



UNIVERSIDAD CATÓLICA DE MANIZALES

Evaluación de la capacidad de las imágenes de Radar de Apertura Sintética para la detección del cultivo del Café en Pitalito Huila

JORGE ALBERTO MEDINA VALDERRAMA

Universidad Católica de Manizales
Facultad de Ingeniería y Arquitectura
Maestría en Teledetección
Manizales - Caldas
2018

Evaluación de la capacidad de las imágenes de Radar de Apertura Sintética para la detección del cultivo del Café en Pitalito Huila

JORGE ALBERTO MEDINA VALDERRAMA

Trabajo de investigación presentada como requisito para optar al título de:

Magíster en Teledetección

Director:

MSc. Mario Fernando Monterroso Tobar

Línea de Investigación:

Procesamiento de datos RADAR

Universidad Católica de Manizales
Facultad de Ingeniería y Arquitectura
Maestría en Teledetección
Manizales - Caldas
2018

Nota de Aceptación

Presidente del Jurado

Jurado

Jurado

Manizales, Abril de 2018

*Este trabajo y el invaluable tiempo
lo dedico con el cariño más
grande a mi Tío Jorge*

Agradecimientos

A mi hermano Mauricio, a su valioso acompañamiento e inmejorable asesoría en este trabajo.

Al Servicio Nacional de Aprendizaje, por propiciar un ambiente óptimo para el crecimiento profesional, técnico y académico que facilitó llegar a buen puerto en el propósito de obtener este posgrado.

Al Ingeniero MSc. Gustavo Vega del SENA de Pitalito por los datos de los lotes de café proporcionados para esta investigación y al Ingeniero Cesar López del SENA de Pitalito por su apoyo en la concepción de esta idea de investigación.

Al Ingeniero MSc. Camilo Alexander León por sus valiosos aportes iniciales, esperando que este trabajo corresponda en gran medida al nivel de sus contribuciones.

Al Ingeniero MSc. Mario Fernando Monterroso Tobar por propiciar el uso y apropiación de los conocimientos básicos de los datos SAR para la presente investigación.

CONTENIDO

	Pág.
GLOSARIO	13
1. INTRODUCCIÓN.....	16
1.1 Planteamiento del problema y justificación	17
1.1.1 Definición del problema.....	17
1.2 Pregunta de Investigación e Hipótesis.....	18
1.2.1 Pregunta de investigación	18
1.2.2 Hipótesis	18
1.3 Justificación	19
2 Objetivos.....	21
2.1 General.....	21
2.2 Específicos	21
3 MARCO TEÓRICO	22
3.1 Generalidades de la Teledetección	22
3.1.1 Fuente de energía.....	23
3.1.2 Composición de una imagen satelital óptica	24
3.1.3 Composición de una imagen de Radar de Apertura Sintética.....	25
3.2 La teledetección y agricultura	26
3.3 Métodos de clasificación de cobertura agrícola	27
3.3.1 Índices de vegetación:.....	27
3.3.2 Polarimetría de Radar	28
3.3.3 Análisis de Componentes Principales:	32
3.3.4 Análisis de texturas:	32
3.3.5 Bosques Aleatorios:	33
3.4 Sistemas de producción de café en Colombia.....	35
4 ESTADO DEL ARTE	36
4.1 Teledetección y caficultura	36
4.2 Detección de Café en Colombia	36
4.2.1 Sensores ópticos de baja resolución espacial.....	36

4.2.2	Sensores ópticos de alta resolución espacial.....	37
4.3	Tecnología SAR en la detección de coberturas y cultivos agrícolas.....	38
4.3.1	Enfoque monosensor	38
4.3.2	Enfoque multisensor.....	42
5	DATOS Y MÉTODOS.....	46
5.1	Zona de estudio	46
5.2	Datos	47
5.3	Métodos.....	48
5.3.1	Metodología desarrollada en la investigación	48
6	DESARROLLO DEL PROYECTO	53
6.1	Procesamiento inicial.....	53
6.1.1	Capas derivadas de la imagen del sensor Sentinel 1.....	53
6.1.2	Capas derivadas de la imagen del sensor Sentinel 2.....	56
6.2	Definición de las clases y áreas de entrenamiento.....	57
6.2.1	Clases de cobertura	57
6.2.2	Selección de las áreas de entrenamiento	58
6.3	Presentación de los resultados de la clasificación por Random Forests. .	60
	Mosaico de imágenes 11. Resultados de la clasificación incluyendo el área urbana. Fuente: Elaboración propia, datos European Space Agency 2016	62
6.4	Evaluación de la exactitud	63
6.5	ANÁLISIS Y COMPARACIÓN DE LOS RESULTADOS.....	66
6.6	Análisis del enfoque monosensor	66
6.6.1	Clasificación monosensor de café con sombra	66
6.6.2	Clasificación monosensor de café semisombra	67
6.6.3	Clasificación monosensor café sin sombra	68
6.7	Análisis del enfoque multisensor	69
6.7.1	Clasificación multisensor café sombra	69
6.7.2	Clasificación multisensor café semisombra.....	70
6.7.3	Clasificación multisensor café sin sombra.....	71
7	CONCLUSIONES.....	73

8	RECOMENDACIONES.....	74
9	BIBLIOGRAFÍA.....	75

LISTA DE TABLAS

Tabla 1.	Exactitud de clasificación de cultivos de café con imágenes ópticas.	17
Tabla 2.	Publicaciones realizadas sobre clasificación de tierras agrícolas con imágenes SAR.....	20
Tabla 3.	Rangos de valores del coeficiente de retrodispersión σ°	39
Tabla 4.	Características de la clasificación mixta.....	39
Tabla 5.	SENTINEL-1: Características del Sensor.	47
Tabla 6.	SENTINEL-2: Características del Sensor.	47
Tabla 7.	Clasificación de las coberturas en el área de estudio.	57
Tabla 8.	Matriz de confusión para la clasificación enfoque monosensor	63
Tabla 9.	Matriz de confusión para la clasificación enfoque multisensor.....	64

LISTA DE GRÁFICAS

Gráfica 1. Clasificación de píxeles en la exactitud de usuario para el café con sombra	67
Gráfica 2. Clasificación de píxeles en la exactitud de usuario para el café semisombra	68
Gráfica 3. Clasificación de píxeles en la exactitud de usuario para el café sin sombra	68
Gráfica 4. Clasificación de píxeles en la exactitud de usuario multisensor para el café sombra	70
Gráfica 5. Clasificación de píxeles en la exactitud de usuario multisensor para el café semisombra	71
Gráfica 6. Clasificación de píxeles en la exactitud de usuario multisensor para el café sin sombra	72

LISTA DE FIGURAS

Figura 1. El Espectro Electromagnético.....	23
Figura 2. Sistemas Pasivo y Activo de Percepción Remota.	23
Figura 3. Composición de una imagen satelital óptica.....	24
Figura 4. Esquemas de polarización Horizontal y Vertical (dB), Sensor AIRSAR, Bahía de San Francisco.....	25
Figura 5. Transmisión / Recepción Dual-Pol y Quad-Pol.....	29
Figura 6. Mecanismos de dispersión.	29
Figura 7. Ecuación para la descomposición H- α	30
Figura 8: Parámetro de Entropía.....	30
Figura 9. Parámetro de Anisotropía.	31
Figura 10. Parámetro de Ángulo Alfa Medio.	31
Figura 11. Área de estudio en el Departamento del Huila..	46
Figura 12. Descriptor de textura "Segundo Momento Angular" Sigma0_VH de la imagen del sensor Sentinel 1 para el área de estudio.	54
Figura 13. Índice de Diferencia Normalizada de Vegetación (NDVI).	56

Acrónimos

ACP: Análisis de Componentes Principales

ALOS PALSAR: Advanced Land Observing Satellite

CARET: Classification And REgression Training

EG: Exactitud Global

EP: Exactitud del Productor

EU: Exactitud del Usuario

ESA: European Spatial Agency

GRD: Ground Range Detected

SICA: Sistema de Información Cafetera

IW: Interferometric Wide

NDVI: Normalized Difference Vegetation Index

RF: Random Forests

SAR: Synthetic Aperture Radar

SNAP: Sentinel Application Platform

TM: Thematic Mapper

VPR: Relación de Verdaderos Positivos

VNR: Relación de Verdaderos Negativos

GLOSARIO

Extensionista: Término con el cual se conoce a los funcionarios de la federación Nacional de Cafeteros que visitan a los caficultores en las fincas. Se les llama así por hacer parte del servicio de extensión (León, 2015, p. 9).

Interferometric Wide Swath Mode: Consiste en uno de los 4 modo de orientación del haz de microondas que permite un amplio ancho de escena (250 km) y una resolución espacial moderada entre 5 y 10m (European Space Agency, 2013).

Polarización: Esquema de orientación de las microondas planas emitidas o retrodispersadas de manera horizontal o vertical (Lira, 2010)

Sombrío: Asociación de especies forestales, frutales o alimenticias con plantaciones de café que se pueden implementar en diversos sistemas productivos (FNC, 2007).

Matriz de co-ocurrencia: Calcula la relación espacial que guarda un píxel con respecto al valor de gris de otro píxel (vecino) (Presutti, 2004).

Clasificación Supervisada y no Supervisada: La primera se refiere a la definición a priori de clases de coberturas determinadas para segmentar el espacio en regiones basado en la información de píxeles prototipo. El segundo procedimiento no requiere de píxeles prototipos determinados por el investigador, el parámetro de segmentación es la cantidad de clases a segmentar por medio del algoritmo seleccionado (Lira, 2010).

RESUMEN

El presente estudio, comprende la aplicación de un marco metodológico para evaluar la capacidad de los datos de Radar de Apertura Sintética (SAR por su siglas en inglés) para la detección de plantaciones de café en función de la densidad de sombrío presente en el cultivo¹.

Este marco metodológico está orientado al aprovechamiento de las propiedades de la radicación coherente de los sensores SAR en el reconocimiento de características morfológicas y estructurales de la vegetación agrícola como insumo principal en la detección y clasificación del café a libre exposición solar, con densidad media de sombra y alta densidad de sombra. La clasificación de las plantaciones de café en función de la densidad de sombrío se apoyó en la aplicación del algoritmo de Bosques Aleatorios (RF por su sigla en inglés) con enfoque monosensor SAR (Sentinel-1) y enfoque multisensor SAR/óptico (Sentinel-1 y Sentinel-2): en el enfoque monosensor se evaluó la clasificación Random Forests, en donde se incluyeron descriptores de textura por cada polarización de la imagen SAR VH - VV y el valor de la intensidad de los pulsos retrodispersados para las polarizaciones VH y VV apilados en una sola imagen. En el enfoque multisensor, además de los descriptores de texturas y la intensidad de los pulsos retrodispersados, se fusionaron a estas capas las diferentes respuestas espectrales de las coberturas asociadas al café provenientes de las imágenes ópticas multiespectrales Sentinel-2 así como el Índice de Vegetación de Diferencia Normalizada (NDVI por su sigla en inglés). La exactitud de clasificación en cada uno de los enfoques se evaluó por medio de la matriz de confusión en donde la exactitud global se estimó en 81,2% (enfoque monosensor) y 89,65% (enfoque multisensor). La exactitud del productor y del usuario para las coberturas de café en el enfoque monosensor se ubicó entre 65,93% y el 75,69%. El enfoque multisensor arrojó exactitudes de usuario y productor para las clases de café entre 66,79% y 77,91% mostrando una mejoría en la clasificación atribuida a la complementariedad de los datos SAR y ópticos.

Palabras clave: Cultivo de Café, Densidad de Sombrío, Radar de Apertura Sintética, Sinergia de imágenes SAR e imágenes ópticas, Bosques Aleatorios.

¹ La densidad de sombrío entendida como la cantidad de área cubierta por cualquier especie arbórea permanente por hectárea plantada de café.

Abstract

The current study comprehends the application of a methodological frame for evaluating the ability of Synthetic Aperture Radar SAR images for detection of coffee plantations in function of the shadow density present in the crop².

This methodological frame is oriented to the harnessing of SAR sensor's coherent radiation properties in the recognition of morphological and structural characteristics of the agricultural vegetation as a main input in detection and classification of free solar exposition coffee, with medium shadow density and high shadow intensity. Classification of coffee plantations in function of shadow density was supported by the application of Random Forest (RF) algorithm with SAR monosensor approach (Sentinel 1) and SAR/Optic multisensor approach (Sentinel 1 and Sentinel 2): In the monosensor approach, the RF classification was evaluated, where the texture descriptors were included for every polarization of the SAR VH-VV image and the intensity value of the backscattered pulses for VH and VV polarizations stacked in a single image. In the multisensor approach, besides the texture descriptors and backscattered pulses intensity, it were fused the different spectral responses of coffee associated covers coming from the Sentinel 2A and 2B optical multispectral images as well as complementary analysis related to Normalized Difference Vegetation Index (NDVI). The accuracy of classification on each of the approaches was evaluated through confusion matrix, where global accuracy was estimated in 81.2% (monosensor approach) and 89.65% (multisensor approach). Producer's and user's accuracy for coffee covers, in the monosensor approach was located between 65.93% and 75.69%. Multisensor approach issued the user's and producer's accuracy for the coffee classes between 66.79% and 77.91%, showing an enhancement in classification, attributed to SAR and Optic data complementarity.

Keywords: Coffee Crop, Shadow Density, Synthetic Aperture Radar, synergy of SAR and optical images, Random Forest.

² The shadow density, understood as the quantity of área covered by any kind of permanent arboreal specie per cofee planted hectare.

1. INTRODUCCIÓN

Según Bolanos (2007) en la actualidad, los métodos que los países en desarrollo aplican para mapear los cultivos de café tienen múltiples dificultades como alto costo e imprecisión en los resultados, esto dificulta la actualización frecuente de los mapas del cultivo del café. Ante esto, León (2015) indica que en el Sistema de Información Cafetero (SICA) de la Federación Nacional de Cafeteros de Colombia, la principal función de actualización la realizan los extensionistas utilizando fotografías aéreas que proveen una fuente de datos para la elaboración de mapas limitándose a la fotointerpretación y análisis visual *“para el dibujo de cultivos y fincas, parcializando su uso al no considerar algunas de las herramientas que puede ofrecer la teledetección”* (León, 2015, p.5), así mismo el autor advierte que técnicas y metodologías de levantamiento de información espacial diferentes a la teledetección tardan mucho en obtener resultados concretos.

Teniendo en cuenta los escenarios planteados, la presente investigación basa su componente metodológico en el aprovechamiento de la idoneidad de las imágenes de Radar de Apertura Sintética (SAR por su sigla en inglés) para capturar la riqueza textural del área de interés y sus capacidades para la obtención de datos de la superficie terrestre con mayor frecuencia independientemente de las condiciones de iluminación y cobertura de nubes (Haack & Bechdol, 2000; S. Moran et al., 2012; Muñoz, 2013; Saatchi, Agosti, Alger, Delabie, & Musinsky, 2001).

Las imágenes SAR utilizadas para esta investigación fueron clasificadas bajo técnicas de Aprendizaje Automático (Machine Learning) específicamente el algoritmo de Bosques Aleatorios (Random Forest) para facilitar la construcción un clasificador contextual que tenga como parámetros de entrada adicionales la intensidad de los pulsos retrodispersados de la imagen SAR (Sentinel-1) e información proveniente de sensores ópticos (Sentinel-2).

1.1 Planteamiento del problema y justificación

1.1.1 Definición del problema

Durante el desarrollo del presente documento, se encontraron distintos trabajos científicos relacionados directamente con el uso de la teledetección para la identificación del cultivo del café, de los cuales solo 1 involucra el uso de imágenes SAR. No obstante, la prevalencia de estudios basados en imágenes ópticas en este tema, su principal problema es la baja exactitud en la clasificación de dicho cultivo, como lo muestra la Tabla 1.

Año	Sensor	Autor	Método de clasificación	Exactitud (%)
1997	Landsat 5 (TM)	Langford & Bell	Supervisada de máxima verosimilitud	33% - 65%
2007	Landsat 7 (ETM+)	Bolaños	Análisis lineal de mezclas espectrales Análisis orientado a objetos	72% - 75%
2007	Landsat 5 (TM)	Moreira, Barros, & Rudorff	Supervisada Maxver	67% - 76%
2007	Landsat 7 (ETM+)	Cordero-Sancho & Sader	Clasificación supervisada	26% - 81%
2014	Quick Bird	Mukashema, Veldkamp, & Vrieling	Redes Bayesianas	50% - 77%
2012	RapidEye	Castillo	Clasificación supervisada	24% - 83%

Tabla 1. Exactitud de clasificación de cultivos de café con imágenes ópticas.

Fuente: Elaboración propia

Autores como Bolanos, (2007), Haack & Bechdol, (2000), Langford & Bell, (1997), Moreira et al., (2004); Trabaquini et al., (2010), coinciden en que la segmentación entre el cultivo del café agroforestal y coberturas boscosas primarias y secundarias en la mayoría de los casos es poco precisa debido a la similitud de sus respuestas espectrales, ya que ambos tipos de cobertura consisten en especies leñosas de densidad y estructura variable. Por otro lado, a pesar de la riqueza espectral de las imágenes ópticas, dicha riqueza está acompañada de la inherente presencia de nubes en las escenas (Lira, 2010; Saatchi et al., 2001).

1.2 Pregunta de Investigación e Hipótesis

1.2.1 Pregunta de investigación

La implementación de imágenes SAR en labores de identificación del cultivo del café ha sido escasa, como se evidencia en la recopilación del estado del arte desarrollada en esta investigación. Estudios orientados a la agricultura como el desarrollado por Silva et al., (2009) incluyen este cultivo en sus respectivas clasificaciones de cobertura del suelo, en un escenario dónde el café es cultivado a libre exposición solar en un terreno plano, condiciones muy diferentes a las que se encuentran en la caficultura colombiana.

Teniendo en cuenta lo anterior y el planteamiento del problema de investigación, es importante formular el siguiente cuestionamiento.

¿Cuáles son las características inherentes de las imágenes SAR que permitirían detectar y clasificar plantaciones de café en función de la densidad sombrío presente en el cultivo?

1.2.2 Hipótesis

En los estudios previos se generaliza el uso de imágenes ópticas multiespectrales con diferentes tamaños de píxel, cuyos resultados varían en la exactitud de la clasificación, mejorándose ésta proporcionalmente con el aumento de la resolución espacial.

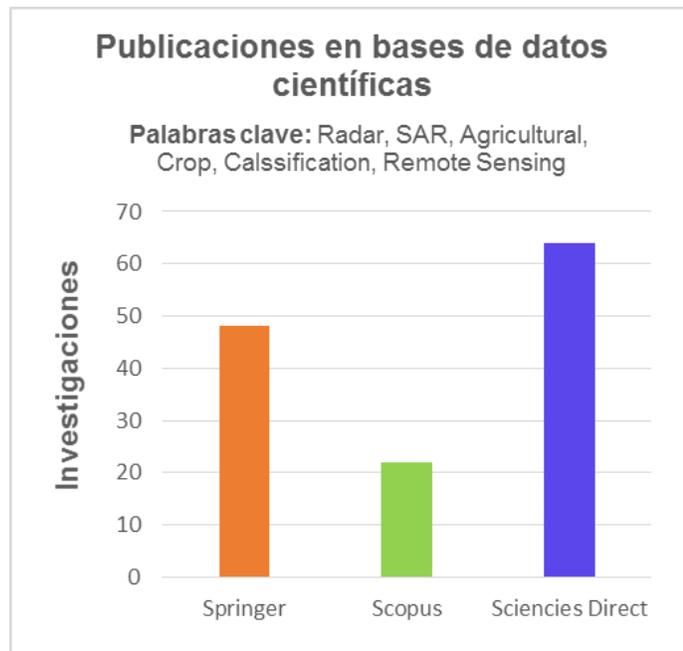
Esta investigación considera que las características propias de la irradiación coherente de las microondas de los sensores SAR y su interacción con las diferentes coberturas de la superficie terrestre aportan información suficiente para la detección del cultivo de café bajo un enfoque de análisis exclusivo de este tipo de datos. Por otro lado, se espera que las imágenes SAR complementen de manera significativa la detección del cultivo de café a través de un enfoque multisensor empleando un clasificador contextual a una nueva imagen producto de la fusión de datos ópticos y SAR.

1.3 Justificación

Para el año 2013 el Sistema de Información Cafetera (SICA) de Colombia registró 920.000 ha de café de las cuales el 33,1% (304.360 ha) se encuentran con semisombra, 16,8% (154.956 ha) con sombrío y el 50% (460.289 ha) se cultivan sin ningún estrato de sombra (Vega, 2013), teniendo en cuenta que los métodos de recolección y actualización de información se involucra a la teledetección de manera parcial (León, 2015) es significativo contar con alternativas de fuentes de datos y métodos que fortalezcan las iniciativas en el campo de la percepción remota, con el fin de reducir tiempo, esfuerzo y costos para la consolidación de cifras relacionadas con el área sembrada y el tipo de sistema productivo implementado.

Para el caso específico del mapeo del café bajo sistemas productivos que incluyen algún grado de densidad de sombrío, es importante involucrar datos de fuentes alternas como los sensores SAR, que aporten un enfoque diferenciado e información complementaria a la suministrada por los sensores ópticos para enriquecer y mejorar la exactitud de la detección y clasificación de este tipo de cultivo agroforestal.

El uso de la tecnología SAR es común en la clasificación de tierras agrícolas, las principales bases de datos científicas cuentan con publicaciones suficientes para una adecuada revisión bibliográfica. Esto se comprobó en las principales bases de datos científicas concentrando la búsqueda en "Title", "Abstract" y "Keywords" (Gráfica 1). Así mismo, la presente investigación tuvo en cuenta 4 investigaciones para la detección de cultivos con enfoque monosensor (exclusivamente imágenes SAR) y 3 investigaciones con enfoque multisensor (imágenes SAR y ópticas).



Gráfica 1. Publicaciones realizadas sobre clasificación de tierras agrícolas con imágenes SAR.
 Fuente: Sistema Nacional de Bibliotecas. Universidad Nacional de Colombia. Disponible en:
<http://www.sinab.unal.edu.co/> (consultado Marzo de 2018).

La evaluación de técnicas de procesamiento de imágenes SAR para el mapeo de cultivos de café que se desarrolla en esta investigación, busca mejorar la precisión en la detección, clasificación y cuantificación del área sembrada de dicho cultivo, (enfaticando en aquellos sistemas productivos cafeteros con algún grado de densidad de sombra). De lograrse el mejoramiento de la precisión para detectar el café bajo sombra, los aportes subsecuentes se enmarcarán en la gestión de recursos naturales especialmente de estos espacios agroforestales reconocidos como ecosistemas responsables de prestar servicios ambientales como polinización, eliminación de la contaminación, regulación hídrica (Guhl, 2004) y como nichos de hábitat por presentar características estructurales y biológicas diversas, con valor cultural y social de importancia (Vega, 2013).

2 Objetivos

2.1 General

Evaluar la capacidad de las imágenes de sensores SAR para la detección y clasificación de plantaciones de Café en función de la densidad sombrío presente en el cultivo.

2.2 Específicos

1. Identificar y clasificar a través del algoritmo Random Forests las plantaciones de café en función de la densidad sombrío presente en el cultivo a partir de 2 enfoques de datos, monosensor (Datos SAR) y multisensor (Datos SAR y Ópticos).
2. Comparar la exactitud de los resultados proporcionados por las clasificaciones con enfoque monosensor y multisensor.
3. Determinar la capacidad de los enfoques empleados para la identificación de las plantaciones de café en función de la densidad sombrío.

3 MARCO TEÓRICO

Las generalidades de la teledetección, los diferentes sistemas de percepción remota y sus principales productos serán abordados en la sección 3.1. Las menciones que se harán sobre los avances desarrollados en la Percepción Remota para la identificación de plantaciones de café tienen como punto de partida un panorama general relacionado con estado del arte entre la teledetección y la agricultura (Sección 3.2), en segunda instancia, se referencian los métodos de clasificación de cobertura agrícola más recurrentes aplicables tanto para imágenes ópticas y SAR (Sección 3.3), después se relacionan de manera general los tipos de sensores e imágenes ópticas con mayores casos de aplicación mundial en la detección del café (Sección 3.4), partiendo de esta relación, se mencionan los estudios más relevantes a nivel nacional en detección de café (Sección 3.5), así mismo se recopilan las principales desventajas en el uso de las imágenes ópticas en la detección de café (Sección 3.6), conclusiones aportadas por los autores de los principales estudios mencionados en la sección 3.3. Por último (Sección 3.7) en el escenario internacional, se describen los casos de aplicación de las imágenes SAR para la clasificación de la cobertura agrícola bajo enfoques de tratamiento de datos monosensor (únicamente datos SAR) y multisensor (Fusión de datos ópticos y SAR).

En cuanto a los fundamentos sobre sistemas de producción cafetera en Colombia se desglosan en la sección 3.4.

3.1 Generalidades de la Teledetección

Una de las definiciones más amplias para esta ciencia fue aportada por Chuvieco, (1995), quien no limita a la teledetección como el proceso de capturar por medio de sensores aerotransportados o espaciales la información electromagnética (Figura 1) que interactúa con la superficie de la tierra sin tener contacto directo con ella, agregando el tratamiento informático posterior a las imágenes resultantes en el marco de una aplicación determinada.

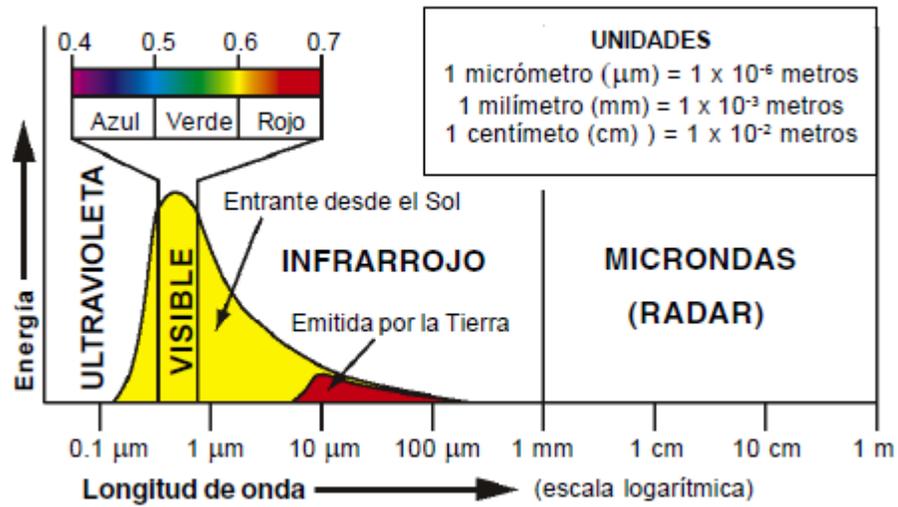


Figura 1. El Espectro Electromagnético. Fuente: R. Smith, (2004)

3.1.1 Fuente de energía

Un aspecto clave para comprender la naturaleza de la información empleada en las aplicaciones de la teledetección es la fuente de energía utilizada por el sensor, la cual determina la construcción de una imagen digital. La fuente de energía solar es un foco externo a los sensores ópticos y entre ambos conforman los sistemas de percepción pasivos de energía reflejada, así mismo cuando el sensor posee su propia fuente de energía electromagnética para la captura de información se conoce como sistema activo de energía reflejada (Melo & Camacho, 2005).

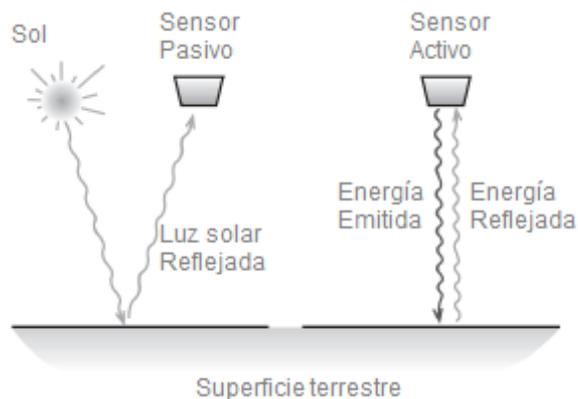


Figura 2. Sistemas Pasivo y Activo de Percepción Remota. Fuente: Adaptado de Tempfli, Kerle, Huuneman, & Jansen, (2001)

3.1.2 Composición de una imagen satelital óptica

También conocidas como imágenes multispectrales, son el resultado de la captura de los niveles de radiancia de la superficie terrestre a través de los sistemas de percepción pasivos de energía reflejada por medio de sensores fotoeléctricos. La radiancia es transformada en valores numéricos digitales y segmentados en bandas individuales para las diferentes regiones del espectro visible, infrarrojo y térmico, representadas en una matriz de píxeles (Pérez & Muñoz, 2006).

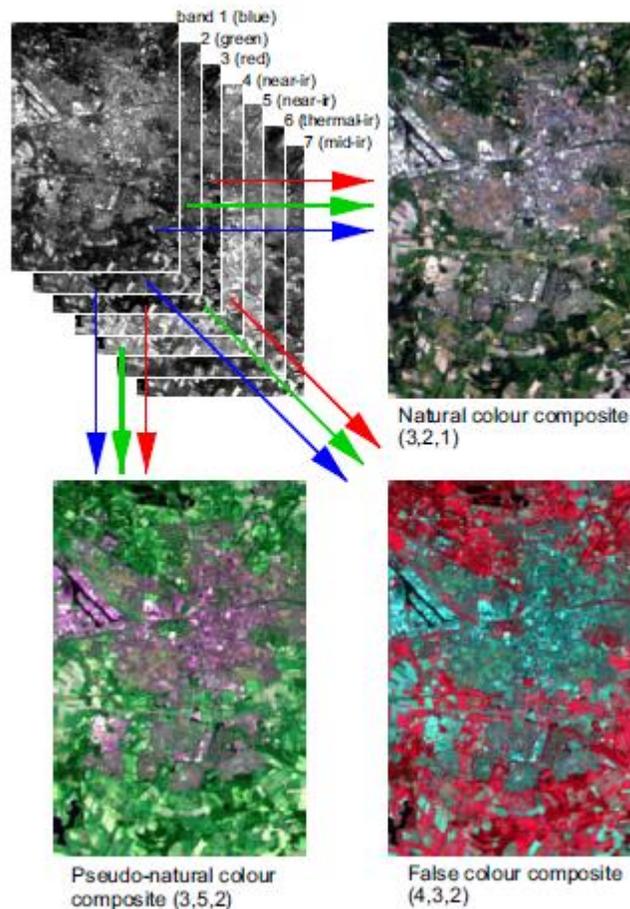


Figura 3. Composición de una imagen satelital óptica. Fuente: Tempfli et al., (2001)

3.1.3 Composición de una imagen de Radar de Apertura Sintética

Dentro de la categoría de los sistemas activos de energía reflejada, la formación de imagen SAR requiere de una radiación coherente en la región de microondas, dicha radiación coherente es dispuesta en esquemas de polarización Horizontal o Vertical tanto para la transmisión de la radiación emitida como para la medida de los pulsos retrodispersados, en este sentido es posible tener diferentes esquemas y sus posibles combinaciones como HV, VH, HH y VV (Lira, 2010).

Los píxeles de las imágenes SAR contienen un nivel digital con valores lineales o en escala de decibeles relacionados con la intensidad de la energía retrodispersada proveniente del suelo. La potencia de la energía reflejada está relacionada con las características de la cubierta terrestre (Tempfli et al., 2001).

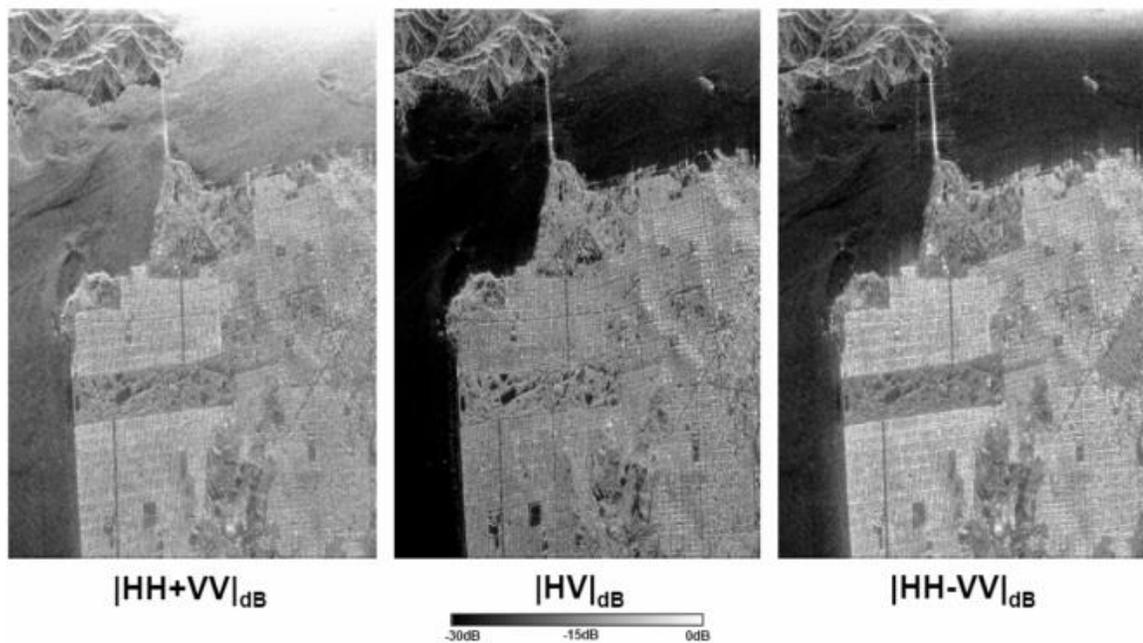


Figura 4. Esquemas de polarización Horizontal y Vertical (dB), Sensor AIRSAR, Bahía de San Francisco. Fuente: Lavalle, (2008)

3.2 La teledetección y agricultura

El uso y aplicación de la teledetección y sus respectivas técnicas de procesamiento digital de imágenes ofrecen una diversidad de opciones para el mapeo y monitoreo de cultivos, presentando ventajas importantes frente a estudios de campo, y en particular han sido ampliamente usadas en labores de identificación de áreas sembradas, discriminación varietal, estimación de área foliar, estimaciones de productividad entre otras, de acuerdo con lo señalado por Anaya & Valencia, (2013); Atzberger, (2013); Bolanos, (2007); León, (2015); M. S. Moran, Inoue, & Barnes, (1997); Murillo & Carbonell, (2012). Sin embargo, varios autores coinciden en que existe un grupo reducido de cultivos que se han visto más beneficiados por la teledetección que otros en cuanto a cantidad de aplicaciones e investigaciones científicas, esto debido a su relativa supremacía en la cantidad de área sembrada y producción a nivel mundial, estos cultivos son: el trigo, el maíz, la soya y el arroz (Badhwar, 1984; Daughtry, Walthall, Kim, Brown de Colstoun, & McMurtrey, 2000; Murillo & Carbonell, 2012; Vina et al., 2004). Es importante mencionar que además de contar con mayor área y producción, el trigo, el maíz, la soya y el arroz son monocultivos y tienen un patrón estacional de crecimiento (Bolanos, 2007; Van Niel & McVicar, 2004; Zwiggelaar, 1998) lo que facilita el monitoreo y la correlación de los datos obtenidos por los sensores remotos con las condiciones atmosféricas y con el estado de crecimiento de la planta, proporcionando a la teledetección un escenario óptimo para posicionarse como una herramienta económica, rápida y precisa para levantar información agrícola y agronómica (Murillo & Carbonell, 2012)

En el marco técnico y teórico, el procesamiento digital de imágenes provenientes de sensores remotos, fundamenta su aplicación a la agricultura en la respuesta espectral de las plantas a la radiación solar, determinadas por sus características físicas y químicas, entre las que se encuentran la estructura de las hojas, los procesos fotosintéticos como la absorción de clorofila, contenido de pigmento y de agua (Bolanos, 2007; Anaya y Valencia, 2013). En consecuencia cada cultivo tiene un comportamiento (firma) espectral único que lo diferencia de los demás (Murillo, 2012)

La revisión bibliográfica evidencia que la percepción remota aplicada a la agricultura se ha concentrado en el análisis y procesamiento de imágenes del espectro óptico y por ende los estudios dependen de la interacción entre la luz solar y las características físicas y químicas de la vegetación o cultivo.

3.3 Métodos de clasificación de cobertura agrícola

De los métodos de clasificación que se describen a continuación, los dos primeros son de aplicación exclusiva en el tratamiento de imágenes ópticas denominados “clasificación orientada a píxel” ampliamente utilizados en las investigaciones relacionadas con la detección agrícola y de las plantaciones de café. Los demás métodos son homólogos para los datos ópticos y SAR y se denominan “clasificación orientada a objetos”. Aunque el Análisis de Componentes Principales también es un método homólogo, este se excluye de los dos grupos de clasificación de imágenes debido a que su función no es precisamente clasificar píxeles u objetos en una escena.

3.3.1 Índices de vegetación:

Al respecto, Lira (2010) menciona que “los índices espectrales están determinados por una base vectorial que genera un espacio donde se encuentran referidas las bandas de una nueva imagen multiespectral”. En el marco de los Índices de Vegetación (IV), el Índice Diferencia Normalizado de Vegetación (NDVI por su sigla en inglés) es el más común para evaluar el estado de la vegetación y los cultivos agrícolas (Anaya & Valencia, 2013; Bolanos, 2007; Chuvieco, 1995; León, 2015; Lira, 2010; Murillo & Carbonell, 2012).

En síntesis la aplicación del NDVI cuantifica la diferencia entre las reflectividades de la franja del Infrarrojo Cercano (IRC) y del Rojo, cuanto mayor sea dicha diferencia mayor será el vigor de la vegetación teniendo en cuenta principalmente el parámetro de verdor y humedad, sin embargo esto no quiere decir que se interprete como cantidad de biomasa (Anaya & Valencia, 2013; Chuvieco, 1995; Lira, 2010).

Según los autores citados, el NDVI se expresa de la siguiente manera:

$$NDVI = \frac{IRC - R}{IRC + R} \quad (1)$$

Además Lira (2010) expresa el NDVI según la caracterización espectral del sensor LANDSAT de la siguiente manera:

$$NDVI = \frac{TM4 - TM3}{TM4 + TM3} \quad (2)$$

En ese marco, Chuvieco (1995) y Murillo & Carbonell (2012) coinciden en que el NDVI logra cuantificar satisfactoriamente los siguientes parámetros de la vegetación: contenido de clorofila en la hoja, contenido de agua en la hoja, flujo neto de CO₂, radiación fotosintéticamente activa absorbida por la planta, productividad neta de la vegetación, índice de área foliar, cantidad de lluvia recibida por el dosel vegetal, dinámica fenológica, evapotranspiración potencial.

Lo anterior abre una perspectiva muy alta para estudios de vegetación en regiones tropicales de gran biodiversidad y cultivos agroforestales.

3.3.2 Polarimetría de Radar

Es una técnica de clasificación de imágenes de Radar, basada en el análisis matemático de la potencia de la señal, la dirección de propagación de las ondas recibidas y los mecanismos de dispersión de dichas ondas (Earthnet, 2011)

Como se mencionó en el numeral 3.1.3, la polarimetría consiste en la dirección de propagación H (horizontal) o V (vertical). La Figura 5, muestra en rojo y azul el esquema para sensores de polarización doble que transmiten en H o en V y reciben H y en V simultáneamente. Así mismo enmarcado con color verde se ilustra el esquema para sensores de cuatro polarizaciones que transmiten en H y en V y reciben H y en V a la par.

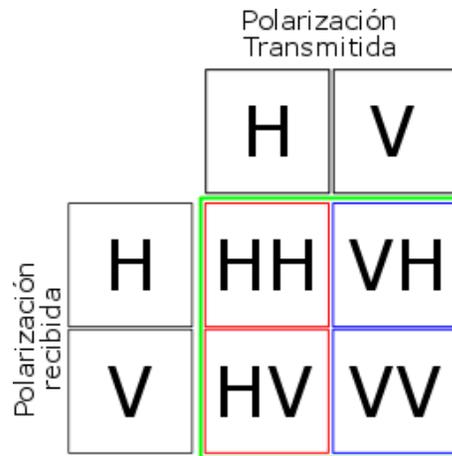


Figura 5. Transmisión / Recepción Dual-Pol y Quad-Pol.
 Fuente: Adaptado de López-martínez & June, (2008)

Los diferentes mecanismos de dispersión confieren las características de las imágenes polarimétricas, es decir, que la intensidad de la señal recibida por el sensor obedece a la interacción de ésta con las diferentes coberturas y objetos distribuidos en la superficie terrestre (Du, Samat, Waske, Liu, & Li, 2015). La Figura 6, ilustra los 3 tipos de mecanismos de dispersión de microondas SAR, la primera indica una retrodispersión con superficies descubiertas, la segunda asociada a superficies con cobertura vegetal y la tercera muestra la interacción con objetos perpendiculares en la superficie, generalmente construcciones y aglomeraciones urbanas.

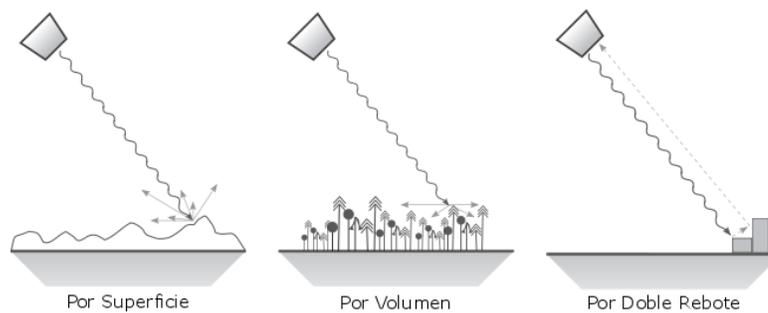


Figura 6. Mecanismos de dispersión.
 Fuente: Adaptado de Tempfli et al.,(2001)

Para cuantificar los mecanismos de dispersión es necesario codificar la intensidad y la fase de la señal captada en una matriz de coherencia, la cual necesita especificar el tamaño de una ventana. Por ejemplo, la construcción de una matriz de coherencia configurada con una ventana móvil de tamaño 3x3, los 9 elementos son promediados para cada píxel de la imagen. Una vez surtido este proceso es

necesario “*descomponer*” la información a un número limitado de descriptores que permitan clasificar los mecanismos de dispersión en la escena SAR (Earthnet, 2011).

La descomposición **H- α** es una de las más comunes en la clasificación de cobertura vegetal, se basa en la descomposición propia de una matriz de coherencia generalmente de tamaño 3x3. Dónde λ_1 , λ_2 y λ_3 son los valores propios de la matriz de coherencia ($\lambda_1 > \lambda_2 > \lambda_3 > 0$), y u_1 , u_2 y u_3 sean los vectores propios correspondientes expresados así:

$$u_i = [\cos \alpha_i \quad \sin \alpha_i \quad \cos \beta_i e^{j\delta_i} \quad \sin \alpha_i \quad \cos \beta_i e^{j\gamma_i}]^T \quad (3)$$

Por último, se definen tres parámetros secundarios como una función de los auto valores y los vectores propios de la matriz 3x3 para simplificar el análisis de la información física proporcionada por esta descomposición propia:

Entropía:

$$H = -\sum_{i=1}^3 p_i \log_3(p_i) \quad p_i = \frac{\lambda_i}{\sum_{k=1}^3 \lambda_k}$$

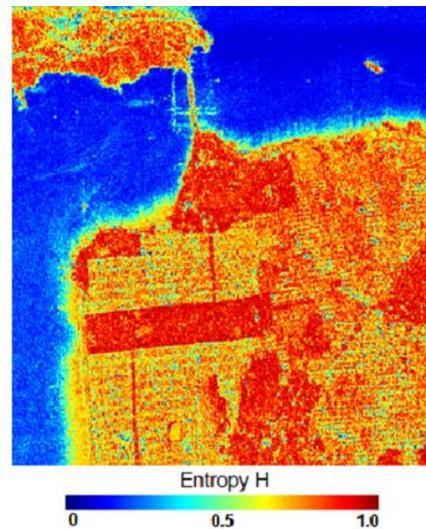


Figura 7: Parámetro de Entropía. Fuente: Earthnet (2011)

- Anisotropía:

$$A = \frac{\lambda_2 - \lambda_3}{\lambda_2 + \lambda_3}$$

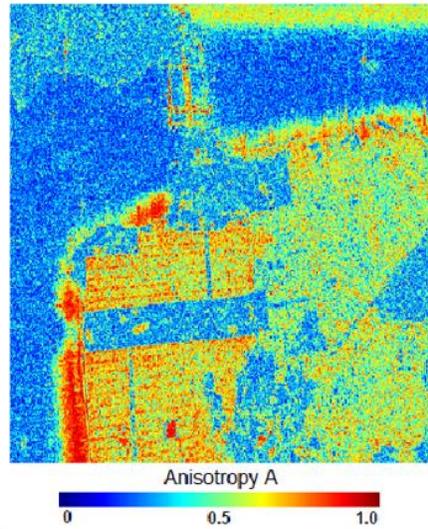


Figura 8. Parámetro de Anisotropía. Fuente: Earthnet (2011)

- Ángulo Alfa Medio:

$$\underline{\alpha} = \sum_{i=1}^3 p_i \alpha_i$$

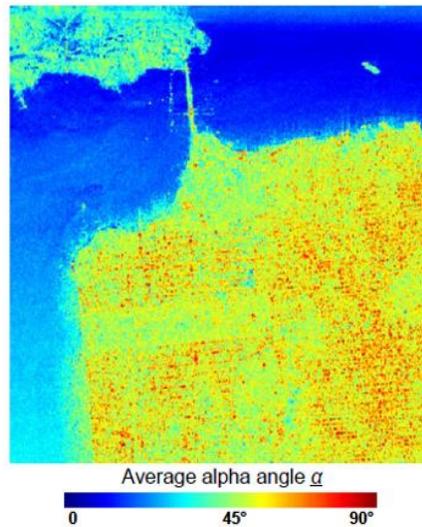


Figura 9. Parámetro de Ángulo Alfa Medio. Fuente: Earthnet (2011)

3.3.3 Análisis de Componentes Principales:

El análisis de grandes volúmenes de información puede dar lugar un elevado número de variables que en algunos casos presentan alta correlación entre sí, lo cual da lugar a un espectro amplio de entidades con características similares susceptibles de redundancia (L. I. Smith, 2002). El Análisis de Componentes Principales (PCA por su sigla en inglés) es un método estadístico que busca depurar la información mediante la transformación de un conjunto de datos determinado con variables correlacionadas a un conjunto secundario de menor tamaño con variables incorrelacionadas (George, 1989). El resultado es un set de datos de dimensiones más discretas que conserva la representatividad de la fuente original y favorece la emergencia de patrones, por lo tanto, los componentes principales explican la mayoría de la variabilidad de un conjunto de datos con un mínimo de pérdida de información (Cuadras, 2014; Peña, 2002). En el contexto de la percepción remota, el Análisis de Componentes Principales permite descartar la información redundante de una imagen multibanda ya que se asume que las bandas adyacentes están correlacionadas entre si y poseen información casi similar, en consecuencia se resumen las variables en un conjunto nuevo y más pequeño sacrificando la menor información posible (Chuvieco, 1995; Lira, 2010; Murillo & Carbonell, 2012; Rodarmel & Shan, 2002)

3.3.4 Análisis de texturas:

Conforme a lo aportado por Chuvieco (1990) y Lira (2010) los rasgos texturales de una imagen se relacionan con las características de la forma y la estructura de los elementos contenidos en la escena captada por el sensor, aportando una valiosa descripción cuantitativa de la distribución y organización espacial de los mismos, es así como la textura comprende una expresión organizada de una escena local de tonos de grises en una imagen, y su análisis busca producir una nueva imagen que contenga el grado de contraste entre los píxeles vecinos. Uno de los métodos de análisis de textura más extendidos y aceptados, por su sensibilidad y la confiabilidad de los resultados, es el de matriz de co-ocurrencia (Argenti, Alparone, & Benelli, 1990). El principio fundamental yace en la probabilidad de que un nivel de gris en un píxel (de referencia) se presente en un área determinada de la imagen y la relación espacial que guarda con respecto al valor de gris de otro píxel (vecino) (Presutti, 2004). Para su cálculo, es necesario definir un píxel de origen o píxel de referencia y una dirección de análisis, NE, SE, E y W, posteriormente se establecen todas las posibles combinaciones en que se pueden presentar los niveles de grises

del píxel de origen y el píxel vecino y se determina la frecuencia en que ocurre. A partir de esta información se construye una matriz de probabilidades para la ocurrencia de combinaciones específicas, el análisis de los elementos de la matriz resultante brinda información crítica sobre las características texturales de la imagen. Entre las medidas texturales objetivo más recurrentes de éste análisis se encuentran: Homogeneidad, contraste, media, desviación típica, segundo momento angular y entropía (Chuvieco, 1995).

Lira, (2010) indica que los elementos de una matriz de co-ocurrencia están dados por:

$$c(\lambda_p, \lambda_q, \beta, \delta) = \frac{O\{r|r, r + \beta \in \sigma(\delta), f(r) = \lambda_p, f(r + \beta) = \lambda_q\}}{O\{r|r + \beta \in \delta\}} \quad (4)$$

Donde $f(r)$ es la imagen, $\sigma(\delta)$ es una isometría de traslación sobre la ventana, δ es el orden del conjunto y $r = (i,j)$ es el vector de posición de un píxel de la imagen.

Para ciertas coberturas, en especial arreglos vegetales complejos como los cultivos agroforestales en donde las características espectrales de cada celda resulta ser insuficiente para categorizar una superficie (Chuvieco, 1995; MacGiillavry, 1998), se puede inferir que la inclusión del análisis de textura en los algoritmos de clasificación aporta una visión complementaria para afinar la asignación de clases.

3.3.5 Bosques Aleatorios:

Descrito por Breiman (2001), Random Forests es considerado un algoritmo de aprendizaje automático o Machine Learning. En Percepción Remota el algoritmo "RF" extrae los valores de los píxeles correspondientes a la superposición de los polígonos de las áreas de entrenamiento seleccionadas aleatoriamente sobre los predictores representados por las diferentes bandas espectrales, índices o descriptores de las imágenes a clasificar. Como tal, RF construye muchos árboles de decisión (DT o Decision Tree), cada árbol en el bosque es construido a partir de un subconjunto de vectores seleccionado aleatoriamente (Áreas de entrenamiento), de esta manera cada árbol es entrenado con la información aportada por los predictores para emitir un voto de mayoría para la clase más popular. Una de las

ventajas más sobresalientes de RF es la capacidad de estimar el error de clasificación a través de una nueva clasificación que involucra las áreas de entrenamiento que no fueron tenidas en cuenta en la selección aleatoria, la estimación del error también permite determinar la importancia de una variable en la clasificación (Forkuor, Conrad, Thiel, Landmann, & Barry, 2015; Peters, Coillie, Westra, & Wulf, 2011; Waske & Braun, 2009).

La presente investigación basó la evaluación de las capacidades de las imágenes SAR por medio de Random Forests, la selección de este algoritmo de clasificación radica en la amplia literatura científica que lo relaciona con la detección de diferentes tipos cultivo y coberturas utilizando Imágenes de Radar, en virtud de que ofrece una metodología de clasificación multidisciplinaria con alta efectividad y con una ventaja comparable con relación a otros modelos más complejos, por lo cual su aplicación en sensores remotos ha sido extensa (Hongsheng Zhang; Hui Lin; Yuanzhi Zhang; Qihao Weng, 2016).

Es posible la aplicación del algoritmo de clasificación Random Forest sobre todo mediante la cuantificación de las características texturales mediante la generación de una Matriz de Coocurrencia de Nivel de Gris (GLCM), tal como fue desarrollado por Akar & Güngör, (2012).

Topouzelis & Psyllos, (2012) evaluaron la técnica de selección y clasificación basada en bosques de decisión para la identificación de derrames de petróleo con diferenciación de similares a través de imágenes SAR del European Remote Sensing Satellite 2 (ERS-2) con una eficiencia general de clasificación del 84.4%.

Waske & Braun, (2009) aplicaron los conjuntos clasificadores como árboles de decisión amplificados (Boosted decision tree) y Random Forests a datos SAR multitemporales para el levantamiento de mapas de cobertura, alcanzando precisiones cercanas al 84% y concluyendo la eficiencia computacional de los bosques aleatorios y su factibilidad en la clasificación de coberturas de suelo.

3.4 Sistemas de producción de café en Colombia

Teniendo en cuenta los objetivos planteados en el presente documento, la descripción de los sistemas de producción cafetera es fundamental para la comprensión del nivel de dificultad que presenta la identificación de las plantaciones de café en función de la densidad de sombrero presente en el cultivo.

La Federación Nacional de Cafeteros clasificó los sistemas productivos así:

- Sistema de producción tecnificado: *se considera un lote de café con variedad Caturra o Castillo, el cual ha sido trazado, establecido al sol o con sombrero regulado y una población mayor a 2.500 plantas por hectárea.* (FNC, 2007, p. 19)
- Sistema de producción con semisombra: *se define en función del componente arbóreo como regulador de la luz solar. Generalmente, se emplean especie arbóreas como el guamo, el nogal o el chachafruto, entre otros y con una densidad entre 20 y 50 árboles por hectárea, o cualquier especie arbustiva semipermanente (plátano o banano) con un número de plantas entre 300 y 750 sitios por hectárea.*(FNC, 2007, p.19)
- Sistema de producción de café con sombra. *Está caracterizado por el empleo de cualquier especie arbórea permanente con una densidad superior a 50 árboles por hectárea, equivalente a una distancia de siembra de 14 x 14 m. También puede darse la regulación de la luz incidente por cualquier especie arbustiva semipermanente con más de 750 sitios por hectárea, la cual puede establecerse con una distancia de siembra de 3,7 x 3,7 m, con un arreglo espacial uniforme.* (FNC, 2007, p19)

4 ESTADO DEL ARTE

4.1 Teledetección y caficultura

Como se ha mencionado a lo largo de presente documento, el uso de métodos de análisis y procesamiento de imágenes ópticas ha favorecido notablemente el estudio de un gran número de cultivos agrícolas en muchas de sus dimensiones, el café no es ajeno a esta tendencia.

En estudios relacionados con el cultivo del café, el autor encontró dos tendencias marcadas durante la revisión bibliográfica, por ejemplo, autores como Langford & Bell, (1997), Moreira et al., (2004), Cordero-Sancho & Sader, (2007), Bolanos, (2007), Moreira, Barros, & Rudorff, (2008), Trabaquini et al., (2010) apoyaron sus investigaciones en datos de sensores multispectrales de mediana resolución espacial, particularmente de la serie Landsat (TM y ETM+), por otro lado Lelong & Thong-Chane, (2003); León, (2015); Mukashema, Veldkamp, & Vrieling, (2014) aplicaron distintos métodos de clasificación para la detección del café utilizando datos ópticos de mayor resolución espacial como los provenientes de sensores orbitales como Ikonos y Quickbird así como de sensores aerotransportados.

4.2 Detección de Café en Colombia

4.2.1 Sensores ópticos de baja resolución espacial

Las aportaciones hechas por Langford & Bell, (1997) en la clasificación de coberturas de la tierra en el departamento cafetero del Cauca, se concentran en la comparación de la clasificación espectral de una escena del sensor Landsat 5 (TM) del año 1989 con la fotointerpretación previa basada en una fotografía aérea a escala 1: 36.000 del mismo año.

Su objetivo principal fue alcanzar el mismo nivel de discriminación proveniente de la fotointerpretación (10 clases incluyendo cultivo de café) a través de la aplicación de un clasificador supervisado de máxima verosimilitud en la escena Landsat 5 (TM), este objetivo no fue logrado ya que los resultados obtenidos obedecen a solo 6 clases temáticas producto de la generalización de varias coberturas, entre ellas el café con los demás territorios agrícolas, motivada por la baja exactitud de clasificación que oscila entre el 33% y el 65%.

Bolanos, (2007), centró su investigación en la discriminación de tres sistemas productivos de café (con sombra, semi-sombra y sin sombra) en municipios cafeteros del sur del departamento de Huila. Los datos espectrales fueron clasificados teniendo en cuenta el nivel digital (Banda 7 Infrarrojo lejano, 2 Verde y 5 Infrarrojo medio) de los píxeles evaluados con apoyo en muestreo de campo de las diferentes coberturas asociadas al paisaje cafetero y un refinamiento aplicando análisis lineal de mezclas espectrales para separar la clasificación de café de sombra y el café sin sombra.

Por otro lado la segmentación de las clases de cobertura también se sustentó en el análisis orientado a objetos (análisis de texturas) y finalmente, la integración con los Sistemas de Información Geográfica se implementó considerando datos derivados del Modelo Digital de Elevación SRTM (Shuttle Radar Topography Mission). El resultado de la exactitud total de la clasificación basada en píxeles fue de 71,89% y para la clasificación basada en objetos fue de 74,88%.

4.2.2 Sensores ópticos de alta resolución espacial

León, (2015) implementó datos multiespectrales de alta resolución espacial provenientes de plataformas satelitales y aerotransportadas con la finalidad de obtener mayor exactitud en la clasificación, teniendo en cuenta las particularidades de la tenencia de las tierras cafeteras de Colombia en donde el 95% de las fincas tienen una extensión menor a las 2 hectáreas.

Para la identificación del cultivo de café, el autor evaluó diferentes técnicas digitales enmarcadas en la clasificación orientada a píxeles y orientada a objetos, apoyado de información espacial sobre los lotes de café tomada en campo y almacenada en el Sistema de Información Cafetera (SICA).

En la clasificación orientada a píxeles el autor empleó el algoritmo k-means bajo procedimientos no supervisados, y el algoritmo de máxima verosimilitud bajo procedimientos supervisados.

En el escenario de la clasificación orientada a objetos se empleó el algoritmo de multiresolución basado en criterios de homogeneidad locales teniendo en cuenta los píxeles adyacentes para la definición de objetos.

En el ámbito de la clasificación orientada a pixel en imagen Ikonos, los resultados más sobresalientes se obtuvieron con el procedimiento supervisado en donde la exactitud global, la exactitud del usuario y la exactitud del productor, alcanzaron valores de 86,97%, 85,65% y 93,71% respectivamente.

Por otro lado, en el contexto de la clasificación orientada a objetos en la misma imagen, el autor logró una exactitud del productor del 97,09%, lo que significa que poco menos del 3% de los pixeles asignados como café no fueron clasificados como tal. De lo anterior se puede puntualizar que el manejo de datos con mayor resolución espacial mejora considerablemente la detección del cultivo de Café.

4.3 Tecnología SAR en la detección de coberturas y cultivos agrícolas

Teniendo en cuenta los objetivos planteados para el presente estudio, esta sección recopila las investigaciones que incorporan las técnicas y los métodos más utilizados en la percepción remota de la agricultura a partir de imágenes SAR bajo enfoques monosensor y multisensor, éste último en el marco de la combinación de datos de microondas y ópticos.

4.3.1 Enfoque monosensor

La investigación desarrollada en Colombia por Beaulieu, Hill, Leclerc, & Escobar, (1999) para el CIAT, se realizó mediante la utilización de imágenes RADARSAT y JERS1, mediante las cuales se clasificó la cobertura de la tierra en el Municipio de Puerto López con el fin de obtener cartografía orientada especialmente a la diferenciación entre pastos introducidos y sabanas nativas, a partir del análisis de umbrales de la retrodispersión aplicando matriz de confusión para las siguientes clases e intervalos de σ° :

Clases del mapa	Intervalos de retrodispersión		Precisión del usuario
	RADARSAT	JERS-1	
Pastos Introducidos	$\sigma^{\circ} < -21$ dB en RADARSAT		81.0
Sabana Nativa	$-21 \text{ dB} \leq \sigma^{\circ} < -12.5$ dB		79.3
Vegetación Arbustiva	$\sigma^{\circ} \geq -12.5$ dB	$\sigma^{\circ} < -11$ dB	29.6
Bosque		$-11 \text{ dB} \leq \sigma^{\circ} < -8$ dB	-
Agua		$\sigma^{\circ} \geq -8$ dB en JERS-1	-

Tabla 2. Rangos de valores del coeficiente de retrodispersión σ° .
Fuente: Beaulieu et al., (1999)

La calidad general se calculó en 74.9% concluyéndose que con una clasificación eventual que incluya únicamente agua, vegetación corta y bosque, lograría una confianza del 90%.

El ejercicio realizado por Quiñones, (2011) tuvo como objetivo implementar un sistema de clasificación automática de los estados de desarrollo del cultivo de arroz en el municipio de Saldaña Departamento del Tolima, utilizando una imagen del sensor RADARSAT-2 capturada en febrero de 2009. Durante las primeras etapas de la investigación, el autor desarrolló un método de filtrado para mejorar los resultados de la reducción del speckle en la imagen. Así mismo, el autor desarrolla un clasificador mixto que involucra los resultados previos 3 diferentes métodos de clasificación, el clasificador Bayesiano, el clasificador Fuzzy c-mean y el Perceptrón Multicapa, esto permite obtener una exactitud mayor al 94%.

	Sensibilidad (VPR)	Especificidad (VNR)	Exactitud (ACC)
Terreno en soca	73,20%	97,90%	93,80%
Terreno preparado antes de la siembra	98,50%	97,50%	97,70%
Cultivo con 25 días de sembrado	83,30%	96,20%	94,10%
Cultivo con 50 días de sembrado	81,20%	99,80%	96,70%
Cultivo con más de 75 días de sembrado	87,00%	95,20%	93,80%
Pastizales	82,30%	94,40%	92,40%
Promedio	84,30%	96,80%	94,80%

Tabla 3. Características de la clasificación mixta.
Fuente: Quiñones, (2011)

En 1995, Ban, Treitz, Howarth, Brisco, & Brown, en el sur de Ontario Canadá, utilizaron imágenes SAR aerotransportado de banda C con polarización HH y HV con resolución espacial de 4m, cuyo principal objetivo fue evaluar dos métodos de clasificación (orientado a píxeles y a objetos) para los cuatro principales cultivos de la zona de estudio, trigo de invierno, maíz, soja y alfalfa.

Los resultados de ambos métodos se compararon para evaluar la efectividad de cada uno. La clasificación de los píxeles utilizó los datos crudos y preprocesados de C-HH y C-HV, en dónde se tomaron muestras aleatorias de celdas en los campos de cultivos mencionados para calibrar el clasificador de mínima distancia a implementar.

La evaluación de ésta clasificación consistió en la selección al azar de píxeles de validación para cada cultivo independientes de los píxeles de calibración ya seleccionados. Los campos que presentaron anomalías relacionadas con la retrodispersión que desviaron de manera significativa la norma de alguna de las clases estipuladas fueron excluidos de las muestras de calibración y validación.

Una vez se obtuvieron los píxeles de entrenamiento y validación, los autores examinaron los histogramas de las imágenes para determinar cuál procedimiento de clasificación orientado a píxeles era el más adecuado, encontrando que los valores digitales en la escena no correspondían a una distribución gaussiana.

Teniendo en cuenta la distribución de los datos, los resultados obtenidos indicaron que la clasificación no supervisada de "mínima distancia" funcionó mejor en la mayoría de las circunstancias comparado con la clasificación supervisada de máxima verosimilitud, pasando de exactitudes de 69% a 78%. Por otro lado, en la clasificación orientada a objetos se implementó el algoritmo de crecimiento de regiones y clasificador homogéneo.

En dicha implementación se incluyó la polarización simple C-HH y dual C-HV de la siguiente manera: textura media C-HH; textura media C-HH + C-HH; filtrado C-HH + filtrado medio C-HV; textura C-HH + textura C-HV; media C-HH + C-HV. Para estas 5 clasificaciones la precisión fue de $K=0,91$ debido a la alta correlación ($r \geq 0,98$) entre las imágenes empleadas.

Los métodos empleados para evaluar la exactitud en la clasificación de cultivos agrícolas resultaron ser eficaces, especialmente el método de clasificación orientado a objetos. Los resultados indican que los datos C-HH y C-HV, clasificados usando un clasificador estándar de píxeles de Distancia Media, proporcionan

precisiones de clasificación relativamente pobres. La inclusión de las estadísticas de utilizando un clasificador de regiones, las precisiones de clasificación mejoraron aproximadamente en un 40%.

Saatchi et al., (2001) emplearon imágenes de radar del SIR – C/X-SAR para la identificación y diferenciación de parches de bosque primario y bosque cabruca, este último se refiere al sistema agroforestal de plantación de cacao cabruca, que utiliza la sombra propiciada por el bosque nativo; los resultados mostraron 89% de precisión general calculada mediante matriz de confusión obtenida al relacionar el número de píxeles clasificados correctamente entre el número total de píxeles analizados.

En esta instancia, cobra importancia la capacidad de un sensor de captar información de las similitudes morfológicas entre distintos tipos de cobertura, especialmente cuando estas se encuentran mezcladas, caso particular de este estudio en relación al cultivo del cacao y también de los sistemas de producción cafetera ampliamente utilizados en Colombia.

En el año 2011, los campos de trigo, cebada, Avena, maíz, cebolla y alfalfa de Barrax España, fueron objeto de escrutinio dentro del análisis de la sensibilidad de la retrodispersión en 57 imágenes SAR (RADARSAT-2) de cuádruple polarización en banda C, apoyado por información meteorológica de la zona (Temperatura del aire, velocidad y dirección del viento, radiación solar incidente y Evapotranspiración) y los parámetros biofísicos y características fenológicas propias de cada cultivo.

De forma preliminar se determinó que la polarización dual HV logró ser muy útil para registrar las condiciones del cultivo y del suelo. También se identificó que una mayor separabilidad de los cultivos de cebada, el maíz y la cebolla se presentó en la primavera, coincidiendo con la postcosecha de la cebada y etapas tempranas de crecimiento del maíz y la cebolla.

La tendencia de la retrodispersión σ_0 está definida por el tipo de cultivo, fenología, riego y precipitación, en el caso particular, los valores de retrodispersión aumentaron en los cultivos con mayor cantidad de biomasa verde. Por otro lado los autores hallaron correlación entre la banda filtrada σ_0 con el índice de vegetación normalizado de los campos de cebolla y maíz extraído de una imagen óptica del sensor RapidEye (S. Moran et al., 2012) .

Otro ejemplo de la aplicación de la tecnología SAR fue desarrollado en la parte oeste del estado de Bahía, Brasil en 2009. En esta aplicación se elaboró a priori un mapa de referencia de la cobertura del suelo teniendo como fuente de datos una imagen Landsat TM capturada 6 días posteriores a la toma de los datos del sensor SARR99B (aerotransportado) de banda L multipolarimétrico, para garantizar datos afines y posteriores comparaciones.

El tratamiento de los datos incorporó la aplicación de una clasificación con procedimientos supervisados denominada Modos Condicionados Iterados, éste algoritmo procesa polarizaciones simples, múltiples y completas. Los autores incluyeron en la clasificación 2 clases de café (I y II) determinadas por la dirección de las hileras de siembra del mismo, en donde el café I y II están perpendicular y paralelo a la dirección de observación del sensor respectivamente, estas condiciones del cultivo hace que la respuesta de polarización sea compleja. Para la polarización VV el café I (orientación perpendicular) tenía valores ligeramente mayores en comparación con el Café II, en consecuencia en la polarización HH se observó una inversión de estos valores (Silva et al., 2009)

4.3.2 Enfoque multisensor

Forkuor, Conrad, Thiel, Landmann, & Barry, (2015), con el ánimo de mejorar la discriminación de cultivos en 2 cuencas hidrográficas de la sabana sudanesa (Vea y Dano), aplicaron una variante de la técnica clasificación secuencial de enmascaramiento a imágenes ópticas y SAR (RapidEye, Landsat, TerraSAR-X).

A diferencia de los métodos de clasificación tradicionales (clasificación de una etapa) la clasificación secuencial se concentra en procesos individuales usando una máscara específica para la discriminación de un cultivo en la escena, aplicable a la misma escena captada en fechas diferentes cuando hay un enfoque multitemporal.

La metodología incluye dos etapas, la primera consistió en la obtención de una máscara para separar las tierras no agrícolas de las agrícolas, posteriormente sobre las áreas agrícolas discriminadas en la primera etapa se ejecutó el enmascaramiento secuencial para discriminar los diferentes tipos de cultivo, para ambos enmascaramientos se aplicó el algoritmo denominado “Bosques Aleatorios” (Random Forest) implementado en el software geoestadístico R. Dicho algoritmo predice la clasificación a partir de un conjunto de datos de entrenamiento mediante la implementación de árboles de decisión múltiples.

En cada etapa de la metodología, los autores validaron los resultados mediante la producción de matrices de confusión con un conjunto independiente de datos de referencia, en donde se encontró que la exactitud general fue de 89% y 94% en las cuencas de Dano y Veá Respectivamente.

Así mismo el estudio comparó sus resultados con la clasificación en una etapa, el enfoque de enmascaramiento secuencial mejoró la precisión general de la clasificación entre 6% y 9%, mientras que los incrementos en la precisión de las clases de cultivo individuales se situaron entre el 4% y el 19%.

Mcnairn, Champagne, Shang, Holmstrom, & Reichert, (2009) evaluaron 3 metodologías de clasificación a lo largo de la frontera sur de Canadá para determinar cuál presenta mayores ventajas para su posterior aplicación en la elaboración del inventario anual de cultivos de dicho país.

Las metodologías integraron la clasificación de imágenes ópticas y SAR de manera individual y conjunta para disminuir los riesgos asociados con la dependencia de una sola fuente de datos, así como para obtener mejores rendimientos y precisiones de clasificación.

El conjunto de datos ópticos consistió en imágenes del sensor SPOT 4/5 y Landsat-5 con porcentajes menores al 20% de cobertura nubosa. El conjunto de datos SAR incluyó imágenes del sensor RADARSAT (HH) y Envisat ASAR (VV-VH).

Para los 24 sitios piloto, se recolectaron datos de observación en campo en tres momentos durante la temporada de crecimiento para asegurar calidad de datos, reconocer variaciones y cambios en el cultivo y para entrenar los modelos de clasificación supervisados así como la evaluación de la exactitud de los resultados finales. Se evaluó la exactitud del productor, del usuario y el índice de kappa, para el método de clasificación de Árboles de Decisión (DT Decision Tree) el cual se empleó teniendo en cuenta 2 tipos de enfoques, el temporal en donde se evaluó la exactitud de la clasificación monoestacional y multiestacional de los cultivos, y el enfoque monosensor y multisensor, lo anterior para favorecer el clasificador con mayores precisiones, ante esto los autores consideran que el criterio de selección del método es una relación de eficiencia entre la exactitud, los plazos de entrega y los recursos asignados.

La evaluación más sencilla consistió en el enfoque monoestacional y monosensor, que en términos generales los autores encontraron que las clasificaciones de imágenes individuales ópticas y SAR no lograron alcanzar la meta de precisión del 85% para considerarlas exitosas, en el caso de las imágenes SAR, la exactitud se manifestó siempre entre un 20% y un 25% por debajo de la lograda a través de imágenes ópticas en donde se logró obtener un 70% en la mayoría de los casos.

El enfoque multiestacional, consistió en la comparación de clasificaciones individuales que se implementaron para un conjunto de datos de imágenes ópticas y SAR entre los años 2004 y 2005. Los resultados mostraron que la exactitud de clasificación en imágenes ópticas fue superior al 85% pero no así para las imágenes SAR que solo lograron aportar precisiones entre el 74% y el 84%.

En esta etapa, los autores manifiestan que los mejores resultados se obtuvieron para las fecha de finales de agosto y principios de septiembre debido a que las diferencias estructurales de la vegetación son mayores, en contraste con la exactitud de las adquisiciones de junio cuando la cobertura vegetativa es relativamente baja en donde el suelo aporta una retrodispersión significativa para el caso particular de la clasificación de la microondas.

El último enfoque evaluado involucra la clasificación monoestacional basada en la fusión de los conjuntos de datos ópticos y SAR para evitar la adquisición de múltiples imágenes teniendo en cuenta limitaciones de recursos. En esta etapa los resultados de la exactitud de la clasificación basada en la fusión de las imágenes siempre fue menor cuando se involucraron los datos del sensor RADARSAT, esto debido a su condición de polarización simple (HH), por otro lado la contribución de la polarización dual del sensor ASAR (VV y VH) en la fusión de datos mejoró la clasificación entre 3% y 18%, lo que significa que las exactitudes generales oscilan entre 70% y 90% en las áreas piloto de estudio.

La investigación desarrollada por Carreiras, Jones, Lucas, & Shimabukuro, (2017) tuvo como objetivo evaluar datos de los sensores Landsat Thematic Mapper (TM) y Advanced Land Observing Satellite (ALOS PALSAR) en el período 2007-2010 para discriminar bosques maduros, bosques no forestales, bosques secundarios y la edad de los bosques secundarios en 3 zonas de la amazonia brasileña (Manaos, Santarém, Machadinho d'Oeste).

Para la discriminación de la edad de los bosques secundarios, en la selección de áreas de entrenamiento se incluyó un conjunto espacialmente representativo de

áreas cubiertas con bosques secundarios de edad conocida con un tamaño de 100 m * 100 m, el tamaño de las muestras responde a la necesidad de evitar errores de superposición entre las imágenes ALOS PALSAR y Landsat TM.

El algoritmo de aprendizaje automático usado para clasificación fue Random Forests y los datos de entrada consistieron en la combinación de la intensidad de retrodispersión ALOS PALSAR en las polarizaciones HH y HV junto con la reflectancia superficial Landsat 5 TM en las regiones espectrales infrarrojas (Infrarrojo Cercano y de onda corta).

La relación entre las variables de entrada (ALOS PALSAR y Landsat TM) y la edad de los bosques secundarios, se evaluó ajustando lineamientos utilizando mínimos cuadrados generalizados, correlación de errores y varianzas desiguales y como resultado se estableció una relación directa entre la edad con el aumento de la intensidad en la retrodispersión en HH y HV e inversa con la reflectancia en las regiones espectrales del rojo, infrarrojo cercano y de onda corta.

Con respecto a la precisión general en la discriminación de los bosques maduros, bosques no forestales y bosques secundarios es alta (95-96%), este porcentaje alto de exactitud general se debe principalmente al aporte de la clasificación del bosque no forestal el cual siempre estuvo por encima del 99% para la exactitud del usuario y por encima del 98% para la exactitud del productor en cada una de las observaciones realizadas para las imágenes de los años 2007, 2008, 2009 y 2010.

5 DATOS Y MÉTODOS

5.1 Zona de estudio

El área de estudio está localizada en el departamento del Huila, Colombia. Según el Censo Nacional Agropecuario 2014 desarrollado por el Departamento Nacional de Estadística, el Departamento y el Municipio de Colombia con mayor área cosechada de café a nivel nacional fueron Huila con 113.373 has (15,1%) y Pitalito 14.959 (2%) respectivamente (DANE, 2016).

El conjunto de datos de imágenes SAR y Ópticas cubre parcialmente el municipio de Pitalito a través de un recorte rectangular por lo cual también está incorporado en el área de análisis de manera parcial el municipio de Isnos.

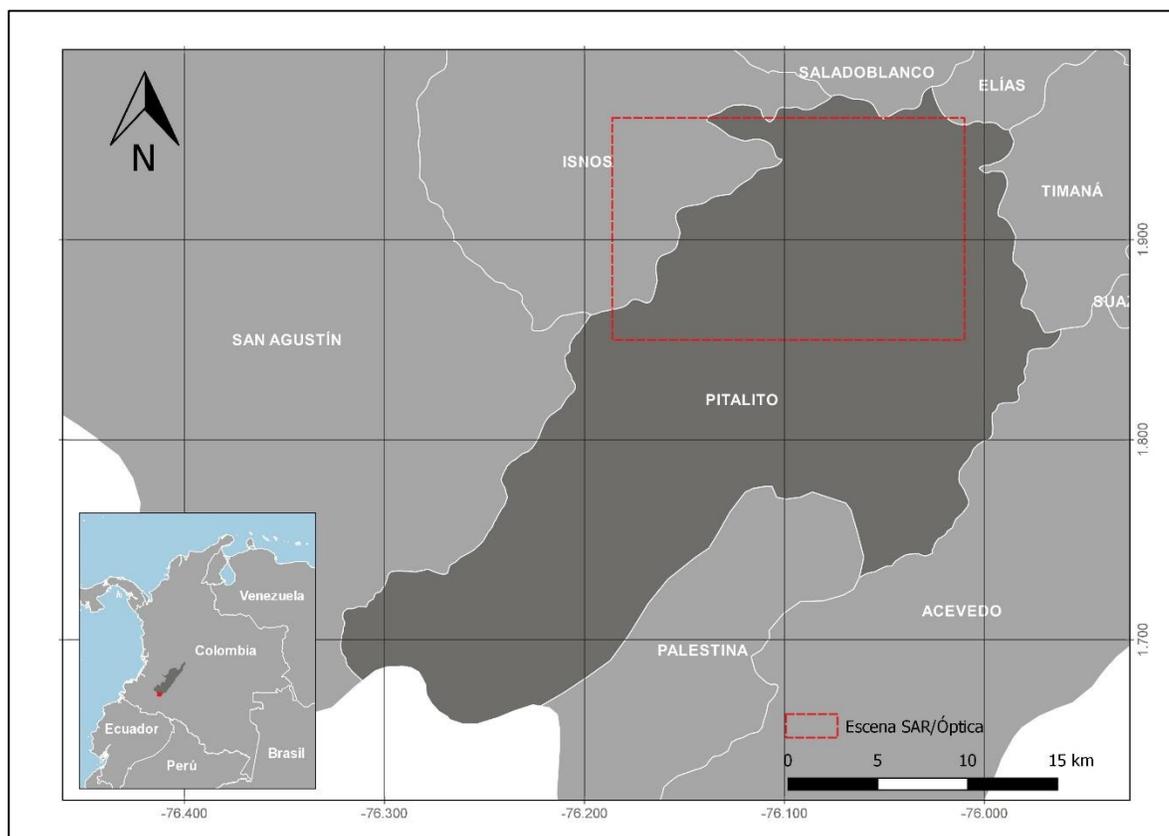


Figura 10. Área de estudio en el Departamento del Huila. Fuente: Elaboración propia, datos tomados del Instituto Geográfico Agustín Codazzi 2010.

5.2 Datos

Se plantea evaluar la clasificación de las imágenes de los siguientes sensores SAR y ópticos:

Tabla 4. SENTINEL-1: Características del Sensor.

Frecuencia	Polarización	Resolución Espacial	Nivel	Modo de adquisición	Modo	Fecha de adquisición
5.405 GHz (banda C)	VH+VV,	20 x 20 m	1 GRD	Interferometric Wide swath (IW)	Ascendente	3/10/2016

Fuente: European Space Agency, (2013)

Tabla 5. SENTINEL-2: Características del Sensor.

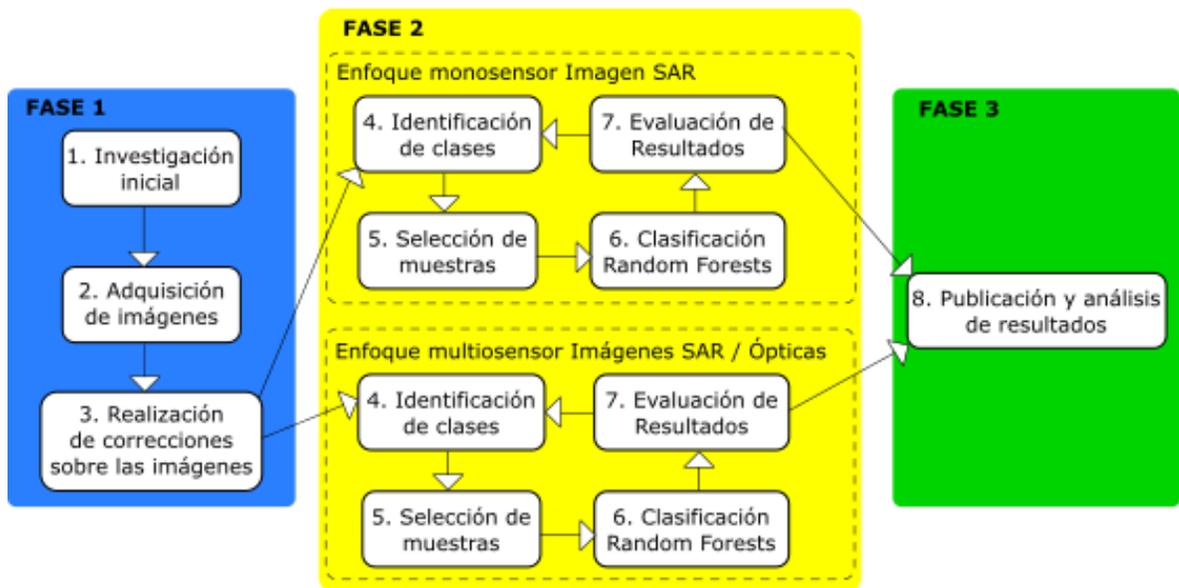
Banda	Resolución Espacial	Long de onda central	Región espectral	Resolución radiométrica	Nivel	Fecha de adquisición
1	60 m	443 nm	Ultravioleta			
2		490 nm	Azul			
3	10 m	560 nm	Verde			
4		665 nm	Rojo			
5		705 nm				
6	20 m	740 nm	Visible e infrarrojo cercano	12 bits	1-C	18/10/2016
7		783 nm				
8	10 m	842 nm				
9	20 m	865 nm				
10		940 nm	Infrarrojo de onda corta			
11	60 m	1375 nm				
12		1610 nm				
13	20 m	2190 nm				

Fuente: European Space Agency, (2017)

5.3 Métodos

5.3.1 Metodología desarrollada en la investigación

En el esquema 1 se despliega la metodología a empleada para la evaluación de la capacidad de los datos SAR con enfoque monosensor y multisensor para la detección del cultivo del Café en función de la densidad de sombrero presente.



Esquema 1. Metodología de la investigación. Fuente: Adaptado de León 2015

El desarrollo de la investigación involucra 3 fases, en la primera se aborda la recopilación del estado del arte relacionado con esta aplicación, así como la selección, adquisición y preparación de los datos SAR y ópticos. Preparar y corregir las imágenes involucradas en el análisis según lo indicado en el compendio estudios de la sección 4, permitirá obtener los insumos óptimos para la fase de clasificación.

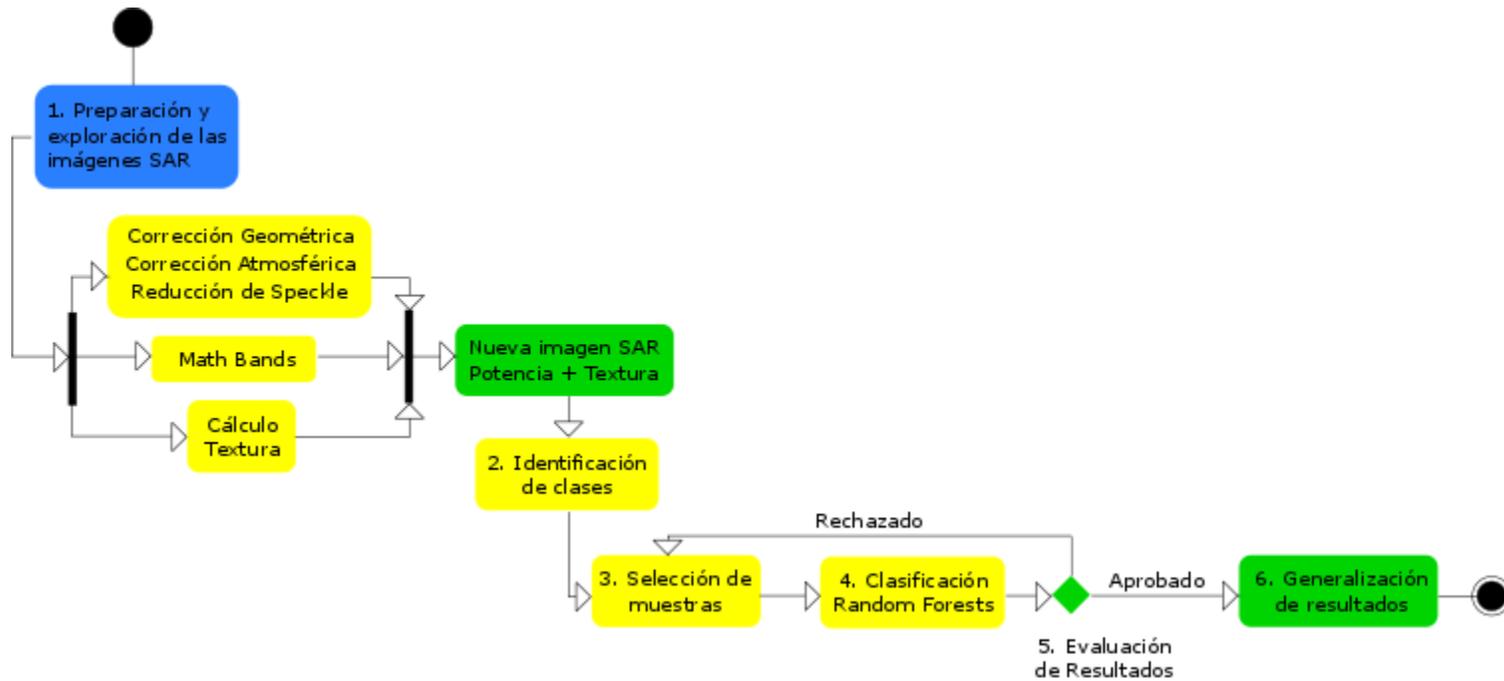
La segunda fase tiene 2 enfoques. En el primero se analiza la clasificación del algoritmo Random Forests exclusivamente para los datos SAR a través de su intrínseca riqueza textural sumado al valor de la intensidad de los pulsos retrodispersados para las polarizaciones VH y VV. El segundo enfoque integra los datos SAR con datos ópticos, con el ánimo de aprovechar las características y propiedades de dichas regiones del espectro electromagnético.

Partiendo del esquema 1, a continuación, se detalla la metodología empleada para el análisis según los enfoques considerados para alcanzar el objetivo de la investigación.

El esquema 2 ilustra el esquema correspondiente a la clasificación por Random Forests de las texturas y la potencia de la retrodispersión de la imagen SAR.

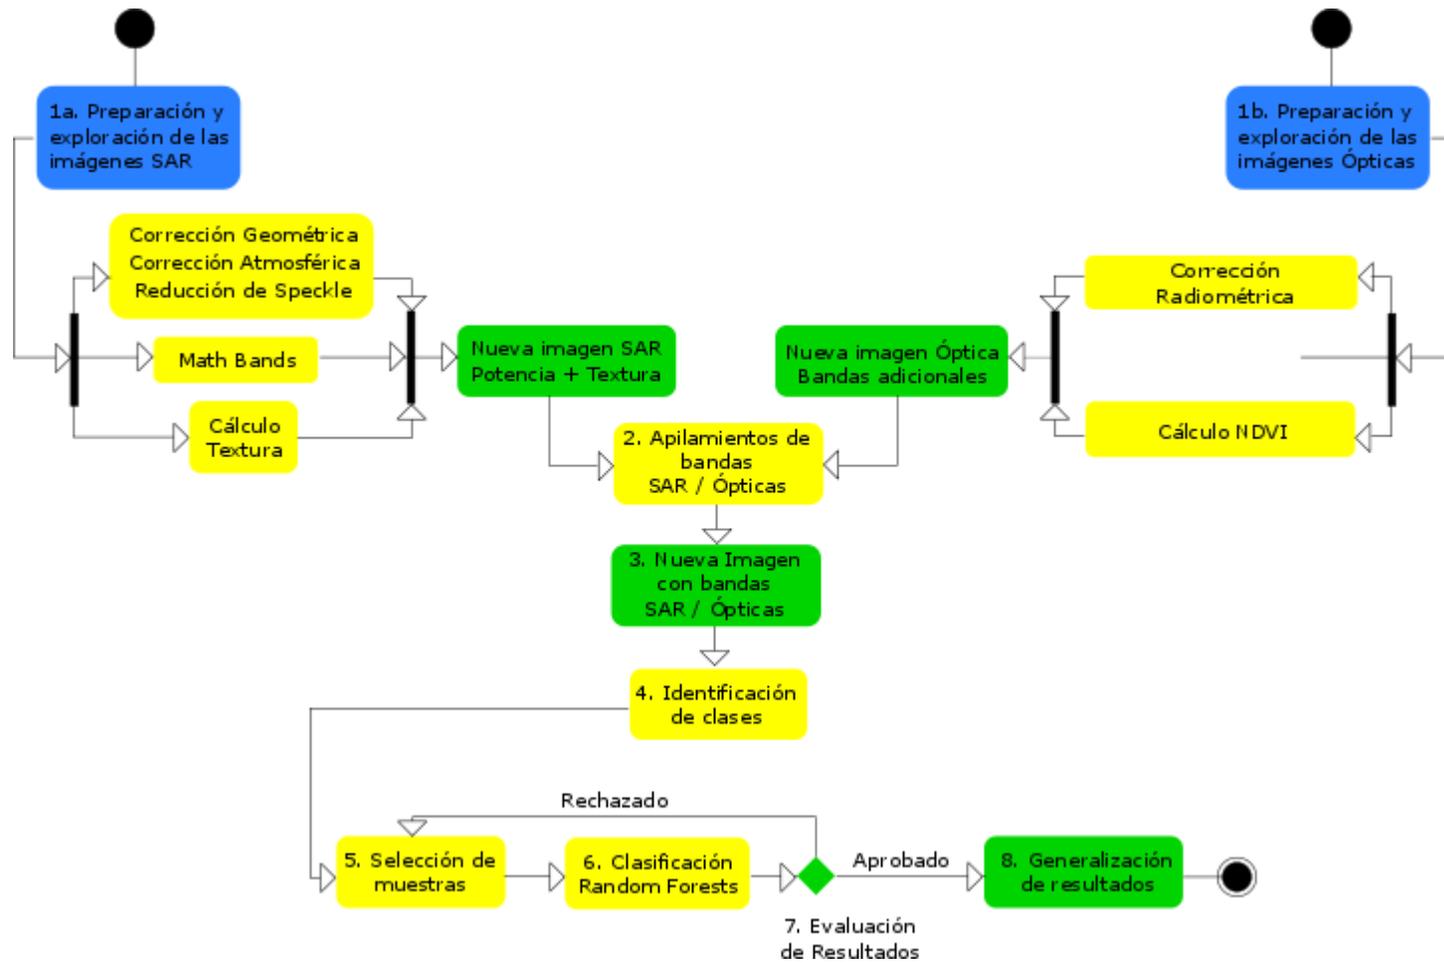
El primer paso del proceso consistió en la aplicación de las correcciones necesarias para iniciar los procesamientos y análisis digitales sobre las mismas, así como una inspección visual detallada de la imagen SAR con el objetivo de identificar los niveles de rugosidad relacionados con la presencia de café y otras coberturas en la zona de estudio.

Una vez corregidas las imágenes se procedió a calcular la matriz de co-ocurrencia con 10 descriptores de texturas (Agregar sección) y la obtención nuevas bandas (diferencia, media y relación entre VH y VV) a través de la herramienta math bands. En el segundo paso se procedió a la identificación de las clases de cobertura presente en la escena de la imagen SAR corregida tanto para la retrodispersión como para los descriptores de textura. En la tercera actividad se prepararon las muestras de cada clase definida en el paso 2 para el entrenamiento de los bosques aleatorios. El cuarto paso involucró la parametrización y ejecución del algoritmo de clasificación Random Forests. Los 2 pasos finales consistieron en la evaluación de la exactitud de la clasificación y la generalización de los resultados.



Esquema 2. Diagrama de actividades clasificación por Random Forests imagen SAR. Fuente: Adaptado de León 2015

El esquema 3 ilustra el esquema correspondiente al enfoque multisensor apoyada por la sinergia de los datos provenientes de las imágenes ópticas y SAR.



Esquema 3. Diagrama de actividades Clasificación por Random Forests con enfoque multisensor. Fuente: Adaptado de León 2015

Para el enfoque multisensor, la preparación de los datos SAR realizada fué exactamente igual al enfoque monosensor. Por su parte a los datos ópticos se les aplicó la corrección radiométrica y se calculó el Índice de Diferencia Normalizada de Vegetación. Seguidamente el paso 2 correspondió al aplilamiento de los datos provenientes de las imágenes ópticas y SAR, en la cual se obtiene una nueva imagen con propiedades complementarias para aumentar la capacidad del espectro óptico incluyendo el IRC con la información aportada por el espectro de las microondas y viceversa. A partir del tercer paso, los demás son homólogos al enfoque monosensor.

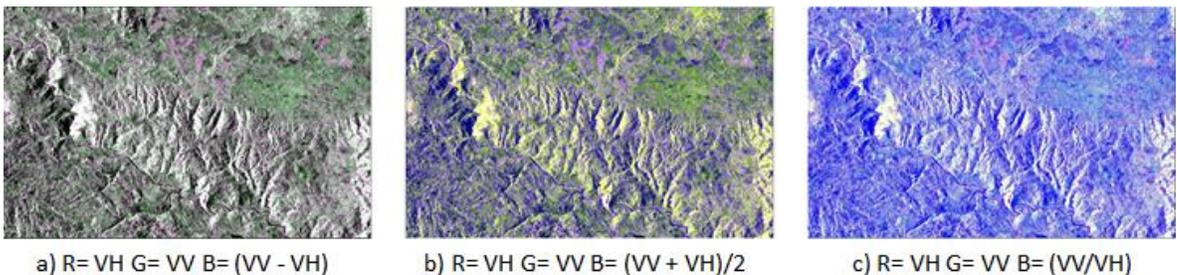
6 DESARROLLO DEL PROYECTO

6.1 Procesamiento inicial

Este apartado comprende el preprocesamiento y las correcciones inherentes descritos en la sección 5.4 de los datos crudos de los sensores SENTINEL 1 y 2. A partir de los resultados del procesamiento inicial, para el sensor SENTINEL 1, el primer subproducto alcanzado consistió en la conversión de los valores digitales de la retrodispersión a valores en escala de decibeles (db), el segundo subproducto comprende 3 nuevas bandas que son resultado de la comparación a través de álgebra de mapas y por último 10 descriptores de texturas para la retrodispersión en la polarización VH. De forma similar, luego del preprocesamiento para los datos de SENTINEL 2, se obtuvo el Índice de Diferencia Normalizada de Vegetación (NDVI).

6.1.1 Capas derivadas de la imagen del sensor Sentinel 1

Para complementar la información aportada por las bandas originales y los descriptores de textura, se procedió a calcular nuevas capas para la retrodispersión VV y VH, diferencia (VV-VH), media $(VV+VH)/2$ y relación (VV/VH) como se puede apreciar en el mosaico de imágenes 1, lo anterior según lo indicado por Abdikan, Sanli, Ustuner, & Calò, (2016), para finalmente obtener 15 capas apiladas en un solo archivo de imagen (Mosaico de imágenes 4).



Mosaico de imágenes 1. Composiciones RGB falso color para las nuevas capas derivadas. Fuente: Elaboración propia, datos European Space Agency 2016

Basado en el algoritmo matriz de coocurrencia para niveles de gris (GLCM) en el programa ESA SNAP 4.0 sobre las bandas Sigma0_VH en una ventana de 5 x 5 píxeles, se procedió a calcular los descriptores de textura: Contraste, disimilitud,

homogeneidad, segundo momento angular (Mosaico de imágenes 3), energía, máxima probabilidad, entropía, GLCM media, GLCM varianza, GLCM correlación.

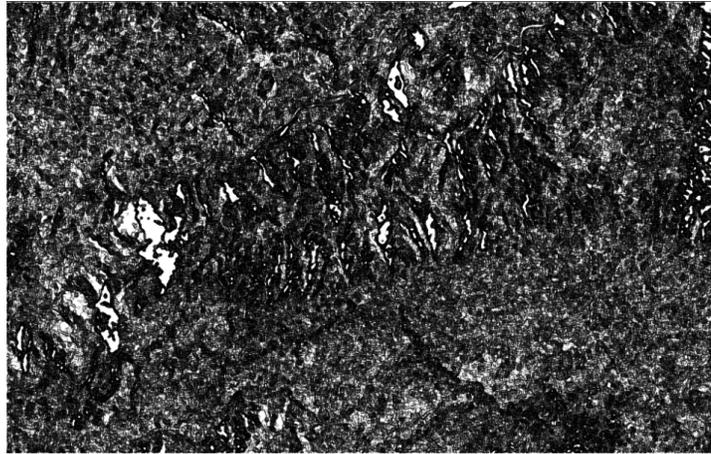
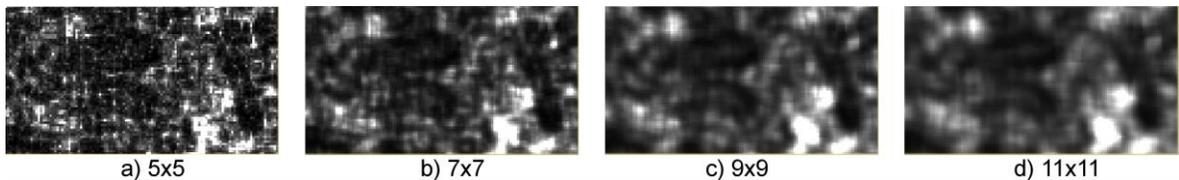
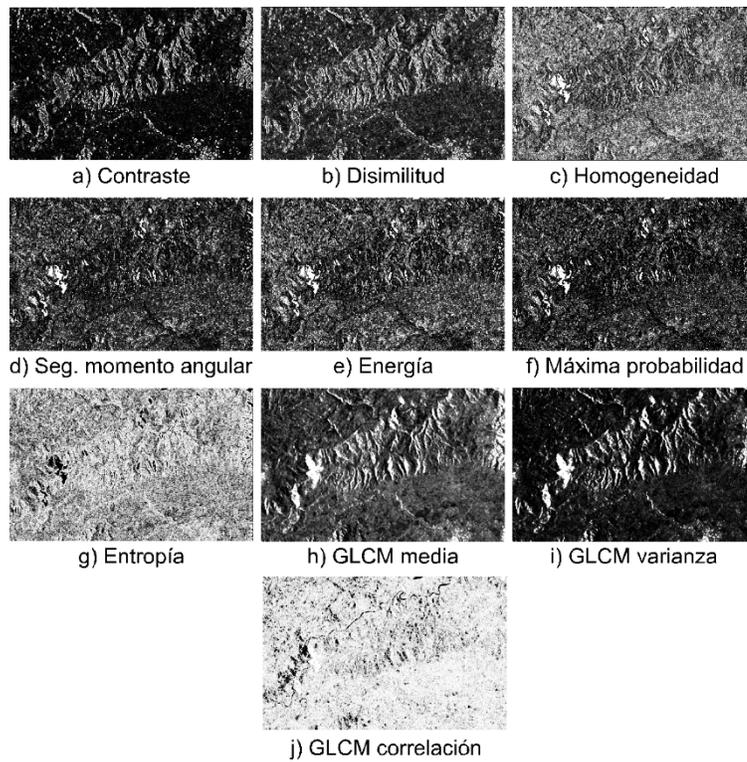


Figura 11. Descriptor de textura "Segundo Momento Angular" Sigma0_VH de la imagen del sensor Sentinel 1 para el área de estudio. Fuente: Elaboración propia, datos European Space Agency 2016

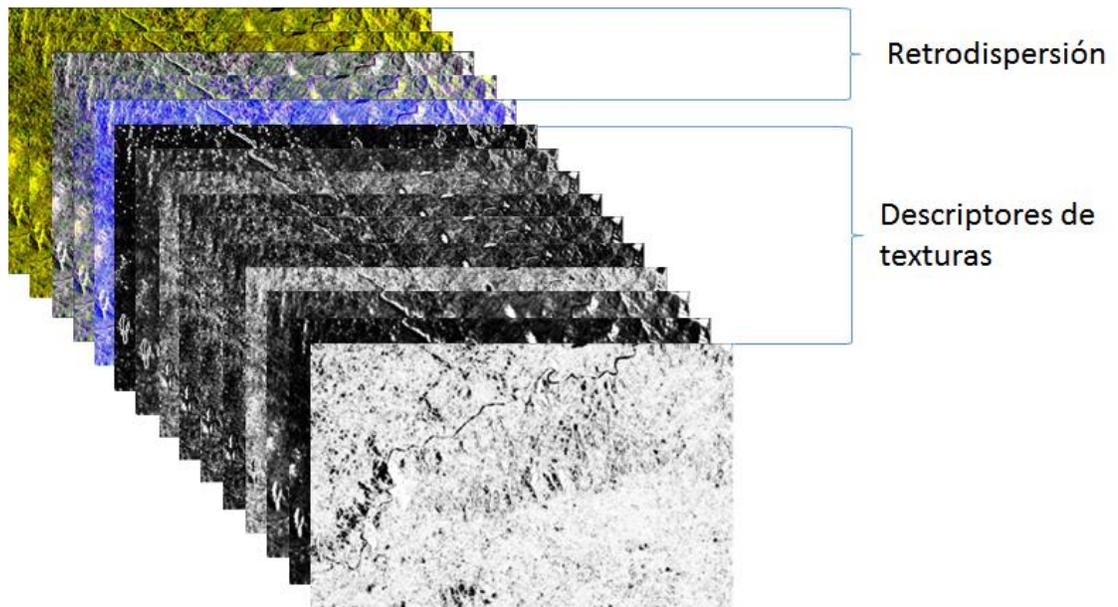


Mosaico de imágenes 2. Comparación de resultados para el descriptor de textura "Segundo Momento Angular". Fuente: Elaboración propia, datos European Space Agency 2016

La comparación entre los diferentes tamaños de ventanas de los descriptores de texturas muestra una evidente generalización a partir de la ventana 9x9 (Figura 6), por tal motivo y debido a la heterogeneidad de la zona de estudio y por el tamaño del píxel de la imagen, se optó por utilizar los resultados de la ventana 5x5 para garantizar regiones texturales más pequeñas (Mosaico de imágenes 2).



Mosaico de imágenes 3. Descriptores de textura ventana 5x5 derivados de la imagen SAR. Fuente: Elaboración propia, datos European Space Agency 2016



Mosaico de imágenes 4. Apilamiento de las capas originales y derivadas de la imagen SAR. Fuente: Elaboración propia, datos European Space Agency 2016

6.1.2 Capas derivadas de la imagen del sensor Sentinel 2

La información derivada de los datos ópticos corresponde al Índice de Diferencia Normalizada de Vegetación (NDVI) y se obtuvo a partir de los valores de reflectancia de la escena.

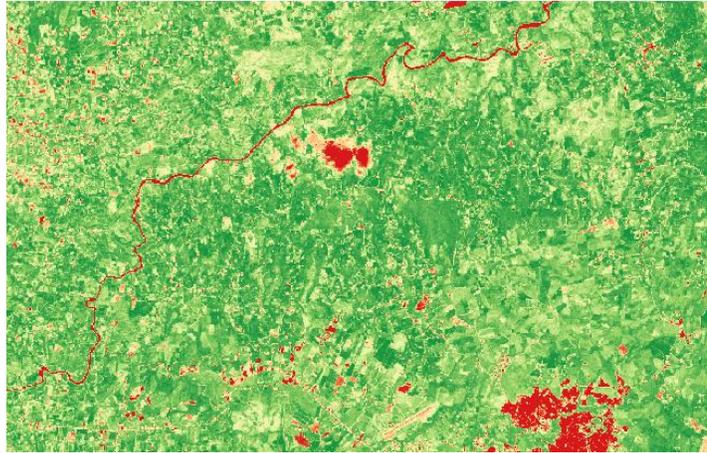
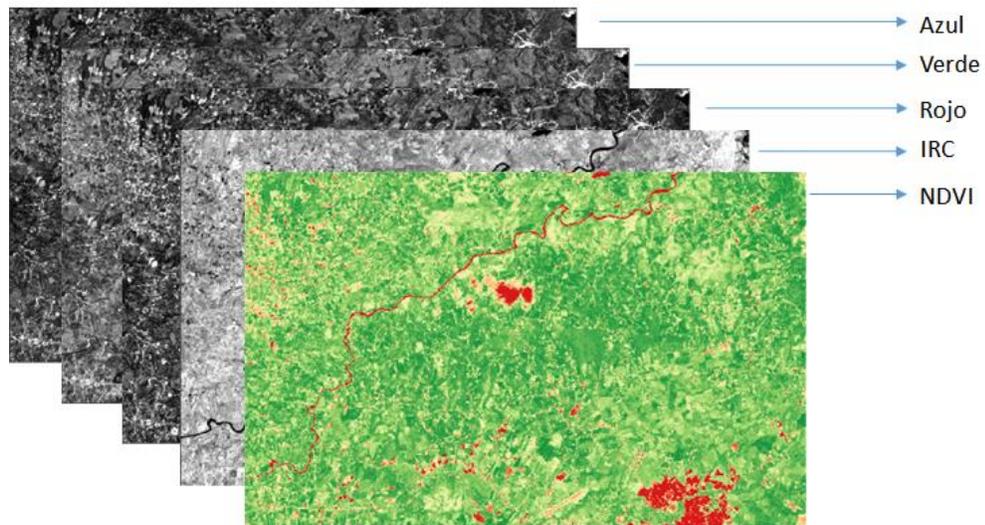


Figura 12. Índice de Diferencia Normalizada de Vegetación (NDVI). Fuente: Elaboración propia, datos European Space Agency 2016

Posterior al cálculo del NDVI, se realizó el apilamiento de las capas ópticas Azul, Verde, Roja e Infrarroja corregidas radiométricamente (Figura 10).



Mosaico de imágenes 5. Apilamiento de las capas originales y derivadas de la imagen Óptica.
Fuente: Elaboración propia, datos European Space Agency 2016

6.2 Definición de las clases y áreas de entrenamiento

6.2.1 Clases de cobertura

Partiendo de los objetivos de la presente investigación, las clases de café se definieron según la densidad de sombrero en el cultivo. Así mismo, el autor definió las demás clases basado en los tipos de cobertura de la tierra con mayor presencia en el área de estudio y también las características propias de cada tipo de imagen como la presencia de nubes, sombras de nubes y las sombras provocadas por la obstrucción del relieve a las microondas del sensor SAR.

Tabla 6. Clasificación de las coberturas en el área de estudio.

Código	Nombre de la clase	Simbología	Enfoque SAR	Enfoque multisensor
1	Cafe_Sombra	#800000	x	x
2	Cafe_Semisombra	#993300	x	x
3	Cafe_Sin_Sombra	#996600	x	x
4	Bosque	#375623	x	x
5	Pastos	#a9d08e	x	x
6	Superficie_Agua	#0610d0	x	x
7	Construcciones	#808080	x	x

8	Vias	#bfbfbf	x	x
9	Suelo_Desnudo	#dbc125	x	x
10	Guaduales	#66ff33	x	x
11	Nubes	#ffffff		x
12	Sombras_nubes	#000000		x
13	Sombras_SAR	#41637f	x	x

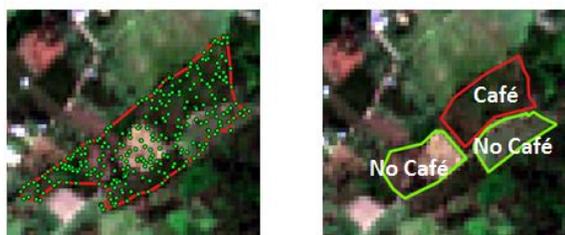
Fuente: Elaboración propia

6.2.2 Selección de las áreas de entrenamiento

Las áreas de entrenamiento relacionadas con el cultivo de café fueron extraídas a partir del censo georreferenciado de especies arbóreas presentes en 30 lotes productivos de café realizado por Vega, (2013), el cual incluye el cálculo de la densidad de sobra para cada plantación de café. La digitalización de los polígonos también se basó en la interpretación visual de la imagen Ikonos (2013) del servicio de GoogleEarth desplegado con el plugin OpenLayer de Qgis y la imagen de SENTINEL 2 (2016) para la detección de los cambios presentados en el periodo de 3 años.

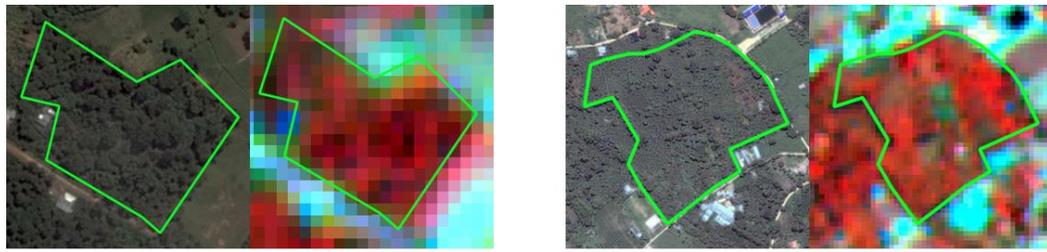


a) Imagen Ikonos, 2013



b) Imagen Sentinel-2, 2016

Mosaico de imágenes 6. Identificación de cambios en lotes de café a partir de imágenes Ikonos de 2013 y Sentinel-2 de 2016. Fuente: Elaboración propia, datos European Space Agency 2016.



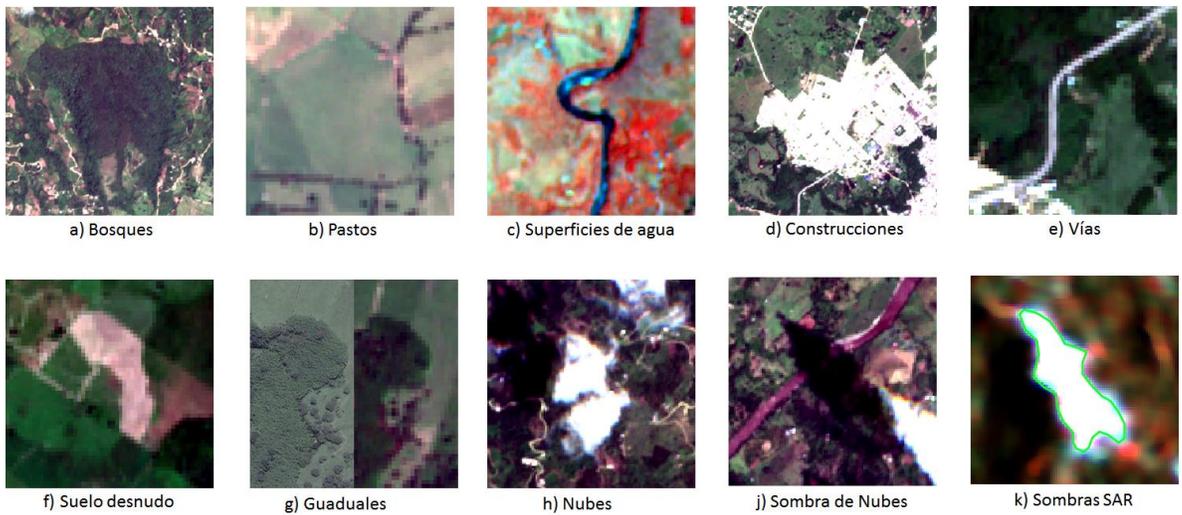
a) Café de Sombra

b) Café Semisombra



b) Café sin Sombra

Mosaico de imágenes 7. Ejemplos de las áreas de Café extraídas de la imagen Sentinel-2 con apoyo de interpretación visual Ikonos 2013. Fuente: Elaboración propia, datos European Space Agency 2016



a) Bosques

b) Pastos

c) Superficies de agua

d) Construcciones

e) Vías

f) Suelo desnudo

g) Guadales

h) Nubes

i) Sombra de Nubes

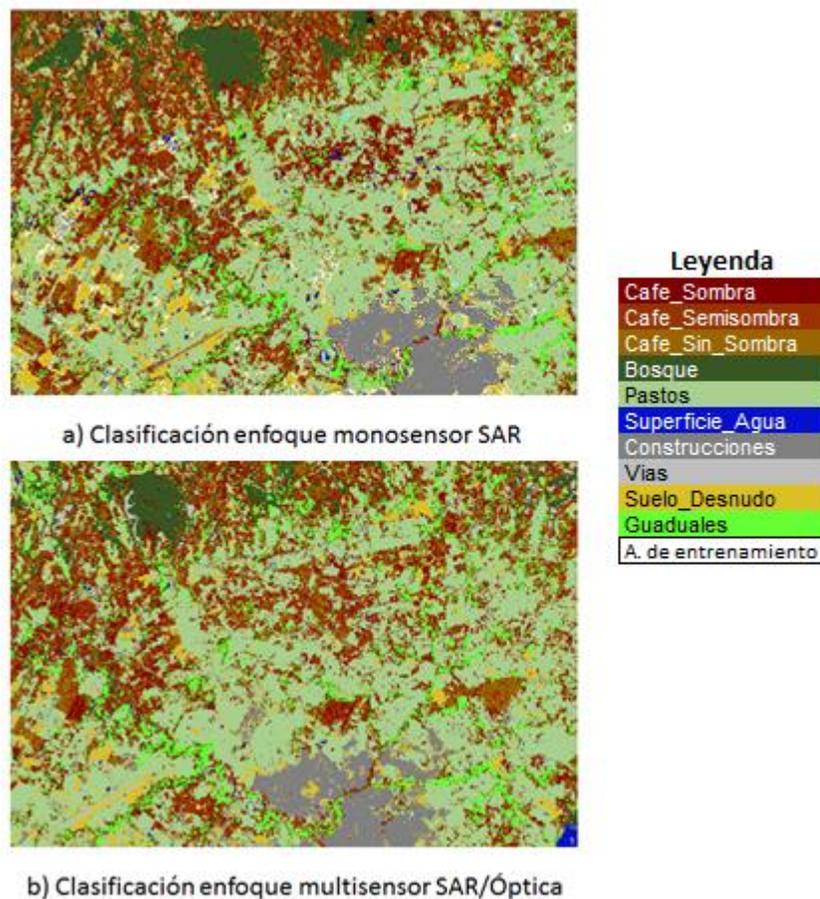
k) Sombras SAR

Mosaico de imágenes 8. Ejemplos de áreas de entrenamiento extraídas de la imagen Sentinel-2. Fuente: Elaboración propia, datos European Space Agency 2016

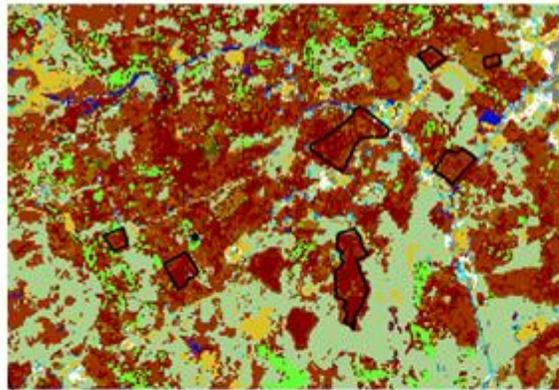
6.3 Presentación de los resultados de la clasificación por Random Forests.

Esta sección presenta los resultados de acuerdo a la metodología planteada en la sección 5.3 sobre los 2 enfoques de datos SAR y SAR/Óptico (Esquema 2 y 3).

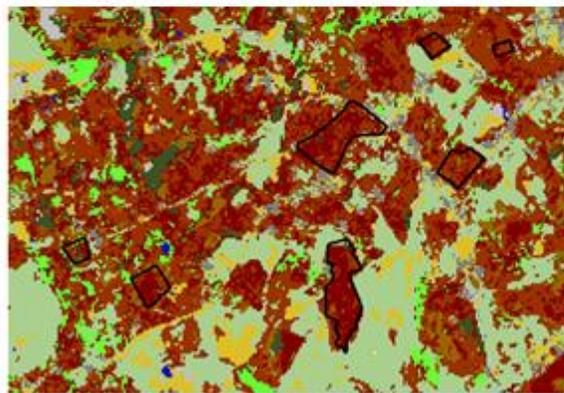
El mosaico de imágenes 9 despliega un panorama general de la clasificación en los enfoques planteados, los mosaicos de imágenes 10 y 11 de igual manera muestran los resultados de las clasificaciones para el área rural y urbana de la escena seleccionada de las imágenes Sentinel-1 y Sentinel-2.



Mosaico de imágenes 9. Vista general de la clasificación Random Forests para los enfoques monosensor y multisensor. Fuente: Elaboración propia, datos European Space Agency 2016



a) Clasificación enfoque monosensor SAR

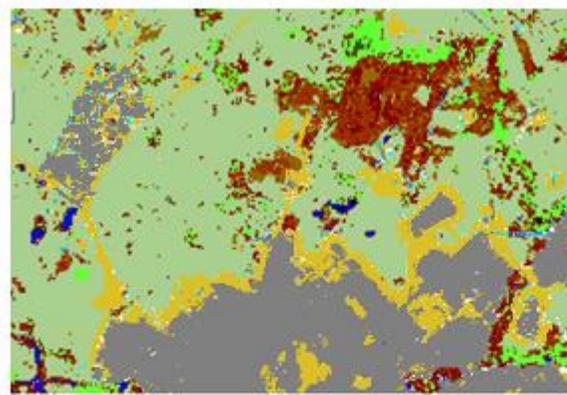


b) Clasificación enfoque multisensor SAR/Óptica

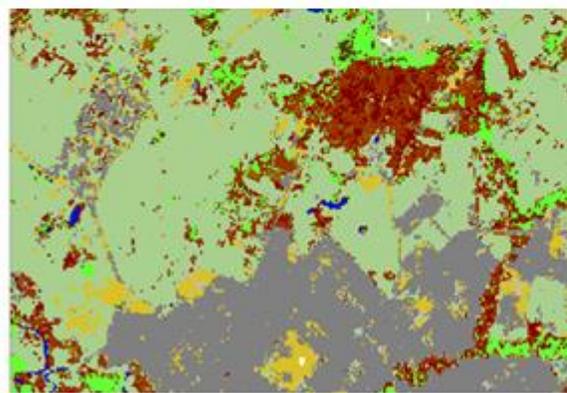
Leyenda

Cafe_Sombra
Cafe_Semisombra
Cafe_Sin_Sombra
Bosque
Pastos
Superficie_Agua
Construcciones
Vias
Suelo_Desnudo
Guaduales
A. de entrenamiento

Mosaico de imágenes 10. Resultado clasificación área rural incluyendo áreas de entrenamiento de lotes de café. Fuente: Elaboración propia, datos European Space Agency 2016



a) Clasificación enfoque monosensor SAR



b) Clasificación enfoque multisensor SAR/Óptica

Leyenda

Cafe_Sombra
Cafe_Semisombra
Cafe_Sin_Sombra
Bosque
Pastos
Superficie_Agua
Construcciones
Vias
Suelo_Desnudo
Guadales
A. de entrenamiento

Mosaico de imágenes 11. Resultados de la clasificación incluyendo el área urbana. Fuente: Elaboración propia, datos European Space Agency 2016

En general se puede apreciar una distribución apropiada de las clases en el área de estudio, predominancia de coberturas de pastos alrededor del área urbana, presencia importante de las 3 clases objetivo de plantaciones de café en la zona rural, y algunas clasificaciones erróneas de café con las coberturas de guadua en la rivera de las corrientes de agua.

6.4 Evaluación de la exactitud

Como argumento dentro del script utilizado en el lenguaje R para la clasificación Random Forests se reservó el 30% de las áreas de entrenamiento con las cuales se seleccionaron aleatoriamente 7.248 píxeles (muestras sobre imagen SAR) y 7.912 píxeles (muestras sobre la imagen SAR/Óptica) para la evaluación de la exactitud por medio de la matriz de confusión calculada al final del procesamiento del algoritmo “SuperClass” del paquete RStoolbox.

Las tablas 4 y 5 presentan la matriz de confusión para la clasificación Random Forests aplicada a los enfoques monosensor (SAR) y multisensor (SAR/Óptico) respectivamente.

Tabla 7. Matriz de confusión para la clasificación enfoque monosensor

Predicción	1	2	3	4	5	6	7	8	9	10	11	Total fila	EU %
1 - Cafe_Sombra	563	150	95	36	0	2	3	0	0	0	0	849	66,31
2 - Cafe_Semisombra	15	423	103	51	0	0	0	0	0	21	0	613	69,00
3 - Cafe_Sin_Sombra	30	56	386	18	20	0	0	0	0	0	0	510	75,69
4 - Bosque	0	5	0	253	0	0	0	0	0	0	0	258	98,06
5 - Pastos	6	12	0	0	905	0	0	0	0	1	17	941	96,17
6 - Superficie_Agua	0	0	0	0	0	148	1	0	0	35	0	184	80,43
7 - Construcciones	9	6	0	0	0	0	848	63	95	0	0	1021	83,06
8 - Vias	1	0	0	0	0	2	0	301	0	3	0	307	98,05
9 - Suelo_Desnudo	0	0	0	0	0	0	126	0	859	0	0	985	87,21
10 - Guaduales	150	36	20	0	60	0	6	3	0	808	2	1085	74,47
11 - Sombras_SAR	80	15	0	0	1	0	0	0	0	23	459	578	79,41
Total columna	854	703	604	358	986	152	984	367	954	891	478	7331	
EP %	65,93	60,17	63,91	70,67	91,78	97,37	86,18	82,02	90,04	90,68	96,03		81,20

La exactitud global de la clasificación con enfoque netamente SAR es:

$$EG = \frac{563 + 423 + 386 + 253 + 905 + 148 + 848 + 301 + 859 + 808 + 459}{7331} = 81,20\% \quad 3$$

Tabla 8. Matriz de confusión para la clasificación enfoque multisensor

Predicción	1	2	3	4	5	6	7	8	9	10	11	12	13	Total fila	EU %
1 - Cafe_Sombra	356	8	13	27	1	0	0	0	0	97	0	0	0	502	70,92
2 - Cafe_Semisombra	57	473	66	40	0	0	0	0	0	0	1	0	0	637	74,25
3 - Cafe_Sin_Sombra	5	36	194	7	7	0	0	0	0	0	0	0	0	249	77,91
4 - Bosque	63	20	2	525	0	0	0	0	0	0	0	0	0	610	86,07
5 - Pastos	1	4	3	0	506	1	10	0	0	2	0	0	20	547	92,5
6 - Superficie_Agua	0	0	0	1	0	104	1	0	0	0	0	4	0	110	94,55
7 - Construcciones	0	2	0	0	0	0	934	3	18	0	12	0	0	969	96,39
8 - Vías	0	0	0	0	0	0	0	118	8	0	0	0	0	126	93,65
9 - Suelo_Desnudo	0	5	1	0	0	0	0	4	934	0	0	0	0	944	98,94
10 - Guadales	23	84	6	19	0	0	13	0	3	903	0	0	0	1051	85,92
11 - Nubes	0	7	0	2	0	0	8	0	2	0	193	1	0	213	90,61
12 - Sombras_nubes	20	13	0	0	0	0	1	0	0	0	0	932	0	966	96,48
13 - Sombras_SAR	8	11	0	0	20	0	0	0	3	0	0	3	728	773	94,18
Total columna	533	663	285	621	534	109	967	125	968	1002	206	940	748	7697	
EP %	66,79	71,34	68,07	84,54	94,76	95,41	96,59	94,4	96,49	90,12	93,69	99,15	97,33		89,65

La exactitud global de la clasificación con enfoque multisensor es:

$$EG = \frac{356 + 473 + 194 + 525 + 506 + 104 + 934 + 118 + 934 + 903 + 193 + 932 + 728}{7697} = 89,65\% \quad 4$$

Teniendo en cuenta el panorama de la exactitud global de ambos enfoques, como se esperaba, la complementariedad de los tipos de datos empleados se refleja en un aumento 8 puntos porcentuales en la exactitud general para el enfoque multisensor:

- Exactitud Global

$$EG_{mono} > EG_{multi} = 81,20\% > 89,65\%$$

- Exactitud del Usuario para el cultivo de café de sombra

La clasificación con enfoque multisensor también arrojó resultados mejores en cuanto a la detección del café de sombra mejorando la exactitud en 2 puntos porcentuales con respecto a la clasificación monosensor.

$$EU_{mono} = \frac{563}{849} = 66,31\% \quad (5)$$

$$EU_{multi} = \frac{356}{502} = 70,92\% \quad (6)$$

- Exactitud del Usuario para el cultivo de café semisombra.

De la misma manera, la clasificación multisensor arrojó mejores resultados a la hora de clasificar el café semisombra con 4,56 puntos porcentuales por encima del enfoque monosensor.

$$EU_{mono} = \frac{423}{613} = 69\% \quad (7)$$

$$EU_{multi} = \frac{473}{637} = 74,25\% \quad (8)$$

- Exactitud del Usuario para el cultivo de café sin sombra

Por último, los escenarios anteriores se replican a la hora de abordar los resultados de la exactitud del usuario para el café sin sombra, que se acerca considerablemente al 80% de aciertos en la clasificación.

$$EU_{mono} = \frac{386}{510} = 75,69\% \quad (9)$$

$$EU_{multi} = \frac{194}{249} = 77,91\%$$

(10)

Teniendo en cuenta los resultados de la clasificación relacionados con las clases objetivo de esta investigación, el autor considera que la clasificación por Random Forests arroja mejores resultados bajo un enfoque multisensor acorde con la literatura citada en las secciones 4.3.1 y 4.3.2.

6.5 ANÁLISIS Y COMPARACIÓN DE LOS RESULTADOS

En esta sección se analizarán los resultados más relevantes de la investigación para cada uno de los enfoques planteados en los objetivos específicos en el marco de la clasificación Random Forests.

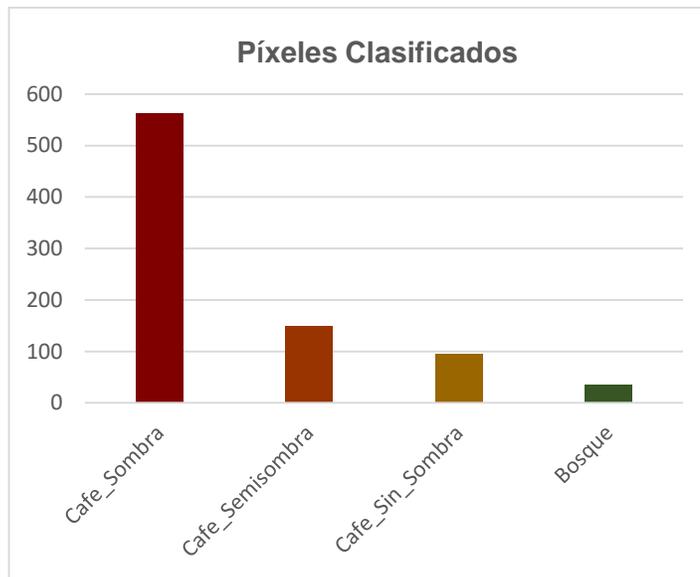
6.6 Análisis del enfoque monosensor

El enfoque monosensor es la línea base de la investigación y a partir de la evaluación de sus resultados se desglosan las comparaciones y conclusiones para determinar la capacidad del sensor Sentinel-1 para la identificación de plantaciones de café en función de la densidad de sombrero presente.

Como se presentó en la sección 6.4, la exactitud del usuario para las clases de café va desde el 66,31% hasta 75,69%.

6.6.1 Clasificación monosensor de café con sombra

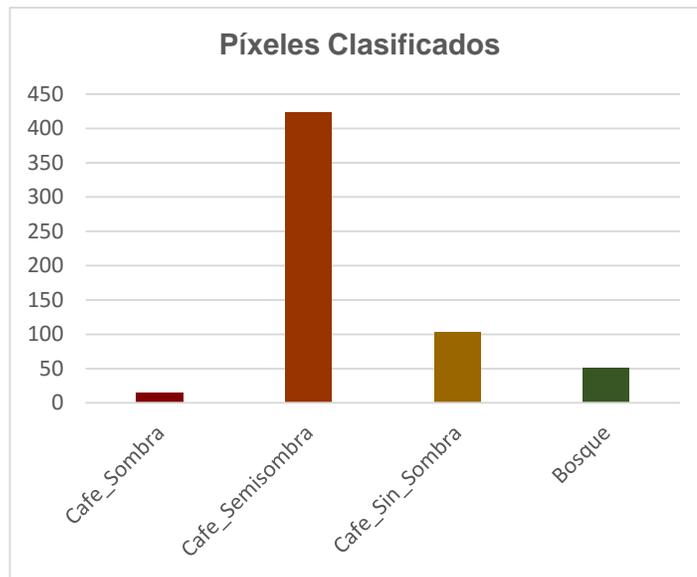
Según la matriz de confusión de error (Tabla 4) la exactitud del usuario más baja corresponde a la clase de café con sombra con 66,31%, debido a que el clasificador Random Forests reconoció erróneamente otras coberturas dentro de las áreas de entrenamiento destinadas para la validación como lo muestra la gráfica 1:



Gráfica 2. Clasificación de píxeles en la exactitud de usuario para el café con sombra

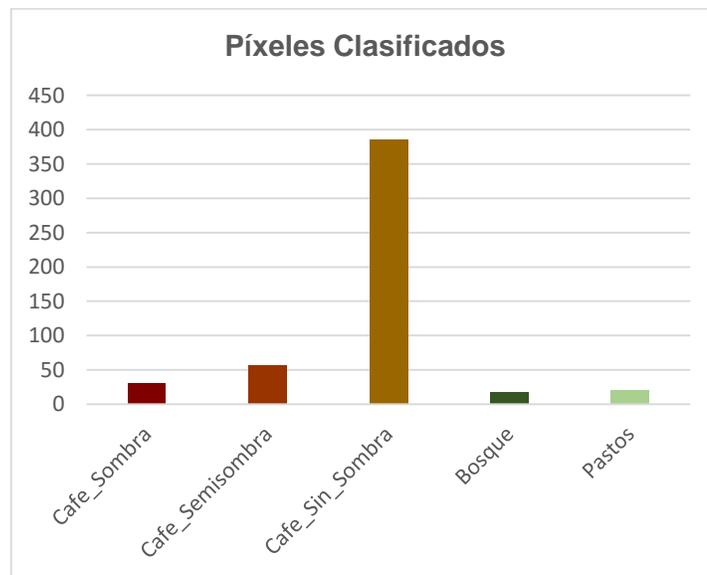
6.6.2 Clasificación monosensor de café semisombra

La clase de café de semisombra arroja mejores resultados de clasificación con respecto al café de sombra con 2,69 puntos porcentuales adicionales. Lo anterior se explica debido a menor presencia de especies arbóreas lo que permite una interacción mayor entre las plantas de café con las microondas del sensor Sentinel-1. En este caso los falsos positivos se presentan con mayor frecuencia con la clase de café sin sombra, como lo muestra la gráfica 2.



Gráfica 3. Clasificación de píxeles en la exactitud de usuario para el café semisombra

6.6.3 Clasificación monosensor café sin sombra



Gráfica 4. Clasificación de píxeles en la exactitud de usuario para el café sin sombra

Bajo el enfoque monosensor, la clase Café sin sombra fue la categoría que presentó mayor exactitud con más del 77% de píxeles bien clasificados. Por su condición, el café sin sombra presenta menos ambigüedad en su clasificación con respecto

presencia de árboles y una directa interacción de las microondas con el suelo adyacente y al interior de la plantación de café.

Los resultados erróneos de todas las clases de café están correlacionados por cuanto estas coberturas tienen características en común, por ejemplo, la cobertura boscosa está presente mayormente en la clase café de sombra y en menor medida con el café de semisombra, así mismo todas las clases objetivo de la investigación tienen presencia de plantas de café que interactúan con las microondas dependiendo de la densidad y la separación entre las especies forestales que conforman el sombrero.

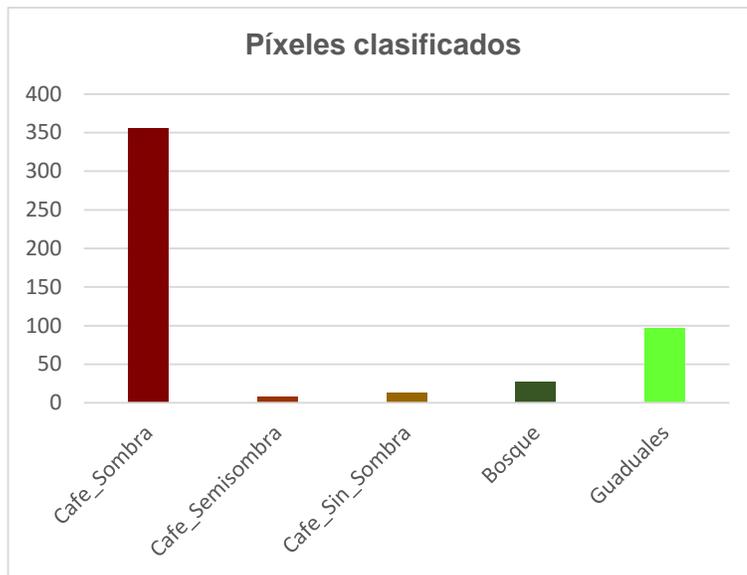
6.7 Análisis del enfoque multisensor

Con base a los resultados de la clasificación Random Forests sobre los datos de la escena del sensor Sentinel-1, el análisis del enfoque multisensor permitirá determinar la capacidad individual así como la capacidad complementaria de los datos SAR de banda C en combinación con datos ópticos para la identificación del cultivo de café. a

El comportamiento de la clasificación con enfoque multisensor mejoró significativamente manteniendo una tendencia igual al enfoque monosensor para cada una de las clases objetivo de la investigación. Esto quiere decir que la exactitud del usuario y del productor mejoró según el cultivo del café estuviera acompañado de menor cantidad de especies forestales por hectárea.

6.7.1 Clasificación multisensor café sombra

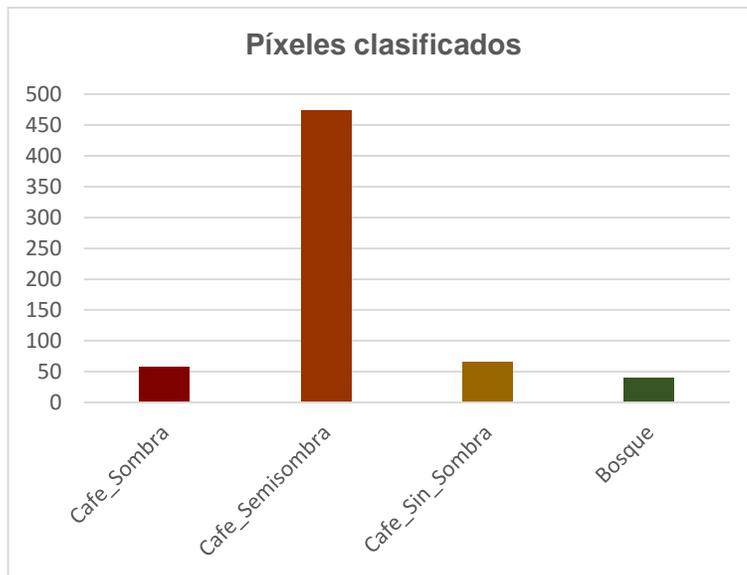
En la clasificación multisensor, la clase café sombra también obtuvo la más baja exactitud del usuario con respecto a las demás clases objetivo de la investigación con 70,92% de aciertos, es decir un incremento de 4,61 puntos porcentuales con respecto a la clasificación con enfoque monosensor. Así mismo, se mantiene una clasificación errónea con otras coberturas con características morfológicas y espectrales similares, para este caso particular, algunos píxeles de coberturas de guaduales fueron clasificados como café de sombra, tal como se aprecia en la Figura 4.



Gráfica 5. Clasificación de píxeles en la exactitud de usuario multisensor para el café sombra

6.7.2 Clasificación multisensor café semisombra

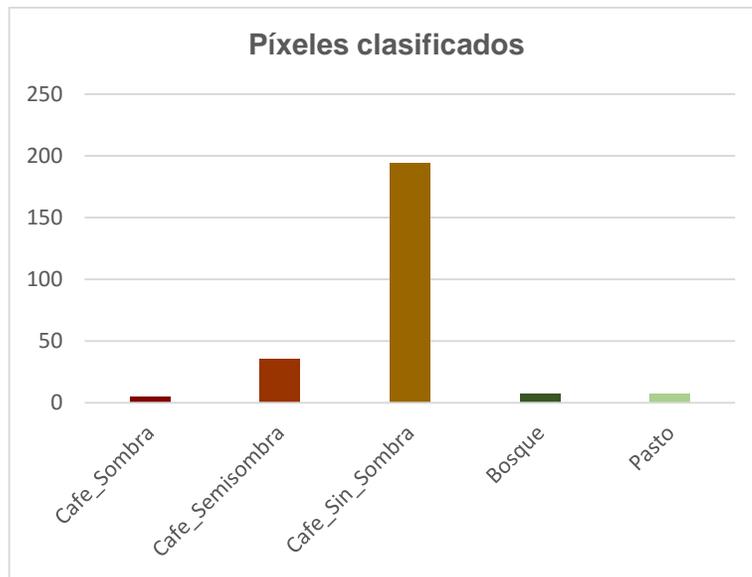
La segunda mejor exactitud del usuario para las clases objetivo de la investigación permaneció para la clase de café semisombra con 47,25%, significando un aumento de 5,25 puntos porcentuales por encima del resultado arrojado en la clasificación monosensor. La matriz de confusión de la tabla 5, muestra falsos positivos de clasificación con las demás coberturas de café y la de bosque.



Gráfica 6. Clasificación de píxeles en la exactitud de usuario multisensor para el café semisombra

6.7.3 Clasificación multisensor café sin sombra

La exactitud del usuario más alta para las 3 categorías de café en la clasificación multisensor corresponde a la clase café sin sombra. La agregación de los datos ópticos permitió llegar a una exactitud de 77,91%, aumentando con respecto a la clasificación monosensor en 2,22 puntos porcentuales. Para esta clase hay una marcada relación de falsos positivos con la cobertura de café semisombra.



Gráfica 7. Clasificación de píxeles en la exactitud de usuario multisensor para el café sin sombra

7 CONCLUSIONES

La capacidad de las imágenes del sensor Sentinel-1 no es adecuada para la identificación del cultivo de café. Teniendo en cuenta la evaluación de la exactitud de la clasificación del algoritmo Random Forests bajo el enfoque monosensor, se evidenció que las imágenes de SAR alcanzaron porcentajes de exactitud del usuario y del productor entre el 65,93% y el 75,69% lo que indica que las imágenes del sensor Sentinel-1 por si solas no alcanzan el porcentaje mínimo de exactitud planteado por Foody, (2002) quien sugiere que la precisión debe ser mayor o igual al 85% para ser considerada como satisfactoria.

A partir de la comparación de las exactitudes arrojadas por la clasificación Random Forests para los 2 enfoques de datos planteados, se concluye que los mejores resultados fueron aportados por el enfoque multisensor, para el cual, el aumento de la exactitud más austero fue de 0,86 puntos porcentuales en la exactitud del productor para la clase de café de sombra. Por otro lado el aumento de la exactitud más amplio corresponde a 5,25 puntos porcentuales para la clase de café sin sombra.

Las similitudes espectrales y morfológicas entre las clases objetivo con otras como el bosque y guaduales, no permitieron alcanzar una exactitud mínima para considerar exitosa la clasificación del café según la densidad de sombrero presente en el cultivo.

Bajo el enfoque monosensor, las clases Bosque, Pastos, Vías y Suelo Desnudo lograron superar el 85% mínimo de exactitud y se considera satisfactoria su clasificación.

Bajo el enfoque multisensor, las únicas clases que no superaron el porcentaje mínimo de exactitud fueron café de sombra, café semisombra y café sin sombra. Sin embargo las clases de Bosque (86,06%), Pasto (92,5%), Superficies de agua (94,55%), Construcciones (96,39%), Suelo desnudo (98,94%) y Guaduales (85,92%) se consideran clasificaciones exitosas.

8 RECOMENDACIONES

Bajo cualquiera de los enfoques planteados en el presente trabajo, se recomienda la incorporación de datos SAR de sensores tales como Cosmo Skymed y TerraSAR que poseen mayor longitud de onda para contar con la capacidad de penetración del dosel arbóreo y obtener información de los objetos más cercanos al suelo y eventuales modelos de tomografía SAR.

En el marco de los datos ópticos, se recomienda el uso de imágenes con mayor resolución espacial (<5m) de sensores como QuickBird, RapidEye, Spot 5, 6 y 7 que permitan el reconocimiento de objetos más pequeños en la escena. Así mismo conservar en el análisis las propiedades de los datos del sensor Sentinel-1 a través de la aplicación del algoritmo Pan-sharpening con datos de resolución espacial mayor a 5m.

La recolección en campo o la consulta de librerías de firmas espectrales para las especies vegetales que conforman las distintas tipologías de sombra (especies arbóreas y frutales) para la segmentación óptima de los píxeles de mediana resolución a través de un análisis de desmezclas lineales y determinar el porcentaje de área cubierta por café o por otras especies arbóreas.

9 BIBLIOGRAFÍA

- Abdikan, S., Sanli, F. B., Ustuner, M., & Calò, F. (2016). Land Cover Mapping Using Sentinel-1 Sar Data. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLI-B7(July), 757–761. <http://doi.org/10.5194/isprsarchives-XLI-B7-757-2016>
- Akar, Ö., & Güngör, O. (2012). Classification of multispectral images using Random Forest algorithm. *Journal of Geodesy and Geoinformation*, 1(2), 105–112. <http://doi.org/10.9733/jgg.241212.1>
- Anaya, J. A., & Valencia, G. M. (2013). Fenología de Ambientes Tropicales en el Marco de la Teledetección, 2008–2010.
- Argenti, F., Alparone, L., & Benelli, G. (1990). Fast algorithms for texture analysis using co-occurrence matrices. *IEE Proceedings F - Radar and Signal Processing*, 137(6), 443–448. <http://doi.org/10.1049/ip-f-2.1990.0064>
- Atzberger, C. (2013). Advances in Remote Sensing of Agriculture: Context Description, Existing Operational Monitoring Systems and Major Information Needs, 949–981. <http://doi.org/10.3390/rs5020949>
- Badhwar, G. D. (1984). Classification of Corn and Soybeans. *Remote Sensing of Environment*, 16, 172–182.
- Ban, Y., Treitz, P. M., Howarth, P. J., Brisco, B., & Brown, R. J. (1995). Improving the Accuracy of Synthetic Aperture Radar Analysis for Agricultural Crop Classification. *Canadian Journal of Remote Sensing*, 21(2), 158–164. <http://doi.org/10.1080/07038992.1995.10874609>
- Beaulieu, N., Hill, P., Leclerc, G., & Escobar, G. (1999). Cartografía de la cobertura de la tierra en el municipio de Puerto López, Colombia, utilizando imágenes de RADARSAT-1 y de JERS-1. Proyecto Colombia-8 GlobeSAR-2. *Simposio Final GlobeSAR 2 "Aplicaciones de RADARSAT En América Latina,"* (May), 1–7.
- Bolanos, S. (2007). *Using Image Analysis and GIS for coffee Mapping*. McGill University.
- Breiman, L. (2001). Randomforest2001, 1–33. <http://doi.org/10.1017/CBO9781107415324.004>
- Carreiras, J. M. B., Jones, J., Lucas, R. M., & Shimabukuro, Y. E. (2017). Mapping major land cover types and retrieving the age of secondary forests in the Brazilian Amazon by combining single-date optical and radar remote sensing data. *Remote Sensing of Environment*, 194, 16–32. <http://doi.org/10.1016/j.rse.2017.03.016>

- Chuvienco, E. (1995). *FUNDAMENTOS DE TELEDETECCIÓN ESPACIAL*. (Ediciones RIALP S.A, Ed.) (Segunda ed). Madrid: Ediciones RIALP, S.A.
- Cordero-Sancho, S., & Sader, S. a. (2007). Spectral analysis and classification accuracy of coffee crops using Landsat and a topographic-environmental model. *International Journal of Remote Sensing*, 28(7), 1577–1593. <http://doi.org/10.1080/01431160600887680>
- Cuadras, C. M. (2014). Nuevos Métodos De Análisis Multivariante.
- DANE. (2016). *CENSO NACIONAL AGROPECUARIO Décimo segunda entrega resultados 2014*.
- Daughtry, C., Walthall, C., Kim, M., Brown de Colstoun, E., & McMurtrey, J. (2000). Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance. *Remote Sensing of Environment*, 74(2), 229–239. [http://doi.org/10.1016/S0034-4257\(00\)00113-9](http://doi.org/10.1016/S0034-4257(00)00113-9)
- Du, P., Samat, A., Waske, B., Liu, S., & Li, Z. (2015). Random Forest and Rotation Forest for fully polarized SAR image classification using polarimetric and spatial features. *ISPRS Journal of Photogrammetry and Remote Sensing*, 105, 38–53. <http://doi.org/10.1016/j.isprsjprs.2015.03.002>
- Earthnet. (2011). Polarimetric Decompositions. *Earthnet Polarimetry Tutorial*, 1–28file:///home/onfi/Documents/Biblio%20Cotriguac.
- ESA online. (2007). Spatial - Resolutions - Sentinel-2 MSI - User Guides - Sentinel Online. Retrieved April 22, 2017, from <https://sentinel.esa.int/web/sentinel/user-guides/sentinel-2-msi/resolutions/radiometric>
- European Space Agency. (2013). Sentinel-1 User Handbook. *European Space Agency*, 1, 1–80. <http://doi.org/10.1017/CBO9781107415324.004>
- FNC. (2007). *Sistemas de producción del café en Colombia (I)*. Chinchiná, Caldas.
- Forkuor, G., Conrad, C., Thiel, M., Landmann, T., & Barry, B. (2015). Evaluating the sequential masking classification approach for improving crop discrimination in the Sudanian Savanna of West Africa. *Computers and Electronics in Agriculture*, 118, 380–389. <http://doi.org/10.1016/j.compag.2015.09.020>
- George, D. (1989). *Principal Components Analysis*. Retrieved from [https://books.google.com.co/books?hl=es&lr=&id=Pzwt-CMMt4UC&oi=fnd&pg=PA5&dq=principal+components+analysis&ots=ifewtCgNg5&sig=w9nIYXQJ4FKWD0i5gcJ-Is_jnW0#v=onepage&q=principal components analysis&f=false](https://books.google.com.co/books?hl=es&lr=&id=Pzwt-CMMt4UC&oi=fnd&pg=PA5&dq=principal+components+analysis&ots=ifewtCgNg5&sig=w9nIYXQJ4FKWD0i5gcJ-Is_jnW0#v=onepage&q=principal%20components%20analysis&f=false)
- Guhl, A. (2004). Café y cambio de paisaje en la zona cafetera colombiana entre 1970 y 1997. *Cenicafé*, 55(1), 29–44. Retrieved from <http://biblioteca.cenicafe.org/handle/10778/102>

- Haack, B., & Bechdol, M. (2000). Integrating multisensor data and RADAR texture measures for land cover mapping. *Computers and Geosciences*, 26(4), 411–421. [http://doi.org/10.1016/S0098-3004\(99\)00121-1](http://doi.org/10.1016/S0098-3004(99)00121-1)
- Hongsheng Zhang; Hui Lin; Yuanzhi Zhang; Qihao Weng. (2016). *Remote Sensing of Impervious Surfaces in Tropical and Subtropical Areas*. Boca Raton, Florida.
- Langford, M., & Bell, W. (1997). Land cover mapping in a tropical hillsides environment: A case study in the Cauca region of Colombia. *International Journal of Remote Sensing*, 18(6), 1289–1306. <http://doi.org/10.1080/014311697218421>
- Lavalle, M. (2008). Introduction to Radar Polarimetry. *Geoinformation Ph.D. Programme at European Space Agency*.
- Lelong, C. C. D., & Thong-Chane, a. (2003). Application of textural analysis on very high resolution panchromatic images to map coffee orchards in Uganda. *IGARSS 2003. 2003 IEEE International Geoscience and Remote Sensing Symposium. Proceedings (IEEE Cat. No.03CH37477)*, 2(C), 1007–1009. <http://doi.org/10.1109/IGARSS.2003.1293994>
- León, C. (2015). *Evaluación de técnicas digitales para identificar cultivos de café a partir de imágenes multiespectrales*. Universidad Distrital Francisco José de Caldas, Bogotá.
- Lira, J. (2010). *Tratamiento Digital de Imágenes* (Segunda ed, Vol. 1). Retrieved from http://books.google.es/books?id=TQT6DF3_YgkC
- López-martínez, C., & June, I. C. C. (2008). SAR Polarimetry and Polarimetric SAR Interferometry, (June).
- MacGiavry. (1998). Textural pattern recognition: distinguishing between occupation densities in the centre of Dar Es Salaam, Tanzania., 1–20.
- Mcnairn, H., Champagne, C., Shang, J., Holmstrom, D., & Reichert, G. (2009). ISPRS Journal of Photogrammetry and Remote Sensing Integration of optical and Synthetic Aperture Radar (SAR) imagery for delivering operational annual crop inventories. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(5), 434–449. <http://doi.org/10.1016/j.isprsjprs.2008.07.006>
- Melo & Camacho, M. (2005). *Interpretación visual de imágenes de sensores remotos y su aplicación en el levantamiento de cobertura y uso de la tierra*. (Instituto Geográfico Agustín Codazzi, Ed.) (I). Bogotá.
- Moran, M. S., Inoue, Y., & Barnes, E. M. (1997). Opportunities and limitations for image-based remote sensing in precision crop management. *Remote Sensing of Environment*. [http://doi.org/10.1016/S0034-4257\(97\)00045-X](http://doi.org/10.1016/S0034-4257(97)00045-X)
- Moran, S., Alonso, L., Moreno, J., Cendrero, P., De la Cruz, F., & Montoro, A. (2012). A RADARSAT-2 quad-polarized time series for monitoring crop and soil conditions in Barrax, Spain. *IEEE Transactions on Geoscience and Remote Sensing*, 50(4), 1057–

1070. <http://doi.org/10.1109/TGRS.2011.2166080>

- Moreira, M. A., Adami, M., & Rurdorff, B. F. T. (2004). Spectral and temporal behavior analysis of coffee crop in Landsat images Abstract. *Pesquisa Agropecuária Brasileira*, 39(3), 223–231.
- Moreira, M., Barros, M., & Rudorff, B. (2008). Geotecnologias No Mapeamento Da Cultura Do Café Em Escala Municipal. *Sociedade & Natureza*, 20(1), 101–110. <http://doi.org/10.1590/S1982-45132008000100007>
- Mukashema, A., Veldkamp, A., & Vrieling, A. (2014). Automated high resolution mapping of coffee in Rwanda using an expert Bayesian network. *International Journal of Applied Earth Observation and Geoinformation*, 33(1), 331–340. <http://doi.org/10.1016/j.jag.2014.05.005>
- Muñoz, E. A. (2013). A Dissertation on Crops Discrimination Researches using SAR Data.
- Murillo, P., & Carbonell, J. (2012). *Principios y aplicaciones de la percepción remota en el cultivo de la caña de azúcar en Colombia*.
- Peña, D. (2002). Análisis de datos multivariantes. *Book*, 515. <http://doi.org/8448136101>
- Peréz, C., & Muñoz, Á. L. (2006). *Teledetección: nociones y aplicaciones*. *Journal of Chemical Information and Modeling* (Vol. 53). <http://doi.org/10.1017/CBO9781107415324.004>
- Peters, J., Coillie, F. Van, Westra, T., & Wulf, R. De. (2011). Synergy of very high resolution optical and radar data for object-based olive grove mapping, 25(6), 971–989. <http://doi.org/10.1080/13658816.2010.515946>
- Presutti, M. (2004). La matriz de co-ocurrencia en la clasificación multispectral: tutorial para la enseñanza de medidas texturales en cursos de grado universitario. *4ª Jornada de Educação Em Sensoriamento Remoto No Âmbito Do Mercosul*, 9.
- Quiñones, J. A. (2011). Clasificación automática de los estados de desarrollo del arroz a partir de imágenes de RADARSAT-2, 126. Retrieved from <http://www.bdigital.unal.edu.co/8005/>
- Rodarmel, C., & Shan, J. (2002). Principal component analysis for hyperspectral image classification. *Surveying and Land Information Science*, 62(2), 115. <http://doi.org/10.1109/IGARSS.2001.976068>
- Saatchi, S., Agosti, D., Alger, K., Delabie, J. H. C., & Musinsky, J. (2001). Examining Fragmentation and Loss of Primary Forest in the Southern Bahian Atlantic Forest of Brazil with Radar Imagery. *Conservation Biology*, 15(4), 867–875.
- Silva, W. F., Rudorff, B. F. T., Formaggio, A. R., Paradella, W. R., & Mura, J. C. (2009). ISPRS Journal of Photogrammetry and Remote Sensing Discrimination of agricultural crops in a tropical semi-arid region of Brazil based on L-band polarimetric airborne SAR

- data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(5), 458–463. <http://doi.org/10.1016/j.isprsjprs.2008.07.005>
- Smith, L. I. (2002). A tutorial on Principal Components Analysis Introduction. *Statistics*, 51, 52. <http://doi.org/10.1080/03610928808829796>
- Smith, R. (2004). Percepcion Remota del Ambiente (PRA).
- Tempfli, K., Kerle, N., Huuneman, G. C., & Jansen, L. L. F. (2001). Principles of Remote Remote Sensing - An introductory text book, 591.
- Topouzelis, K., & Psyllos, A. (2012). Oil spill feature selection and classification using decision tree forest on SAR image data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 68, 135–143. <http://doi.org/10.1016/J.ISPRSJPRS.2012.01.005>
- Trabaquini, K., Miglioranza, É., França, V. De, & Pereira Neto, O. C. (2010). Uso da Geotecnologia para caracterizar os cafezais no municipio de Londrina-PR, em relação à altimetria, declividade e tipo de solo. *Eng. Agríc. Jaboticabal*, 30, 1136–1147. <http://doi.org/10.1590/S0100-69162010000600014>
- Van Niel, T. G., & McVicar, T. R. (2004). Determining temporal windows for crop discrimination with remote sensing: A case study in south-eastern Australia. *Computers and Electronics in Agriculture*, 45(1–3), 91–108. <http://doi.org/10.1016/j.compag.2004.06.003>
- Vega, G. (2013). *Influencia de cobertura arbórea en relación a la oferta de servicios ecosistémicos bajo sistemas agroforestales de coffea arabica, establecidos en Pitalito, Huila*. Universidad de la Amazonia, Florencia - Caquetá.
- Vina, A., Gitelson, a a, Rundquist, D. C., Keydan, G., Leavitt, B., & Schepers, J. (2004). Remote sensing - Monitoring maize (Zea mays L.) phenology with remote sensing. *Agronomy Journal*, 96(4), 1139–1147. <http://doi.org/10.1016/j.jenvman.2011.10.007>
- Waske, B., & Braun, M. (2009). ISPRS Journal of Photogrammetry and Remote Sensing Classifier ensembles for land cover mapping using multitemporal SAR imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(5), 450–457. <http://doi.org/10.1016/j.isprsjprs.2009.01.003>
- Zwiggelaar, R. (1998). A review of spectral properties of plants and their potential use for crop / weed discrimination in row-crops. *Crop Protection*, 17(3), 189–206.