos previos

En general, no se encuentran trabajos que consideren simultáneamente los tres procesos involucrados en esta tesis, sino que se han abordado de forma independiente, produciendo resultados alentadores, o que permiten abrir nuevas sendas de investigación, y que resultan muy numerosos, pero que destacaremos algunos de los más importantes o representativos en el área del procesamiento y análisis de las imágenes de sensores remotos.

Cheng & Han (2016) abordan la detección de objetos en las imágenes de sensores remotos, como un área que desempeña un rol importante en un amplio rango de aplicaciones, destacando los recientes progresos que se han llevado a cabo sobre categorías de objetos genéricas, comparando diferentes métodos de detección, como los basados en templates, en conocimiento, en objetos y en aprendizaje de máquinas, proponiendo dos líneas de investigación promisorias, como la representación de atributos basados en deep learning y la detección de objetos geoespaciales basada en aprendizaje supervisado débil.

Wang et al. (2010), destacan el alto potencial del análisis de imágenes de sensores remotos basado en objetos, especialmente sobre imágenes de alta resolución (VHRS). Propusieron un algoritmo automático de segmentación basado en regiones que utiliza el agrupamiento k-means, llamado Region-based Image Segmentation Algorithm (RISA sigla en inglés), que se compone de 5 fases, agrupamiento k-means, inicialización de segmentos, generación de semillas, crecimiento de regiones y fusión de regiones, el cual genera regiones homogéneas que representan exitosamente los objetos de referencia.

En cuanto a la clasificación no supervisada, existen varias propuestas para la determinación del número de clusters, pero todavía es un problema no resuelto, porque

depende tanto del método de agrupamiento, como de las características de la distribución de los datos. En el área procesamiento de imágenes Xiang y Gong (2008), han propuesto la estimación del número de clusters bajo una agrupación jerárquica, para la segmentación de imágenes, que resulta muy útil para identificar objetos diferentes, utilizando una aproximación basada en aprendizaje de máquinas y el reconocimiento de patrones. Mientras, Reza & Torre (2009) propusieron un método para la determinación del número de clusters, utilizando una función que incorpora la forma y la textura, brindando buenos resultados sobre distintas bases de datos de imágenes de texturas, como Brodatz y UICTex.

### **1.3 Descripción del problema**

El procesamiento y análisis de las imágenes de sensores remotos de alta resolución (VHSR sigla en inglés) no es una tarea sencilla (Dos Santos et al., 2013). A pesar de los avances significativos que se han logrado desde el análisis visual y descriptivo de estas imágenes, todavía falta mucho por investigar sobre la derivación de información cuantitativa a partir de ellas.

Los componentes biofísicos básicos de los paisajes, capturados por las imágenes VHSR de sensores remotos, exhiben propiedades distintivas y discretas detectables (patrones), pero no a través de los píxeles individuales, los cuales tienen poco significado por sí mismos, sino a través de su agregación en unidades espaciales denominadas objetos geográficos. Aunque la habilidad para extraer información de los objetos geográficos e interpretarlos depende no solo de las capacidades del sensor, sino en cómo manipularlos para convertirlos en productos mejorados para el análisis e interpretación, por lo que se considera que la clave está en aprovechar las características de los objetos en la escena, como su variabilidad espectral, su contorno, su geometría o su contexto espacial.

Generalmente, el procesamiento y análisis de las imágenes de sensores remotos depende en su mayoría del factor humano, es decir, del conocimiento de un experto o la experiencia del usuario, quienes en primera instancia, realizan una interpretación visual de la escena, luego seleccionan el método o técnicas apropiados para extraer la información requerida y definen los parámetros de operación utilizando la metodología de ensayo-error. Finalmente, validar el resultado, tanto cualitativa (visual) como cuantitativamente

(métricas), y en caso de no superar los requerimientos mínimos, se debe repetir el proceso nuevamente. Este proceso se torna muy costoso en tiempo, no es reproducible y requiere una constante verificación de la calidad.

Esta tesis aborda el procesamiento automático de imágenes de sensores remotos bajo una aproximación basada en líneas, donde no hay participación de un experto orientando el proceso, sino que la metodología propuesta extrae la información requerida a partir de los datos intrínsecos que brinda la imagen, determina los parámetros de los algoritmos utilizados para la determinación de la escala, la segmentación y la clasificación, entregando una imagen con los objetos geográficos representativos de la imagen.

## **1.4 Objetivos**

### **1.4.1 General**

Proponer una metodología para el procesamiento y análisis automático de imágenes VHSR de sensores remotos basado en objetos geográficos que incorpore los patrones contextuales de la escena.

### **1.4.2 Específicos**

Proponer un método para determinación automática de la escala de imágenes de alta resolución utilizando la información inherente de la imagen.

Desarrollar un método de segmentación automático de objetos geográficos presentes en las imágenes de alta resolución basado en crecimiento de regiones.

Plantear un método de clasificación no supervisado de las imágenes de alta resolución bajo una estrategia adaptativa que incorpore patrones contextuales de los objetos geográficos como información a priori en el proceso.

Integrar los métodos desarrollados como parte de una metodología automática para el análisis de imágenes de sensores remotos basado en líneas evaluando su desempeño con respecto a los objetos geográficos.

## 1.5 Contribuciones

El aporte principal de esta tesis consiste en el diseño de una metodología basada en líneas para el procesamiento automático de las imágenes de sensores remotos de alta resolución, que involucra varias etapas de forma secuencial (escala, segmentación y clasificación); y que cumple con varias características deseables, como son su buen rendimiento, eficiencia, reproducibilidad y transferibilidad.

En particular, las contribuciones que se desarrollaron fueron:

Un método automático para la determinación de la escala en las imágenes de sensores remotos que utiliza la entropía para seleccionar la línea con la mayor diversidad de niveles de gris en la escena, lo cual es proporcional al número de objetos diferentes en la escena, permitiendo identificar la escala de los objetos más representativos.

Un método automático para la segmentación de las imágenes de sensores remotos, donde a partir de la línea seleccionada, se realiza un proceso de unificación iterativo de los niveles de gris, el cual permite la construcción una curva que se somete a un proceso de optimización para encontrar su punto de inflexión, el cual se utiliza para definir los umbrales de parada durante el crecimiento de regiones durante la segmentación de la imagen.

Un método no supervisado para la clasificación de las imágenes de sensores remotos basado en el agrupamiento jerárquico, que recibe como parámetro el número de clusters a producir, cuyo valor también se obtiene a partir de la línea seleccionada para la imagen. Se utilizaron diferentes combinaciones de atributos de los objetos geográficos, como el componente de color (bandas espectrales), la textura (patrón) y relaciones de vecindad, resultando el componente de color como atributo que mejor discrimina las clases.

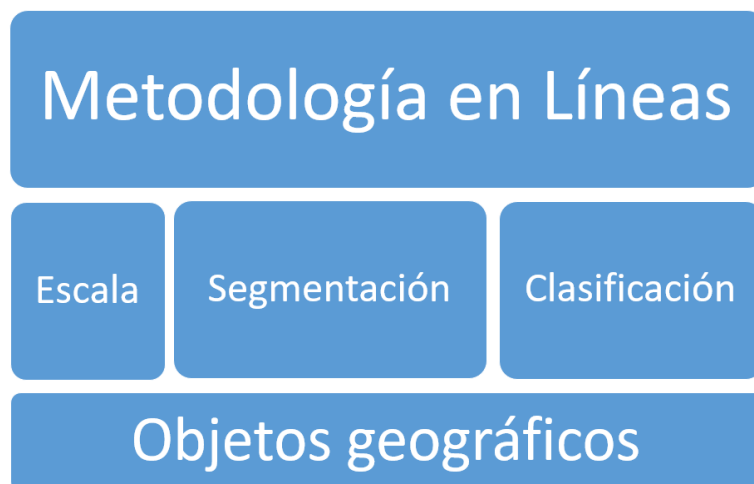
## 1.6 Estructura

La **Figura 1.1.1** ilustra la estructura de esta tesis, destacando los componentes principales de la metodología basada en líneas, orientada hacia el procesamiento y análisis de los objetos geográficos que aparecen en las imágenes de sensores remotos VHSR.

El capítulo II presenta un marco teórico referencial sobre los componentes fundamentales de la tesis, abordando los diferentes para. El capítulo III se enfoca en la determinación de

la escala de la imagen a través de un método que utiliza los objetos que se encuentran sobre la línea seleccionada en la imagen. El capítulo IV se presenta el método para la segmentación automática de las imágenes de sensores remotos, a partir del procesamiento de la línea seleccionada, se identifican los parámetros a utilizar para la delimitación de los objetos geográficos usando un algoritmo de crecimiento de regiones. El capítulo V describe el método de clasificación de los objetos utilizando una aproximación no supervisada, basado en el agrupamiento jerárquico conocido como *HAC (Hierarchical Agglomerative Clustering* en inglés). Finalmente, el capítulo VI, presenta la discusión de los resultados sobre la metodología basada en líneas, enlazando las tres etapas que integran la metodología propuesta, como son la escala, la segmentación y la clasificación, las cuales operan de forma secuencial. Inicialmente, se parte de una imagen de sensores remotos VHRS, se identifica la escala, la cual se utiliza para segmentar los objetos geográficos, y finalmente, esos objetos son clasificados utilizando atributos como el color, la textura y la vecindad bajo una aproximación no supervisada, para obtener como producto final, una imagen procesada automáticamente.

**Figura 1.1.1.** Estructura de la tesis







## 2.MARCO TEÓRICO

### 2.1 Introducción

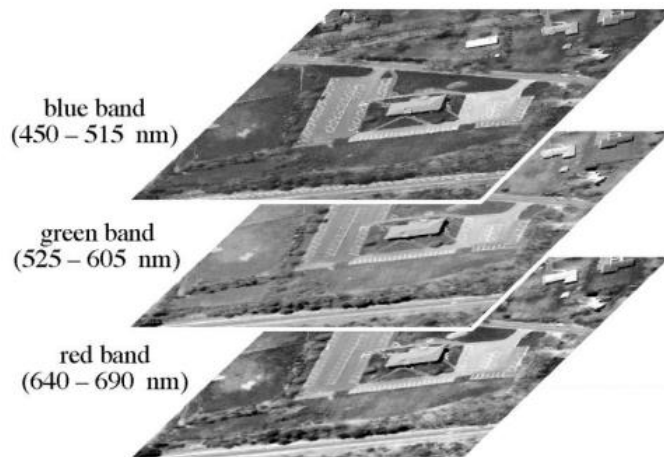
El procesamiento y análisis de imágenes (IPA sigla en inglés) consiste básicamente de cuatro etapas principales, como son: a) adquisición de la imagen, b) procesamiento de la imagen, c) análisis de la imagen, y d) interpretación de la imagen (Pinoli, 2014). La primera y la cuarta etapas están por fuera del ámbito de la presente investigación, por lo cual no se profundiza en ellas, pero a manera de descripción, puede mencionarse que la adquisición se enfoca en la tecnología de captura de las imágenes, el desarrollo de sensores especializados y la mejora de la imagen, mientras que la interpretación se orienta al entendimiento de la imagen, a partir de las relaciones que se descubren entre los objetos de la imagen.

Las etapas de interés en esta investigación, corresponden las etapas b) y c), como son el procesamiento y posteriormente el análisis, las cuales se describen a continuación. El procesamiento de las imágenes se refiere a todas aquellas operaciones y transformaciones que buscan mejorar la calidad del contenido de la imagen, mientras que el análisis de las imágenes se encarga de la extracción de información, tanto cualitativa y/o cuantitativa.

Una imagen digital se define un modelo aproximado de una escena, dado que generalmente constituye una representación parcial o incompleta, denominada FoV (*Field of View* en inglés), definido por el largo y ancho de una imagen bidimensional. Esta escena se compone de objetos localizados en un contexto, donde los objetos de interés dependerán del problema bajo estudio (ej. órganos, planetas, arboles, rostros, etc.), que para el caso de las imágenes de sensores remotos se identifican como objetos geográficos, denominación que hace referencia a la relación fundamental con la superficie física representada por la geografía terrestre, que utiliza un sistema de coordenadas, para la ubicación precisa de cada elemento sobre ella.

Una imagen digital bidimensional consta de una retícula (también conocida como matriz o grilla) compuesta por unidades básicas llamadas pixel, considerada la unidad fundamental de una imagen, que almacena un nivel de gris particular, que representa el valor de intensidad de la iluminación (luz incidente) reflejada por la escena y capturada por el sensor. Teniendo en cuenta lo anterior, de acuerdo al número de espectros (conocidos como canales o bandas espectrales) que posea la imagen, se clasifica como pancromática (1 canal), color (3 canales), multiespectral (4-15 canales) o hiperespectral (> 15 canales), (**Figura 2.1.1.** Representación de una imagen a color con 3 canales espectrales correspondientes al rojo, verde y azul.).

**Figura 2.1.1.** Representación de una imagen a color con 3 canales espectrales correspondientes al rojo, verde y azul.



En cuanto al proceso de formación de la imagen, el proceso multiplicativo es el más ampliamente aceptado (Gonzalez y Wintz, 1972), que denota la imagen como el producto de dos componentes fundamentales, la radiación incidente (iluminación) y la reflectancia, las cuales se combinan produciendo un valor de intensidad para cada unidad espacial (pixel), localizado en una posición  $(x,y)$ , de acuerdo a la siguiente función:


$$F(x,y) = I(x,y) \cdot R(x,y)$$

donde F, I, R representan la imagen, la intensidad y la reflectancia, respectivamente.

## 2.2 Procesamiento y análisis de imágenes de sensores remotos

Este campo del conocimiento surgió hacia los años 1960, con la publicación del libro *Picture processing by computer* de Rozenfeld (1969), y en la década de 1970 con el libro *Digital Image Processing* de Gonzalez y Wintz (1972) y *Digital Image Processing* de Pratt (1978), y específicamente para el área de conocimiento de los sensores remotos, las ediciones más recientes de los libros *Remote Sensing of the Environment* de Jensen (2007) y *Remote Sensing Digital Image Analysis* de Richards (2013). En general, el procesamiento de imágenes de sensores remotos involucra 3 fases, como se puede ver en la **Figura 2.2**, en el cual, el IPA, se desarrolla específicamente en la segunda fase, que involucra la conversión de los datos que contienen las imágenes en información útil extraída a partir de ellas.

**Figura 2.2.** Macrocomponentes del procesamiento y análisis de imágenes de sensores remotos



El IPA involucra varios componentes que generalmente se aplican de forma secuencial sobre las imágenes de sensores remotos, pero que no son de obligatorio uso, dado que algunos pueden intercalarse u obviarse, dependiendo de cada situación en particular. La Tabla 2.1, lista algunos de las tareas que usualmente se ejecutan en cada fase sobre las imágenes de sensores remotos (Jensen, 2007).

**Tabla 2.1.** Sub-componentes de las fases de procesamiento y análisis.

Componentes del IPA	
Procesamiento	Análisis
Corrección (Radiométrica, Geométrica)	Clasificación
Mejora del contraste	Medición
Eliminación de ruido	Modelamiento
Segmentación	Visualización

## 2.3 Paradigmas existentes

El procesamiento y análisis de las imágenes de sensores remotos, tradicionalmente ha utilizado la aproximación basada en el pixel, elemento considerado como la unidad mínima de información en una imagen; pero a partir del año 2000, ha surgido el análisis basado en objetos geográficos (Batz & Schape, 2000), que representan agrupaciones de pixeles que comparten propiedades homogéneas, demostrando resultados superiores en imágenes de alta resolución espacial (Blaschke, 2010; Castilla & Hay, 2008, Zhou et al., 2009), logrando progresos considerables en la extracción de información espacial explícita. Adicionalmente, existe la aproximación basada en campos (Aplin et al., 1999, Janssen & Molenaar, 1995), quienes proponen la integración de información basada en pixel junto con información vectorial procedente de un GIS (*Geographic Information System* siglas en inglés), aunque presenta muchas semejanzas con la aproximación basada en objetos.

La aproximación basada en pixeles se puede considerar la aproximación por defecto en el procesamiento y análisis de imágenes (Wilkinson, 2005), y que usualmente se utiliza como base para la comparación de nuevas propuestas. Esta aproximación es conceptualmente simple, porque solo utiliza la información del pixel bajo análisis, sin tener en cuenta su vecindad (Jahne, 2002, Budreski et al., 2007). Su popularidad alcanzó la cima en la década de los años 80, cuando la resolución espacial de las imágenes no era adecuada para otras aproximaciones (Unsalan & Boyer, 2011).

Por su parte, la aproximación basada en objetos geográficos se vislumbra como un método promisorio para reducir o cerrar la brecha entre la creciente cantidad de datos geo-espaciales detallados y el problema del reconocimiento de características complejas, demostrando mejoras en la precisión de la clasificación de imágenes entre un 7-18% al compararlo con la aproximación basada en pixel (Cleve et al., 2008; Whiteside, 2011); y especialmente porque éste enfoque tiene en cuenta el contexto, el cual se modela a través de las relaciones topológicas de la vecindad entre los diferentes objetos, generados previamente usando una técnica de segmentación (Lucieer, 2004; Blaschke, 2014). Este tipo de información contextual permite delinear y clasificar de forma eficiente los elementos del paisaje sobre la superficie de la tierra (Hay, 2005); que junto con la mayor disponibilidad

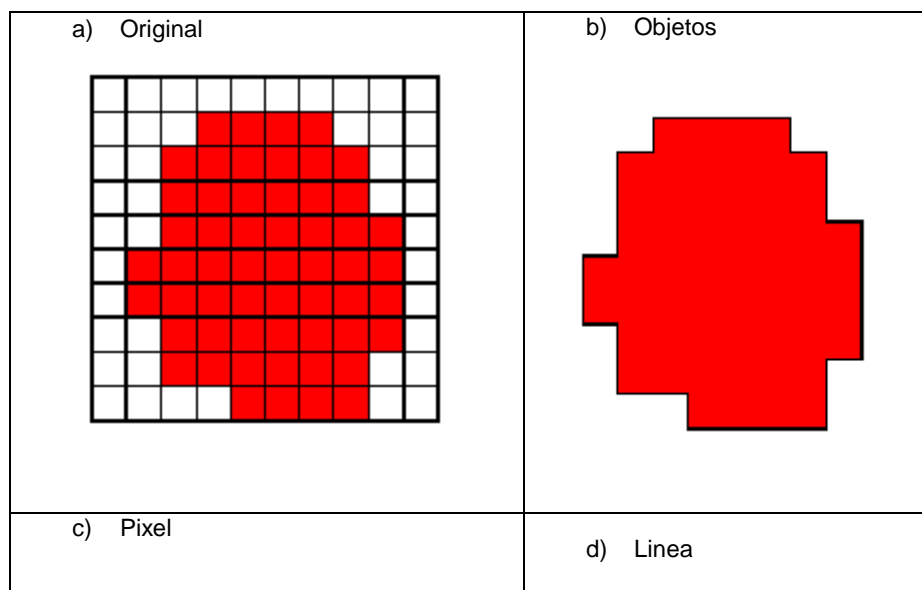
de imágenes VHSR y el aumento en la capacidad de computacional, ha favorecido ampliamente su popularidad (Walter, 2004)

Las aproximaciones basadas en segmentos, campos (Aplin et al., 1999), regiones o parches (Lee & Warner, 2004), se consideran vertientes que comparten características muy similares a la aproximación basada en objetos, por lo cual no se profundizara sobre ellas, pero se sugiere consultar las referencias de cada uno.

## 2.4 Aproximación basada en líneas

Esta aproximación se propone como una nueva alternativa frente a las mencionadas anteriormente (**Figura 2.3.** Representación gráfica de un objeto de acuerdo a la unidad básica de procesamiento.), que adiciona nuevos elementos, como la extracción de información a partir de líneas específicas sobre la imagen bajo estudio, la utilización del concepto de entropía para la selección de las líneas de interés en la imagen, el uso de los niveles de gris de la línea para la definición de los parámetros (umbrales) para el algoritmo de crecimiento de regiones, y la definición del número de clusters a generar para la clasificación no supervisada utilizando un algoritmo de agrupamiento.

**Figura 2.3.** Representación gráfica de un objeto de acuerdo a la unidad básica de procesamiento.






## 2.5 Objetos geográficos

Uno de los propósitos fundamentales del procesamiento y análisis de imágenes de sensores remotos consiste en extraer objetos (también conocidos como regiones, campos, segmentos, parches) (**Figura 2.4.** Imagen de sensor remoto (izquierda) junto con los objetos geográficos delimitados (derecha), arboles, suelo desnudo y lecho seco de un río.) que sean consistentes con objetos del mundo real, tanto en su forma como en su clasificación, dado que los objetos geográficos resultan muy apropiados para el entendimiento de la imagen (Yong & Guo, 2011). El concepto de objeto fue descrito inicialmente por Hay et al. (1997), como una entidad auto-contenida y resoluble en una imagen digital, donde los píxeles que la conforman presentan características similares. En las etapas iniciales de la segmentación, a los objetos también se les suele denominar objetos primitivos u objetos candidatos, para distinguirlos de los objetos reales de la escena (Blaschke, 2010).

**Figura 2.4.** Imagen de sensor remoto (izquierda) junto con los objetos geográficos delimitados (derecha), arboles, suelo desnudo y lecho seco de un río.



Addink et al. (2012) indican que la buena definición de un objeto, brinda la posibilidad de extraer un amplio rango de propiedades de éste, las cuales pueden aplicarse en procesos posteriores, como la clasificación o interpretación de la imagen. Entre las propiedades del objeto que se pueden destacar están el valor de reflectancia espectral, forma, tamaño y relaciones de vecindad, por ejemplo, el tamaño y la forma resultan útiles para categorizar los cuerpos de agua, como los ríos, lagos, reservorios de agua y el mar (Navulur, 2007). En cuanto a los tipos de objetos geográficos que se extraen de las imágenes de sensores remotos, Baltsavias (2004), menciona que los más importantes son las vías y los edificios, los cuales constituyen una capa temática de datos geo-espaciales muy importante para un diverso número de aplicaciones (ej. catastro, planificación urbana, etc.), y han sido motivo de investigación intensiva en la última década buscando automatizar su extracción. Adicionalmente, también se extraen otros objetos como los bosques (Batista & Antunes, 2012), vegetación (Bertani et al. 2013), cultivos (Lisita et al., 2013), límites de parcelas (Vieira et al., 2012), cobertura y uso del suelo (Myint et al., 2011), y objetos específicos como áreas quemadas (Polychronaki & Gitas, 2012), deslizamientos (Aksoy & Ercanoglu, 2013) y árboles (Ardila et al., 2012). Con relación a los métodos de análisis de imagen para extracción de objetos, Baltsavias (2004) señala que la utilización del conocimiento (información a priori no detallada, modelos, reglas, restricciones, contexto, etc.) y de los geo-datos existentes asociados con ellos, así como la utilización de aproximaciones semiautomáticas, son los factores más decisivos para una extracción exitosa de objetos.





### **3. MÉTODO PARA LA DETERMINACION DE LA ESCALA EN LAS IMÁGENES DE SENSORES REMOTOS BASADO EN LA ENTROPIA**

En el procesamiento y análisis de las imágenes de sensores remotos, el concepto de escala es una de los más importantes porque su determinación impacta fuertemente el comportamiento del fenómeno bajo estudio o la forma particular como se desarrolla un patrón a partir de ésta (Jantz & Goetz, 2005, Weng, 2014). El Consorcio Universitario sobre la Ciencia de la Información Geografica (UCGIS, 2006) ha establecido el concepto de la escala como uno de puntos estratégicos, destacando varias líneas de investigación orientadas al desarrollo de métodos nuevos para la generalización de los datos (Vanwambeke et al., 2006), así como nuevas aproximaciones para hallar la escala óptima para el estudio de la textura en las imágenes de sensores remotos (Lam, 2004, Lee & Wagner, 2004)); mientras Blaschke (2010) considera fundamental el desarrollo de un método para la definición de la escala en el análisis de imágenes basado en objetos geográficos (*GeoBIA* siglas en inglés).

Actualmente, se requiere la participación de un experto humano, quien es el encargado de escoger el a utilizar para la determinación de la escala en una imagen de sensores remotos, y dependiendo del método escogido, se requiere definir algunos parámetros (como puede ser el tamaño de la ventana o la variabilidad permitida), de acuerdo a los objetos de interés (Whiteside et al., 1011), con la finalidad de obtener la información más precisa posible; proceso que usualmente requiere el uso de metodologías basadas en ensayo-error, lo que torna el proceso muy subjetivo (Arbor et al., 2013).

La literatura sobre el estudio de la escala en imágenes de sensores remotos establece una taxonomía sobre los diferentes tipos de escala, cuya aplicabilidad en general, depende del tipo de estudio que se llevará a cabo (ambiental, social, militar, etc.). Uno de los tipos de escala, conocida como escala operacional, se relaciona directamente con los objetos que definen el proceso que ocurre en una imagen particular, nombrada como la escala de acción por Wu & Li (2009), mientras Pinoli (2014), la denomina como escala estructural, de naturaleza intrínseca en la imagen. . Esta escala difiere de la escala de observación (Liang & Weng, 2014), la cual está directamente relacionada a la resolución espacial del sensor que capturó la imagen específica (Lam & Quattrochi, 1992, Pinoli, 2014), y que depende de la vista de campo instantánea (*IFOV* sigla en inglés) del sensor, definido como el ángulo máximo de vista en la cual el sensor puede detectar efectivamente la energía electromagnética (Camp-Vals et al., 2012).

### **3.1 Concepto de la escala**

La escala se define formalmente como la relación entre la medida de una cantidad y la medida de su representación (Pinoli, 2014), que para una imagen corresponde a la relación entre los objetos de interés (ej. objetos geográficos) y su dimensión física (ej. diámetro), pero que usualmente presentan fluctuaciones (variabilidad intrínseca) y presenta varios tipos, como la escala observacional, relacionada con la resolución espacial o escala estructural, relacionada con los objetos de interés o más representativos en la imagen.

Las imágenes de sensores remotos son dependientes de la escala (Weng, 2014), debido a que desempeña dos roles principales. Primero, la escala es un atributo que permite describir los datos geográficos (Cao & Lam, 1997), conocidos como objetos espacialmente referenciados u objetos con una relación con su espacio físico; y segundo, la escala permite determinar la relación entre los objetos, patrones y procesos abordados durante el estudio (Marceau & Hay, 1999). Usualmente, la escala se define de forma a priori por un experto humano después de observar directamente los objetos de interés en la imagen, estableciendo un tamaño de la ventana acorde a ellos, pero como argumentó Levin (1993), existen muchas posibilidades de ventanas, lo cual afecta sensiblemente el resultado obtenido.

---

De acuerdo a esta idea, Martha et al. (2011), considera que se hace necesaria una mejor representación de la escala bajo una aproximación jerárquica, porque los objetos de las imágenes de sensores remotos poseen características multidimensionales. También, consideran que es imperativo encontrar un método que permita determinar automáticamente la escala de la imagen, usando solamente los datos inherentes a la imagen, sin utilizar otra información a priori.

Por su parte, Jantz & Goetz (2005), consideran que la dependencia a la escala en el modelamiento cambio de uso del suelo usualmente no se realizan, a pesar del auge de las aproximaciones del análisis de imágenes multiescala (Kok et al. 2001), donde los procesos urbanos importantes o patrones específicos deben identificarse a priori, identificar las estadísticas de ajuste, y evaluar el rendimiento bajo múltiples escalas, hasta identificar aquella escala apropiada para estudiar el fenómeno bajo estudio.

### 3.2 Métodos existentes

Existen diferentes métodos para determinar la escala de una imagen de sensores remotos, por lo cual se dará una breve descripción de los más conocidos. El método de Varianza Geográfica (*GVM* sigla en inglés), utiliza un método de agregación simple sobre los datos espaciales, pero su uso es limitado a datos jerárquicos (Wu & Li, 2009). Por su parte, el método de Varianza Local (*LVM* en inglés) y el método basado en la textura están basados en pequeñas ventanas móviles (también conocidas como kernel), de tamaño impar, usualmente de 3 x 3 píxeles, aunque algunas veces el valor de la escala determinado por este método puede no ser representativo para la imagen completa (Woodcock & Strahler, 1987, Bocher & McCloy, 2006).

El método basado en el semivariograma (*SVM* sigla en inglés), proviene del área de la estadística espacial, la cual requiere predefinir una ventana de tamaño particular, que puede conducir a resultados imprecisos sobre las imágenes VHSR. Además, este método sufre del conocido efecto de bordes, y también de un tiempo de cálculo largo (Yue et al., 2013). Los métodos basados en Wavelets y Fractales (Lam & Quattrochi, 1992), se consideran dos aproximaciones promisorias, pero requieren mayor investigación para evaluar su impacto. Primero, se debe enfocar esfuerzos sobre como migrar los resultados sobre datos unidimensionales hacia los datos 2D (Arnedo et al., 2000). Dragut et al. (2014) proponen un método automático basado en *LVM* para seleccionar el valor de la escala

bajo diferentes niveles de jerarquía, pero este método requiere definir previamente el tamaño de la ventana para calcular la variación local.

### 3.3 Entropía

El concepto de entropía proviene originalmente de la termodinámica, pero se ha adaptado a otros contextos o campos de investigación. La entropía significa energía en las ciencias físicas (Greven et al., 2003), incertidumbre o desorden en la teoría de la información (McKay, 2003), diversidad en ecología (Masisi, 2008), y organización o inestabilidad en las ciencias biológicas (Hammes & Schiffer, 2015). La definición de una función para la entropía fue propuesta por Shannon (McKay, 2003), usando la formulación Boltzmann-Gibbs para la entropía, en su artículo seminal (1948), utilizando la siguiente fórmula matemática (1):

$$H = - \sum P(x) \log(P(x)) \quad (1)$$

donde  $P(x)$  es la probabilidad para el valor de un bit dado (dígito binario), que indica la información ganada de un evento particular (ej. Valor de nivel de gris), el cual está relacionado con su probabilidad de ocurrencia (Pal & Pal, 1991).

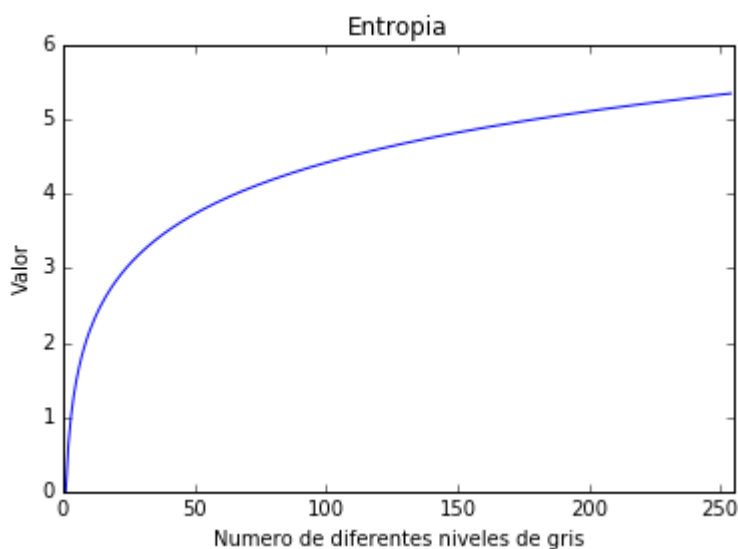
Esta nueva aproximación para la definición de la escala en las imágenes de sensores remotos se enfoca sobre la variabilidad de la intensidad (niveles de gris) de los píxeles en la imagen. La idea detrás de esta aproximación proviene del hecho que los objetos de las imágenes se definen a través de varios atributos, como la información espectral, bordes cerrados, forma o tamaño específico, entre otros. El valor espectral (información de color o escala de gris) permite delimitar un objeto o actúa como un indicador de la existencia de un objeto a través de la variación del nivel de gris, lo que significa que las regiones de la imagen con baja variabilidad tiene una relación directa con pocos objetos (o quizás solo uno); y al contrario, una mayor variabilidad indica la existencia de varios objetos.

La variabilidad de la información espectral podría medirse utilizando descriptores estadísticos tradicionales, como la desviación estándar o la varianza, pero estos pueden presentar sesgos cuando los valores de intensidad están desbalanceados (ej. Existencia de una región grande conjuntamente con muchas regiones pequeñas), cuando existen valores de gris extremos o presencia de ruido, lo cual podría enmascarar o obscurecer los

estimados para los niveles de gris verdaderos. Por su parte, la entropía no se ve afectado por valores escasos o comunes en la imagen, porque esta pondera cada valor de gris por su respectiva frecuencia (Jost, 2006).

Se considera que la entropía como una medida de la variabilidad de objetos porque permite cuantificar el contenido de información (ej. Diversidad de objetos) sin ser afectado por los valores extremos, ruido o datos desbalanceados. Se ha encontrado una relación positiva entre la entropía y la variabilidad de niveles de gris (**Figura 3.1**. Incremento del valor de la entropía a medida que aumenta la cantidad de niveles gris diferentes en el vector). Las imágenes VHSR presentan una mayor variabilidad de niveles de gris debido a una mejor representación de los detalles de los objetos, por lo cual, un valor de entropía más alto puede interpretarse como una mayor presencia de objetos. Adicionalmente, se conoce que la distribución (arreglo de los pixeles) no se ve afectado por el valor de entropía (Chalidze, 2000), que se constituye como una propiedad muy importante, porque en un imagen se requiere obtener una mejor representación de los diferentes valores de niveles de gris, y no un orden en particular de los niveles de gris, porque una mayor presencia de niveles de gris diferentes está directamente relacionado con una mayor presencia de objetos.

**Figura 3.1.** Incremento del valor de la entropía a medida que aumenta la cantidad de niveles gris diferentes en el vector



Esta aproximación presenta algunas ventajas sobre los demás métodos descritos inicialmente. Primero, este método muestra un balance entre el comportamiento global y local, porque esta no opera sobre toda la imagen (entropía global) o sobre una pequeña vecindad (entropía local), pero captura la información sobre cuantos objetos están presentes en la zona de mayor variabilidad en la imagen, a través de una línea que cruza la imagen de un extremo al otro. Segundo, no requiere asumir ningún supuesto sobre el contenido de la imagen, y finalmente, su obtención se hace a través de un cálculo muy simple, se escanea la imagen completa en cada una de las posibles direcciones, pero sin involucran ningún proceso de convolución para su cálculo.

## 3.4 Metodología

La metodología involucra tres componentes principales, como son el proceso de selección de las imágenes, cálculo de la entropía por líneas, y determinación de la escala.


### 3.4.1 Selección de imágenes

Este proceso involucra varios criterios importantes. Primero, se seleccionaron seis imágenes de sensores remotos VHSR/HSR, que presentan un rango de resolución espacial entre 0.3 y 15.0 metros por pixel, capturadas por sensores de alto desempeño como son WorldView, GeoEye, Landsat y SPOT; así como las imágenes aéreas del programa NAIP. Tercero, se constató que las imágenes presentaras diferentes coberturas del suelo, con presencia de vegetación (bosques y pastos), infraestructura urbana (vías, edificios,) y no urbanas (suelo desnudo, cultivos, bosques), así como la presencia de objetos de tamaño variado (grandes y pequeños), como lagos, árboles y edificios. Finalmente, las imágenes son multiespectrales (tres canales de color) (**Figura 3.2.** Imágenes VSHR (arriba) y HSR (abajo) correspondientes a las ciudades de Madrid, Tokio, Charlotte, Barcelona (dos) y Seattle.).

Las imágenes hacen parte de repositorios para su acceso libre, tanto en la página de la compañía DigitalGlobe, como de la entidad FAS, dependencia de la reconocida USDA, que requiere el diligenciamiento de un formulario, para conocer sobre su destinación y uso posterior.

En la **Tabla 3.1** **Tabla 3.1**. Características de las imágenes utilizadas. se describen las principales características de las imágenes seleccionadas. Las dimensiones originales de las imágenes oscila entre 3.500 y 6.000 píxeles, pero solo se utilizó una fracción de ellas, para evitar que los tiempos de procesamiento se tornen muy largos, debido a que los algoritmos no están optimizados.

**Figura 3.2.** Imágenes VSHR (arriba) y HSR (abajo) correspondientes a las ciudades de Madrid, Tokio, Charlotte, Barcelona (dos) y Seattle.



**Tabla 3.1.** Características de las imágenes utilizadas.


Característica	Imágenes					
	WorldView3	GeoEye1	NAIP	SPOT5	SPOT5	Landsat8
Tipo (canales)	RGB	RGB	RGB	IRG	IRG	RGB
Resolución espacial (mt/píxel)	0.31	0.50	1.0	5.0	10.0	15.0

Resolución radiométrica	11-bit	11-bit	8-bit	8-bit	8-bit	8-bit
Tamaño (píxeles)	500	500	500	500	500	500
Formato	GeoTIFF	GeoTIFF	GeoTIFF	AFR	AFR	GeoTIFF

### 3.4.2 Cálculo de la entropía

El cálculo de la entropía se realiza utilizando líneas que siguen tres patrones diferentes: circular, horizontal y vertical, que brindan un cubrimiento completo de la imagen (**Figura 3.3**). Los valores de niveles de gris de la imagen cubiertos por la línea, conforman un vector, sobre el cual se aplica la función de entropía usando el logaritmo natural con base  $e$  y del módulo estadístico del lenguaje Python, llamado Scipy (Jones et al., 2001).

**Figura 3.3.** Fragmento de imagen ilustrando las direcciones utilizadas para el trazado de las líneas (no se han trazado el total de 1360 líneas usadas para no ocultar la imagen de fondo).



Asumiendo que las imágenes presentan una forma geométrica cuadrada, la línea tendrá una longitud mínima igual a la longitud de un lado de la imagen, y una longitud máxima igual a la diagonal de la imagen (de esquina a esquina). El cumplimiento de este requerimiento es importante para evitar un comportamiento local del método, es decir, evitar líneas cortas que podrían tener un valor de entropía más alto, pero cuya información



no sería representativa del contenido de la imagen (objetos geográficos). El **Algoritmo 3.1**. Conteo de objetos geográficos y llenado de vectores. ilustra la secuencia de pasos utilizados para calcular la línea con el valor de entropía máximo para cada imagen.

**Algoritmo 3.1.** Conteo de objetos geográficos y llenado de vectores.

---

```

Entrada: vector L, valor_variabilidad n
Contador = inicializar_variable()
Unicos = crear_lista()
Para_todo valores desde 0 hasta n hacer
    etiquetas <- suavizamiento(L,valor)
    adicionar(Unicos, etiquetas)
    Para_todo etiqueta desde 0 hasta longitud(etiquetas) hacer
        Si diferentes (etiqueta, proxima(etiqueta))
            incrementar(contador)
    fin_para
    adicionar(conteo, contador)
fin_para
retornar Unicos, conteo

```

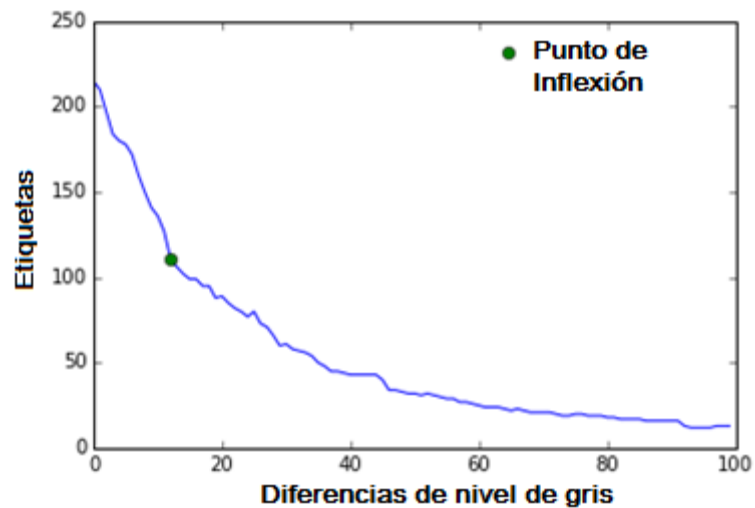
---

### 3.4.3 Determinación de la escala

El valor de la escala se determina usando un método basado en la función de entropía que se aplica sobre el vector con los valores de niveles de gris presentes de la línea respectiva. Estos valores de la línea sobre la imagen se procesan en cuatro pasos: a) Inicialmente, se crean dos vectores, uno para almacenar las etiquetas únicas (niveles de gris diferentes) denominado ULB, y el otro vector almacena el número de objetos, denominado CTS, avanzando en orden creciente de variabilidad (1,100), lo que significa que cada valor de gris se fusiona con su vecino, cuando su valor de diferencia de gris cae dentro de un nivel de diferencia de gris predefinido, b) para cada diferencia de nivel de gris, se contabiliza cuantos valores únicos de niveles de gris se mantienen (actualizando el vector ULB), y se cuenta cuantos objetos existen en ese momento, lo que resulta equivalente a regiones con el mismo nivel de gris (actualizando el vector CTS), c) Luego, con la diferencia de niveles de gris y su respectivo número de etiquetas únicas (niveles de gris), se traza un gráfico entre las etiquetas únicas y las diferencias de nivel de gris (ULB vs [1,100], lo cual entrega una línea decreciente, que presenta un codo, d) posteriormente, se aplica una función de optimización sobre la línea para determinar su punto de inflexión (**Figura 3.4**. Grafica que

ilustra el punto de inflexión [12, 110] para la curva.), que se interpreta como el punto donde ocurre el cambio principal en la imagen, es decir, representa el valor de la escala para los objetos más influyentes presentes en la escena.

**Figura 3.4.** Grafica que ilustra el punto de inflexión [12, 110] para la curva.



El **Algoritmo 3.2.** Suavizamiento del vector para obtención de etiquetas ilustra los pasos aplicados para realizar el suavizamiento sobre el vector, el cual es llamado por el Algoritmo 2.1, para obtener las etiquetas en cada iteración.

---

**Algoritmo 3.2.** Suavizamiento del vector para obtencion de etiquetas

---

```

Entrada: vector L, variabilidad n
  Para_todo valor desde 0 hasta longitud(L) hacer
    Si primer_ciclo = T
      inicializar variables
    Si_no
      Si no mayor(L[valor], promedio) & menor(L[valor], promedio)
        lista_valores <- vector(posicion1, posicion2)
        Para_todo valor desde 0 hasta longitud(lista_valores) hacer
          actualizar(salida, promedio)
        fin_para
      Si_no
        actualizar(variables)
    fin_para
  Unicos <- no_valores_repetidos(salida)
  Para_todo valores desde 0 hasta longitud(L) hacer
    indice <- valor_indice(distancia_minima(valor - L[valor]))
  Fin_para
  retornar salida[indice]

```

---

Finalmente, el valor único retornado por el **Algoritmo 3.2.** Suavizamiento del vector para obtencion de etiquetas permite extraer el número de objetos a partir del vector CTS, y con la longitud del vector, para lo cual se procede a calcular el valor de escala para la imagen, utilizando la siguiente función (2):

$$escala = L / O \quad (2)$$

donde  $L$  representa la longitud del vector, y  $O$  representa el número de objetos presentes en la línea.

Para propósitos de comparación, se seleccionaron dos métodos bien conocidos para la determinación de la escala en las imágenes, como son el método de *LVM* (*Local Variance Method* en inglés), y *SVM* (*Semi-Variogram Method* en inglés). El valor de escala del método *LVM* fue calculado a través de un filtrado de la imagen utilizando una ventana pequeña, de tamaño 3x3, con la finalidad de obtener la distribución del valor medio de los valores de la desviación estándar.

El valor de escala calculado con el método *SVM* se obtuvo usando dos direcciones, horizontal y vertical, con espaciamentos entre [0,100], utilizando el rango SV como la representación de la escal, donde de acuerdo a (Dragut et al., 2014), siendo el valor donde el SV alcanza la cima, el punto que representa la variabilidad espacial en los datos.

### 3.5 Resultados

Las imágenes VHRS se están convirtiendo en el insumo principal para el procesamiento y análisis de imágenes de sensores remotos. Existen diferentes sensores que ofrecen información espacial muy detallada sobre los objetos geográficos que contienen haciendo necesaria la determinación de un valor de escala apropiada para delimitarlos y analizarlos.

Aunque hay métodos bien conocidos para la determinación de la escala, se requiere de un método objetivo para la selección de la escala de una imagen particular, que utilice solamente los datos inherentes a la imagen (orientado por los datos), porque cuando el valor de la escala se define por un usuario/experto no se pueden garantizar la consistencia o repetitividad de los resultados, debido al uso de metodologías basadas en ensayo-error, incremento en el tiempo y costo del proceso y se torna difícil establecer comparaciones entre diferentes imágenes. Además, la posibilidad de automatizar el proceso se ve muy limitada.

La aproximación propuesta en esta investigación ha arrojado buenos resultados sobre diferentes tipos de imágenes VHRS/VHR, cuya resolución espacial oscila entre 0.3 y 15 metros por pixel, enfocándose sobre los objetos geográficos presentes, en lugar de otros atributos como el tamaño de la imagen, el tamaño de la ventana (*kernel*), el proceso de convolución u otro conocimiento a priori. Este método basado en la entropía sobre líneas de la imagen solamente utiliza solamente la información espectral de la imagen para la identificación de los objetos más representativos de una imagen particular, y junto con la medida de resolución espacial del sensor, se calcula la escala apropiada de la imagen. Este método opera de forma simple, que presenta un alto potencial para abrir la posibilidad de automatizar el proceso sobre las imágenes de sensores remotos.


Este nuevo método cumple varios requerimientos importantes para su funcionamiento completamente automático, no depende del apoyo de un usuario/experto y proporciona resultados consistentes y repetibles, utilizando solamente los valores de niveles de gris, permitiendo definir el valor de escala apropiado para detectar los objetos más representativos en la imagen.


El uso del concepto de entropía es robusto para evaluar el contenido de información, en diferentes áreas como la biología o las ciencias de la información. En esta aproximación

propuesta, la entropía ha demostrado un buen desempeño para detectar la región (línea) que presenta una mayor variabilidad de objetos geográficos, sin verse afectada por la dominancia de ciertos niveles de gris, encontrando correspondencia entre el valor de entropía y la cantidad de objetos presentes. La **Figura 3.5**, ilustra como la línea blanca seleccionada en cada imagen, recorre las áreas de la imagen con mayor diversidad de objetos diferentes (edificios, vías, vegetación, etc.), donde se puede apreciar un balance entre los niveles de gris de la imagen, cubriendo desde el negro hasta el blanco.

Las imágenes utilizadas son imágenes en escala de grises (8-bit), con un rango de valores entre  $[0,255]$ , lo que significa que una línea que contenga todos los posibles niveles de gris, tendrá como máximo un valor de entropía igual a 5.08, mientras una línea con solamente un nivel de gris, tendrá un valor de 0.0. La **Tabla 3.2**. Valor de escala obtenido con los diferentes métodos, junto con los promedios discriminados por tipo de imagen (VHSR y HSR). **Tabla 3.2** enumera los valores de entropía hallados para cada imagen, donde los valores de entropía permiten establecer una división entre las imágenes VHSR (entropía promedio 4.74) y las imágenes HSR (entropía promedio 4.44). Este comportamiento evidencia la relación positiva entre la entropía y la variabilidad de niveles de gris de una imagen.

**Figura 3.5.** Trazado de las líneas que poseen con el valor de entropía más alto para cada una de las imágenes utilizadas.





Usualmente, durante el procesamiento o análisis de imágenes de sensores remotos, la escala se asume como geográfica o cartográfica, la cual se obtiene directamente a través de la relación entre el área que ocupa un pixel en la imagen en comparación con el área real que ocupa sobre la superficie terrestre, lo que daría por sentado que una imagen VHSR poseerá un valor de escala más detallado que para una imagen HSR, pero esto no necesariamente es cierto, porque como han demostrado los resultados de la presente investigación, el valor de la escala de una imagen de sensores remotos está definido por la información específica que contiene, es decir, los objetos geográficos, y no necesariamente basado en la resolución espacial que posea el sensor, el uso final de la información a extraer (dependencia a la aplicación) o determinada subjetivamente por un usuario/experto después de analizar la imagen bajo estudio.

De acuerdo a los resultados obtenidos, se considera que la imagen en sí misma, proporciona toda la información requerida para decidir la escala apropiada, la cual está contenida en los niveles de gris y su variación particular (patrón), que constituyen un atributo que permite discernir visualmente entre los diferentes objetos geográficos presentes en la escena. La **Tabla 3.2**, lista los valores de escala obtenidos por cada método para las imágenes utilizadas, separadas en dos categorías, VHSR y HSR.

**Tabla 3.2.** Valor de escala obtenido con los diferentes métodos, junto con los promedios discriminados por tipo de imagen (VHSR y HSR).

Imagen	Resolución espacial	Métodos		
		Varianza Local (LV)	Semi-Variograma (SV)	Entropía (Propuesto)

WV3	0.31	10.28 (3.18)	95.39 (29.57)	<b>3.31 (1.03)</b>
GE1	0.50	<b>6.38 (3.19)</b>	25.76(12.88)	8.93 (4.47)
NAIP	1.00	9.84 (9.85)	75.50 (75.5)	<b>3.51 (3.51)</b>
<i>Promedio VHSR</i>	<i>0.60</i>	<i>8.83 (5.41)</i>	<i>65.55 (39.32)</i>	<i>5.25 (4.49)</i>
SPOT5	5.0	5.78 (28.88)	22.91 (114.55)	<b>4.42 (22.10)</b>
SPOT5	10.0	9.31 (93.05)	8.50 (85.00)	<b>4.27 (42.70)</b>
LandSat8	15.0	7.82 (117.30)	22.01 (330.15)	<b>4.46 (66.90)</b>
<i>Promedio HSR</i>	<i>10.0</i>	<i>7.64 (79.74)</i>	<i>17.81(176.57)</i>	<i>4.38 (43.9)</i>


Los valores de la escala se indican en pixeles(metros), aquellos en negrilla corresponden a los mejores valores.

El método propuesto ha demostrado su efectividad para encontrar el valor de escala que permite detectar los objetos geográficos más pequeños en cada imagen, algunos de los cuales se delimitaron manualmente en la **Figura 3.6**, para constatar el tipo de objetos geográficos que se pueden identificar con la respectiva escala determinada por el método propuesto.

También, es importante anotar como el método *SVM* tiene algunas dificultades para encontrar un valor de escala razonable de acuerdo a la resolución espacial de la imagen, probablemente resulta afectado por la alta variabilidad de los niveles de gris de las imágenes, haciendo difícil encontrar una distancia apropiada.

Aunque el método *LVM* brinda valores de escala aceptables, su desempeño fue superado por el método propuesto, que encontró valores para la escala muy cercanos al tamaño de los objetos presentes en las imágenes, siendo consistente en todas las imágenes.

**Figura 3.6.** Ilustración manual (cuadro rojo) de los objetos identificables en cada imagen de acuerdo a la escala determinada por el método propuesto.



### 3.6 Conclusiones

El método propuesto para la definición de la escala es una nueva aproximación guiada por el concepto de entropía, el cual hace un uso eficiente de la información de niveles de gris de la imagen, permitiendo la identificación de los objetos dominantes de la escena. El procedimiento utilizado por este método, permite la definición automática de la escala de una imagen de sensores remotos, a través del establecimiento de una relación directa entre el número de niveles de gris diferentes y el número de objetos encontrados, siendo el único responsable para la definición de la escala, evitando la dependencia sobre la resolución espacial de la imagen o sobre la experiencia del usuario/experto.

Este método también permite la identificación de estructuras multi-escala en las imágenes, en el sentido de que si el problema en cuestión requiere de una escala superior (objetos más grandes), se puede aplicar previamente un proceso de filtrado sobre la imagen



(conocido como *smoothing* en inglés), luego del cual se repite el método propuesto, que determinara la nueva escala, creando tantas escalas como sean necesarias para la identificación de objetos más grandes.

Esta nueva aproximación permite avanzar en la dirección para lograr el procesamiento automático de imágenes, permitiendo la consecución de resultados precisos, repetibles y consistentes, evitando decisiones subjetivas de los usuarios/expertos.



# **4. MÉTODO PARA LA SEGMENTACIÓN AUTOMÁTICA DE IMÁGENES DE SENSORES REMOTOS BASADO EN CRECIMIENTO DE REGIONES**

La posibilidad de hallar un método de segmentación eficiente es una de las etapas más críticas en el procesamiento de imágenes de sensores remotos (Dey et al., 2010), porque se busca encontrar regiones significativas de interés (ej. Objetos geográficos), que sean unidades fundamentales para las etapas posteriores de un análisis particular, tal como la clasificación de imágenes basada en objetos (Blaschke, 2005, Richards et al., 2006, Zhang, 2015).

Técnicamente, la segmentación se define como un proceso de partición de la imagen, donde los píxeles (unidad básica de una imagen), se asignan a segmentos u objetos, que son agrupaciones de píxeles (Pal & Pal, 1993; Lucieer, 2004; Richards, 2013). En las décadas anteriores, este tópico ha recibido considerable atención, principalmente sobre imágenes de baja o media resolución espacial. Recientemente, con la mayor disponibilidad de imágenes de sensores remotos de muy alta resolución espacial (*VHSR* en inglés), se ha desarrollado una variedad de algoritmos para extraer objetos geográficos a escala fina, tales como árboles individuales (Hirschmugl et al., 2007), sombras (Adeline et al., 2013), edificaciones (Hofmann, 2001, Baltsavias, 2004, Belgiu & Dragut, 2014), carreteras (Nobrega et al., 2008, Kumar et al., 2014), vehículos (Razakarivony & Jurie, 2016), por nombrar algunos.

Mientras algunas etapas del procesamiento de imágenes de sensores remotos pueden realizarse con intervención humana reducida, la automatización del proceso de segmentación todavía presenta algunos aspectos problemáticos. Primero, el proceso usualmente necesita usuarios/expertos que definan la configuración de los parámetros más apropiada basado en la imagen específica y las características del terreno, por lo que requieren el uso de metodologías ensayo-error (Hay et al., 2003, Yu et al., 2006, Myint et al., 2011), que torna costoso en tiempo este proceso, así como un cuello de botella cuando se requiere analizar un gran volumen de imágenes (Chen & Han, 2016). Segundo, cada imagen VHSR frecuentemente contiene información muy detallada de los objetos geográficos, que exhiben diversidad de características (ej. tamaño, forma o textura), haciendo difícil determinar apropiadamente los objetos y su contornos (Gurcan et al., 2009, Benes & Zitova, 2015, Chen & Han, 2016).

Se han dedicado numerosos esfuerzos de investigación a la automatización de la segmentación de imágenes, muchos de los cuales se han originado en el análisis de imágenes médicas o desde el área de la visión por computador, extrayendo tejidos de la retina (Zhao et al., 2014), segmentación de tumores del pecho (Rouhi et al., 2015) o reconocimiento de textos escritos a mano (Saeed & Albakoor, 2009). Dadas las características únicas de las imágenes de sensores remotos, los investigadores han desarrollado muchos métodos semiautomáticos para el delineamiento de objetos en la imagen minimizando la intervención humana. Por ejemplo, el método de segmentación basado en regiones (*RISA* sigla en inglés), utiliza el algoritmo de agrupamiento k-means para definir las semillas del algoritmo de crecimiento de regiones (Wang et al., 2010), pero requiere la definición previa del número de clusters, así como un criterio de parada, ambos definidos por un usuario/experto. Este algoritmo requiere una segmentación inicial de la imagen con la cual se entrena un sistema basado en lógica difusa, pero requiere una fase intensiva de entrenamiento para mejorar su robustez sobre diferentes conjuntos de imágenes.

Byun et al. (2011) propusieron una aproximación para segmentar imágenes VHSR usando un algoritmo de crecimiento de regiones, seleccionando automáticamente las semillas utilizando un método basado en bloques, cuyo tamaño debe ser definido a priori. Por su parte, Akcay & Aksoy (2008), propusieron una aproximación basada en la combinación de

---

información espectral y estructural de la imagen, junto con operaciones morfológicas para construir un árbol jerárquico para realizar la segmentación automática, el cual demostró resultados promisorios, pero requiere el apoyo de expertos/usuarios para definir los elementos estructurales y clusters de acuerdo a los objetos de interés.

## 4.1 Crecimiento de regiones

El algoritmo de segmentación por crecimiento de regiones fue propuesto inicialmente por Adams & Bischof (1994), el cual opera de acuerdo a un criterio de homogeneidad entre los píxeles vecinos; de esta forma, si el píxel bajo análisis cumple con las condiciones previamente definidas, el píxel se adiciona a la región, de lo contrario la región detiene su crecimiento, y se selecciona una nueva semilla para iniciar el proceso de crecimiento de una nueva región (Haralick & Shapiro, 1985, Gonzalez & Woods, 2002).

Aunque este método ha demostrado un buen rendimiento para la segmentación de imágenes de sensores remotos, requiere la toma de dos decisiones críticas, como son la selección del criterio de homogeneidad y la forma como se seleccionaran las semillas (Fan et al, 2005, Wang et al, 2010). Una característica particular de su funcionamiento, este método produce regiones que dependen del orden de procesamiento de los píxeles (Mehnert & Jackway, 1997), debido a que es inherentemente secuencial (Tremeau & Colantoni, 2000, Byun et al, 2011).

El algoritmo de crecimiento de regiones se ha combinado con otras aproximaciones como el agrupamiento o clustering (Wang et al., 2010), morfología matemática (Malek et al., 2010), información de bordes (Fan et al, 2005), redes neuronales (Lu et al., 2008), aprendizaje basado en instancias (Gomez et al., 2007), algoritmo Watershed (Xu et al., 2011), así como también con el renombrado método de segmentación por Multiresolution (*MRS* sigla en inglés) propuesto por Baatz & Schape (2000) utilizado para la segmentación basada en objetos.

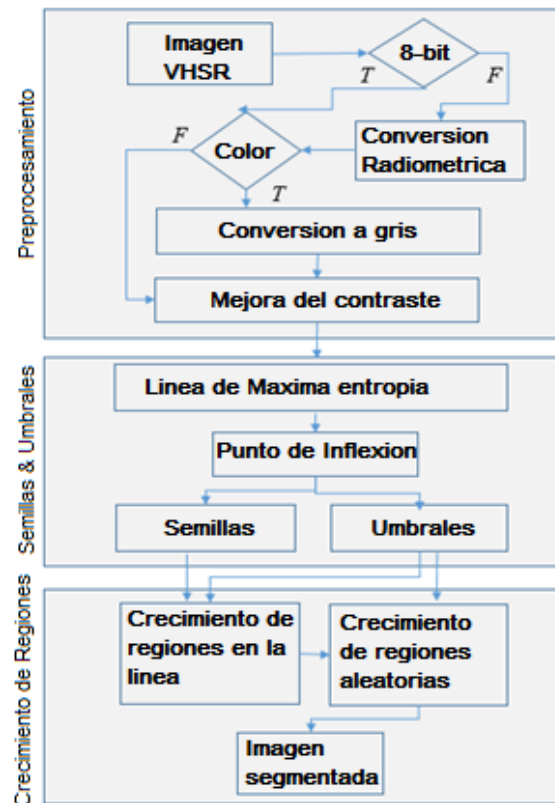
El algoritmo *MRS* es una de las exitosas aproximaciones a la segmentación de imágenes de sensores remotos, la cual crea una jerarquía de objetos aplicando una estrategia abajo-arriba (bottom-up en inglés) del algoritmo de crecimiento de regiones llamado *FNEA* (Fractal Net Evolution Approach en inglés) (Wang et al., 2010), basada en algunos atributos con la escala, formas, compacidad, entre otros. Ha demostrado mejores resultados en la

segmentación comparado con otras aproximaciones tradicionales, pero también posee algunas desventajas, principalmente su dependencia en usuarios/expertos humanos para la definir la configuración de los parámetros de segmentación a través de una metodología ensayo-error; así como durante la construcción de relaciones entre objetos, convirtiéndolo en un proceso muy subjetivo que no puede ser fácilmente transferido a otras imágenes (Hay et al., 2003, Carleer et al., 2005, Castilla & Hay, 2008, Blascke, 2010, Aplin, 2011).

## 4.2 Metodología

El método propuesto para realizar la segmentación está basado en el algoritmo de crecimiento de regiones, utilizando una aproximación basada en la información inherente a la imagen, denominada *DDRG* (sigla en inglés), la cual consta de tres etapas principales: a) preprocesamiento de la imagen, b) identificación de los parámetros de segmentación (semillas y umbrales), y c) segmentación en línea y aleatoria, tal como se ilustra en la **Figura 4.1**. Diagrama de flujo del método de segmentación automático propuesto.

**Figura 4.1.** Diagrama de flujo del método de segmentación automático propuesto.



### 4.2.1 Preprocesamiento de la imagen

Las resoluciones radiométricas más comunes de las imágenes VHSR son de 8-bit, 11-bit y 16-bit, pero como este tipo de resolución tiene menos impacto que la resolución espectral y espacial para la extracción de información de la imagen, se considera que el formato de 8-bit presenta un compromiso razonable entre la eficiencia computacional y la precisión de los resultados (Franks, 2006). El método propuesto opera sobre imágenes en escala de grises, por lo cual se requiere que la imagen a color (RGB), se convierta previamente, utilizando una conversión calibrada (Poynton, 2009).

$$g(x,y) = 0.2125 [R(x,y)] + 0.7154 [G(x,y)] + 0.0721 [B(x,y)] \quad (3)$$

donde  $R(x,y)$ ,  $G(x,y)$  y  $B(x,y)$  denotan los valores de nivel de gris en los canales rojo, azul y verde, respectivamente; y los coeficientes representan la ponderación espectral específica para calcular la luminancia real CIE de cualquier imagen RGB, de acuerdo a la Rec. 709 Color space (ITU, 1990).

Posteriormente, se aplica un mejoramiento de contraste de la imagen para mejorar la perceptibilidad de los objetos, mejorando las diferencias de brillo entre ellos. Esta operación se realiza a través de una proyección (re-mapeo) de los valores de gris para cubrir el rango dinámico completo de la imagen ( $[0,255]$ ). Esta es una transformación lineal que usa la siguiente función:

$$g'(x,y) = [g(x,y) - GL(min) / GL(max) - GL(min)] \times 255 \quad (4)$$

donde  $GL(max)$  y  $GL(min)$  representan los valores de gris máximo y mínimo de la imagen, mientras  $g(x,y)$  es el valor de gris del pixel en la posición  $(x,y)$ .

### 4.2.2 Definición de parámetros de segmentación

El algoritmo tradicional de crecimiento de regiones requiere la identificación de un conjunto de semillas, que corresponden a puntos de inicio para el crecimiento de las regiones, y un umbral como criterio de parada para cada región. Liu et al. (2015) indica que las semillas pueden definirse utilizando alguno de los siguientes procedimientos: un procedimiento manual, uno basado en gradientes o una aproximación aleatoria. Desde el punto de vista de una aproximación automática, los dos primeros procedimientos son descartados porque

requieren cierto nivel de asistencia humana, por lo cual se optó por la utilización de un procedimiento basado en la entropía junto con el proceso aleatorio, porque ambos permite cumplir con una aproximación automática.

La imagen se somete a un proceso de barrido (escaneado) utilizando líneas que siguen tres patrones diferentes: rotativo, horizontal y vertical, calculando el valor de entropía para cada una de ellas. La línea con el valor máximo de entropía posee la mayor variación de niveles de gris en la imagen bajo estudio (Singh & Singh, 2008), por lo tanto, se asume que los objetos que se encuentran bajo esa línea son representativos de las características de la escena completa.

Los valores de niveles de gris presentes en la línea seleccionada, conforman un vector de datos conservando el mismo orden es sometido a un proceso de unión entre píxeles vecinos, siempre y cuando su diferencia de nivel de gris no supere un nivel determinado, el cual se incrementa en cada paso. Una vez finalizado el proceso de unión, se procede a generar una gráfica que contrasta el número de incrementos utilizados frente al número de niveles de gris que se conservan en cada paso, produciendo una línea decreciente, que es sometida a un proceso de optimización para encontrar su punto de inflexión, tal como se explicó anteriormente, en el capítulo 3.

### **4.2.3 Crecimiento de regiones**

Este es el proceso final y el más importante de la aproximación propuesta. Este proceso se compone de dos fases secuenciales, correspondientes al crecimiento de regiones en la línea denominada *LRG* (siglas en inglés), y a continuación se aplica el crecimiento de regiones aleatorio, denominado *RRG* (siglas en inglés). Estas dos fases se diferencian, en que el *LRG* solo crece regiones sobre la línea seleccionada previamente, mientras la fase *RRG* crece regiones en las demás áreas de la imagen de forma aleatoria. De esta forma, se da solución a los dos elementos más críticos del algoritmos de crecimiento de regiones (Fan et al., 2005), como son a) la determinación de las semillas y b) la determinación de los umbrales.

El Algoritmo 3.1 describe el procedimiento utilizado para la segmentación automática basada en el crecimiento de regiones. Este algoritmo aplica para ambas fases mencionadas (*LRG* y *RRG*), las cuales solo difieren en la metodología para la generación



de las semillas para crecer las regiones, la primera genera las semillas secuencialmente sobre la línea seleccionada, mientras la segunda las genera aleatoriamente sobre las áreas no segmentadas en la fase previa (*LRG*).

**Algoritmo 4.1.** Descripción del algoritmo de crecimiento de regiones.

---

**Entrada:** *imagen* Im, *listas* Contornos, Visitados, *escalar* Etiqueta, *semilla*, *tupla* umbrales  
 direcciones = 0, 45, 90, 135  
 valor\_gris = Im[semilla]  
 posicion\_actual = semilla  
**Mientras** valor\_gris > umbral[0] y valor\_gris < umbral[1] **hacer**  
     **Para** i desde 0 hasta longitud(direcciones) **hacer**  
         anexar(Contornos, posicion\_actual)  
         Contornos[actual\_posicion] = Etiqueta  
         Visitados[actual\_posicion] = T  
     valor\_gris = distancia\_minima(Contornos)  
     posicion\_actual = Contornos[indice(valor\_gris)]  
     borrar(Contornos[indice(valor\_gris)])  
**retornar** listas Contornos, Visitados

---

## 4.3 Resultados

El proceso de segmentación automático se sometió a prueba sobre las imágenes VHSR capturadas por los satélites WorldView3, GeoEye 1, mientras las imágenes NAIP (sigla en inglés) del programa norteamericano de agricultura, las cuales se ilustran en la **Figura 4.2**.

**Figura 4.2.** Imágenes VHSR utilizadas para evaluar el desempeño del método de segmentación.



Las métricas seleccionadas para medir el rendimiento de la segmentación y establecer una comparación objetiva frente a otros métodos se conocen como métricas supervisadas (Zhan et al., 2010, Benes & Zitova, 2015), y llamadas métodos de discrepancia por Cardoso & Corte-Real (2005), debido a que existe una segmentación de referencia (también denominada ground truth en inglés). Estas métricas incluyen diferentes tipos, como los tipos estadístico, posicional y geométrico. La **Tabla 4.1** ofrece una descripción de cada una de las métricas, las cuales brindan un amplio y sólido criterio de evaluación, evitando la posibilidad de obtener resultados distorsionados debido a una insuficiencia de métricas (Benes & Zitova, 2015).

### 4.3.1 Evaluación cualitativa


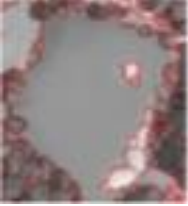
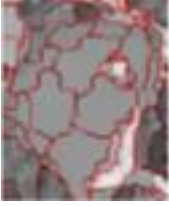

















La evaluación cualitativa involucra el análisis de atributos visuales que pueden ser detectados y diferenciados fácilmente por un experto humano. En este caso, se hizo especial énfasis en tres atributos diferentes, como son: a) la fidelidad del borde, b) la similaridad entre áreas, y c) la presencia de artefactos al interior de los objetos. Se seleccionaron seis (6) objetos diferentes en las imágenes, como árboles, lagos, calles o parques.

**Tabla 4.1.** Métricas utilizadas para evaluar la segmentación.

Métricas	Sigla	Nombre	Rango	Valor optimo	Autor	Año
Estadística	RI	Índice Rand	[0,1]	1	Rand	1971
Posicional	PD	Discrepancia en posición	[0,...]	0	Montagui et al.	2013
	AFI	Índice de Ajuste de Área	[-1,0,1]	0	Lucieer	2004
Disimilaridad	HD	Distancia Hamming	[0,1]	0	Hamming	1950
	JJ	Distancia Jaccard	[0,1]	0	Jaccard- Needham	1908
Similaridad	FM	Índice Fowlkes- Mallows	[0,1]	1	Fowlkes- Mallows	1983

La **Figura 4.3** ilustra los objetos seleccionados y la respectiva segmentación realizada por el método seleccionados junto con su evaluación cualitativa.

**Figura 4.3.** Comparación visual de la segmentación (borde rojo) bajo los tres métodos.sobre diferentes objetos geográficos.

Objetos geográficos	Métodos		
	Watershed	Multiresolution	Propuesto
 Lago	 Aceptable	 Deficiente	 Aceptable
 Edificio	 Aceptable	 Aceptable	 Bueno
 Arboles	 Aceptable	 Aceptable	 Aceptable
 Calle	 Aceptable	 Bueno	 Bueno
 Pasto	 Bueno	 Aceptable	 Bueno
Evaluación	Aceptable	Aceptable	Buena

Los métodos de comparación escogidos corresponden con métodos muy conocidos y que han demostrado sus bondades en el proceso de segmentación de imágenes, como son el método Watershed (*WS* sigla en inglés) y Multiresolution (*MRS* sigla en inglés), pero que al ser métodos asistidos por expertos, sus resultados son fuertemente dependientes de la configuración de los parámetros escogida. En este caso en particular, los parámetros de segmentación para estos métodos de comparación fueron seleccionados a través de una metodología ensayo-error, de tal forma que arrojaran una buena segmentación, especialmente sobre los objetos de menor área.

Se puede apreciar como los métodos utilizados para comparar el método propuesto, tienden a sobre-segmentar los objetos grandes (ej. lago y edificaciones), lo cual es comprensible porque están segmentando todos los objetos de la imagen, no objetos en particular, lo cual ocasiona que creen objetos no existentes (subregiones), que requieren una fase de post-procesamiento para eliminarlas a través de la técnica de fusión de regiones. Por su parte, el método propuesto no presenta este comportamiento, demostrando en general una mejor definición de los bordes, como se puede apreciar en objetos geográficos (ej. lago, parques o edificios).

Una evaluación cualitativa como la anterior, se sabe que puede presentar elementos de subjetividad, debido a que la evaluación puede estar sesgada por el juicio del analista, lo cual puede resultar controversial, resaltando la importancia de acompañarla con una evaluación cuantitativa, que permita medir precisamente su rendimiento.

### **4.3.2 Evaluación cuantitativa**

La segmentación de referencia (*ground truth* en inglés) utilizada en esta investigación, no fue creada para objetos particulares, como edificios o árboles, lo cual resulta en un proceso muy arduo porque implica delimitar cada objeto (Clinton et al., 2010), ni tampoco se tiene una segmentación de referencia de la imagen completa, porque es un proceso muy costoso en tiempo y en laboriosidad (Ge et al., 2007). Por el contrario, la segmentación, tanto la de referencia como la obtenida por el método propuesto y los métodos escogidos para comparación, se evalúa sobre la línea seleccionada, lo que conlleva que se segmentan todos los objetos que están bajo su influencia, implicando que solamente se señala el pixel limítrofe entre objetos vecinos, generando un vector binario, donde el valor

cero (0) corresponde a los bordes o límites entre objetos vecinos, y el valor uno (1) corresponde al interior de los objetos, lo cual resulta en un método muy ágil, preciso y eficiente en tiempo.

Para la evaluación cuantitativa se utilizaron las siete métricas descritas anteriormente, y cuyos resultados se enumeran en la **Tabla 4.2**.

**Tabla 4.2.** Valores de las métricas de evaluación para los tres métodos utilizados.

Métricas	Imagen	Método de segmentación		
		Watershed (WS)	Multiresolution (MRS)	Propuesto (DDRG)
Índice Rand (RI)	WV	0.64	0.63	0.65
	GE	0.71	0.73	0.67
	NAIP	0.66	0.63	0.69
	<i>Promedio</i>	<b>0.67</b>	0.66	<b>0.67</b>
Discrepancia posicional (PD)	WV	3.06	2.89	1.98
	GE	7.59	6.67	3.46
	NAIP	2.04	2.95	2.45
	<i>Promedio</i>	4.23	4.17	<b>2.63</b>
Índice de Ajuste de Área (AFI)	WV	0.43	0.42	0.36
	GE	0.35	0.12	0.48
	NAIP	0.19	0.28	-0.06
	<i>Promedio</i>	0.32	0.27	<b>0.26</b>
Distancia Hamming (HD)	WV	0.23	0.24	0.23
	GE	0.18	0.16	0.20
	NAIP	0.21	0.24	0.19
	<i>Promedio</i>	<b>0.21</b>	<b>0.21</b>	<b>0.21</b>
Índice Jaccard (JI)	WV	0.24	0.26	0.24
	GE	0.18	0.17	0.21
	NAIP	0.22	0.25	0.20
	<i>Promedio</i>	<b>0.21</b>	0.23	0.22
Índice Fowlkes- Mallows	WV	0.76	0.75	0.76
	GE	0.82	0.83	0.80

(FM)	NAIP	0.79	0.75	0.81
	Promedio	<b>0.79</b>	0.78	<b>0.79</b>

Los valores del Índice Rand (*RI* sigla en inglés), el cual está relacionado con la precisión o similitud entre clusters, midiendo la correspondencia entre los contornos, pero al mismo tiempo, la correspondencia entre las áreas al interior de los objetos. Se puede constatar como los tres métodos de segmentación alcanzan valores *RI* similares (alrededor de 0.67), demostrando un buen comportamiento en la tarea de reconocer los bordes de los objetos geográficos, teniendo en cuenta que los bordes solo tienen un pixel de ancho.

En cuanto a las métricas encargadas de evaluar la correspondencia geométrica y posicional, como son las métricas *PD* y *AFI*, el método propuesto en esta investigación presenta los mejores puntajes (2.63 y -0.06 respectivamente), indicando su buen comportamiento para el reconocimiento de las formas originales de los objetos. En cuanto a las métricas que evalúan la disimilaridad entre las segmentaciones, los índices *HD* y *JI*, arrojan puntajes similares entre los tres métodos, lo cual es significativo para el método propuesto, porque no tiene asistencia humana, mientras los otros dos si cuentan con este elemento.

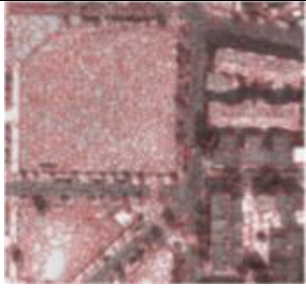

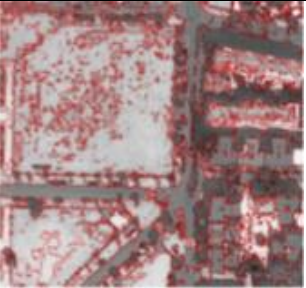

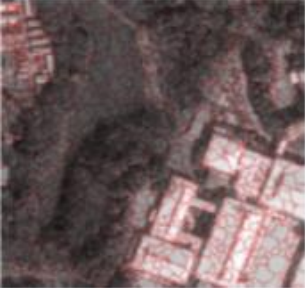
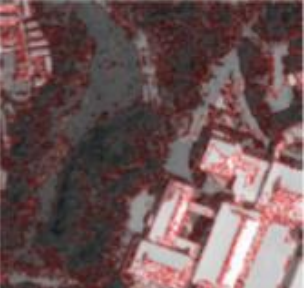



Finalmente, el índice *FM*, que mide la similaridad entre las segmentaciones, utilizando los valores de la tabla de contingencia, también entrega valores muy similares entre los tres métodos evaluados, alcanzando un valor significativo, cercano al 80%, indicando una tasa alta de verdaderos positivos y precisión (completeness o correctness en inglés) (Dornaika et al., 2016), lo que demuestra las bondades para la segmentación, tanto del método automático propuesto, como de los dos métodos asistidos por usuario/experto.

El método de segmentación propuesto es completamente automático, no requiere una configuración de parámetros previa, realizando la segmentación dirigida únicamente por los niveles de gris de la imagen bajo estudio, logrando resultados comparables o superiores a métodos ampliamente reconocidos en la segmentación de imágenes de sensores remotos, como son el método *Watershed* y el método *Multiresolution*, los cuales requieren una asistencia por parte de usuarios/expertos para la configuración de sus parámetros de segmentación, lo que involucra un elemento de subjetividad en el proceso, dado que diferentes usuarios/expertos pueden utilizar diferentes configuraciones para

segmentar los mismo objetos presentes en una imagen, lo que impide su transferibilidad del proceso hacia otras imágenes.

Un comportamiento deseable que presenta el método propuesto es la capacidad para segmentar objetos geográficos de diferentes tamaños indistintamente, mientras que los métodos utilizados para comparar el rendimiento de la segmentación, no pueden hacerlo, porque sus parámetros limitar el crecimiento de los objetos después de cierto umbral, (ej. parámetro de escala o tolerancia), lo que trae como consecuencia la sobre-segmentación característica en ellos (**Figura 4.4**).

**Figura 4.4.** Traslape de la segmentación (borde rojo) sobre las imágenes VHSR en escala de grises bajo los tres métodos utilizados.

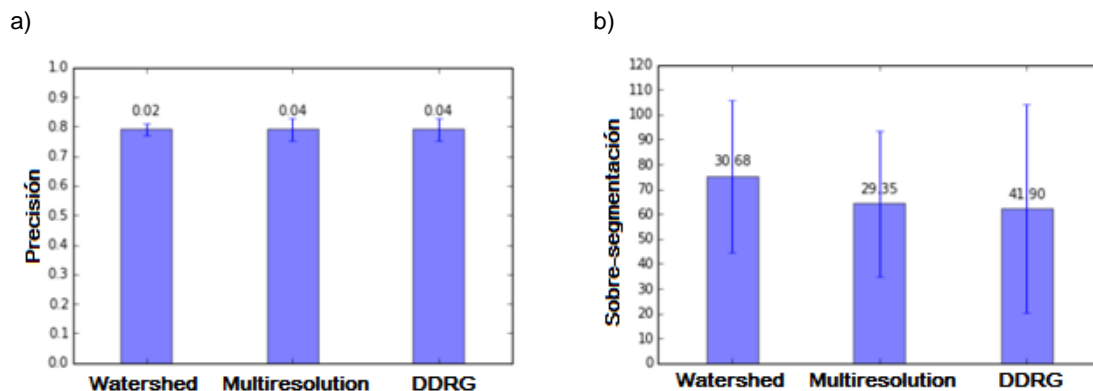
Imagen	Métodos de segmentación		
	Watershed	Multiresolution	DDRG (Propuesto)
WV3			
GE1			
NAIP			



Por último, las dos últimas medidas de desempeño, la precisión (P) y la sobre-segmentación (SG), también confirman los beneficios de nuestro método (**Figura 4.5**). Aunque los tres métodos de segmentación muestran buenos resultados de segmentación, superiores al 78% (), se prefiere nuestro método propuesto, ya que funciona totalmente automático, mientras que los otros dos métodos requieren un ajuste previo de los parámetros. Aunque en la segmentación de las imágenes de sensores remotos es preferible algún nivel de sobre segmentación de los objetos (Carleer et al., 2005), su exceso es perjudicial, porque hace necesario un post-proceso para realizar la fusión de objetos. Aunque nuestro método arroja un valor de sobre-segmentación entre tres métodos, no muy lejano de los otros dos métodos, se considera que esto es producto de la presencia de una mayor cantidad de objetos pequeños que los otros métodos omiten, debido al umbral mínimo que evita su delimitación.

Se identificamos un patrón aquí, el método propuesto (DDRG) delimita una gran cantidad de objetos pequeños, sin sobre-segmentar los objetos grandes; mientras que los otros dos métodos supervisados, por el contrario, sobre-segmentan los objetos grandes y delimitan las más pequeños. Este patrón indica que el método propuesto sería una mejor opción para segmentar una imagen, cuando la imagen tenga objetos con diferentes tamaños sin ninguna jerarquía; mientras los otros dos métodos, serían la mejor opción cuando hay un tipo específico de objetos de interés para segmentar, dado que los objetos presentarían tamaños similares.

**Figura 4.5.** a) Precisión (%) y b) Sobre-segmentación de los tres métodos





---

## 4.4 Conclusiones

El método propuesto para la segmentación automática de imágenes de sensores remotos VHSR presenta un conjunto de ventajas en comparación con métodos ampliamente utilizados para la segmentación de imágenes, como son el método *Watershed* y el método *Multiresolution*.

Primero, es un método que utiliza el concepto de entropía sobre líneas, que permite la segmentación de los objetos estructuralmente más importantes en la imagen. Segundo, la determinación de los parámetros del algoritmo de crecimiento de regiones se hace a partir de un proceso matemático sobre la línea seleccionada. Tercero, este método involucra un proceso que no requiere el establecimiento de ningún tipo de supuesto a priori sobre el contenido de la imagen. Finalmente, aunque no menos importante, este método garantiza resultados repetibles, consistentes y con un rendimiento comparable o ligeramente superior a otros métodos tradicionales o ampliamente conocidos en la segmentación de imágenes de sensores remotos.

Segundo, el método propuesto lleva a cabo la segmentación automática utilizando únicamente la información espectral de la imagen, eliminando la subjetividad que conlleva la asistencia de un usuario/experto, no requiere el uso de estructuras de datos complejas o grandes bases de datos para su entrenamiento; haciendo posible la segmentación de un alto volumen de imágenes, lo que redundaría en la posibilidad de lograr un balance entre la producción de imágenes y la generación/extracción de información a partir de ellas.

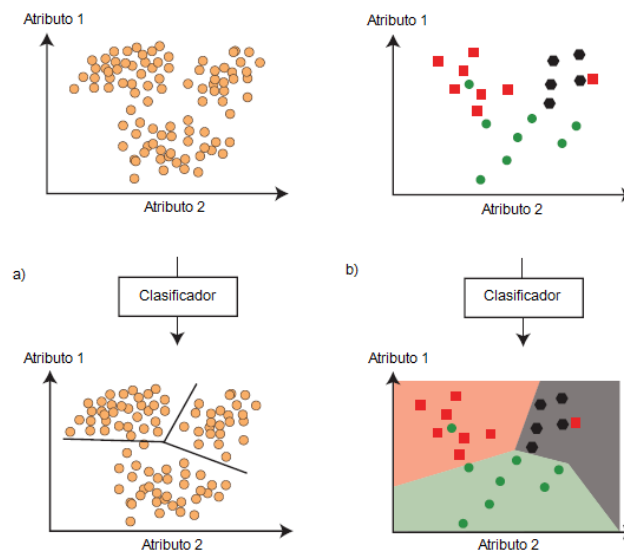
Tercero, el método de segmentación propuesto alcanzó los mejores puntajes de las 5 de las 7 métricas empleadas, lo que confirma sus bondades al compararlo frente a los otros dos métodos, alcanzando un rendimiento superior, lo cual teniendo en cuenta que es un método automático, que no requiere la asistencia de un usuario/experto.



# 5. METODO PARA LA CLASIFICACIÓN NO SUPERVISADA DE IMÁGENES DE SENSORES REMOTOS BASADA EN AGRUPAMIENTO JERÁRQUICO

Las imágenes de sensores remotos brindan una representación de la superficie de la tierra similar a un mapa, el cual se obtiene a través de la clasificación de las imágenes (Foody, 2002). Esta clasificación generalmente se realiza bajo dos categorías (**Figura 5.1**), la clasificación no supervisada y la supervisada.

**Figura 5.1.** Tipos de clasificación de imágenes: a) Clasificación no supervisada, que utiliza solo atributos (x) de las instancias, b) Clasificación supervisada, que utiliza atributos y clases (x,y) del conjunto de datos.



La clasificación no supervisada consiste en agrupar cada instancia (objeto geográfico) utilizando un conjunto de atributos que lo describen (ej. información espectral, textura, etc.), o por su relación con otros objetos (Hastie et al, 2009), los mientras la clasificación supervisada ubica las instancias de acuerdo a su similitud con unas clases predefinidas y caracterizadas (Duda et al, 2004).

En general, la clasificación consiste en construir un modelo utilizado para predecir la clase (o categoría) a la que pertenece una instancia (objeto):

$$y=f(x,\Phi) \tag{5}$$

donde  $\Phi$  representa los parámetros del modelo, y  $x$  es el vector de atributos d-dimensional utilizado para construir el modelo,

$$x_i=\{x_i(1),x_i(2),\dots,x_i(d)\}^T \in R^d$$

Usualmente se han utilizado clasificadores paramétricos, estableciendo supuestos estadísticos, que no siempre se cumplen, y que resultan muy difíciles de implementar en escenas complejas con clases que presentan alta varianza (Lee & Warner, 2004; Budreski et al., 2007). Los métodos no-paramétricos, como los árboles de decisión o el clustering no están limitados por este tipo de supuestos y presentan ventajas adicionales como su facilidad de uso y eficiencia computacional (Sande et al., 2003).

La tarea de clasificar una imagen de sensores remotos, se refiere específicamente a la clasificación de los diferentes tipos de cobertura física que presenta el terreno, es decir, aquella que se observa sobre la superficie de la tierra (Martínez et al., 2012), la cual posee determinados elementos claves, definidos como aquellos componentes físicos que caracterizan una o más categorías de cobertura o de uso, que para el caso de un área boscosa, el elemento clave sería un árbol.

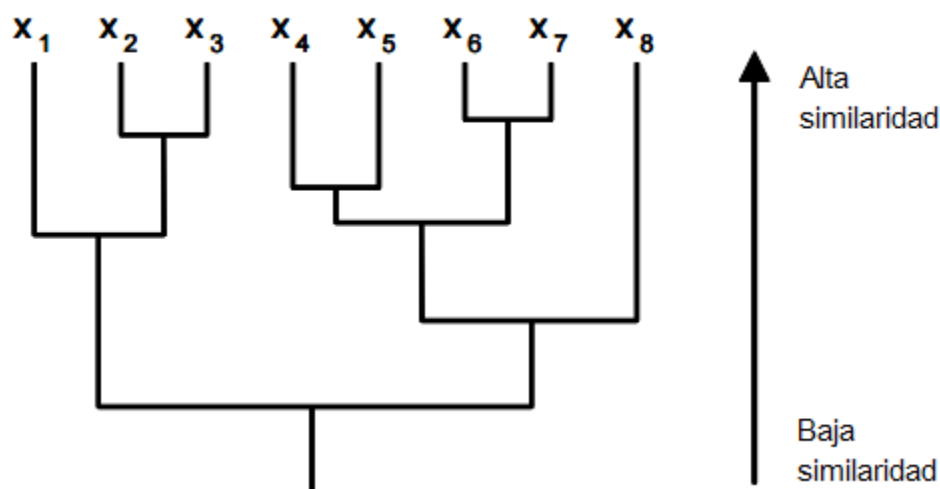
En las imágenes de sensores remotos VHRS cada pixel no está relacionado al carácter del objeto o área como un todo, sino a los componentes de la imagen, por lo cual se detectan mayor cantidad de clases al realizar la clasificación (Smith, 2000 citado por Ali, 2009), lo que produce un traslape espectral entre las clases reales, produciendo un incremento en la variabilidad natural de los objetos dentro de una clase específica (Lee & Warner, 2004), reflejándose en los errores de la clasificación de la imagen.

## 5.1 Clasificación no supervisada Jerárquica

### Aglomerativa

La clasificación no supervisada busca agrupar elementos que comparten características similares entre sí, de tal forma que la distancias por parejas entre miembros de un mismo cluster sea menor, que entre parejas de grupos diferentes. Para el caso de la clasificación jerárquica, esta no requiere el conocimiento del número de grupos o clusters con anterioridad, porque utiliza una estrategia B-U (*Bottom-Up* en inglés), creando grupos recursivamente hasta construir un árbol (llamado dendrograma), es decir, aprende a clasificar a partir de los datos, creando jerarquías naturales (Hastie et al., 2009), fusionando los grupos más cercanos entre sí usando una métrica de distancia, usualmente la distancia euclidiana; y según una estrategia de fusión, que puede ser completa, simple, centroide o Ward, hasta finalmente obtener solo una agrupación, que aglutina todas las instancias.

**Figura 5.2.** Dendrograma invertido que ilustra la estructura típica de un agrupamiento



La mayoría de los métodos aglomerativos poseen la propiedad de la monotonidad, lo que significa que la disimilitud entre los clusters fusionados se incrementa de forma monótona a medida que aumenta el nivel del árbol, donde la altura de cada nodo es proporcional al valor de la disimilitud intergrupala entre los dos clusters hijos, lo cual se puede apreciar en el dendrograma resultante de la agrupación (Hastie et al., 2009)

## 5.2 Atributos

Con los nuevos desarrollos de la tecnología de los sensores remotos, el impacto de los atributos extraídos de los objetos se ha vuelto más prominente, lo que produce un incremento de su dimensionalidad, por lo cual, Jia et al. (2011) consideran importante investigar sobre los métodos que permitan reducirla, con miras a seleccionar aquellos atributos que contribuyan a mejorar la clasificación de las imágenes, para evitar el efecto Hughes (o maldición de la dimensionalidad), que suele aparecer cuando se usan tamaños de entrenamiento pequeños y se incrementa la dimensión de los atributos (Myburgh & Van Niekerk, 2013).

La selección de atributos es muy popular en la clasificación supervisada, porque cada instancia utilizada en la fase de entrenamiento cuenta con su respectiva clase y atributos, por lo cual se puede implementar una función que maximice la precisión de la predicción de las clases, pero en la clasificación no supervisada, esto no es posible, porque solo se tienen los atributos de cada instancia, pero no su respectiva clase. Existen algunas aproximaciones para la selección de atributos bajo el ámbito de la clasificación no supervisada, pero según Dy & Brodley (2004), estos desarrollos son todavía prematuros.

Para Platt & Rapoza (2008), argumentan que la única fase que permite incrementar de forma individual la precisión del análisis, es la optimización del espacio de atributos, dado que éstos pueden llegar a ser cientos, incluyendo datos espectrales, jerárquicos, de forma y textura. Además, las imágenes VHSR permiten la extracción de una rica variedad de atributos espaciales, especialmente atributos relacionados con la forma y textura (Jiao & Liu, 2012); pero hay que tener en cuenta que una gran cantidad de atributos puede perjudicar el rendimiento de la clasificación de algunos métodos de clasificación no supervisada (Dy & Brodley, 2004).

Laliberté et al. (2012) indican que no solo debe tenerse en cuenta para la selección de atributos, aquellos que mejoren la precisión de la clasificación, sino también aquellos que reduzcan el tiempo de procesamiento.

---

### 5.2.1 Información espectral

Esta información se refiere a los niveles de gris que poseen los píxeles de la imagen (Dey et al., 2010), la cual se ha utilizado ampliamente como un atributo discriminador por su facilidad de uso, pero no tanto por su alto desempeño discriminativo.

Weidenhiller & Denzler (2014) utilizaron el color como atributo discriminador de las cortezas de arboles, pero sugieren combinarlo con otros atributos como la textura, para mejorar su poder discriminativo.

### 5.2.2 Textura

La textura puede definirse como un patrón de intensidad local en la imagen, generado por las diferencias de niveles de gris entre los píxeles bajo una relación de distancia y ángulo (Basile et al., 2012, Hurni et al., 2013).

Existen diferentes métodos para el cálculo de la textura, entre los que se encuentran la matriz de coocurrencia de niveles de gris (*GLCM* sigla en inglés), (Haralick et al., 1973), Análisis de la función de correlación (Lin et al., 1997), filtrado bidimensional en el dominio del tiempo y el espacio (Coggins & Jain, 1985), entre otros. El método *GLCM* opera desplazando una ventana de tamaño predefinido, usualmente de tamaño impar (3x3, 5x5, etc.), a partir de la cual se determinan las frecuencias relativas de pares de niveles de gris de acuerdo a una distancia y ángulo, cuyos valores se acumulan en la matriz. Para la presente investigación, el tamaño de la ventana se determina de acuerdo al valor obtenido para la escala de la imagen, ajustándola al tamaño impar más cercano, pero evitando grandes tamaños (>11x11), debido a que las ventanas grandes pueden brindar un mejor estimado de la distribución y disminuir el error aleatorio, pero pueden incluir información de diferentes clases, lo que podría incrementar el error sistemático (Franklin et al., 2000).

Ursani et al. (2012) han utilizado la textura junto con información espectral (ej. nivel de gris) para clasificar imágenes VHRS utilizando una aproximación no supervisada, logrando una mejor delimitación de los bordes en los objetos (ej. cultivos) de la imagen; mientras Li et al. (2011) encontraron útil la combinación de atributos espectrales y textura para la clasificación supervisada basada en objetos de vegetación. Por su parte Hu et al. (2005) combinaron ambos atributos para la segmentación de imágenes de sensores remotos

logrando resultados positivos. Según Richards y Jia (2006), la caracterización cuantitativa de la textura no es una tarea simple, por lo cual generalmente se usa en combinación con otros atributos, como la forma, el contexto o la información espectral (Dey et al., 2010).

Los atributos seleccionados para extraer de la GLCM, se utilizaron los descritos en la **Tabla 5.1** (López & Branch, 2005).

**Tabla 5.1.** Atributos extraídos de la matriz de coocurrencia.

Atributo	Formula
Contraste	$\sum_{i,j=0}^{ng-1} P_{i,j} (i-j)^2$
Disimilaridad	$\sum_{i,j=0}^{ng-1} P_{i,j}  i-j $
Homogeneidad	$\sum_{i,j=0}^{ng-1} \frac{P_{i,j}}{1 + (i-j)^2}$

Donde  $P_{i,j}$  es el elemento de la matriz de coocurrencia espacial en la posición  $i,j$ , que representan las filas y columnas de la matriz.  $Ng$  es el número de niveles de gris, que para una imagen de 8-bit es 255.

### 5.2.3 Vecindad

La vecindad es una propiedad contextual que tiene en cuenta la relación entre dos o más objetos, complementando la información sobre el objeto, junto con las demás propiedades, como la información espectral, geométrica o algún patrón característico (Dey et al., 2010). Un ejemplo de esta relación es las imágenes de sensores remotos VHSR, donde se destaca la presencia de sombras de objetos (Ali et al., 2009), como edificaciones y árboles, por lo el conocimiento de su relación de vecindad con un objeto en particular, brinda elementos adicionales que pueden favorecer su clasificación.

Una propiedad interesante de los atributos contextuales como la vecindad, es que evita la fragmentación de objetos segmentados (Dey et al., 2010), por lo cual resulta muy útil cuando se requiere clasificar objetos grandes como cultivos, bosques o cuerpos de agua.



Mylonas et al. (2014) consideran promisorio la incorporación de la información espacial para mejorar la clasificación de imágenes, a través del uso de la información contextual usando el concepto de vecindad entre píxeles, que acompañen la información de carácter espectral, en el vector de atributos.

Para la determinación de la vecindad de cada objeto  $W_i$ , se determina el vector de vecindades del objeto, y de acuerdo a la distancias entre el vector del objeto y la matriz de adyacencia, se define la clase a la que pertenece de acuerdo a la distancia mínima encontrada según:

$$X_{VM} = \arg \min \{ \sum_{x_j \in W_i} \|x - x_j\| \} \quad (6)$$

## 5.3 Metodología

El método propuesto para realizar la clasificación consiste en la utilización de un algoritmo de agrupamiento jerárquico aglomerativo (bottom up en inglés), el cual recibe como parámetro el número de clusters (grupos), extraído de la línea seleccionada para la imagen utilizando el método del codo, b) se ejecuta la clasificación no supervisada, y finalmente, c) se produce el dendrograma con una profundidad máxima igual al número de clusters, con la finalidad de apoyar el proceso de post-clasificación requerido para la evaluación cuantitativa de la clasificación

### 5.3.1 Numero de clusters

Aunque el número de clusters no es un parámetro exigido por el método de agrupamiento jerárquico, debido a que agrupan todas las instancias usando una estrategia de unión bottom-up. Existen diferentes métodos y con diferente nivel de complejidad para la determinación del número de clusters, principalmente dirigidos para el método k-means, que tiene ese parámetro como requisito fundamental. Entre los métodos más conocidos se pueden destacar el método de la curva (*L-curve* en inglés), basados en modelos (ej. BIC), basado en el principio de MDL (*Minimum Description Length* en inglés), basado en la distribución Gaussiana, entre otros. A pesar de esto, no existe un método que sea el mejor en todos los casos, y queda bajo decisión del analista (Koonsanit & Jaruskulchai, 2011).

El número de clusters se obtiene a partir del punto de inflexión de la línea identificada para cada imagen, el cual permite la determinación del número de agrupaciones (*clusters* en inglés) a obtener para cada imagen.

### 5.3.2 Clasificación jerárquica aglomerativa

Este método presenta la ventaja de no requerir la determinación del número de clusters a producir, porque se utilizan todos los datos para producir el árbol o dendrograma, pero como este puede tornarse muy grande, para este caso de las imágenes utilizadas en esta investigación se contabilizan entre 4000-6000 objetos, por lo tanto se puede limitar su tamaño a los últimos  $n$  grupos, para facilitar la su visualización, la identificación de las clases más representativas, y el análisis de las relaciones entre los diferentes clusters.

**Algoritmo 5.1.** Clasificación jerárquica aglomerativa.

---

```

Entrada: imagen I, kernel K, atributos A, clusters C
    datos, lista = obtener_atributos(I, K, A)
    Z, lista_clases = agrupamiento_jerarquico(datos, C)
    Para cada contorno desde 0 hasta n hacer
        coordenadas <- centroide(contorno)
        etiqueta <- clasificacion_jerarquica(Z, lista_clases, coordenadas)
    D = dendrograma(Z)
    Fin_for
retornar imagen Clasificacion, dentrograma D

```

---

Por tal motivo, para la clasificación jerárquica aglomerativa se le pasa como parámetro el número de clusters a producir, de acuerdo al valor obtenido del punto de inflexión de la línea para la imagen respectiva.

### 5.3.3 Dendrogramas

Los dendrogramas obtenidos para cada clasificación jerárquica se encuentran truncados en el nivel correspondiente al número de clusters a generar, de esta forma se facilita su visualización, dado que solo se visualizan desde el nivel de clusters a generar hasta la raíz del dendrograma. Esto resulta muy conveniente, debido a la gran cantidad de clusters que se generan al operar sobre una imagen VHSR.

---

## 5.4 Resultados

El proceso de clasificación no supervisada se ejecutó sobre las mismas imágenes VHRS utilizadas para la segmentación, es decir, las imágenes WorldView3, GeoEye 1 y NAIP, porque para la clasificación se utilizan los objetos delimitados durante la fase de segmentación.

Típicamente la evaluación de la clasificación está basada en la comparación frente a una clasificación de referencia o frente a otro conjunto de datos de interés, donde los desacuerdos entre ambas se interpretan como errores de la clasificación, pero Hartigan (1985) afirma que al evaluar el resultado de una clasificación no supervisada (por agrupamiento), no se puede indicar cuál es la mejor, porque eso depende del propósito de la clasificación. Además, debido al traslape entre los valores de los atributos, suelen aparecer clusters que no representan una clase en particular, sino la combinación de dos o más clases.




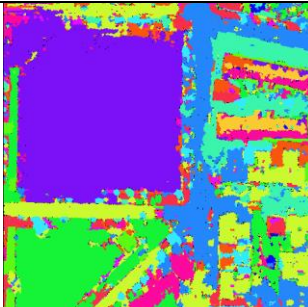
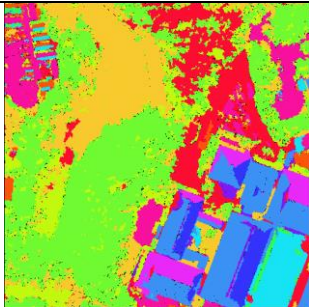
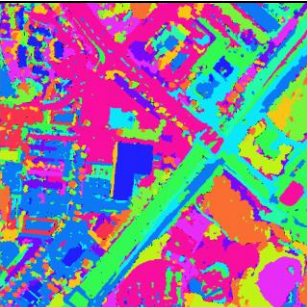

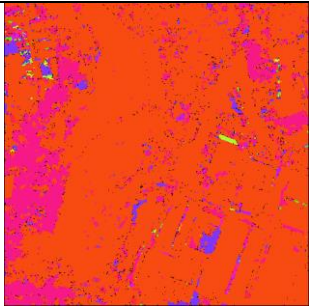
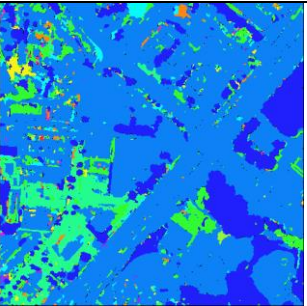
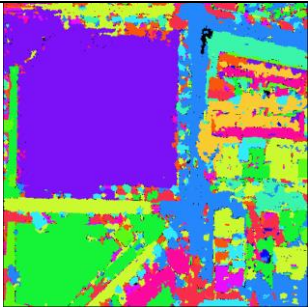
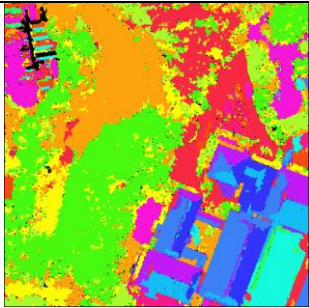
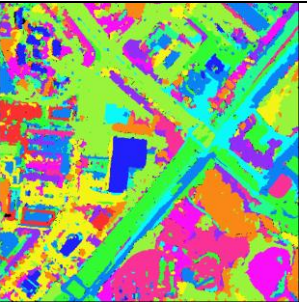
A pesar de existir una gran cantidad de índices para evaluar la clasificación, no existe un índice universalmente aceptado, pero algunos autores recomiendan calcular varias métricas sobre la precisión, y acompañarlas con la matriz de errores para tener una descripción más completa de la precisión de la clasificación. Para este caso particular, se calculó la precisión (P), el Índice Kappa (K) y la Matriz de Errores (también llamada matriz de confusión).

La **Figura 5.3** ilustra las clasificaciones obtenidas para cada imagen, utilizando diferentes combinaciones de atributos, en primera línea, solo se utiliza el atributo color (RGB) de cada objeto, en la segunda línea, se utilizan dos atributos (color y textura), y en la tercera línea, se utilizan tres atributos (color, textura y vecindad).

Se puede apreciar como el atributo color, representa el atributo más discriminador entre los tres, mientras la textura presenta un comportamiento ambiguo, dado que discrimina bien unas clases (ej. clases de vegetación), pero combina otras clases diferentes (ej. vías y pasto); por su parte, la vecindad, resulta útil para eliminar algunas clases menos representativas, pero no es del todo conveniente, porque en las imágenes VHRS existen muchos objetos pequeños, que siendo importantes (ej. autos), suelen desaparecer al utilizar este atributo. El atributo color permite lograr una alta discriminación entre las clases mas representativas, aunque crea algunas subclases de algunas categorías (ej. vías),

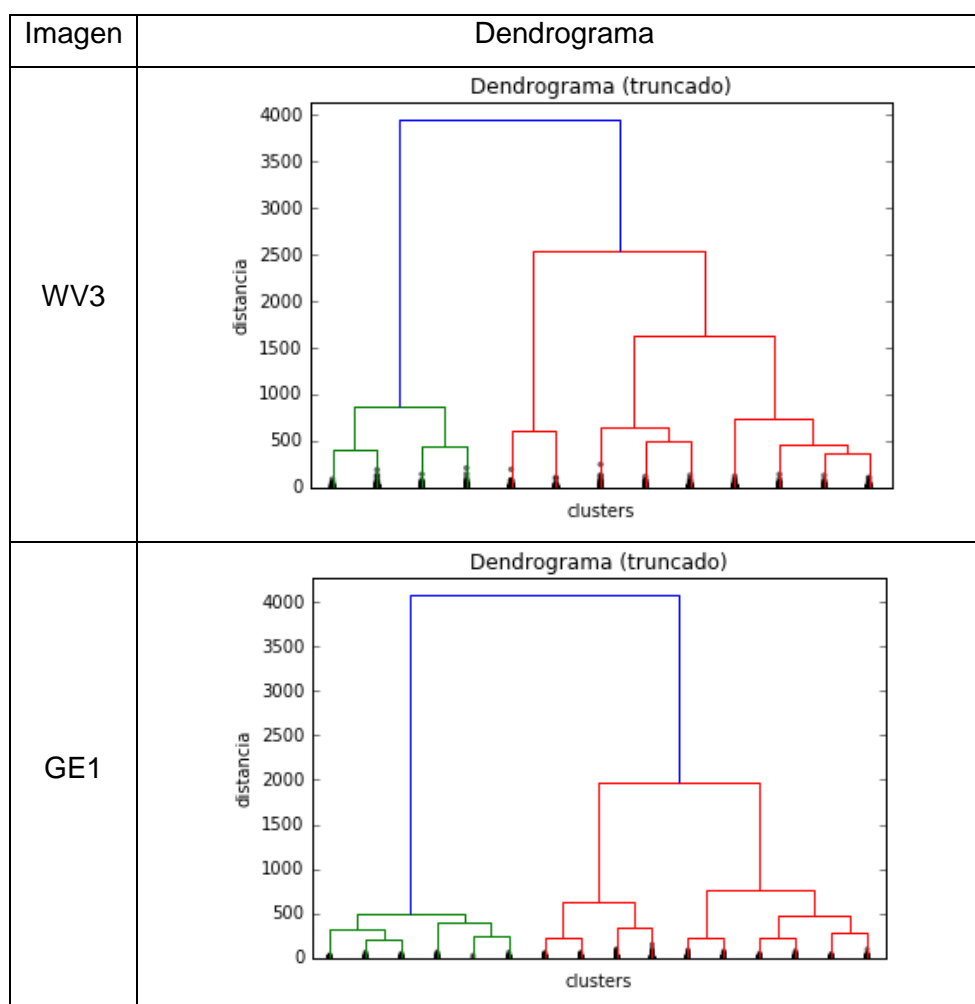
debido a que estas presentan diferentes materiales como pavimento, cemento o ladrillo, lo que el atributo interpuesta como una clase diferente.


**Figura 5.3.** Clasificación de las imágenes VHSR obtenidas con diferentes combinaciones de los atributos.

	Imagen		
Atributos	WV3 (13 clases)	GE1 (16 clases)	NAIP (12 clases)
Original			
Color			
Color & Textura			
Color & Vecindad			

De lo anterior, y teniendo en cuenta la sugerencia de Hartigan (1985), la importancia de los dendrogramas truncados obtenidos para cada clasificación, dado que permiten visualizar las relaciones entre los diferentes clusters, y con base en esto, producir una reclasificación de interés para el experto/usuario, de acuerdo a las distancias entre los clusters. La **Figura 5.4** permite identificar en los dendrogramas la existencia de 3-4 clusters principales, por lo cual se procedió a reclasificarlas, y realizar la evaluación sobre estas.

**Figura 5.4.** Dendrogramas correspondientes a la agrupación jerárquica aglomerativa para cada imagen VHSR.






Las imágenes producto de la reclasificación (**Figura 5.5**) presentan resultados contrastantes, dado que para la imagen WV3 combina clases muy diferentes (ej. edificios y suelo desnudo, árboles y vías); mientras que para la imagen GE1, brinda una discriminación entre la infraestructura, vegetación y las vías. Por su parte, para la imagen NAIP, aunque la reclasificación combina clases como vías e infraestructura, permite una buena discriminación de la vegetación.

**Figura 5.5.** Reclasificación de cada imagen con ayuda el dendrograma.

Imagen		
WV3 (3 clases)	GE1 (3 clases)	NAIP (3 clases)





Los valores de las métricas utilizadas para evaluar la clasificación (**Tabla 5.2.** Métricas de evaluación de la clasificación no supervisada.), confirman el análisis cualitativo (visual) realizado previamente. Los valores de la precisión (P) indican muy buen desempeño para la imagen GE1 (98%), deficiente para la imagen WV3 (55%), y aceptable para la imagen NAIP (76%), arrojando un promedio de 76%, el cual se puede considerar bueno, pero teniendo en cuenta que esta se logra a partir de una clasificación no supervisada, y apoyada por un experto/usuario quien reclasifica las categorías de acuerdo las clases de interés con ayuda del dendrograma,

Estos resultados son muy alentadores porque usualmente los objetos de interés en una imagen de sensores remotos se obtienen a través de un proceso de clasificación supervisado que requiere la utilización de un conjunto de entrenamiento o la digitalización manual realizada por un operario, donde ambas involucran otra conjunto de supuestos (ej. normalidad de los datos, experticia del operario) que pueden incrementar el error, así como un incremento del tiempo y de los costos incurridos para el procesamiento de los datos.

**Tabla 5.2.** Métricas de evaluación de la clasificación no supervisada.

Métrica	Imagen									Promedio
	WV3			GE1			NAIP			
Precisión	54.79			97.56			75.38			75.91
Kappa	27.18			95.11			59.90			60.73
Clases	3			3			3			3
Matriz de errores	0.60	0.64	0.47	1.00	0.00	0.00	0.82	0.75	0.06	
	0.05	0.36	0.41	0.0	1.00	0.00	0.00	0.88	0.06	

	0.14	0.07	0.59	0.0	0.09	0.96	0.05	0.75	0.56	
--	------	------	------	-----	------	------	------	------	------	--

## 5.5 Conclusiones

El método de clasificación no supervisado de tipo jerárquico aglomerativo no requiere la determinación de parámetros, como número de clusters o semillas, dado que utiliza todos los datos bajo una estrategia bottom-up, creando clusters de acuerdo a una métrica de distancia, lo que lo hace muy adecuado para obtener un dendrograma que brinda una idea del comportamiento de los datos.

En esta investigación, se determinó el número de clusters de forma a priori, de acuerdo al punto de inflexión de la línea identificada para cada imagen. Esto represento dos beneficios; primero, obtener un dendrograma truncado (simplificado) que permite apreciar de mejor forma la organización de los clusters más representativos de la imagen; y segundo, permite a un experto/usuario reclasificar la imagen de acuerdo a su interés, sin la necesidad de incurrir en una fase de entrenamiento, posibilitando la tarea de eliminar aquellos objetos que afecten la clasificación, ya sea por su número o tamaño.

Se confirmó lo que argumentan algunos autores para algunos métodos de clasificación no supervisada, que no necesariamente el aumento en el número de atributos puede afectar la precisión de la clasificación, dado que al combinar el atributo color, con los demás atributos (textura y vecindad), el rendimiento de la clasificación fue inferior (color y textura) o igual (color y vecindad), que al utilizar solamente el atributo color.



## 6.DISCUSION DE RESULTADOS SOBRE LA METODOLOGIA EN LINEAS

Este capítulo presenta una discusión integrada de los resultados alcanzados con la metodología basada en Líneas, compuesta por tres fases fundamentales del procesamiento y análisis de imágenes de sensores remotos, como son la determinación de la escala, la segmentación basada en crecimiento de regiones y finalmente, la clasificación no supervisada de los objetos segmentados.

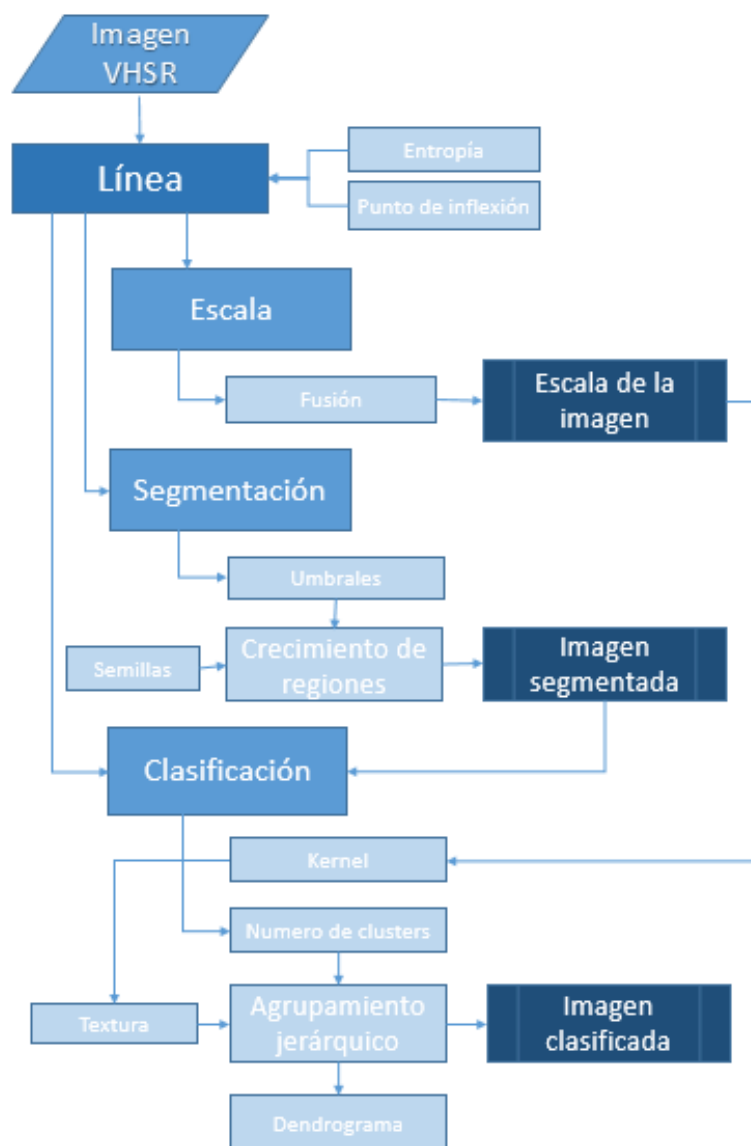
La **Figura 6.1**. Diagrama de flujo de la metodología basada en líneas, indicando los procesos y los subprocesos (azul medio y azul claro respectivamente), mientras los productos finales se indican con azul oscuro. ilustra las etapas secuenciales que involucra la metodología, la cual requiere como entrada la imagen de interés, sobre la cual se aplican los métodos desarrollados, para finalmente obtener un producto final, que puede ser un mapa, una imagen clasificada o una lista de contornos.

Esta metodología propuesta constituye una nueva aproximación al procesamiento y análisis de imágenes de sensores remotos, porque utiliza la línea como elemento fundamental, la cual permite la ejecución automática de los procesos involucrados, lo cual resulta muy conveniente para la extracción de información a partir de gran volumen de imágenes que existe actualmente, y que continua en aumento, particularmente las imágenes VHRS.

Existen algunas aproximaciones para el procesamiento y análisis automático de imágenes, pero no están dirigidas para la ejecución de varias etapas, sino que se enfocan en una tarea específica, como *Region-based GeneSYS* (Mylonas et al, 2014), dirigida a la

clasificación, mientras las aproximaciones denominadas *Region-based Image Segmentation Algorithm* (Wang et al., 2010) y *Region-based Algorithmic Framework* (Hu et al, 2005), ambas dirigidas a segmentación. Además, estas tres aproximaciones mencionadas podrían considerarse como semi-automáticas, porque en cierto momento requieren la asistencia humana, especialmente para la definición de los parámetros requeridos por algoritmos como el *k-means*, crecimiento de regiones o la definición de reglas de pertenencia difusas.

**Figura 6.1.** Diagrama de flujo de la metodología basada en líneas, indicando los procesos y los subprocesos (azul medio y azul claro respectivamente), mientras los productos finales se indican con azul oscuro.



La componentes principales de la metodología, donde se puede observan la posibilidad de enlazar los procesos, es decir, para realizar la segmentación, se requiere el cálculo de la escala de la imagen, y para la clasificación requiere el resultado de la segmentación, lo que convierte esta aproximación en una propuesta unificada, que podría involucrar nuevos

componentes en el futuro, como una fase de pre-procesamiento (transformaciones o filtrado), y posiblemente también una fase de pos-procesamiento (interpretación o reconocimiento).

Con relación a los tiempos de ejecución del procesamiento y análisis de imágenes, la , indica que en promedio se tarda 4.32 minutos la ejecución de las tres fases involucradas, lo cual se considera un tiempo razonable, teniendo en cuenta que los algoritmos están implementados en lenguaje Python, sobre una máquina convencional, y posiblemente algunas rutinas, requieran algún tipo de optimización. Su tiempo de procesamiento podría mejorarse al implementar en lenguaje C, aquellas rutinas que consuman más tiempo.

También, se puede observar como la fase de la segmentación consume el 70% del procesamiento de una imagen, debido a que el algoritmo de crecimiento de regiones opera de forma iterativa, y además, está dividido en dos partes, cuando opera sobre la línea, y posteriormente, sobre el resto la imagen.

Con relación a las fases escala y clasificación, sus tiempos de ejecución son similares, y no son demasiado altos, aunque también pueden ser sometidos a una optimización, posiblemente una implementación en paralelo sea lo apropiado para la determinación de la escala.

Una tendencia decreciente en el tiempo de procesamiento se observa a medida que se reduce la resolución espacial de las imágenes, mostrando correspondencia con el tiempo de ejecución en la fase de segmentación de las imágenes. Esto es consecuencia de que mayor resolución espacial se produce un aumento de la variabilidad, y esta mayor variabilidad se traduce en un mayor tiempo de procesamiento, especialmente en la segmentación, la cual opera a nivel de pixel, mientras que la fase de clasificación opera a nivel de objetos.

**Tabla 6.1.** Tiempos de ejecución para cada uno de los procesos involucrados para tres imágenes VHSR.

Proceso	Imagen			<i>Promedio</i>
	WV3	GE1	NAIP	

---

Escala	39.97	39.50	41.12	40.20
Segmentación	246.36	188.93	121.73	185.67
Clasificación	35.56	41.60	22.92	33.36
<i>Total</i>	<i>321.89</i>	<i>270.03</i>	<i>185.77</i>	<i>259.23</i>

Tiempo en segundos

## 7. Conclusiones y recomendaciones

### 7.1 Conclusiones

El método para la determinación de la escala en las imágenes de sensores remotos brinda una aproximación automática y ágil en comparación con los demás métodos existentes, los cuales requieren una participación activa del experto/usuario, quien debe determinar algunos parámetros como el tamaño de la ventana (método *LVM*), y determinar el *lag* o distancias (método por semivariograma), al igual que otros métodos no ensayados aca como los métodos basado en wavelets o en fractales.

El método de segmentación automático basado en crecimiento de regiones ha demostrado su buen rendimiento y competitividad frente a métodos supervisados de segmentación como los métodos *Watershed* y *FNEA*, ampliamente conocidos en el procesamiento de imágenes de sensores remotos. Además de ser completamente automático, presenta una ventaja adicional frente a esos métodos, como la cualidad de no sobre-segmentar los objetos, lo que significa que se pueden analizar los objetos bajo una sola escala, así como un ahorro en tiempo de posprocesamiento (fusión de regiones) frente a las propuestas comparadas.

El método de clasificación no supervisado basado en agrupamiento jerárquico aglomerativo se comporta adecuadamente frente a la determinación a priori de los clusters a producir, permitiendo al experto/usuario hacer un análisis visual (dendrograma) y gráfico (imagen), para determinar el número de clases de interés para su propósito particular.

Aunque esto dificulta la posibilidad de compararlo frente a otros métodos alternativos (ej. supervisados), permite una reducción en el tiempo de clasificación, aunque requiera la inversión de un tiempo adicional, en la fase de pos-clasificación, pero que no es superior al tiempo invertido durante la fase de entrenamiento que requiere un método supervisado.

Finalmente, se ha demostrado como la metodología basada en *líneas* se puede convertir en una alternativa viable frente a las aproximaciones existentes, porque aborda de forma integral el procesamiento y análisis de imágenes de las imágenes de sensores remotos, tomando como elemento central el concepto de línea, definida como el conjunto de píxeles que representa, aglutina o resume el comportamiento de los objetos que se encuentran en toda la imagen. En esta investigación se ha obtenido la información contenida en la línea, para determinar la escala de la imagen, y también definir los parámetros requeridos por los diferentes algoritmos empleados para la segmentación (crecimiento de regiones) y clasificación (agrupación jerárquica aglomerativa).

## 7.2 Recomendaciones

Se considera que el componente de selección de atributos que no se abordó en la presente investigación debido a la aproximación no supervisada que se realizó para la clasificación, se puede profundizar en algunos métodos propuestos para su realización, de tal forma que se pueda ampliar la utilización del abanico de atributos que actualmente existe, y que siguen proponiéndose en el campo del procesamiento y análisis de imágenes, que permitan mejorar el rendimiento de la clasificación, sin afectar demasiado el tiempo de procesamiento.

Se considera importante evaluar el desempeño de la metodología basada en líneas en las imágenes capturadas con drones (*UAV* sigla en inglés), las cuales presentan resoluciones espaciales muy altas (<10 cm), pero cuyos sensores de captura todavía no están estandarizados, pero que en el futuro llegaran a convertirse en una fuente abundante de imágenes de sensores remotos.

A pesar que el tiempo de procesamiento no fue una premisa en la presente investigación, se considera que este tiempo pueden reducirse significativamente implementando algunas

funciones en lenguaje C, principalmente la encargada del crecimiento de las regiones, que es la que consume aproximadamente el 70% del tiempo incurrido durante el procesamiento de las imágenes.



# A. Anexo: Especificaciones técnicas de las imágenes VHSR

Para el desarrollo de esta investigación se utilizaron imágenes gratuitas cedidas por las compañía privada Digital Globe y de la entidad pública norteamericana FSA (Farm Service Agency sigla en inglés), filial del Departamento de Agricultura Norteamericano (USDA sigla en inglés)

## **Imagen WorldView 3**

Bandas pancromáticas: 450-800 nm

Resolución espacial: Nadir Pancromático: 0.31 m GSD en Nadir, 0.34 m en 20° Off-Nadir

Nadir Multiespectral: 1.24 m en Nadir, 1.38 m en 20° Off-Nadir

Rango dinámico: 11-bits por pixel Pancromatico y Multiespectral

Área de la escena: 13.1 x 13.1 km

Adaptado de: <http://www.satimagingcorp.com/satellite-sensors/worldview-3/>

## **Imagen GeoEye 1**

Resolución espacial: 0.46 m Pancromático (nominal en Nadir)

1.84 m Multiespectral (nominal en Nadir)

Rango espectral: Pancromático: 450 - 800 nm

Blue: 450 - 510 nm

Green: 510 - 580 nm

Red: 655 - 690 nm

Near Infra Red: 780 - 920 nm

Precisión Métrica/Geolocalización: 5 m CE90, 3 m CE90 (medido)

Área de la escena: 15 x 15 km

Adaptado de: <http://www.satimagingcorp.com/satellite-sensors/geoeye-1/>

**Imagen NAIP**

Resolución espacial: 1.0 m  
Resolución espectral: color natural color (RGB)  
Nubosidad: inferior al 10%  
Sistema de coordenadas: UTM (NAD 83)  
Formato: MrSID

Adaptado de:

<https://www.fsa.usda.gov/programs-and-services/aerial-photography/imagery-programs/naip-imagery/>

## **B. Anexo: Entorno de desarrollo**

Esta investigación se desarrolló utilizando tres herramientas fundamentales como son: Lenguaje Python, Plataforma Anaconda y Librería OpenCV

### **Lenguaje Python:**

Es un lenguaje potente y rápido creado por Guido van Rossum, que trabaja armónicamente con otros lenguajes con C/C++, se puede ejecutar en cualquier sistema operativo, es amigable y fácil de aprender. Adicionalmente, es abierto.

Versión: Python 2.7

Disponible en: <https://www.python.org/>

### **Plataforma Anaconda:**

Es una distribución gratuita que consta de un manejador de paquetes, entorno de administración, una distribución de Python y una colección que contiene más de 720 paquetes de código abierto con apoyo continuo de una comunidad libre. Es una herramienta utilizada por analistas de negocios, científicos, desarrolladores e ingenieros desarrollada por la empresa Continuum Analytics.

Versión: Anaconda 4.1.1. (32-bit)

Disponible en: <https://docs.continuum.io/anaconda/>

### **Librería OpenCV:**

Esta librería esta liberada bajo la licencia BSD, por lo cual es libre para uso académico y comercial. Tiene interfaces para C++, C, Python y Java y soporta ambientes Windows, Linux, Mac OS, iOS y Android. OpenCV ha sido diseñada hacia la eficiencia computacional con un enfoque hacia las aplicaciones en tiempo real. Está escrita en lenguaje C/C++ optimizado, y toma ventaja del procesamiento multi-núcleo. Habilitada con OpenCL por lo cual puede tomar ventaja de la aceleración de hardware en plataformas computacionales

heterogéneas. Es utilizada alrededor del mundo, y tiene más de 47 mil usuarios en su comunidad, con un estimado de 9 millones de descargas. Su uso se extiende desde el arte interactivo, inspección de minas, gestión de mapas en la web o en robótica avanzada.

Version: OpenCv 3.1 (Windows)

Disponible en: <http://opencv.org/>

### **Modulo Scikit-Image:**

Es una colección de algoritmos para el procesamiento de imágenes. Es acceso libre sin restricciones. Contiene código de alta calidad, revisado por pares y escrito por una comunidad muy activa de voluntarios.

Version: 0.12.3 (stable) (Marzo 2016)

Disponible en: <http://scikit-image.org/>

### **Notebook Jupyter**

El Proyecto Jupyter nació a partir del proyecto IPython en el 2014 a medida que evolucionó para el soporte interactivo de la computación científica a través de todos los lenguajes de programación. Una comunidad vibrante fue la que permitió la creación de esta sorprendente plataforma. Desarrolladores dinámicos junto con científicos avanzados así como usuarios cotidianos trabajaron conjuntamente para incluir las mejores herramientas.

El equipo principal está compuesto por un comité de 14 miembros

Disponible en: <http://jupyter.org/>

## Bibliografía

- Adams, R. y Bischof, L. (1994). Seeded region growing. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 16(6):641–647
- Addink, E.A., De Jong, S.M. y Pebesma, E.J. (2007). The importance of scale in object-based mapping of vegetation parameters with hyperspectral imagery. *Photogrammetric Engineering & Remote Sensing*, 72, 905–912.
- Adeline, K.R.M., Chen, M., Briottet, X., Pang, S.K. y Papanoditis, N. (2013). Shadow detection in very high spatial resolution aerial images: A comparative study. *ISPRS Journal of Photogrammetry and Remote Sensing*, 80, 21-38.
- Akçay, H.G. y Aksoy, S. (2008). Automatic Detection of geospatial objects using multiple hierarchical segmentations. *IEEE Trans. Geoscience and Remote Sensing*, 46(7), 2097-2111.
- Aksoy, B. y Ercanoglu, M. (2012). Landslide identification and classification by object-based image analysis and fuzzy logic: An example from the Azdavay region (Kastamonu, Turkey). *Computers & Geosciences*, 38(1), 87-98.
- Ali, S.S., Dare, P.M y Jones, S.D. (2009). A Comparison of Pixel- and Object-Level Data Fusion Using Lidar and High-Resolution Imagery for Enhanced Classification. En: S. Jones, K. Reinke (eds.), *Innovations in Remote Sensing and Photogrammetry*, 3 Lecture Notes in Geoinformation and Cartography, Springer-Verlag Berlin Heidelberg. DOI 10.1007/978-3-540-93962-7\_1.
- Aplin, P, Atkinson, PM y Curran, P.J. (1999). Per-field classification of land use using the forthcoming very fine spatial resolution satellite sensors: problems and potential solutions. *Advances in remote sensing and GIS analysis*, 219-239.
- Aplin, P. y Smith, G.M. (2011). Introduction to object-based landscape analysis *International Journal of Geographical Information Science*, 25(6), 869-875.

- Ardila, J.P., Bijker, W., Tolpekin, V.A., Stein, A. (2012). Quantification of crown changes and change uncertainty of trees in an urban environment. *ISPRS Journal of Photogrammetry and Remote Sensing*, 74(0), 41-55.
- Arnedo, A., Decoster, N. y Roux, S.G. (2000). A wavelet-based method for multifractal image analysis. I. Methodology and test applications on isotropic and anisotropic random rough surfaces. *Eur. Phys. J. B*, 15, 567–600.
- Arvor, D., Durieux, L. Laporte, y S.A. M-A (2013). Advances in geographic object-based image analysis with ontologies: a review of main contributions and limitations from a remote sensing perspective. *ISPRS Journal of Photogrammetry and Remote Sensing*, 82, 125–137. <http://dx.doi.org/10.1016/j.isprsjprs.2013.05.003>
- Baätz, M. y Schäpe, A. (2000). Multiresolution segmentation: An optimization approach for high quality multi-scale image segmentation. En: *Angewandte Geographische Informations-Verarbeitung XII*, J. Strobl, T. Blaschke, and G. Griesebner, Eds. Karlsruhe, Germany: Wichmann Verlag, pp. 12–23
- Baltsavias, E.P. (2004). Object extraction and revision by image analysis using existing geodata and knowledge: current status and steps towards operational systems. *ISPRS Journal of Photogrammetry and Remote Sensing*, 58(3–4), 129–151.
- Basile, M., Merola, P., y Allegrini, A. (2102). Texture Analysis for Urban Areas Classification in High Resolution Satellite Imagery. *Applied Remote Sensing Journal*, 2(2), 65-71.
- Batista, N. y Antunes, A.F.B. (2012). Discriminating mixed ombrophilous fores sub-typologies using object-based image analysis and decision trees. *Proceedings of the 4th GEOBIA*, May 7-9, Rio de Janeiro, Brazil. p.338.
- Belgiu, M. y Drăguț. L. (2014). Comparing supervised and unsupervised multiresolution segmentation approaches for extracting buildings from very high resolution imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 96, 67-75.
- Benes, M. y Zitova, B. (2015). Performance evaluation of image segmentation algorithms on microscopic image data. *Journal of Microscopy*, 257(1), 65-85. <http://dx.doi.org/10.1111/jmi.12186>
- Blaschke, T. (2005). In: Erasmi, S., Cyffka, B., Kappas, M. (Eds.), *A framework for change detection based on image objects*, (pp. 1-9). Göttinger Geographische Abhandlungen, Göttingen.

- Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1), 2-16.
- Blaschke, T., Hay, G.J., Kelly, M., Lang, S., Hofmann, P., Addink, E. et al. (2014). Geographic object-based image analysis—towards a new paradigm. *ISPRS Journal of Photogrammetry and Remote Sensing* 87, 180-191.
- Bøcher, P.K. y McCloy, K.R. (2006). The fundamentals of average local variance--Part I: Detecting regular patterns. *IEEE Trans Image Process.*, 15(2), 300-310.
- Budreski, K.A., Wynne, R.H., Browder, J.O. y Campbell, J.B. (2007). Comparison of Segment and Pixel-based Non-parametric Land Cover Classification in the Brazilian Amazon Using Multitemporal Landsat TM/ETM Imagery *Photogrammetric Engineering & Remote Sensing*, 73(7), pp. 813–827.
- Byun, Y., Kim, D., Lee, J. y Y. Kim. (2011). A framework for the segmentation of high-resolution satellite imagery using modified seeded-region growing and region merging. *International Journal of Remote Sensing*, 32(16), 4589-4609. <http://dx.doi.org/10.1080/01431161.2010.489066>
- Cardoso, J.S. y L. Corte-Real. (2005). Toward a generic evaluation of image segmentation. *IEEE Transactions on Image Processing*, 14(11), 1773-1782.
- Carleer, A. P., Debeir, O. y Wolff, E. (2005). Assessment of very high spatial resolution satellite image segmentations. *Photogrammetric Engineering & Remote Sensing*, 71(11):1285–1294.
- Camps-Valls, G., Tuia, D., Gómez-Chova, L., Jiménez, S. y Malo, J. (2012). *Remote Sensing Image Processing*. Morgan and Claypool Publishers.
- Cao, C. y Lam, N.S-G. (1997). Understanding the scale and resolution effects in remote sensing and GIS. In: Quattrochi, D.A. y M.F. Goodchild (eds). *Scale in remote sensing and GIS*. (pp. 57-72). CRC Press.
- Chalidze, V.(2000). *Entropy demystified: potential order, life and money*. Universal publishers. 196 p.
- Cheng, G. y J. Han. (2016). A survey on object detection in optical remote sensing images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 117: 11–28.
- Cleve, C., Kelly, M., Kearns, F. y Moritz, M. (2008). Classification of urban environments for fire management support: A comparison of pixel- and object-based classifications using high-resolution aerial photography. *Computers, Environment and Urban Systems*, 32, 317–326.

- Clinton, N., Holt, A., Scarborough, J., Li, Y. y Gong, P. (2010). Accuracy Assessment Measures for Object-based Image Segmentation Goodness. *Photogrammetric Engineering and Remote Sensing* 76(3):289-299. <http://dx.doi.org/10.14358/PERS.76.3.289>
- Coggins, J.M. y Jain, A.K. (1985). A Spatial Filtering Approach to Texture Analysis. – *Pattern Recognition Letters*, 3, 195-203.
- Dey, V., Zhang, Y. y M. Zhong. (2010). A review on image segmentation techniques with remote sensing perspective. En: Wagner W., Székely, B. (eds.): *ISPRS TC VII Symposium – 100 Years ISPRS, Vienna, Austria, July 5–7, 2010, IAPRS, Vol. XXXVIII, Part 7A*.
- Dornaika, F., Moujahid, A. Merabet, Y.E. y Y. Ruichek. (2016). Building detection from orthophotos using a machine learning approach an empirical study on image segmentation and descriptors: An empirical study on image segmentation and descriptors. *Expert Systems With Applications*, 58: 130–142.
- Dos Santos, J.A., Gosselin, P.H., Philipp-Foliguet, S., Torres, R.S. y Falcao, AX. (2013). Interactive multiscale classification of high-resolution remote sensing images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 6(4), 2020-2034.
- Dragut, L., Csillik, O., Eisank, C. y Tiede, D. (2014). Automated parameterisation for multi-scale image segmentation on multiple layers. *ISPRS Journal of Photogrammetry and Remote Sensing*, 88, 119–127.
- Duda, R.O., Hart, P.E. y Stork, D.G. (2001). *Pattern Classification*. 2nd. ed. Wiley & Sons. New York.
- Dy, J.G. y Brodley, C.E. (2004). Feature Selection for Unsupervised Learning *Journal of Machine Learning Research*, 5, 845–889.
- Fan, J, Zeng, G., Body, M. y M-S. Hacid. (2005). Seeded region growing: an extensive and comparative study. *Pattern Recognition Letters*, 26:1139–1156.
- Foody, G.M.(2002). Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80, 185–201.
- Fowlkes, E.B. y C.L. Mallows. (1983). A method for comparing two hierarchical clusterings. *Journal of the American Statistical Association*, 78(383): 553-569.



- Franklin, S.E., Hall, R.J., Moskal, L.M., Maudie, A.J. y Lavigne, M.B. (2000) Incorporating texture into classification of forest species composition from airborne multispectral images. *International Journal of Remote Sensing*, 21:1, 61-79. <http://dx.doi.org/10.1080/014311600210993>
- Franks, S. (2006). How many bits? Radiometric resolution as a factor in obtaining forestry information with remotely sensed measurements. University of Maryland, College Park, Master of Arts Thesis. 47 p.
- Ge, F., Wang, S. y T. Liu. (2007). New benchmark for image segmentation evaluation. *Journal of Electronic Imaging*, 16(3): 033011(1-16).
- Gómez, O., González, J. y Morales, E.F. (2007). Image Segmentation Using Automatic Seeded Region Growing and Instance-Based Learning. *Progress in Pattern Recognition, Image Analysis and Applications, Proceedings 12th Iberoamerican Congress on Pattern Recognition, CIARP 2007, Valparaiso, Chile, November 13-16.*
- Gonzalez, R.C. y Wintz, P. (1977). *Digital image processing*. Addison-Wesley. USA.
- Gonzalez, R.C. y Woods, R.E. (2002) *Digital Image Processing*, 2nd edn, Pearson Education, Singapore.
- Greven, A., Keller, G. & Warnecke, G. (2003). *Entropy*. Princeton Series. Applied Mathematics, 1-16. Princeton University Press.
- Gurcan, M.N., Boucheron, L., Can, A., Madabhushi, A., Rajpoot, N. y B. Yener. (2009). Histopathological Image Analysis: A Review. *IEEE Rev Biomed Eng*, 2: 147–171. <http://dx.doi.org/10.1109/RBME.2009.2034865>
- Hammes, G.G. y Hammes-Schiffer, S. (2015). *Physical chemistry for the biological sciences*. Second edition. Wyley Series in Methods in Biochemical analysis. <http://dx.doi.org/10.1002/9781118859148>
- Hamming, R.V. (1950). Error detecting and error correcting codes. *Bell Sys. Tech. Journal*, 29: 147-160.
- Haralick, R.M., Shanmugan, K. y Dinstein, I. (1973). Textural Features for Image Classification. *IEEE Transactions on Systems, Man and Cybernetics*, 3(6), 610-621.
- Haralick, R.M. y Shapiro, L.G. (1985). *Computer Vision Graphics and Image Processing*, 29(1):100-132. [http://dx.doi.org/10.1016/S0734-189X\(85\)90153](http://dx.doi.org/10.1016/S0734-189X(85)90153)
- Hastie, T., Tibshirani, R. y Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2nd. ed. Springer.

- Hay, G.J., Blaschke, T., Marceau, D.J. y Bouchard, A. (2003). A comparison of three image-object methods for the multiscale analysis of landscape structure. *ISPRS Journal of Photogrammetry and Remote Sensing*, 57(5), 327-345.
- Hay, G.J. y Castilla, G. (2008). Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline. *Object-based image analysis*, 75-89.
- Hay, G.J., Castilla, G., Wulder, M.A. y Ruiz, J.R. (2005). An automated object-based approach for the multiscale image segmentation of forest scenes. *International Journal of Applied Earth Observation and Geoinformation*, 7(4), 339-359.
- Hay, G.J., Niernann, K.O. y Goodenough, D.G. (1997). Spatial thresholds, image-objects, and upscaling: a multiscale evaluation. *Remote Sensing of Environment*, 62(1), 1-19.
- Hirschmugl, M., Ofner, M., Raggam, J. y M. Schardt. (2007). Single tree detection in very high resolution remote sensing data. *Remote Sensing of Environment*, 110(4): 533-544.
- Hofmann, P. (2001). Detecting buildings and roads from IKONOS data using additional elevation information, *GIS*, 6(1): 28–33.
- Hu, X., Tao, C.V. y Prenzel, B. (2005). Automatic Segmentation of High-resolution Satellite Imagery by Integrating Texture, Intensity, and Color Features. *Photogrammetric Engineering and Remote Sensing*, 71(12), 1399–1406.
- Hurni, K., Hett, C., Epprecht, M., Messerli, P. y Heinimann, A. (2013). A Texture-Based Land Cover Classification for the Delineation of a Shifting Cultivation Landscape in the Lao PDR Using Landscape Metrics. *Remote Sens.* 5, 3377-3396. <http://dx.doi.org/10.3390/rs5073377>
- ITU-R. (1990). Recommendation BT.709 Basic Parameter Values for the HDTV Standard for the Studio and for International Programme Exchange (1990), [formerly CCIR Rec. 709] (Geneva: ITU, 1990).
- Jaccard, P. (1908). Nouvelles recherches sur la distribution florale. *Bull Soc Vaudoise Sci Nat*, 44: 223–270.
- Jähne, B. (2002). *Digital Image Processing*. Springer.
- Janssen, L.L.F. y Molenaar, M. (1995). Terrain Objects, Their Dynamics, and Their Monitoring by The Integration of GIS and Remote Sensing. *IEEE Transactions On Geoscience and Remote Sensing*, 33(3): 749-758.

- Jantz, C.A. y Goetz, S.J. (2005). Analysis of scale dependencies in an urban land-use-change model. *International Journal of Geographical Information Science*, 19(2), 217–241.
- Jensen, J.R. (2007). *Remote sensing of the environment: an earth resource perspective*. 2nd ed. Prentice Hall.
- Jia, S., Qian, Y., Li, J. y Ji, Z. (2010). Feature extraction and selection hybrid algorithm for hyperspectral imagery classification. *Conference: Geoscience and Remote Sensing Symposium (IGARSS), Geoscience and Remote Sensing Symposium(IGARSS), IEEE*, pp. 72-75.
- Jiao, L., Liu, Y, Li, H. (2012). Characterizing land-use classes in remote sensing imagery by shape metrics. *ISPRS Journal of Photogrammetry and Remote Sensing* 72:46–55.
- Jones, E., Oliphant, E., Peterson, P. (2001). *SciPy: open source scientific tools for Python*. Disponible en: <http://www.scipy.org>
- Jost, L. (2006). Entropy and diversity. *OIKOS*, 113(2), 363-375.
- Kok, K., Farrow, A., Veldkamp, A. y Verburg, P.H. (2001). A method and application of multi-scale validation in spatial land use models. *Agriculture, Ecosystems and Environment*, 85, 223–238.
- Koonsanit, K. y Jaruskulchai, C. (2011). A Simple Estimation the Number of Classes in Satellite Imagery. 2011 Ninth International Conference on ICT and Knowledge Engineering IEEE. pp.124-128.
- Krishnaswamy, J., Bonell, M., Venkatesh, B., Purandara, B.K., Lele, S. et al. (2012). The rain–runoff response of tropical humid forest ecosystems to use and reforestation in the Western Ghats of India. *Journal of Hydrology*, 472–473, 216–237.
- Kumar, M., Singh, R.K., Raju, P.L.N. y Y.V.N. Krishnamurthy. (2014). Road network extraction from high resolution multispectral satellite imagery based on object oriented techniques. En: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume II-8, 2014. ISPRS Technical Commission VIII Symposium, 09 – 12 December 2014, Hyderabad, India.
- Laliberte, A.S. y Rango, A. (2011). Image Processing and Classification Procedures for Analysis of Sub-decimeter Imagery Acquired with an Unmanned Aircraft over Arid Rangelands. *GIScience & Remote Sensing*, 48(1), 4–23. <http://dx.doi.org/10.2747/1548-1603.48.1.4>

- Lam, N.S.-N. (2004). Fractals and scale in environmental assessment and monitoring. En: Sheppard, E. y R. McMaster (eds). *Scale and Geography inquiry. Nature, Society and Method*. (pp. 23-40). Oxford, UK: Blackwell Publishing.
- Lam, N.S.-N. y Quattrochi, D.A. (1992). On the issues of scale, resolution, and fractal analysis in the mapping sciences. *Prof. Geogr*, 44, 88-98.
- Lee, J. y Warner, T. A. (2004). Image classification with a region based approach in high spatial resolution imagery. En: *Int. Archives Photogramm., Remote Sens. and Spatial Inf. Sci.*, Istanbul, Turkey, pp. 181–187.
- Levin S.A. (1993). Concepts of scale at the local level. En: J.R. Ehleringer, y C.B. Field. (eds). *Scaling Physiological Processes: Leaf to Globe*. (pp. 7-19). Academic Press.
- Li, Z., Hayward, R., Liu, Y. y Walker, R. (2011). Spectral–texture feature extraction using statistical moments with application to object-based vegetation species classification *International Journal of Image and Data Fusion*, 2(4), 347–361.
- Liang, B. y Weng, Q. (2014). Multiscale Fractal Characteristics of Urban Landscape in Indianapolis, USA. En: Q. Weng (eds). *Scale Issues in Remote Sensing*. (pp. 230-252). <http://dx.doi.org/10.1002/9781118801628>
- Lin, H.C., Wang, L.L. y Yang, S.N. (1997). Extracting periodicity of a regular texture based on autocorrelation functions. *Pattern Recognition Letters*, 18(5), 433-443.
- Lisita, A., Sano, E.E., and Durieux, L. (2013). Identifying potential areas of Cannabis sativa plantations using object-based image analysis of SPOT-5 satellite data. *International Journal of Remote Sensing*, 34(15), 5409-5428.
- Liu, J, Li, P. y X. Wang. (2015). A new segmentation method for very high resolution imagery using spectral and morphological information. *ISPRS Journal of Photogrammetry and Remote Sensing*, 101:145–162.
- Lopez, J. y Branch, J.W. (2005). Comparison of models of automatic classification of textural patterns of minerals presents in colombian coals. *Dyna Revista Facultad Nacional de Minas*, 72(146), 115-124.
- Lu, Y., Miao, J., Duan, L., Qiaoc, Y. y Jia, R. (2008). A new approach to image segmentation based on simplifiedregion growing PCNN. *Applied Mathematics and Computation*, 205, 807-814.
- Lucieer, Arko. (2004). Uncertainties in segmentation and their visualisation. ITC PhD Thesis Dissertation. No.113. Utrecht University.

- Malek, A.A., ahoo.com, Rahman, W., Ibrahim, A., Mahmud, R., Yasiran, S.S. y Jumaat, A.K. (2010). Region and Boundary Segmentation of Microcalcifications using Seed-Based Region Growing and Mathematical Morphology. *Procedia - Social and Behavioral Sciences*, 8,634-639.
- Marceau, D.J. y Hay, G.J. (1999). Remote Sensing Contributions to the Scale Issue. *Canadian Journal of Remote Sensing*, 25(4), 357-366. <http://dx.doi.org/10.1080/07038992.1999.10874735>
- Martha, T.R., Kerle, N., van Westen, C.J., Jetten, V. y Kumar, K.V. (2011). Segment optimization and data-driven thresholding for knowledge-based landslide detection by object-based image analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 49(12), 4928-4943. <http://dx.doi.org/10.1109/TGRS.2011.2151866>
- Martínez, S. y Mollicone, D. (2012). From Land Cover to Land Use: A Methodology to Assess Land Use from Remote Sensing Data *Remote Sens.* 4, 1024-1045. <http://dx.doi.org/10.3390/rs4041024>
- Masisi, L., Nelwamondo, V. y Marwala, T. (2008). The use of entropy to measure structural diversity. En: *ICCC IEEE International Conference on Computational Cybernetics*, (pp. 27-29). <http://dx.doi.org/10.1109/ICCCYB.2008.4721376>
- McKay, D. (2003). *Information theory, inference and learning algorithms*. Cambridge University Press. 640 p.
- Mehnert, A. y Jackway, P. (1997). An improved seeded region growing algorithm. *Pattern Recognition Letters*, 18, 1065–1071.
- Myburgh, G. y Van Niekerk, A. (2013). Effect of feature dimensionality on object-based land cover classification: A comparison of three classifiers. *South African Journal of Geomatics*, 2(1), 13-27.
- Myint, S.W., Gober, P., Brazel, A., Grossman-Clarke, S. y Q. Weng. (2011). Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. *Remote Sensing of Environment*, 115(5), 1145–1161.
- Mylonas, S.K., Stavrakoudis, D.G., Theocharis, T.G. y Mastorocostas, P.A. (2014). Spectral-Spatial Classification of Remote Sensing Images using a Region-based GeneSIS Segmentation Algorithm. *IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*. July 6-11, 2014, Beijing, China. pp. 1976-1984.
- Navulur, K. (2007). *Multispectral Image Analysis Using the Object-Oriented Paradigm*. CRC Press.

- Nobrega, R.A., O'Hara, C.G. y J.A. Quintanilha. (2008). An object-based approach to detect road features for informal settlements near Sao Paulo, Brazil. In: T. Blaschke, S. Lang, G.J. Hay (Eds.), *Object Based Image Analysis*, Springer, Heidelberg, Berlin, New York (2008), pp. 589–607.
- Pal, N.R. y S.K. Pal. (1993). A review on image segmentation techniques. *Pattern Recognition*, 26 (9), 1277-1294.
- Pal, N.R. y Pal, S.K. (1991). Entropy: a new definition and its applications. *IEEE Trans. Systems, Man and Cybernetics*, 21, 5, 1260-1270.
- Pinoli, J-C. (2014). *Mathematical Foundations of Image Processing and Analysis 1*. Wiley.
- Platt, R.V. y Rapoza, L. (2008). An Evaluation of an Object-Oriented Paradigm for Land Use/Land Cover Classification. *The Professional Geographer*, 60(1), 87-100.
- Poynton, C. (2009). Color FAQ. 24 p. Disponible en: [http:// www.poynton.com/](http://www.poynton.com/)
- Polychronaki, A. y Gitas, I.Z. (2012). Burned Area Mapping in Greece Using SPOT-4 HRVIR Images and Object-Based Image Analysis. *Remote Sensing*, 4(2), 424-438.
- Sande, C., de Jong, S. M. and Roo, A. (2003). A segmentation and classification approach of IKONOS-2 imagery, *International Journal of Applied Earth Observation and Geoinformation* 4(3): 217–229.
- Razakarivony, S. y F. Jurie. (2016). Vehicle detection in aerial imagery: A small target detection benchmark. *Journal of Visual Communication and Image Representation*, 34: 187–203.
- Richards, J.A.(2013) *Remote Sensing Digital Image Analysis: an introduction*. 5 ed. Springer.
- Richards, J.A. y Jia, X. (2006). *Remote sensing digital image analysis: an introduction*. 4th ed. Springer. Germany.
- Rouhi, R., Jafari, M., Kasaei, S. and P. Keshavarzian. (2015). Benign and malignant breast tumors classification based on region growing and CNN segmentation. *Expert Systems with Applications*, 42(3), 990-1002.
- Saeed, K. y M. Albakoor. (2009). Region growing based segmentation algorithm for typewritten and handwritten text recognition. *Applied Soft Computing*, 9(2), 608-617.
- Shannon, C.E. (1948). A mathematical theory of communication. *Bell System Technical Journal*, 27(3), 379–423.

- Singh, B. y A.P. Singh. (2008). Edge detection in gray level images based on the Shannon entropy. *Journal of Computer Science*, 4(3), 186-191.
- Trémeau, A. y Colantoni, P. Regions adjacency graph applied to color image segmentation. *IEEE Transactions on image processing*, 9(4), 735-744.
- UCGIS. (2006) Summer Assembly Report. Disponible en: <http://ucgis.org/wiki-entry/2006-ucgis-summer-assembly-report>
- Ünsalan, C. y Boyer, K.L. (2011). *Multispectral Satellite Image Understanding*, 1-4. Springer. London.
- Ursani, A.A., Kpalma, K., Lelong, C.C.D. y Ronsin, J. (2012). Fusion of Textural and Spectral Information for Tree Crop and Other Agricultural Cover Mapping With Very-High Resolution Satellite Images. *Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(1), 225-235.
- Vanwambeke, S.O., Van Benthem, B.H.B. y Khantikul, N. (2006). Multi-level analyses of spatial and temporal determinants for dengue infection. *International Journal of Health Geographics*, 5(5), 1-5.
- Walter, V. (2004). Object-based classification of remote sensing data for change detection, *ISPRS Journal of Photogrammetry and Remote Sensing* 58(3-4): 225-238.
- Wang, Z., Jensen, J.R. y J. Im. (2010). An automatic region-based image segmentation algorithm for remote sensing applications. *Environmental Modelling & Software*, 25, 1149-1165.
- Weidenhiller, A. y Denzler, J.K. (2014). On the suitability of colour and texture analysis for detecting the presence of bark on a log. *Computers and Electronics in Agriculture*, 106, 42-48.
- Weng, Q. (2014). On the issue of scale in urban remote sensing. En: Q. Weng (eds). *Scale Issues in Remote Sensing*. (pp. 61-78). <http://dx.doi.org/10.1002/9781118801628>
- Whiteside, T.G., Boggs, G.S. y Maier, S.W. (2011). Comparing object-based and pixel-based classifications for mapping savannas. *International Journal of Applied Earth Observation and Geoinformation*, 13(6), 884-893. <http://dx.doi.org/10.1016/j.jag.2011.06.008>
- Wilkinson, G. (2005). Results and implications of a study of fifteen years of satellite image classification experiments. *IEEE Trans. Geosci. Remote Sens.*, 43(3), 433-440.
- Woodcock, C.E. y Strahler, A.H. (1987). The factor of scale in remote sensing. *Remote Sensing of Environment*, 21, 311-332.

- Wu, H. y Li, Z-L. (2009). Scale issues in remote sensing: a review on analysis, processing and modeling. *Sensors*, 9, 1768-1793. <http://dx.doi.org/10.3390/s90301768>
- Xiang, T., y Gong, S. (2008). Spectral clustering with eigenvector selection. *Pattern Recognit.* 41, 1012–1029
- Yue, A.Z., Zhang, C., Yang, J.Y., Su, W., Yun, W.J. y Zhu, D. (2013). Texture extraction for object-oriented classification of high spatial resolution remotely sensed images using a semivariogram. *International Journal of Remote Sensing*, 34, 11, 3736–3759. <http://dx.doi.org/10.1080/01431161.2012.759298>
- Yu, Q., Gong, P., Clinton, N., Biging, G., Kelly, M. y D. Schirokauer. (2006). Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery. *Photogrammetric Engineering and Remote Sensing*, 72(7): 799–811.
- Zhang, Y-J. (2015). Half Century for Image Segmentation. *Encyclopedia of Information Science and Technology*, Third Edition, 10 p. <http://dx.doi.org/10.4018/978-1-4666-5888-2.ch584>
- Zhao, Y.Q., Wang, X.H., Wang, X.F. y F.Y. Shih. (2014). Retinal vessels segmentation based on level set and región. *Pattern Recognition*, 47(7), 2437–2446
- Zhou, W., Huang, G., Troy, A. y Cadenasso, M. (2009). Object-based land cover classification of shaded areas in high spatial resolution imagery of urban areas: A comparison study. *Remote Sens. Environ.*, 113(8), 1769–1777.



## Publicaciones del autor

- López. (2014). Análisis del cambio de tipo de cobertura en la microcuenca urbana Hato de la Virgen ubicada en el municipio de Ibagué. Revista Tumbaga, (próximamente).
- López, J. y Branch, J.W. (2014). Mini-UAV: key imaging tool for GEOBIA. South-Eastern European Journal of Earth Observation and Geomatics (SEEJoEOG). 3(2S):
- López.; Arce, C. y Arévalo, R.L. (2012). Aplicación de la técnica de redes neuronales para la predicción de la altura de árboles de algunas especies maderables promisorias presentes en plantaciones forestales de Colombia. Revista Tumbaga, 2(7): 97-105.
- López, J. (2010). Incorporación de las nuevas tecnologías en la educación superior. Revista Colombiana de la Educación Superior. 2(4): 32-38.
- López, J. y Branch, J.W. (2005). Comparación de modelos de clasificación automática de patrones texturales de minerales presentes en los carbones colombianos. Revista Dyna, 72(146): 115-124.
- López, J. y González, J.F. (2005). Estado del arte: reconocimiento automático del iris humano. Revista Scientia et Technica, 3(29): 77-81.

## Biografía

Jaime López Carvajal nació en Colombia (1969). Durante los años 1990-1997 hizo sus estudios de pregrado en Ingeniería Forestal en la Universidad Nacional de Colombia (UNAL-Medellín). Posteriormente, entre los años 2001-2004 realizó sus estudios de Maestría en Ingeniería de Sistemas en la misma universidad, desarrollando su investigación sobre la clasificación de imágenes digitales utilizando el método bayesiano. En el año 2009, se vinculó como profesor universitario en la Universidad del Tolima, impartiendo cursos sobre sensores remotos y el análisis e interpretación de imágenes de sensores remotos.

En el año 2013 dio inicio a sus estudios doctorales en la Facultad de Minas (UNAL-Medellín), enfocando su investigación en el desarrollo de una metodología automática basada en Líneas para el procesamiento y análisis de imágenes de sensores remotos de alta resolución. Durante su investigación doctoral, participó como profesor visitante en la Universidad de Charlotte (USA), donde aplicó el procesamiento de imágenes de sensores remotos para el estudio de la dinámica de los bosques urbanos. Ha presentado los resultados de sus investigaciones en varias conferencias de carácter internacional, como fue en Grecia (2014) y USA (2015).

Sus intereses se han enfocado en la investigación, desarrollo y aplicación de las tecnologías computacionales sobre las imágenes de sensores remotos para la extracción, procesamiento y utilización de información útil para la conservación y manejo sostenible del medio ambiente.