UNIVERSIDAD DISTRITAL
FRANCISCO JOSÉ DE CALDAS

IMPLEMENTACIÓN DE IMÁGENES HIPERESPECTRALES Y DE RADAR COMO HERRAMIENTA PARA LA IDENTIFICACIÓN MINERALÓGICA PARA GRANDES EXTENSIONES EN ESTUDIOS DE EXPLORACIÓN - ZONA DE ESTUDIO: REGIÓN DEL MAGDALENA MEDIO

Autor
Julio Armando Cuellar Gutiérrez

Tutor

PhD. D. Rubén Javier Medina Daza

Universidad Distrital Francisco José De Caldas
Maestría en Ciencias de la Información y las Comunicaciones
Énfasis en Geomática
Bogotá, Colombia
Junio 2021

Agradecimientos

Primeramente, a Dios por permitirme tener todas las cosas maravillosas que hoy tengo en mi vida, a mi Familia que ha sido mi motor para ser mejor cada día, mi mamá que jamás se cansó de aconsejarme ser el mejor en cualquier cosa que me propusiera en la vida, mi esposa que ha estado conmigo apoyándome y siendo mi consejera y mi gran amiga, mi bebe Juliana Antonella que llego a mi vida para darle alegría a mis días y a través de ella entender el amor de Dios en mi vida, muchas gracias por estar a mi lado y aceptar acompañarme ese 4 de julio en este camino.

A mis profesores y maestros que me ayudaron a crecer profesionalmente y como persona, al profesor Rubén Medina que acepto ayudarme a cumplir este sueño y con su experiencia moldeo una idea para transformarla en este gran proyecto.

“No sé lo que le podré parecer al mundo, pero a mí me parece como si hubiese sido un niño que juega en la orilla del mar y se divierte de tanto en tanto encontrando un guijarro más pulido o una concha más hermosa de lo común, mientras que el inmenso océano de la verdad se extiende inexplorado frente a mí”.

- Isaac Newton

CONTENIDO

CONTENIDO *3*

Lista de Tablas **5**

Lista de Ilustraciones **5**

Anexos **7**

1. RESUMEN ***8***

2. ABSTRACT ***9***

3. PALABRAS CLAVE ***9***

4. INTRODUCCIÓN ***10***

5. PROBLEMA DE INVESTIGACIÓN ***11***

5.1. Planteamiento del problema **11**

5.2. Formulación del problema **11**

6. OBJETIVOS ***12***

6.1. Objetivo general **12**

6.2. Objetivos específicos **12**

7. JUSTIFICACIÓN ***13***

8. ESTADO DEL ARTE ***14***

8.1. Búsqueda de nuevos depósitos mineros con imágenes Hiperespectrales, NASA Misión ASTER **14**

8.1.1. Una Historia de Innovación e integración 15

8.1.2. Entrada de las imágenes Hiperespectrales 16

8.2. Identificación de anomalías inducidas por filtraciones de petróleo mediante datos registrados por satélite (Landsat-7/ETM+), Cuenca de Sangliao, China **19**

8.3. Aplicaciones de la Interferometría SAR para la medida de Deformaciones del Terreno ... **21**

8.4. Detección de la influencia de fugas de gas en vegetación mediante Teledetección Hiperespectral **22**

9. Marco Teórico ***25***

9.1. Teledetección 25

9.2. Imágenes Hiperespectrales 25

9.3. Curvas de reflectancia de materiales 28

9.4. Tratamiento de imágenes Hiperespectrales **29**

9.5. Imágenes de Radar 30

9.6. Constante dieléctrica 32

9.6.1. OIF Factor de índice óptimo 33
9.7. Clasificación de Imágenes 33
9.8. Análisis de estadísticas de entrenamiento 36
9.9. SuperPixel 37
9.10. NDVI 38
9.11. Elementos para la clasificación de Minerales 39
9.12. Clasificación por divergencia de información espectral 40
9.13. Máquina de Vectores de Soporte SVM 42
9.14. Kernels 44
9.15. Clasificación basada en algoritmo de codificación Binaria para imágenes Hiperespectrales 45
9.16. Matriz de Confusión 48
9.17. Segmentación y Clasificación de Texturas 48
9.17.1. Segmentación basada en el uso de un umbral 50
9.18. Tratamiento de imágenes de Radar 51
9.19. Radar de Apertura Real (RAR) 51
9.20. Radar de Apertura Sintética SAR 53
9.21. Ruido de Speckle 54
9.22. Interferometría Diferencial (DinSAR) 57
9.23. ISO 19157 La gestión de la calidad de la Información Geográfica 60
10. METODOLOGÍA Y RESULTADOS 61
10.1. Adquisición de imágenes 62
10.1.1. OIF Factor de índice óptimo 65
10.1.2. NDVI 66
10.1.3. Implementación de clasificación de imágenes basados en Maquinas de Soporte Vectorial 67
10.1.4. Algoritmo de Codificación Binaria 70
10.1.5. Divergencia de Información Espectral 71
10.1.6. Procesamiento de imágenes de radar 73
11. ANÁLISIS DE RESULTADOS 76
12. CONCLUSIONES 77
12.1. Trabajo Futuros 78
13. BIBLIOGRAFÍA 79
14. ANEXOS 83

Lista de Tablas

Tabla 1.Características espectrales de agrupaciones minerales inducidas por filtraciones de petróleo en bandas registradas por el sensor ETM+ 19
Tabla 2. Características espectrales de agrupaciones minerales inducidas por filtraciones de petróleo en bandas registradas por el sensor ETM+ 20
Tabla 3. Parámetros de sistemas Hiperespectrales. 27
Tabla 4. Misiones Satelitales de Radar 32
Tabla 5. Mejor combinación Basados en modelo OIF 65
Tabla 6. Criterios de Zonificación de la cobertura vegetal mediante los valores de NDVI 66
Tabla 7. Análisis de Matriz de confusión para la clasificación de máquinas de soporte vectorial 68
Tabla 8. Análisis de Matriz de confusión para la clasificación de máquinas de soporte vectorial, Precisión del productor (medida del error de omisión, error de comisión) 68
Tabla 9. Análisis de Matriz de confusión para la clasificación de máquinas de soporte vectorial RGB 69
Tabla 10. Análisis de Matriz de confusión para la clasificación por Algoritmo de Codificación Binaria 71
Tabla 11. Análisis de Matriz de confusión para la clasificación de divergencia espectral basado en Algoritmo de Codificación Binaria, Precisión del productor (medida del error de omisión, error de comisión) 71
Tabla 12. Análisis de Matriz de confusión para la clasificación de divergencia espectral basado en perfiles espectrales 72
Tabla 13. Análisis de Matriz de confusión para la clasificación de divergencia espectral basado en perfiles espectrales, Precisión del productor (medida del error de omisión, error de comisión) 72

Lista de Ilustraciones

Ilustración 1. Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER) 14
Ilustración 2. Un esfuerzo de mapeo de minerales de alta tecnología en 2014 en Afganistán por el Servicio Geológico de EE. UU. Es el primero de su tipo. Inicialmente genera $ 146 millones en ingresos anuales, y el ministro de minas y petróleo de Afganistán espera reportar $ 1 mil millones en ingresos 16
Ilustración 3. Recopilación de imágenes Hiperespectrales entre 1999 y 2014 del Valle de Lamar en el Parque Nacional de Yellowstone. Al realizar una serie de clasificaciones en estas imágenes y después de alinear cuidadosamente cada imagen. 17
Ilustración 4. Hiperespectral Remote Sensing Data and a Multi-proxy Investigation for Characterizing Mineral Resources in Alaska 18
Ilustración 5. Velocidad de deformación sobre la comarca del Vallés, Barcelona. La imagen resultante de velocidad de deformación, que cubre unos 20 por 9 km2, se sobrepone a la imagen de amplitud cubriendo la misma área. Observamos varias zonas de deformación. . 21
Ilustración 6. Resultado del estudio sobre un área industrial de Santa Perpetua de Mogoda. El campo velocidad de deformación es sobrepuesto a una ortofoto 1:5000, del Instituto Cartográfico de Cataluña 22
Ilustración 7 Región de interés. Ventura (U.S.A.). Distinción de macro filtración (SEEP), zona afectada por gas y zona no afectada. 24
Ilustración 8. Adquisición de una imagen Hiperespectral 26

Ilustración 9. Tipos de píxeles en imágenes Hiperespectrales. 27
Ilustración 10. Espectro electromagnético mostrando las regiones utilizadas en percepción remota. 28
Ilustración 11. Curvas de reflectancia espectral para diferentes materiales. 29
Ilustración 12. Bandas en la región radar del espectro electromagnético. 30
Ilustración 13. Penetración de la señal radar en función de la longitud de onda y la humedad del terreno 33
Ilustración 14. Cubo Hiperespectral 38
Ilustración 15. Perfiles espectrales base. 40
Ilustración 16. Margen de un hiperplano de separación: a) Hiperplano de separación no-óptimo y su margen asociado, b) Hiperplano de separación óptimo y su margen asociado máximo 42
Ilustración 17. Imagen máximo margen de hiperplanos 44
Ilustración 18. Diagrama de flujo esquemático ilustrativo del procesado interferométrico diferencial de imágenes SAR 51
Ilustración 19. Geometría de adquisición de un sistema RAR instalado en un satélite artificial. 52
Ilustración 20. a) Concepto de un radar de apertura sintética. b) Principio del SAR en la dirección de avance del satélite. c) Relación de la amplitud normalizada del patrón de la antena SAR, donde la función seno cardinal es una función analítica sinusoidal con amplitud que se amortigua con la distancia, es la Transformada de Fourier de una señal rectangular. 54
Ilustración 21. Aumento de la fase en la dirección del rango por desplazamiento del terreno asociado a un sismo 58
Ilustración 22. Contribuciones a la fase de un interferograma, donde los componentes corresponden con las geometrías de la imagen Máster y Slave, B corresponde con línea base a la perpendicular igual a cero, quedando solo la distribución por deformación del terreno y atmosférica 59
Ilustración 23. Modelo ISO 19157 60
Ilustración 24. En la gráfica se describe la metodología emplear basados en el cumplimiento de los objetivos planteados para la presente investigación 61
Ilustración 25. Área de estudio, región de Magdalena Medio, San Martin Cesar 62
Ilustración 26. Unidades Cronoestratigráficas de la zona. 63
Ilustración 27. Geología de la Plancha 85 y 86 SIMITI 64
Ilustración 28. Geología de la Plancha 85 y 86 SIMITI corte del suelo 64
Ilustración 29. Mejor combinación basado en modelo OIF RGB 91-350-353 SPECTIR 65
Ilustración 30. Índice de vegetación normalizado basado en imágenes Hiperespectrales 66
Ilustración 31. Clasificación según los valores de NDVI para coberturas vegetales 67
Ilustración 32. Clasificación basados en máquinas de soporte Vectorial 68
Ilustración 33, Clasificacion usando maquinas de soporte vectorial RGB 69
Ilustración 34. Análisis de Matriz de confusión para la clasificación de máquinas de soporte vectorial, Precisión del productor (medida del error de omisión, error de comisión) RGB 70
Ilustración 35. Clasificación basada en Algoritmo de Codificación Binaria 70
Ilustración 36. Clasificación Basada en Divergencia Espectral 72
Ilustración 37. Diagrama de Trabajo en el software SNAP para tratamiento de imágenes de Radar e interferometría 73
Ilustración 38. Cambio de Fase entre las imágenes de Radar basados en el interferograma usando SNAP 74
Ilustración 39. Análisis de Interferograma y corrección de Fase para Altura 74
Ilustración 40. Interferometría del lugar de estudio medida en centímetros por año 75
Ilustración 41. Mapa de desplazamientos basado en interferogramas 75

Ilustración 42. Desplazamiento Total basados en imágenes de Radar e interferogramas ... 76

Anexos

Anexo 1. Mapa Geológico base 83
Anexo 2. Imagen Hiperespectral Base 84
Anexo 3. Índice de Vegetación normalizado NDVI 85
Anexo 4. Máquinas de Soporte Vectorial 86
Anexo 5. Algoritmo de Codificación Binaria 87
Anexo 6. Divergencia Espectral 88
Anexo 7. Interferometría de Fase 89
Anexo 8. Inspección Final de la Zona de estudio 90

1. RESUMEN

Esta investigación presenta el análisis e identificación de materiales mineralógicos expuestos que conforman los mantos superficiales a partir de imágenes Hiperespectrales de diferentes sensores y utilizando clasificación supervisada, máquinas de soporte vectorial y análisis de divergencia espectral, generando una metodologías que sustenten y permita el desarrollo de la exploración mineralógica de grandes extensiones, que contribuya al mejoramiento de la caracterización y zonificación de yacimientos minerales, permitiendo el mapeo de materiales expuestos con alta precisión espacial, incluso en lugares remotos y de difícil acceso; determinando también la presencia de minerales indicadores para la inspección e identificación en la exploración de recursos naturales, determinando las integraciones lito-estratigráficas, asociaciones mineralógicas y la identificación del tipo de roca o sus componentes, según la relativa constancia en la composición del suelo, la roca base, la madurez de los suelos expuestos y los mapas geológicos, se verificaran los resultados basados en mapas geoquímicos de la zona de estudio buscando una precisión global y un coeficiente Kappa superior al 85%.

Las imágenes Hiperespectrales serán utilizadas para la detección de minerales superficiales expuestos, producto de la degradación de las rocas en áreas de suelos residuales. Este tipo de imágenes permite el mapeo de materiales minerales con alta precisión espacial, basándose en información espectral de los minerales; determinando también la presencia de minerales indicadores para la inspección e identificación de yacimientos, basándonos en mapas geológicos para determinar las correlaciones lito-estratigráficas, asociaciones mineralógicas para la identificación del tipo de roca, en base a la relativa constancia en la composición global del suelo y la roca base que se refleja a su vez en la composición mineral y la madurez de los suelos expuestos para obtener información del contexto ambiental y además el contexto geológico.

Adicionalmente las imágenes de radar permitirán el estudio de las fracturas, movimiento del terreno y estructuras que caractericen el comportamiento dinámico de la zona de estudio (interferometría Diferencial DINSAR), contribuyendo de esta manera al trabajo preliminar de exploración y delimitación de zonas de alto potencial mineralógico.

Una vez analizadas las propiedades del suelo y con base a la relación de estado de cobertura vegetal, estado de cuerpos de agua, la distribución de fallas y estructuras sobre el terreno y las diferentes asociaciones mineralógicas dadas a partir de las imágenes Hiperespectrales, se procederá al mapeo, sectorización y demarcación de las zonas de interés basadas en sus propiedades mineralógicas y a partir de los insumos preliminares en busca de los zonas de mayor o menor concentración mineralógica para la determinación de futuras zonas óptimas de exploración geofísica, geoquímica y la sísmica programática.

La región de estudio se localiza sobre la cuenca del valle medio del Magdalena. Esta zona es de gran interés para exploración de hidrocarburos debido a sus características petroquímicas, por lo cual se cuenta con varios estudios de prospección petrolífera realizados en este sitio que permitirán la correlación y validación de resultados del presente proyecto y cuál es la abundancia mineralógica característica de estas regiones.

2. ABSTRACT

This research presents the analysis and identification of exposed mineralogical materials that make up the surface mantles from Hyperspectral images of different sensors and using supervised classification, vector support machines and spectral divergence analysis, and binary algorithmic classification, generating a methodologies that support and allow the development of the mineralogical exploration of large areas, which contributes to the improvement of the characterization and zoning of mineral deposits, allowing the mapping of exposed materials with high spatial precision, even in remote and difficult-to-access places; also determining the presence of indicator minerals for inspection and identification in the exploration of natural resources, determining litho-stratigraphic integrations, mineralogical associations and the identification of the type of rock or its components, according to the relative constancy in the composition of the soil, the Base rock, the maturity of the exposed soils and the geological maps, the results based on geochemical maps of the study area will be verified looking for global precision and a Kappa coefficient higher than 85%.

Hyperspectral images will be used for the detection of exposed surface minerals, the product of the degradation of rocks in areas of residual soils. This type of images allows the mapping of mineral materials with high spatial precision, even in remote and difficult-to-access places; also determining the presence of indicator minerals for the inspection and identification of deposits, based on geological maps to determine litho-stratigraphic correlations, mineralogical associations for the identification of the type of rock, based on the relative constancy in the global composition of the soil and the base rock that is reflected in turn in the mineral composition and maturity of the exposed soils to obtain information on the environmental context and also the geological context.

Additionally, the radar images will allow the study of fractures, ground movement, and structures that characterize the dynamic behavior of the study area (interferometry), thus contributing to the preliminary work of exploration and delimitation of areas of high mineralogical potential.

Once the properties of the soil have been analyzed and based on the relationship of the state of vegetation cover, state of water bodies, the distribution of faults and structures on the ground, and the different mineralogical associations given from the Hyperspectral images, we will proceed to mapping, location, and demarcation of areas of interest based on their mineralogical properties and from preliminary inputs in search of areas of greater or lesser mineralogical concentration for the determination of future optimal zones for geophysical, geochemical and programmatic seismic exploration.

The study region is located on the basin of the middle Magdalena valley. This area is of great interest for hydrocarbon exploration due to its petrochemical characteristics, for which there are oil prospecting studies carried out at this site that will allow the correlation and validation of the results of this project and what is the characteristic mineralogical abundance of these regions.

3. PALABRAS CLAVE

Hiperespectrales, Prospección, Radar, Yacimientos, Mineralogía.

4. INTRODUCCIÓN

La Teledetección ofrece grandes posibilidades para la realización de progresos en el conocimiento de la naturaleza, estos procesos permiten obtener imágenes de la superficie terrestre de forma remota, es decir captada por sensores situados en satélites o aviones y posteriormente tratarlas e interpretarlas para la obtención de información, características y cambios que esta pueda presentar; la determinación de asociaciones y concentraciones mineralógicas hace posible determinar las áreas de estudio como visión general del subsuelo y de sus estructuras geológicas con miras a la ubicación de zonas de interés, consistiendo en emitir una señal en la superficie para provocar una onda que se propague a través de las capas del subsuelo, reflejándose en cada una de sus diferentes anchos de bandas y de este modo tener un panorama de los diferentes tipos de materiales y estructuras presentes. Los recursos naturales y materias primas son de gran valor formando parte de los principales indicadores económicos a nivel mundial debido a su demanda diaria, dicho contexto desafía a las distintas ramas de la ingeniería a su búsqueda, extracción y tratamiento según procesos óptimos en relación costo-adquisición.

La información que genera el sensor de captura se usará para la optimización de métodos de identificación directos e indirectos que permitan la localización de concentraciones y asociaciones minerales que ayuden a la interpretación del suelo descubierto y el análisis de composición del subsuelo partiendo de la verificación de mapas geológicos y la implementación de sensores tales como: imágenes Hiperespectrales de diferentes sensores para verificar e identificar los componentes mineralógicos expuestos, índice de vegetación, estado de cuerpos de agua, mapas temáticos, entre otros; e Imágenes de Radar para verificación y estudio de interferometría como movimientos multitemporales y caracterización de fallas en la zona de estudio -región del magdalena medio.

La detección remota de asociaciones mineralógicas en la zona de estudio dependerá del diseño, cálculo y evaluación de las variaciones de energía electromagnética reflejada o emitida por la superficie terrestre en la verificación de las imágenes para los diferentes tipos de materiales presentes en la zona para el estudio de caracterización del suelo y su concentración mineralógica aportando a la información geológica base de la región, además de la relevancia de fracturas, movimientos de la capa o anomalías que puedan ser detectadas por las imágenes de radar y la interferometría o movimiento constante del subsuelo en la zona detectado por radar. Se verifica la correlación entre la aplicación de sensores remotos como herramienta de generación de mapas de identificación mineralógica y la adición de sensores de radar como modelos de superficie para la mejor interpretación de la composición litológica del suelo, su textura, concentración y las estructuras generales del área de estudio.

Esta investigación sirve como herramienta para la exploración de recursos naturales superficiales para el mejoramiento de procesos de adquisición de información para áreas extensas y mejor análisis de las zonas de estudio previamente el trabajo de campo y exploraciones bases.

5. PROBLEMA DE INVESTIGACIÓN

Optimizar los procesos de exploración de recursos naturales en su fase inicial generando aportes a la geología base de la zona a partir de la identificación y localización mineralógica en grandes extensiones mediante la implementación de imágenes Hiperespectrales y de Radar, para la detección de materiales expuestos en suelo residual en la región del Magdalena medio.

5.1. Planteamiento del problema

Se genero un aporte a los análisis del suelo y sus componentes mineralógicos basados en imágenes Hiperespectrales, ayudando a delimitar el dominio espacial, espectral, propiedades físicas, zonas limítrofes, propiedades morfológicas, concentraciones, asociaciones mineralógicas y estructuración de yacimientos para generar mapas base de identificación mineralógica, esta investigación se realiza con medios puntuales basándose en las imágenes y el comportamiento de los diferentes materiales expuestos en sus diferentes bandas, esto ayuda al equipo de exploración a limitar las zonas de mayor potencial para verificación de propiedades litográficas y mineralógicas del suelo, además de los recursos y concentración de zonas ya comprobadas de alto potencial en su fase inicial.

Se limito el área de búsqueda de yacimientos mediante métodos indirectos y el uso de sensores remotos que cuenten con una amplia resolución espectral y suficiente información para la obtención de caracterización espectrales de materiales propios de los yacimientos de hidrocarburos y materiales mineralógicos con potencial de explotación. La firma espectral media teórica de algunos materiales con presencia de hidrocarburos o metales propios del suelo, presentan extremos relativos en bandas específicas del espectro electromagnético que pasarían inadvertidas por sensores básicos, pero que, basados en imágenes Hiperespectrales con una amplia riqueza espectral, podremos limitar grandes zonas de estudio ya que las exploraciones convencionales no delimitan áreas de interés bojo concentraciones mineralógicas sino que se basan en estructuras, esta investigación ayudara a determinar mejor las áreas de exploración y mejorar los mapas geológicos base de la zonas de estudio mediante la interpretación de asociaciones lito-estratigráficas en suelos descubiertos y minerales indicadores.

5.2. Formulación del problema

Partiendo de análisis de imágenes hiperespectrales, análisis de curvas de reflectancia Hiperespectral, interferometría basados en imágenes de radar, clasificación de componentes principales del suelo, índice de vegetación normalizado y estructuración geomorfológica ¿es posible generar una metodología para la adquisición de mapas de propiedades mineralógicas y litográficas en suelo descubierto para determinar la concentración de minerales con alta precisión espacial como ayuda en el estudio inicial de la exploración?

6. OBJETIVOS

6.1. Objetivo general

Implementar el uso de imágenes Hiperespectrales e imágenes de Radar como herramienta para el análisis de identificación, asociación, concentración y caracterización mineralógica para grandes extensiones en fase de exploración para la determinación de minerales indicadores.

6.2. Objetivos específicos

1. Caracterizar los diferentes tipos de materiales presentes en la zona de estudio, basados en la información espectral, para la obtención de mapas de composición de suelos e índices de vegetación normalizados mediante imágenes Hiperespectrales.

2. Generar mapas de identificación y concentración mineralógica como aporte a la geología local, mediante el análisis de componentes principales, interpretación de asociaciones, análisis de cuerpos de agua, interferometría de placas y fracturas.

3. Evaluar los resultados obtenidos mediante el mejoramiento de mapas geológicos de la zona, perfiles espectrales de los diferentes materiales expuestos como rocas indicadoras, análisis de deformaciones y desplazamientos basados en interferometrías de la zona de estudio.

4. Validar el aporte a la geología local mediante el análisis de correlación y análisis geoestadístico de los resultados y los datos geoquímicos y petroquímicos de la zona, esto para la generación de mapas geológicos base para la identificación mineralógica de minerales indicadores.

7. JUSTIFICACIÓN

La exploración mineralógica designa la búsqueda de depósitos minerales o combustibles fósiles y está enfocada en un reconocimiento detallado del depósito, estudios y obras necesarios para establecer y determinar la existencia, ubicación del mineral o minerales, la geometría del depósito dentro del área concesionada, en cantidad y calidad económicamente explotables, la viabilidad técnica de extraerlos y el impacto que sobre el medio ambiente y el entorno social puedan causar.

En esta fase se busca establecer y calcular técnicamente las reservas del mineral o minerales, la ubicación y características de los depósitos o yacimientos, la elaboración del plan minero, los medios y métodos de explotación, la escala y duración factible de la producción esperada.

El principal objetivo de la exploración es la localización de anomalías geológicas con propiedades de un depósito de minerales dependiendo el tipo de formación, tipo de concentración, tipo de suelo presente y fallas presentes en la zona de estudio, además de la necesidad de reducción del área de investigación empezando por extensiones de 2500 – 250.000 Km^2 en una primera fase de exploración y posteriormente basados en prospecciones, geoquímica y sísmica poder determinar las concentraciones y el tipo de material presente para lograr al final de la fase de exploración tener un áreas de cubrimiento no mayor a 0.25 a 50 Km^2, para posteriormente iniciar la prospección.

Las imágenes hiperespectrales se basa en la captura de características propias de la superficie basándose en niveles digitales, en el sentido de que sus pixeles no están formados por un único valor discreto, sino por un conjunto amplio de valores correspondientes a las diferentes mediciones espectrales realizadas por un sensor o instrumento de medida en diferentes longitudes de onda o información espectral. Estas imágenes se caracterizan porque pueden ser analizadas desde dos puntos de vista diferentes: el espacial y el espectral. Así, los datos Hiperespectrales pueden ser entendidos al mismo tiempo como un conjunto de medidas espectrales y como una fuente confiable de caracterización de elementos presentes en los diferentes niveles digitales.

Esta investigación abordara una metodología que ayude a mejorar la geología base en su fase inicial de exploración donde tendrá no solo la posibilidad de mejorar la precisión bajo un análisis espacial, sino que basados en los niveles digitales determinar la presencia de diferentes tipos de materiales indicadores que ayuden a la determinación de zonas con mayor potencial de prospección como base para la identificación mineralógica, y así mejorar la caracterización y dinámica de las formaciones como base para el mejoramiento de los mapas geológicos basándonos en sensores remotos para grandes áreas.

8. ESTADO DEL ARTE

Se mostrará la utilización de imágenes en proyectos realizados en calidad de identificación de materiales y mineralogía presenten la zona mediante teledetección usando imágenes de radar e Hiperespectrales. Donde se definirán algunas metodologías aplicadas por organizaciones internacionales en el estudio de la teledetección como herramienta para la definición de suelos y sus componentes, así como los planes de integración de las imágenes Hiperespectrales y de radar en el estudio de las ciencias de la tierra y la investigación.

8.1. Búsqueda de nuevos depósitos mineros con imágenes Hiperespectrales, NASA Misión ASTER

El siguiente articulo (Saral & Esra, 2016) muestra la implementación y desarrollo de los métodos de búsqueda basados en imágenes Hiperespectrales, la misión ASTER de la NASA abre la posibilidad a nuevas formas de clasificaciones e identificación de cualquier tipo de material sobre el manto superficial de la tierra, la misión ASTER fue lanzada en el año 2017 siendo la primera misión en utilizar imágenes Hiperespectrales como base para su estudio obteniendo grandes resultados como se muestra en la ilustración 1.

¿Cuánto oro queda por extraer en la Tierra? ¿Qué tal el elemento chontal menos conocido, necesario para pantallas de computadoras y teléfonos inteligentes? Con las fuentes conocidas de algunos metales esenciales que se enfrentan al agotamiento en las próximas décadas, existe una mayor presión para buscar alternativas a las tecnologías de exploración minera existentes. ¿Cómo podemos encontrar más fácilmente los depósitos necesarios a escala? ¿En la tierra? ¿Y en el espacio?

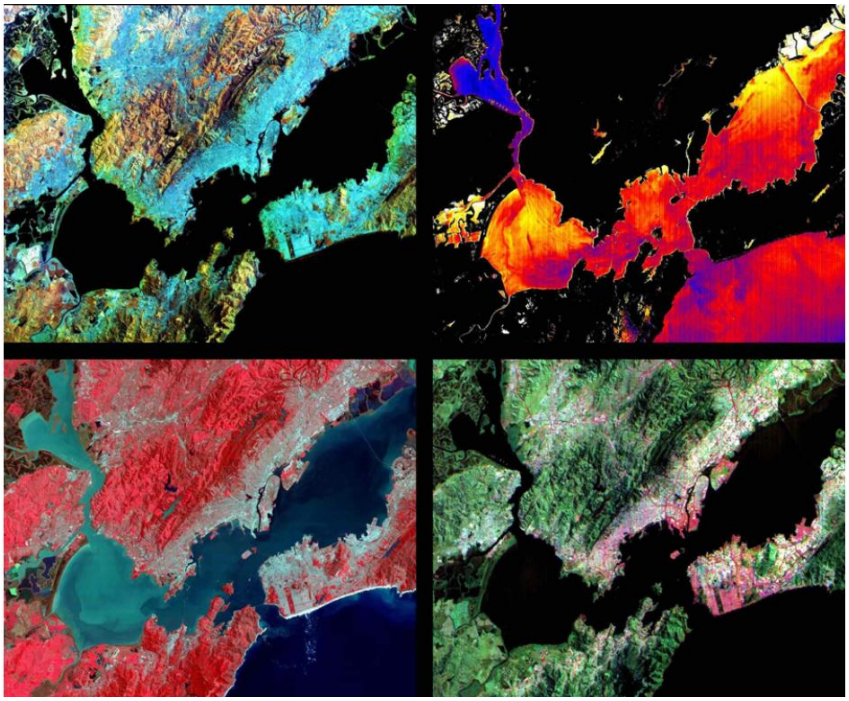


Ilustración 1. Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER)

Fuente: NASA / JPL

La economía es exigente. Las imágenes multiespectrales ya se usan en satélites, aviones no tripulados y sistemas basados en aviones en la búsqueda de nuevos depósitos minerales valiosos en la Tierra y del espacio.

El siguiente paso es la imagen Hiperespectral. El uso rutinario de los sistemas Hiperespectrales existentes por parte de la industria de los minerales se ha visto obstaculizado por la falta de disponibilidad de sistemas para uso industrial, el alto costo de los datos Hiperespectrales (cuando están disponibles) en comparación con los datos multiespectrales típicos y la necesidad de investigación adicional sobre el procesamiento de datos Hiperespectrales.

Después de algunos años difíciles en términos de crecimiento e inversión entre 2010 y 2015, con la caída de los precios y la baja inversión, 2017 está comenzando a verse mejor, y las empresas pueden estar buscando invertir en nuevas tecnologías para encontrar y extraer mejor los recursos del mundo (McCullum, Torres-Pérez, & Bengtsson, 2021).

8.1.1. Una Historia de Innovación e integración

Las imágenes remotas se han utilizado en la exploración durante mucho tiempo. En su nivel más básico, los geólogos y buscadores simplemente apuntarían sus cámaras fuera de los aviones (primero globos, luego aviones, ahora drones) para tomar imágenes del suelo a continuación, recopilando información sobre la topografía y el suelo que podría revelar pistas sobre sobre su composición además de la ubicación de minerales de explotación y de relevancia en actividades de desarrollo de cada país. Con la ayuda de algunas matemáticas complicadas, se podrían derivar mapas detallados de estas fotografías. Hoy en día, la teledetección se ha convertido en uno de los métodos más importantes para adquirir información rápida y directamente sobre la superficie de la Tierra (Ekrem S. E., 2012).

Pero la fotografía de espectro visible solo tenía limitaciones: el clima, la luz del día y el simple hecho de que gran parte de lo que estaban buscando estaba oculto bajo tierra. Mucho tuvo que inferirse. No fue sino hasta la Segunda Guerra Mundial que las nuevas modalidades de detección entraron en juego cuando las tecnologías desarrolladas durante la guerra se aplicaron a aplicaciones comerciales que se convertirían en características distintivas de la exploración minera moderna basada en la aviación. Las cámaras infrarrojas podrían penetrar mejor las condiciones climáticas adversas que la fotografía convencional e identificar más fácilmente el contenido mineral del suelo. Los magnetómetros podían detectar las perturbaciones en el campo magnético de la Tierra para detectar depósitos de mineral metálico en las profundidades subterráneas. Los gravímetros funcionan midiendo la atracción de la gravedad de la Tierra, que varía ligeramente según la posición de varios depósitos minerales subterráneos. La espectrometría de rayos gamma en el aire se desarrolló durante la década de 1960, cuando la profundización de la Guerra Fría aseguró que había una gran demanda de minerales radiactivos como el uranio. El radar tiene muchas de las mismas ventajas que la película infrarroja, pero puede ver a través de una vegetación limitada, revelando las características geológicas debajo, de día o de noche, incluida la textura de la superficie y el contenido de humedad (Yehuda, 2010).

Mover los sistemas de imágenes de los aviones a los satélites también arrojó posibilidades completamente nuevas. El apoyo del gobierno fue fundamental para iniciar esta tecnología.

Las tecnologías actuales incluyen el mapeado temático Landsat y el mapeado multiespectral mapeado temático mejorado de los Estados Unidos y la tecnología de imágenes pancromáticas de alta resolución (SPOT) desarrollada por la Agencia Espacial Francesa además de la utilidad en la recolección de información indirecta como se muestra en la ilustración 2 que permite.

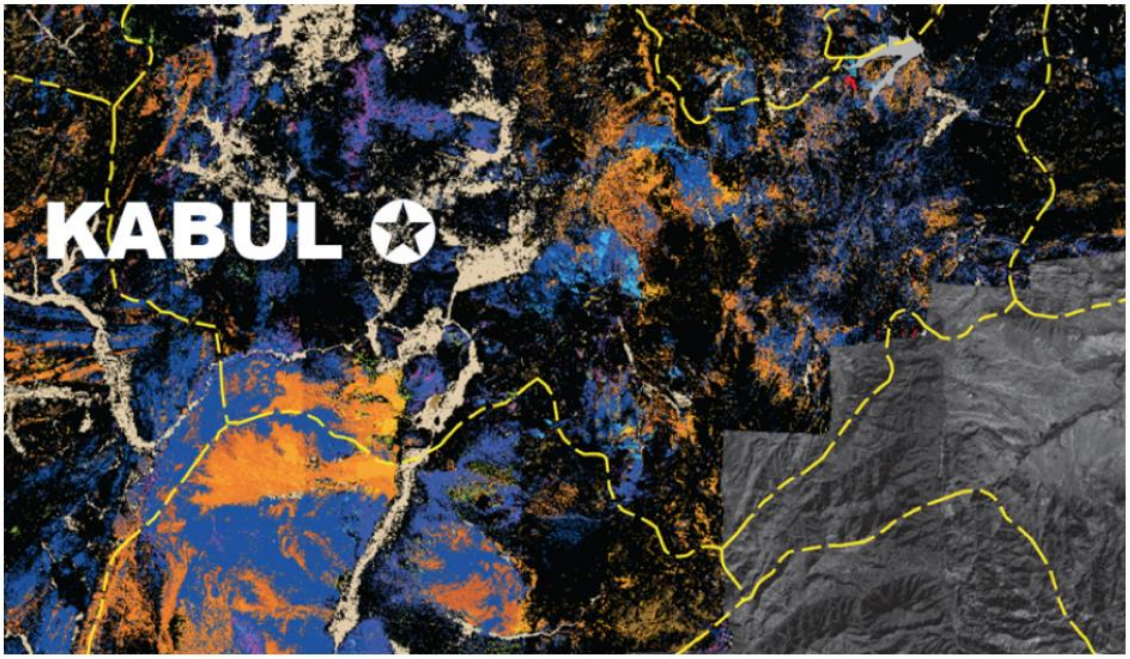


Ilustración 2. Un esfuerzo de mapeo de minerales de alta tecnología en 2014 en Afganistán por el Servicio Geológico de EE. UU. Es el primero de su tipo. Inicialmente genera $ 146 millones en ingresos anuales, y el ministro de minas y petróleo de Afganistán espera reportar $ 1 mil millones en ingresos

Fuente: Departamento de Defensa de los Estados Unidos

8.1.2. Entrada de las imágenes Hiperespectrales

Si bien los datos de estos diferentes métodos fueron muy útiles, aún no proporcionaron los detalles de las imágenes. Las imágenes en el rango visual simplemente no ofrecían los detalles y la información que la industria minera necesitaba. Ingrese a la imagen Hiperespectral, cortesía de la NASA. La tecnología fue desarrollada por primera vez a fines de la década de 1970 por Jet Propulsión Laboratorio, lo que permitió a la NASA colocar equipos de imágenes Hiperespectrales en satélites enviados a Júpiter y Saturno. Mientras que algunas compañías privadas construyeron sus propias cámaras Hiperespectrales, realmente despegó cuando la NASA puso la tecnología a disposición de los investigadores y empresarios, incluso ofreciendo subsidios para probar la efectividad del mundo real de la tecnología, incluida una para los estudios de ecosistemas de Yellowstone (Podest, 2017).

Como la mayoría de las técnicas de detección remota, las imágenes Hiperespectrales hacen uso del hecho de que todos los objetos poseen una huella digital espectral única basada en las longitudes de onda de la luz visible e invisible que absorben y reflejan. Esto revela una gran cantidad de detalles que no están disponibles en el espectro visible, como la diferencia entre los verdes que representan las plantas naturales y los que no son naturales, como los plásticos y los metales. El plástico verde tiene diferentes propiedades reflectantes que la

vegetación natural más allá del espectro visible, incluso las ramas caídas o cortadas tienen una huella digital diferente a la vegetación en crecimiento.

El impacto comercial será enorme, particularmente en el campo de la exploración minera. Si bien el oro se produce en cantidades demasiado pequeñas para detectar con cualquier tecnología disponible, los minerales más comunes como la caolinita y el arsénico, que son productos de algunos de los mismos procesos geológicos, son claramente visibles en paisajes abiertos, como es el caso en gran parte del oeste americano o desierto australiano. Para la industria del diamante, las tuberías de kimberlita, las formaciones volcánicas que trajeron diamantes a la superficie son fáciles de identificar desde el aire con imágenes Hiperespectrales.

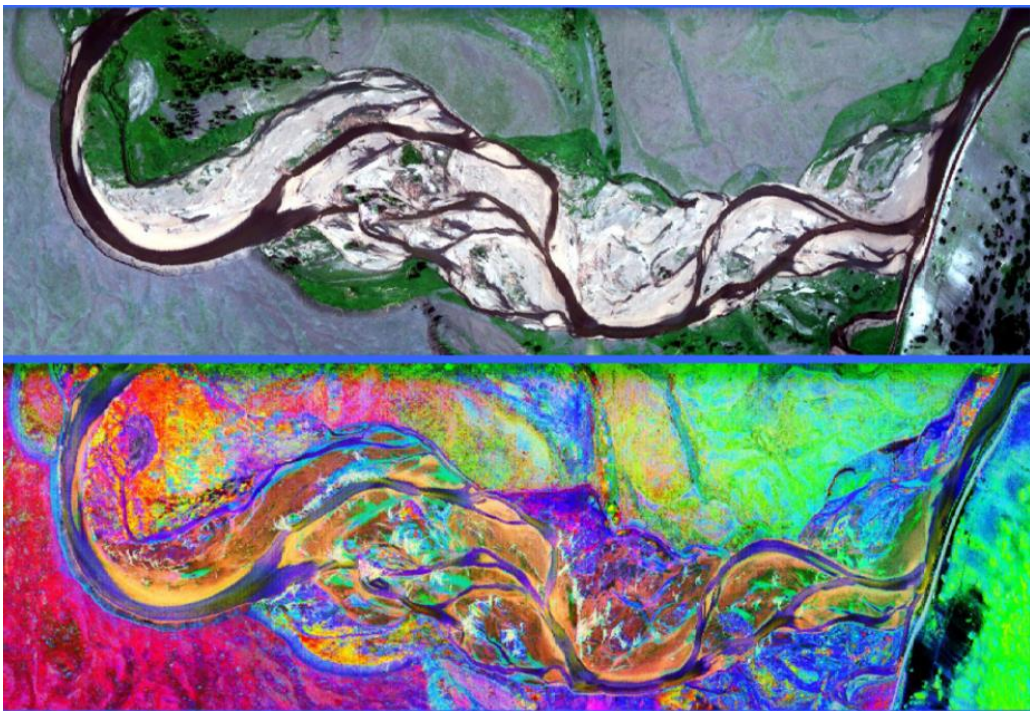


Ilustración 3. Recopilación de imágenes Hiperespectrales entre 1999 y 2014 del Valle de Lamar en el Parque Nacional de Yellowstone. Al realizar una serie de clasificaciones en estas imágenes y después de alinear cuidadosamente cada imagen.

Fuente: Centro de búsqueda ecológica (Ekrem S. E., 2012)

A diferencia del radar, la tecnología Hiperespectral no puede penetrar bajo tierra, ni a través de vegetación o edificios. Pero se puede combinar con el radar para hacerlo aún más potente.

Las integraciones adicionales producen vistas aún más precisas de la superficie de la tierra y sus secretos ilustración 3. LIDAR es un sistema aún más preciso para mapear la topografía, con todos los sistemas que integran datos GPS para eliminar la necesidad de realizar costosos estudios de terreno o correlación de imágenes (Saral & Esra, 2016).

Las demandas de datos son pesadas, lo que ejerce una gran presión sobre la potencia informática de cada organización. Por ejemplo, cuando la NASA usó imágenes Hiperespectrales para investigar el sitio Super búsqueda de 16 millas cuadradas en Leadville, Colorado, salvó años de trabajo en el terreno, con 45 segundos de imágenes satelitales. Aun

así, tardó otros 10 meses en descifrar los números. Solo con el desarrollo de computadoras más potentes se ha sacado este tipo de imagen del laboratorio. El rápido crecimiento de la potencia informática y la capacidad de almacenamiento en plataformas informáticas ampliamente disponibles ha permitido que los conjuntos de datos muy grandes, terabytes y exabytes de información de los instrumentos aerotransportados se manejen en el marco de tiempo requerido por las operaciones de exploración minera.

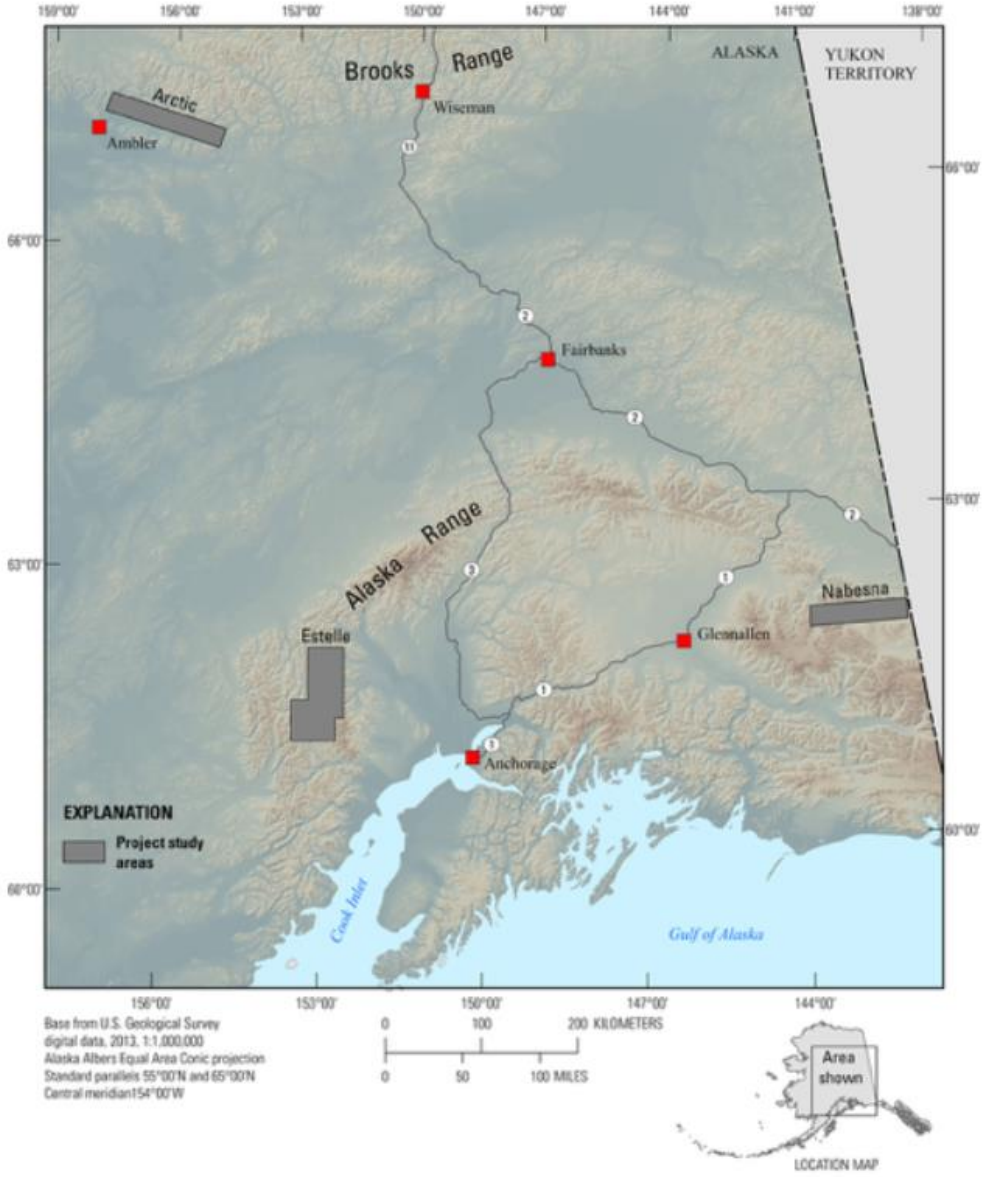


Ilustración 4. Hiperespectral Remote Sensing Data and a Multi-proxy Investigation for Characterizing Mineral Resources in Alaska

Fuente: Centro de búsqueda ecológica , (Ekrem S. E., 2012)

El objetivo del proyecto es definir la huella geológica de depósitos seleccionados mediante espectroscopía de imagen y extrapolar regionalmente este conocimiento a áreas no bien

caracterizadas (Ilustración 4). Se espera que la síntesis de los resultados de este proyecto multidisciplinario mejora nuestra comprensión de la geología regional y se utiliza para desarrollar un modelo de exploración predictivo para la identificación de depósitos de base y metales preciosos en Alaska y regiones remotas similares del mundo.

Hoy en día, las imágenes Hiperespectrales están bien definidas en términos de exploración mineral. Muchos minerales pueden identificarse a partir de imágenes aéreas y su relación con la presencia de minerales valiosos como el oro y los diamantes es bien entendida. Las imágenes Hiperespectrales se pueden usar para mapear grandes cantidades de tierra y reducir el área de búsqueda de valiosos depósitos de minerales. En algunos casos, las imágenes Hiperespectrales se pueden usar para identificar los minerales particulares de interés, pero también pueden ubicar minerales indicadores que sugieren una ubicación cercana a un valioso depósito de mineral (Bedeli, 2013).

8.2. Identificación de anomalías inducidas por filtraciones de petróleo mediante datos registrados por satélite (Landsat-7/ETM+), Cuenca de Sangliao, China

Este articulo (ZHANG, 2007) presenta la introducción a los procesos geológicos que dan lugar a la filtración de petróleo basados en el estudio de composición de bandas y la mejor absorción de información basados en bandas espectrales del sistema Landsat. Realiza también una descripción geológica de la zona y de los datos que se van a utilizar. Se define un tratamiento de la imagen capturada por el satélite Landsat-7: Se establece un tratamiento de tres metodologías: análisis de componentes principales (ACP), ratios entre diferentes bandas y composición falso color (CFC).

Para el análisis de componentes principales, se realiza una transformación lineal en N dimensiones, que para los procesos de teledetección el orden de dimensión (N) coincide con el número de bandas de la imagen, creando N nuevas componentes (o menos) no correlacionadas de acuerdo con el eje de variabilidad. En la siguiente tabla (ZHANG, 2007)se establece una relación entre material de la escena y su respuesta espectral.

Tabla 1.Características espectrales de agrupaciones minerales inducidas por filtraciones de petróleo en bandas registradas por el sensor ETM+

	Banda 1	Banda 3	Banda 4	Banda 5	Banda 7
Metales Ferrosos	Reflectado	Reflectado	Absorbente	Reflectado	Absorbente
Arcillas Rojas en deposito	Reflectado	Reflectado	Absorbente		
Limos y carbonatos				Reflectado	Absorbente

Fuente (ZHANG, 2007)

Se eligieron de forma aleatoria cuatro bandas ETM+ para realizar el análisis de componentes principales. Se eligieron aquellas componentes principales (CP) que mostraron un comportamiento espectral mejorado en relación con los perfiles espectrales de los elementos a clasificar.

Bandas elegidas 1,3,4 y 5 (ACP) / 3 (CP). Mejora relativa para los materiales de la escena con alto contenido en hierro férrico, así como para los estratos con alto contenido en óxido de hierro, los cuales aparentan haber sido parcialmente blanqueados visualmente. De acuerdo con su comportamiento espectral dichos materiales presentan alta reflectividad en bandas 1,3 y 5 así como absorción en la banda 4. En la tabla 2 (ZHANG, 2007) se describe la tercer (CP) del ACP en las bandas 1, 3, 4 y 5 del sensor ETM+ perteneciente a la imagen completa y a dos sub-imágenes.

Tabla 2. Características espectrales de agrupaciones minerales inducidas por filtraciones de petróleo en bandas registradas por el sensor ETM+

1,3,4,5-PCR3	Perdida De Área	ERROR	OMISSION
ETM-1	-0.356	0.236	0.458
ETM-3	0.126	-0.254	0.256
ETM-4	0.287	0.356	0.245
ETM-5	-0.256	0.452	0.289
VALORES	41.279	19.659	38.756
INFORMACIÓN	4.036%	3.309%	5.650%

Fuente (ZHANG, 2007)

En la tabla 2 los valores en las bandas 1, 3 y 5 (aquellas de signo negativo) y los valores en la banda 4 sugieren que los materiales de la escena con alto contenido en hierro férrico y óxido de hierro parcialmente blanqueado resaltarán como píxeles oscuros en este componente. El tercer componente principal (3CP) da un pequeño porcentaje respecto de la varianza (la cual se encuentra en un rango de 3.309 a 5.650). Siguiendo la metodología aplicada anteriormente se puede observar como para las bandas 1,3,5 y 7-3(CP) y 2,3,5 y 7-3(CP) resaltarían los píxeles que provienen de registrar materiales arcillosos y minerales carbonatados. En este caso los materiales que aparecerían más oscuros serían los que tienen mayor contenido en arcilla y minerales carbonatados. Posterior a este análisis se calcula el 4 CP para las bandas 3, 4, 5 y 7. En este caso el valor para la banda 5 (de signo negativo) es bastante alto, así como el de la banda 7 (en signo positivo) lo que sugiere que los materiales con contenidos en arcillas y los minerales carbonatados, van a aparecer significativamente oscuros. Estudiando las bandas 3 y 4 se aprecia como los píxeles con alto contenido en hierro férrico y óxidos de hierro también aparecerían oscuros en la imagen. Como conclusión todos los materiales que sugieren una anomalía por inducción de hidrocarburos quedarían resaltados según píxeles oscurecidos tomando la combinación 3, 4, 5 y 7 de la cuarta componente principal (Barisione, Solarna, Giorgi, Moser, & Serpico, 2016).

Se aprecia combinaciones establecidas para mejorar la calidad de la imagen (en cuanto a localizar materiales alterados por inducción de hidrocarburos). Cuando se representaron dichos cómputos mediante falso color aparecieron halos alrededor de los materiales que presentan mayor índice de anomalía por inducción de hidrocarburos.

8.3. Aplicaciones de la Interferometría SAR para la medida de Deformaciones del Terreno

Este artículo muestra la aplicación de interferometría SAR del valle de Barcelona, enfocado a la exposición de los resultados obtenidos en el Instituto de Geomática en los últimos años usando la técnica de interferometría diferencial SAR (DinSAR). La técnica DinSAR representa una potente herramienta para la monitorización de deformaciones basada en datos radar de teledetección. Es una técnica relativamente nueva, que puede ser usada en un amplio rango de aplicaciones: subsidencias en zonas urbanas, estudios de la explotación de recursos acuíferos, actividades mineras, construcciones bajo tierra, movimientos de hielo, terremotos, volcanes, deslizamientos de tierra, etc. Se describe la capacidad de la técnica DinSAR, mostrando algunos ejemplos obtenidos con la cadena DinSAR desarrollada en el Instituto de Geomática en los últimos tres años (Biescas, 2002).

La interferometría SAR (Synthetic Aperture Radar), InSAR, es una técnica de teledetección usada para aplicaciones como la generación de modelos numéricos del terreno (MNTs) y la monitorización de deformaciones de superficie. La técnica DinSAR (InSAR diferencial) explota la fase del SAR que es sensible a la topografía del terreno y a los cambios de elevación ocurridos entre dos pasadas del satélite sobre la misma área. Si la topografía del terreno es conocida, es decir se dispone de un MDT (Belmonte, 2009), la correspondiente componente de fase puede ser sustraída de la fase InSAR, dejando la componente relacionada con la deformación del terreno: esto hace posible la detección de sutiles deformaciones de la superficie terrestre. La técnica DinSAR, basada en datos SAR desde satélite, ha sido usada con éxito en diferentes aplicaciones, para una revisión general dinámica de glaciares, terremotos, volcanes, deslizamientos y deformaciones debidas a explotación de acuíferos, actividades mineras y trabajos de construcción (Biescas, 2002)

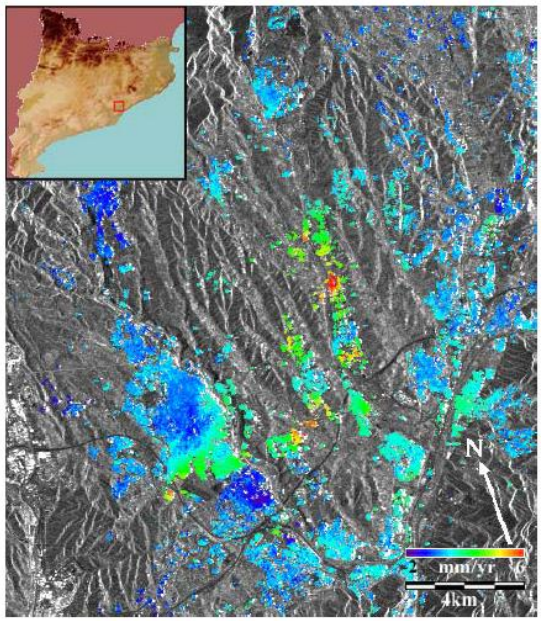


Ilustración 5. Velocidad de deformación sobre la comarca del Vallés, Barcelona. La imagen resultante de velocidad de deformación, que cubre unos 20 por 9 km2, se sobrepone a la imagen de amplitud cubriendo la misma área. Observamos varias zonas de deformación.

Fuente: (Biescas, 2002)

Sobre los resultados mostrados en la Ilustración 5 hay que destacar una amplia zona de subsidencia situada en la parte central de la imagen. En general la zona presenta estabilidad, aunque se destacan áreas de deformaciones próximas a los 2 mm/año y puntualmente algunas que llegan a los 6 mm/año. Además, puede verse el estudio de la misma área, pero hecho con un conjunto de imágenes ascendentes y cubriendo el intervalo comprendido entre junio de 1995 y agosto de 2000. La comparación entre los resultados obtenidos en estos dos estudios independientes nos ayuda para confirmar la validez de los fenómenos observados en la ilustración 6 (Biescas, 2002) como se muestra en la Ilustración 6.

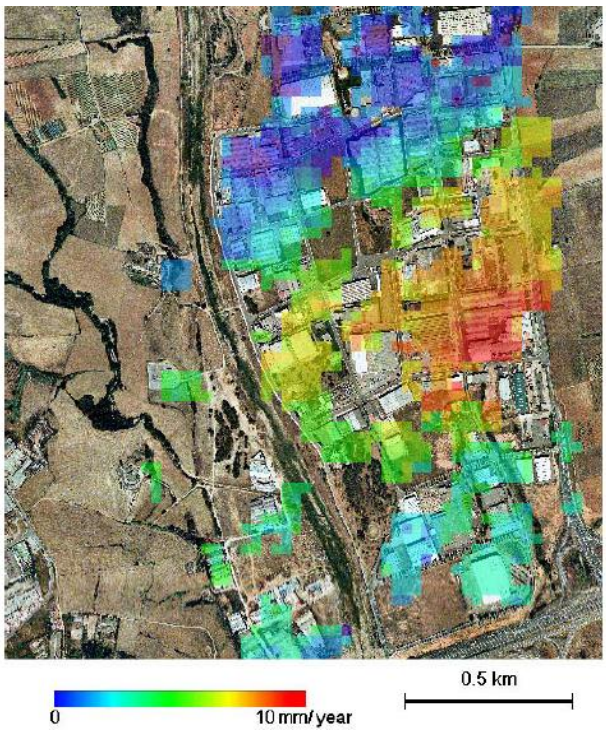


Ilustración 6. Resultado del estudio sobre un área industrial de Santa Perpetua de Mogoda. El campo velocidad de deformación es sobrepuesto a una ortofoto 1:5000, del Instituto Cartográfico de Cataluña

Fuente: (Biescas, 2002)

8.4. Detección de la influencia de fugas de gas en vegetación mediante Teledetección Hiperespectral

El siguiente articulo (Yang, 1999) muestra la búsqueda de hidrocarburos mediante implementación de sensores Hiperespectrales en búsqueda de filtraciones de Gas, Petróleo basados en alteraciones de componente de vegetación NDVI de una zona expuesta a GAS, midiendo los niveles de variación del suelo y sus componentes como base para el estudio de exploración (Yang, 1999).

Se asume que cualquier reserva de gas o presencia de algún tipo especial de hidrocarburo induce alteraciones en su entorno inmediato. Hasta ahora sólo se han estudiado las anomalías producidas sobre rocas y suelos. Se revisa las anomalías que se producen en vegetación y cuerpos de agua estudiando las mismas a través de sensores Hiperespectrales.

No obstante, sugiere características que se dan en las firmas espectrales de la vegetación que se podrían registrar en algunos sensores multiespectrales.

Las anomalías botánicas se pueden dar a causa de los siguientes factores (Noomen, 2010) tales como:

a) *Las filtraciones de hidrocarburos incluyen todos los estados en los que se encuentre el mismo. Los gases que se filtran hasta la superficie desplazan parcialmente el aire que contiene el suelo (donde se incluye el oxígeno que contiene el aire presente en el suelo). En este sentido el suelo contiene una menor cantidad de oxígeno. Además, parte del oxígeno, que aún permanece en el suelo, es usado por bacterias las cuales usan el oxígeno para reducir el metano a dióxido de carbono y agua. Un medio pobre en oxígeno provoca estrés en plantas. Dicho estrés se manifiesta en la correspondiente firma espectral de la planta.*

b) *Un ambiente anaerobio cambia el potencial de las reacciones oxidación-reducción además del pH del suelo. Directamente alrededor de la fuga de gas el medio es reducido. A causa de esta reducción la mineralogía del suelo cambia. La solubilidad de macro y micronutrientes cambia, lo que puede provocar una deficiencia o exceso de nutrientes para las plantas.*

c) *El crecimiento de las plantas cerca de una fuga de hidrocarburos se manifiesta en su firma espectral. Puede que el gas natural no sea nocivo para las plantas, pero las distintas transformaciones químicas que se producen durante su fuga, por ejemplo, la obtención de dióxido de carbono durante una de las fases de migración a superficie resulta tóxico en determinados umbrales. Esto puede causar un envejecimiento de la vegetación o incluso su muerte.*

La reflectividad registrada para vegetación alterada a menudo muestra una mayor reflectividad en la región del visible, una menor reflectividad en el infrarrojo cercano y un cambio en el límite del rojo hacia menores longitudes de onda. Para el caso de vegetación alterada por fugas de gas se identificaron dichos patrones. En algunas investigaciones la reflectividad en el visible e infrarrojo cercano era mayor, mientras que en otra era menor. Se demostró además que el límite rojo cambia hacia longitudes de onda menor (Yang, Hoog, Fan, & Hu, 2016), pero también se puede demostrar la situación contraria.
Finalmente se establece que la anomalía depende de:

1. *Tipo de planta (lo que incluye*
2. *tipo de fotosíntesis que realiza, relación clorofila/agua que se den en sus hojas, además de otras características)*
3. *Tipo de gas, así como cantidad (se realizaron experimentos con metano, etano y dióxido de carbono, este último en pequeñas cantidades puede servir como fertilizante);*
4. *Tipo de suelo basados en qué tipo de materiales afectan la permeabilidad y la determinación de foto somas presentes en las plantas.*

En la Ilustración 7 se puede ver una cubierta vegetal en la que se distinguen zonas de macro filtración, zonas de influencia y zonas sin influencia de hidrocarburos.

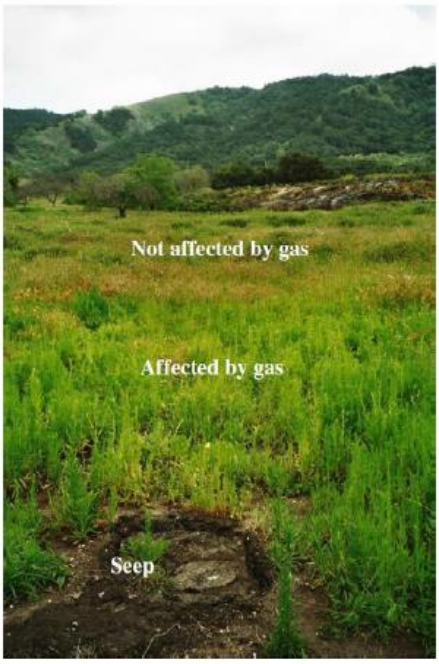


Ilustración 7 Región de interés. Ventura (U.S.A.). Distinción de macro filtración (SEEP), zona afectada por gas y zona no afectada.

Fuente: (Noomen, 2010)

Basados en la Ilustración 7 la reflectividad registrada para vegetación alterada a menudo muestra una mayor reflectividad en la región del visible, una menor reflectividad en el infrarrojo cercano y un cambio en el límite del rojo hacia menores longitudes de onda. Para el caso de vegetación alterada por fugas de gas se identificaron dichos patrones. En algunas investigaciones la reflectividad en el visible e infrarrojo cercano era mayor, mientras que en otra era menor. Se demostró además que el límite rojo cambia hacia longitudes de onda menor (Yang, Hogo, Fan, & Ha, 2016), pero también se puede demostrar la situación contraria.

Finalmente se establece que la anomalía depende de (Yang, 1999):

1. Tipo de planta (lo que incluye tipo de fotosíntesis que realiza, relación clorofila/agua que se den en sus hojas, además de otras características)
2. Tipo de gas, así como cantidad (se realizaron experimentos con metano, etano y dióxido de carbono, este último en pequeñas cantidades puede servir como fertilizante);
3. Tipo de suelo basados en qué tipo de materiales afectan la permeabilidad y la determinación de foto somas presentes en las plantas.

En la Ilustración 7 se puede ver una cubierta vegetal en la que se distinguen zonas de macro filtración, zonas de influencia y zonas sin influencia de hidrocarburos.

9. Marco Teórico

El marco Teórico que fundamenta esta investigación proporcionara al lector una idea clara acerca de los temas que se desarrollaran dentro de la metodología, además de encontrar conceptos básicos, complementarios y específicos de la siguiente investigación.

9.1. Teledetección

La teledetección es el conjunto de técnicas utilizadas para la determinación a distancia de las propiedades de los objetos ya sean estos naturales o artificiales. Expresándolo de otra manera la teledetección consiste en adquirir información acerca de la superficie de la Tierra sin la necesidad de estar en contacto con ella (Huang, 2006). La idea es detectar y registrar la energía reflejada por la superficie terrestre para luego procesarla, analizarla y utilizarla en alguna aplicación específica.

En un proceso de la teledetección podemos identificar siete elementos principales: La fuente de energía o iluminación; la radiación y atmosfera; interacción con la superficie de interés; registro de la energía mediante el sensor; proceso de transmisión; recepción y procesamiento; interpretación, análisis y la aplicación (Tirabala, 2011).

Es necesario indicar que también existen sistemas de teledetección basados en sensores no ópticos, estos sistemas son los sistemas de teledetección radar. Para un sistema óptico de teledetección, el Sol es la fuente de energía. Esta energía del Sol puede ser reflejada o absorbida. Un instrumento de teledetección recibe la radiación electromagnética y lo convierte en señales eléctricas y valores numéricos que también son llamados valores radiométricos. Estos valores son almacenados en matrices compuestos por pixeles.

Un píxel es un componente elemental de una imagen digital definida por su posición (fila y columna) y su valor. Existe una matriz para cada banda espectral (Davis, 2012).

9.2. Imágenes Hiperespectrales

Dependiendo de la literatura existe distinta clasificación para los sensores. Hay quien considera la siguiente clasificación: monoespectrales (o pancromático), multiespectrales e Hiperespectrales. Por otro lado, también se encontró la siguiente clasificación (en función del número de bandas): pancromático (=1), multiespectral (>1), super espectral (>10), e Hiperespectral (>100). Para este Trabajo Fin de Grado se considera como sensor Hiperespectral aquel que realiza un registro en más de 10 bandas, una imagen Hiperespectrales es una imagen que tiene varias bandas espectrales de información a través de todo el espectro electromagnético (Villamizar, 2015).

Los sensores Hiperespectrales adquieren imágenes digitales en una gran cantidad de canales espectrales muy cercanos entre sí, obteniendo, para cada porción de la escena o píxel, una firma espectral o “huella dactilar” característica de cada material (Ayerdi & Romay, 2016).

El resultado de la toma de datos por parte de un sensor Hiperespectral sobre una determinada escena puede ser representado en forma de cubo de datos, con dos dimensiones para representar la ubicación espacial de un píxel (generalmente denominadas líneas y muestras),

y una tercera dimensión que representa la singularidad espectral de cada píxel en diferentes longitudes de onda (Kratt, Coolbougth, & Pepping, 2012). La ilustración 8 muestra la estructura de una imagen Hiperespectral donde el eje X es el indicador de las líneas, el eje Y es el indicador de las muestras y el eje Z es el número de banda, es decir, la longitud de onda de esa banda (canal). La capacidad de observación de los sensores Hiperespectrales permite la obtención de una firma espectral detallada para cada píxel de la imagen, dada por los valores de reflectancia adquiridos por el sensor en diferentes longitudes de onda, lo cual permite una caracterización muy precisa de la superficie de nuestro planeta (Calvo, 2011).

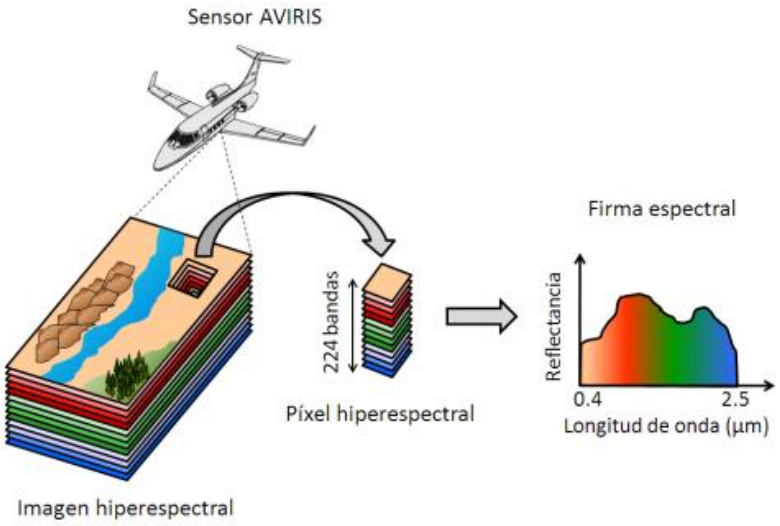


Ilustración 8. Adquisición de una imagen Hiperespectral
Fuente: (Calvo, 2011)

Como puede apreciarse en la ilustración 8, es el elevado número de bandas de este sensor lo que permite la obtención de una firma espectral detallada del píxel. Conviene destacar que, en este tipo de imágenes, es habitual la existencia de mezclas a nivel de subpíxel, por lo que a grandes rasgos podemos encontrar dos tipos de píxeles en estas imágenes: píxeles puros y píxeles mezcla (SpecTIR, 2008). Se puede definir un píxel mezcla como aquel en el que cohabitan diferentes materiales. Estos tipos de píxeles son los que constituyen la mayor parte de la imagen Hiperespectral, en parte, debido a que este fenómeno es independiente de la escala considerada ya que tiene lugar incluso a niveles microscópicos. La ilustración 9 muestra un ejemplo del proceso de adquisición de píxeles puros (a nivel macroscópico) y píxeles mezcla en imágenes Hiperespectrales (Calvo, 2011)

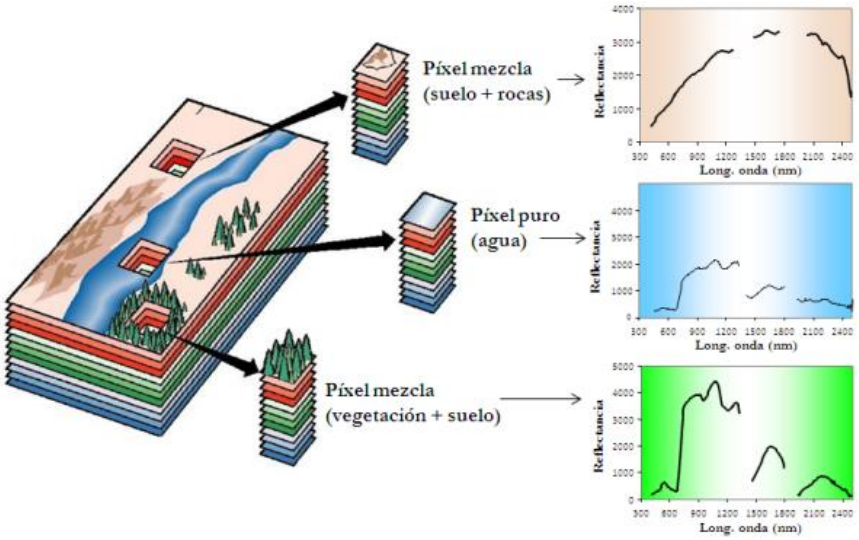


Ilustración 9. Tipos de píxeles en imágenes Hiperespectrales.
Fuente: (Calvo, 2011)

Algunos de los sensores aerotransportados más populares en la actualidad son el HyMap, fabricado por Integrated Spectronics Pty Ltd, y el CASI. Por otra parte, desde el año 2000 se han utilizado sensores Hiperespectrales en plataformas espaciales, siendo el Hyperion el primero en ser lanzado al espacio en el satélite Earth Observing-1 (EO-1) de la NASA. En la Tabla 3 se muestran parámetros espaciales y espectrales de nueve sensores Hiperespectrales: tres aerotransportados (HYDICE, AVIRIS y CASI 1500) y seis a bordo de sistemas espaciales (HYPERION, EnMAP, PRISMA, CHRIS, HyspIRI, IASI) (Davis, 2012).

Tabla 3. Parámetros de sistemas Hiperespectrales.

Parámetros	HYDICE	AVIRIS	CASI1500	HYPERION	EnMAP	PRISMA	CHRIS	HyspIRI	IASI
Altitud (km)	1,6	20	3	705	653	614	556	626	817
Resolución espacial (m)	0,75	20	0,5-2	30	30	5-30	36	60	V: 1-2 km H: 25 km
Resolución espectral (nm)	7-14	10	<3,5	10	6,5-10	10	1,3-12	4-12	0,5 cm^{-1}
Rango espectral (µm)	0,4-2,5	0,4-2,5	0,38-1,0	0,4-2,5	0,4-2,5	0,4-2,5	0,4-1,0	0,38-2,5 7,5-12	3,62-15,5 (645-2760 cm^{-1})
Número de bandas	210	224	288	220	228	238	63	217	8461

Fuente: (Bioucas-Dias, 2013)

9.3. Curvas de reflectancia de materiales

El ojo humano puede ver una combinación de colores que son el resultado de la mezcla de diferentes longitudes de onda reflejadas por los objetos o materiales, donde la radiación solar ha incidido. Las longitudes de onda que el humano es capaz de ver corresponden al espectro visible (0.4 µm a 0.7 µm). Sin embargo, los materiales pueden reflejar longitudes de onda que el humano no puede percibir (infrarrojo o infrarrojo termal), pero pueden ser capturadas por sensores. Esta luz o longitud de onda que es reflejada por un objeto puede ser analizada a través de su curva de reflectancia espectral. De ahí que cada material presenta su propia curva de reflectancia espectral (i.e., pasto, concreto, asfalto, etc.). Estas curvas están definidas por la variación de porcentaje de reflectancia. Por ejemplo, un objeto verde reflejará más en la porción de verde del espectro, pero muy bajo en rojo y azul. Por lo tanto, las gráficas de curvas (firmas o trazas) de reflectancia espectral nos ayudan a entender mejor la naturaleza y composición de la reflectancia de un objeto (Rickeer, 1997)

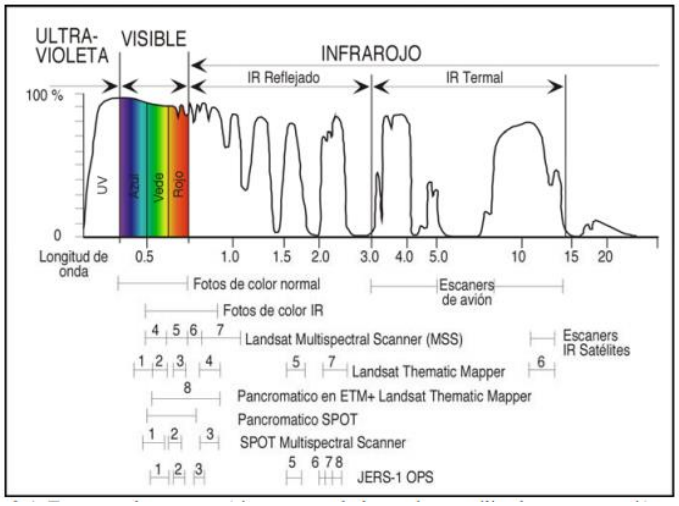


Ilustración 10. Espectro electromagnético mostrando las regiones utilizadas en percepción remota.
Fuente: (Rickeer, 1997)

En espectroscopia de luz reflejada la propiedad fundamental que queremos obtener es la reflectancia espectral: el porcentaje de la energía reflejada sobre la energía incidente como una función de la longitud de onda. La reflectancia varía con la longitud de onda para la mayoría de los materiales ya que la energía en ciertas longitudes de onda es dispersada o absorbida en diferentes grados. Estas variaciones de reflectancia son evidentes cuando comparamos las curvas de reflectancia espectral (gráficos de reflectancia frente longitud de onda) para diferentes materiales, como en la Ilustración 10 (Donovan, 2002). Las desviaciones pronunciadas hacia abajo de las curvas espectrales marcan los rangos de longitud de onda en los cuales los materiales selectivamente absorben la energía incidente. Estas características son comúnmente llamadas bandas de absorción. La forma general de una curva espectral y la posición e intensidad de las bandas de absorción en muchos casos pueden ser utilizadas para identificar y discriminar materiales diferentes. Por ejemplo, la vegetación tiene reflectancias más altas en el rango del infrarrojo cercano y más baja reflectancia en la luz roja que los suelos (Bashevoy, Jonsson, Abajo, & Santos, 2007).

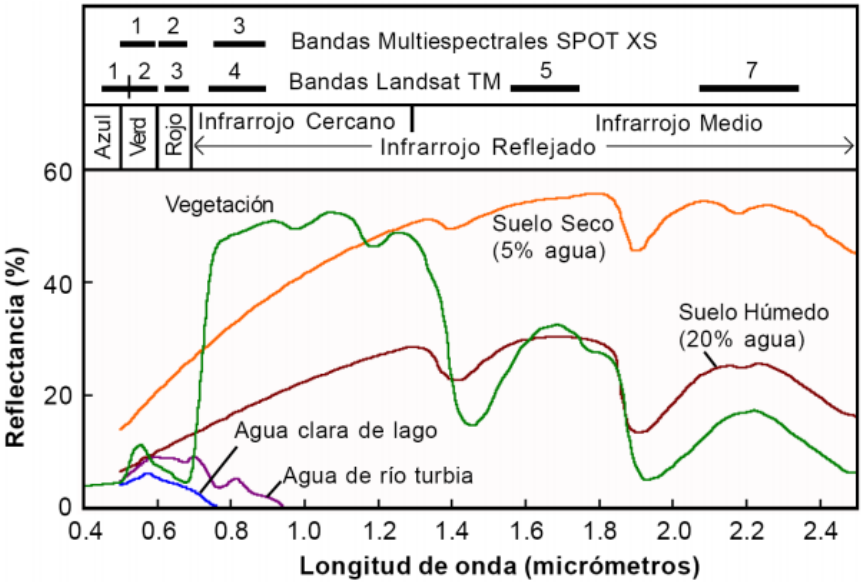


Ilustración 11. Curvas de reflectancia espectral para diferentes materiales.
Fuente: (Calvo, 2011)

9.4. Tratamiento de imágenes Hiperespectrales

La corrección geométrica engloba las técnicas de corrección de las distorsiones que producen las principales fuentes de error en el momento de la adquisición de la imagen, como son el cabeceo (pitch), alabeo (roll), giro lateral (yaw) y las provocadas por la trayectoria, altura y velocidad de la plataforma que sustenta al sensor. A éstas hay que añadir los efectos del relieve y de la esfericidad terrestre. Asimismo, se incluyen en estas técnicas las de georreferenciación, es decir, las de asignar una posición geográfica a los píxeles de la imagen (Yan-ping, 2016).

Se debe eliminar la interferencia atmosférica de las imágenes, esto se puede mediante técnicas “on-the-Fly” para el procesamiento de datos en tiempo real y trabaja con datos multiespectrales e Hiperespectrales. Para tener una representación fiable de la escena es necesario eliminar la interferencia atmosférica antes de comenzar con el proceso de clasificación, la corrección por distorsión es una etapa de preprocesamiento que identifica las propiedades atmosféricas como cantidad de vapor de agua, distorsión por aerosoles y la afectación de la reflectancia de la luz sobre la superficie terrestre, para esto utilizaremos dos módulos de corrección en ENVI:

- **Corrección Atmosférica Rápida (QUAC):** se basa en hallar empíricamente la reflectancia media de los diferentes espectros y materiales presentes en la escena (Excluyendo los materiales altamente estructurados como vegetación, Aguas pocos profunda y tierra húmeda) (Gázquez, 2018).
- **Análisis Atmosférico de Línea Rápida de Hipercubos Espectrales (FLAASH):** es una herramienta de corrección atmosférica que corrige la longitud de onda de la región visible a través de infrarrojos cercanos y regiones de infrarrojos de onda corta.

Una vez que se tiene la imagen en su “situación” corregida, se transfiere el nivel digital utilizando el de la imagen original. Se hace habitualmente de tres formas (Gázquez, 2018):

- **Vecino más próximo (Nearest Neighbor)**. En la celda de la imagen corregida el ND corresponde al del píxel más cercano de la imagen original.
- **Interpolación bilineal (Bilinear)**. Promedia los ND de los cuatro píxeles más cercanos en la original. Difumina contrastes espaciales de la imagen original.
- **Convolución cúbica (Cubic Convolution)**. Considera los ND de los dieciséis píxeles más próximos. Requiere un volumen de cálculo elevado.

9.5. Imágenes de Radar

Un sistema de formación de imagen empleando radiación coherente en la región de microondas es conocido como un sistema radar de imágenes. La región de microondas del espectro electromagnético se encuentra en las longitudes de onda desde algunos milímetros hasta algunas decenas de centímetros. Esta región está subdividida en bandas que son empleadas por los sistemas radar para generar imágenes de la superficie terrestre.

Un dispositivo de generación y registro de imágenes radar (Marinoni & Gamba, 2016) es llamado activo debido a que genera de manera controlada la radiación necesaria para iluminar la escena de interés. Tal radiación es coherente, ya que los paquetes de onda que forman el haz de iluminación tienen la misma longitud de onda y la misma fase. La coherencia de la radiación produce, sin embargo, un ruido llamado *Speckle*, inherente a la formación de la imagen de radar, que puede ser reducido únicamente por el promedio de varias imágenes de la misma escena o por medios digitales aplicados a-posteriori. Debido a la geometría particular de formación de imagen, el sistema de radar es capaz de detectar la riqueza textural de la escena de interés. Las longitudes de onda empleadas en sistemas radar son tales, que la interacción de la radiación electromagnética con los componentes atmosféricos es de una magnitud muy pequeña (Ilustración 12), permitiendo la adquisición de imágenes en prácticamente cualquier condición climática. El uso de radiación coherente en sistemas radar hace posible el empleo de varios esquemas de polarización en la generación de imágenes. Si la transmisión de la radiación se hace bajo polarización horizontal y la medida de los pulsos retro dispersados en polarización vertical, se dice entonces que se tiene un esquema HV. Otros esquemas tales como HH, VV o VH son posibles también. En la actualidad existen sistemas radar de tipo orbital que producen imágenes de radar de la superficie terrestre sobre una base regular (Yang, 1999). En misiones específicas en geometrías de adquisición particulares, los sistemas radares aerotransportados se emplean también. Existen porciones o franjas en la región radar (Ilustración 12) que son empleadas por la mayoría de los sistemas de formación de imágenes, estas son las bandas C, L y X, otras bandas tales como K, P y Q son utilizadas también (Chávez, 2010).

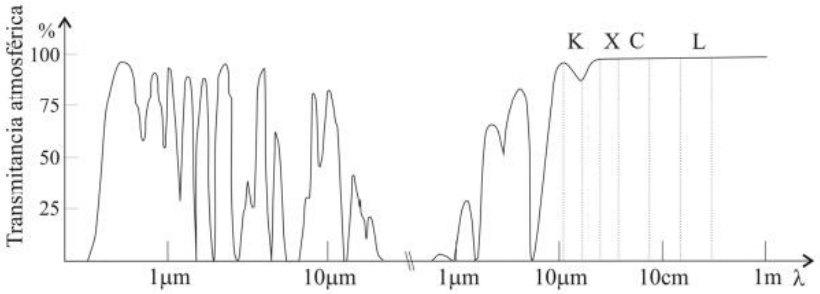


Ilustración 12. Bandas en la región radar del espectro electromagnético.
Fuente: (Chávez, 2010)

Los sensores satelitales pueden captar radiación natural (solar) o emitir su propia energía captándola al regresar a la antena del sensor. Los primeros se conocen como sensores pasivos; los segundos son sensores activos, como es el caso del radar, que funciona emitiendo y recibiendo energía electromagnética en el rango de las microondas. Los investigadores mencionan el advenimiento de una edad de oro de detección con radares, debido, más que nada a la crítica situación del medio ambiente que se anticipa para los próximos años. Las microondas de radar se propagan en la atmósfera con escaso deterioro de sus propiedades, por lo que los sensores pueden generar imágenes de manera prácticamente independiente de perturbaciones por nubosidad, lluvia, niebla, bruma y humo. Se anticipa que estas condiciones atmosféricas se incrementarán considerablemente a nivel mundial. Hace escasos veinte años estas perturbaciones comprendían aproximadamente el 48 % del globo terráqueo; hoy se han incrementado hasta cubrir un 62 % y dentro de 20 años podrían superar el 80 % de manera irreversible (Fernandez, 2016). Bajo estas condiciones la PR óptica dependiente de la luz solar (pasiva) no será aplicable para el seguimiento y estudio de grandes áreas tropicales y subtropicales. Por otro lado, el análisis de imágenes de radar puede tomar en cuenta condiciones ambientales y sociales útiles para diversas aplicaciones como son: la determinación de fronteras agrícola/urbana, el avance de manchas urbanas, la identificación de cultivos y el seguimiento de su condición, la humedad, la labranza del suelo y los residuos post cosecha; el mapeo de áreas forestales de corte y siniestradas por incendios, la identificación de especies forestales, la estimación de biomasa, la deforestación e incluso los cambios en el relieve terrestre. Por sus capacidades de aplicación la PR de radar está siendo cada vez más requerida, en particular la PR con radares de apertura sintética o SAR3. A continuación la ecuación general de las imágenes de Radar:

$$P = \frac{PGA\sigma F^4}{(4^t \Pi^t)^2 R^{t^2} R^{r^2}} \quad (1)$$

Donde en esencia, los algoritmos de análisis se basan en esta ecuación, que permite calcular la potencia de la señal recibida, Pr, relacionándola con las características del radar, el objetivo y la señal recibida (El-Darymli, 2012). La ecuación 26 muestra que: donde Pt denota la potencia de la señal transmitida medida en volts, Gt la ganancia de la antena de transmisión, Ar la apertura efectiva (área) de la antena de recepción, s el corte o sección transversal del radar y Rt la distancia entre el transmisor y el objetivo.

Dicho esto, los sensores tienen un diseño físico que permite simular una antena de mayor tamaño que el real, ampliándose así las capacidades de recepción respecto de los radares de apertura real. De entre los radares SAR los más versátiles operan en modalidad polarimétrica, emitiendo y recibiendo energía polarizada. En SAR la polarización se refiere a la orientación del rayo de energía relativa a la superficie de la Tierra. Los principios físicos de la modalidad polarimétrica se introducen en este trabajo para permitir al lector adentrarse en la comprensión de los datos de imágenes de estos radares y en las técnicas de análisis polarimétrico que pueden aplicarse. Los radares polarimétricos funcionan considerando la polaridad de la señal electromagnética que emiten y las propiedades de polarización de la señal que captan al retorno. Una onda polarizada horizontalmente (H) o verticalmente (V) al incidir sobre un blanco produce otra onda de retorno que puede tener aportaciones en ambas polarizaciones H y V. La señal de retorno contiene implícita información sobre el blanco en tierra porque los dispersores modifican de maneras diferentes la polarización. La polarimetría, también denominada síntesis polarimétrica, se basa en análisis fisicomatemáticos de las propiedades de la onda emitida y de la recibida, principios que fundamentan científicamente

las imágenes SAR. La polarimetría involucra numerosos factores relacionados con el sensor, con la propagación de la energía y su detección. Están involucrados también los sistemas (hardware y software) para el procesamiento de la información captada (Henderson, 1998). En la PR SAR es necesario conocer conceptos básicos de la naturaleza de los datos para elegir los métodos de análisis y procurar una interpretación acertada de la información. La PR SAR continúa siendo un campo fértil de investigación y desarrollo.

En la tabla 4 se encuentran las diferentes misiones realizadas a lo largo de la historia, cuales se encuentran en operación, tipo de imágenes que capturan y un análisis detallado de su funcionamiento.

Tabla 4. Misiones Satelitales de Radar

	Misiones en operación			Misiones finalizadas			Misiones planificadas		
Satélite	RADARSAT -1	ENVISAT	ERS-2	ERS-1	SIR-C	JERS-1	RADARSAT -2	ALOS	SAOCOM
Banda Radar	C	C	C	C	L, C	L	C	L	L
Polarización	HH	HH o VV VV o HH	VV	VV	ALL	HH	HH + HV, VV + VH y HH+HV+VV+VH	HH o VV HV o VH	HH + HV, VV + VH y HH+HV+VV+VH
Angulo de incidencia (grados)	10 – 60	20 -45	24	24	17 – 60	35	10 - 60	20 - 55	11.8 – 48.6
Resolución (metros)	10 – 100	30	25	25	25	18	3 - 100	10 - 100	10 – 100
Ancho de Swath (Km)	50 – 500	50 – 400	100	100	15 – 40	76	10 - 500	70 – 250	31 – 126
Lanzamiento	1995	1999	1995	1991	1994	1992	2004	2004	2005

Fuente: (Resources, 2016)

9.6. Constante dieléctrica

Las propiedades dieléctricas del terreno, expresadas en la constante dieléctrica, afectan críticamente la señal retro dispersada ya que inciden directamente en la absorción y propagación de las ondas electromagnéticas. La parte real de la constante dieléctrica es la permisividad del medio y la parte imaginaria se expresa como la conductividad del medio (Hernández, 2010). El valor de la constante dieléctrica depende del contenido de agua de la superficie: la penetración (ilustración 13) (Gupta & Jacobson, 2006) de la señal electromagnética es mayor y la reflexión de esta es menor para un bajo contenido de humedad. Inversamente, la penetración es menor y la reflexión es mayor cuando la humedad es alta. En cuanto a la conductividad, la penetración es mayor para grandes longitudes de onda (Erdem, 2009).

El efecto de la rugosidad subsuperficial es importante en los casos de nieve y arenas limpias y secas. En ambos casos, el contenido de humedad es muy bajo y en consecuencia la penetración de la señal electromagnética es alta. En la frontera donde termina la nieve o la arena, la constante dieléctrica cambia y se produce alta reflexión y baja penetración (Friðrik, 2009).

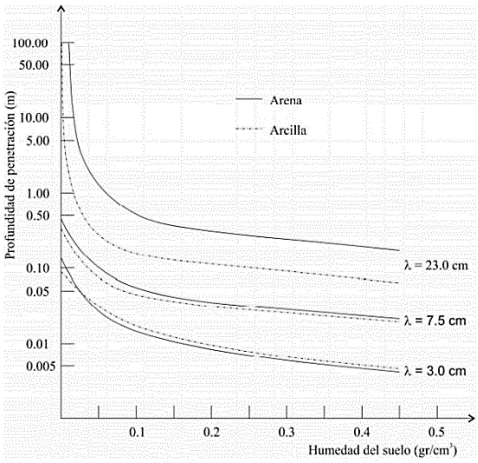


Ilustración 13. Penetración de la señal radar en función de la longitud de onda y la humedad del terreno
Fuente: (Chávez, 2010)

9.6.1. OIF Factor de índice óptimo

El OIF es un valor estadístico que puede ser usado para seleccionar la combinación a color óptima de tres bandas de una imagen satelital. El cálculo de OIF se realiza sobre todas las posibles combinaciones de la imagen, y se basa en la selección de las bandas que conserven la mayor información espectral (mayores covarianzas entre bandas) y la menor duplicidad de información (menores correlaciones entre bandas), matemáticamente se expresa por la siguiente ecuación

$$OIF = \frac{Suma\ de\ Desviación\ de\ 3\ bandas\ individuales}{Suma\ de\ \ coeficientes\ de\ correlación\ \ para\ 3\ bandas} \quad (2)$$

9.7. Clasificación de Imágenes

En muchos casos es habitual que la clasificación sea la fase culminante del tratamiento digital de imágenes. Las operaciones estudiadas anteriormente se suelen orientar hacia ella, pues los resultados de la clasificación marcan la calidad final del proyecto desarrollado. Este papel protagonista viene dado por la misma naturaleza de la teledetección espacial. Los ND adquiridos por el sensor no tienen sentido en sí mismos, sino en cuanto son interpretables; es decir, convertibles a categorías o clases que supongan un mejor conocimiento del territorio. Esta interpretación se puede hacer de manera visual, sobre reproducciones fotográficas de las imágenes empleando la potencia y rapidez de cálculo que proporciona un ordenador. Como resultado de la clasificación digital se obtiene una cartografía e inventario de las clases objeto de estudio. En definitiva, la información espectral se reúne en un documento cartográfico y en unas tablas estadísticas, que definen la localización y ofrecen el inventario superficial de las categorías de interés (Barisione, Solarna, Giorgi, Moser, & Serpico, 2016).

El proceso de clasificación consta de las siguientes fases: definición digital de las categorías (fase de entrenamiento), distribución de los píxeles de la imagen en una de esas categorías (fase de asignación), y comprobación y evaluación de resultados (fase de verificación de resultados) (Calvo, 2011).

9.7.1. Fase de Clasificación

La clasificación digital comienza con la definición de cada una de las clases que pretenden discriminarse. Puesto que se trata de una clasificación numérica, esta definición también debe ser numérica o critica; esto es, se trata de obtener el rango de ND o Nivel Digital, que identifica a cada categoría, para todas las bandas que intervienen en la clasificación.

Debido a los diversos factores que introducen cierta dispersión en torno al comportamiento espectral medio de cada cubierta, las distintas categorías no se definen por un solo ND, sino por una serie de ND, más o menos próximos entre sí. En términos de su clasificación digital, esto supone que existe una cierta dispersión en torno al ND que define cada categoría, más o menos significativa según las clases que se consideren y la propia complejidad del paisaje donde éstas se asienten. Por ello, la fase de entrenamiento es un proceso complejo: se trata de definir con rigor cada una de las categorías que pretenden discriminarse, teniendo en cuenta su propia variabilidad en la zona de estudio (Ekrem E. T., 2012).

Este objetivo se consigue al seleccionar una muestra de píxeles de la imagen que representen, adecuadamente, a las clases de interés. A partir de esos píxeles pueden calcularse los ND medios y la variabilidad numérica de cada categoría, en cada una de las bandas que se emplean en la clasificación. Al igual que en cualquier otro muestreo, el propósito de esta fase es obtener los resultados más precisos con el mínimo coste, es decir, identificar debidamente las distintas categorías, reduciendo a lo imprescindible los trabajos de campo. Así mismo, como en otras aplicaciones del muestreo, es fundamental la correcta selección de las muestras para conseguir buenos resultados en la clasificación posterior. Se ha comprobado que los resultados de la clasificación dependen mucho más de la definición previa de las clases que del criterio escogido para posteriormente discriminarlas. En conclusión, la fase de entrenamiento es la parte fundamental de la clasificación numérica.

Tradicionalmente, en función de la manera en que son obtenidas las estadísticas de entrenamiento, los métodos de clasificación se dividen en dos grupos: supervisado y no supervisado. El método supervisado parte de un conocimiento previo del terreno, a partir del cual se seleccionan las muestras para cada una de las categorías. Por su parte, el método no supervisado procede a una búsqueda automática de grupos de valores homogéneos dentro de la imagen. En este caso, corresponde al usuario la labor de encontrar correspondencias entre esos grupos y sus categorías de interés. La elección entre uno y otro método dependerá de los datos y medios disponibles y de las propias preferencias personales (Gázquez, 2018).

9.7.2. Método supervisado

Como se ha mencionado, el método supervisado parte de un cierto conocimiento de la zona de estudio, adquirido por la experiencia previa o por trabajos de campo. Esta familiaridad con la zona de prueba permite al intérprete delimitar sobre la imagen unas áreas piloto, que se consideran suficientemente representativas de las categorías que componen la leyenda. Estas áreas se denominan regiones o campos de entrenamiento (training fields), cuyo término indica que tales áreas sirven para “entrenar” al ordenador en el reconocimiento de las distintas clases. En otras palabras, el ordenador calcula los ND que caracterizan cada una de las clases, para luego asignar el resto de los píxeles de la imagen a una de esas categorías en función de sus ND (Gázquez, 2018).

La mayoría de los equipos de tratamiento digital permiten localizar interactivamente las regiones de entrenamiento. Así, el usuario introduce sobre la pantalla los vértices que definen cada una de estas áreas, asignándolas a una de las clases definidas en la leyenda con anterioridad. Como ayuda para realizar una localización más precisa de estas áreas, la consulta de trabajos de campo y otros documentos auxiliares (fotografía aérea o cartografía convencional) puede ser utilidad, considerando que debe tratarse de ejemplos suficientemente representativos y homogéneos de la clase que pretende definirse. Al terminar la delimitación de una región de entrenamiento, pueden seleccionarse otras para la misma categoría, o bien culminar con ella la definición de esa clase. En general, resulta conveniente seleccionar varias regiones por categoría, a fin de reflejar adecuadamente su variabilidad en la zona de estudio (Barisione, Solarna, Giorgi, Moser, & Serpico, 2016).

Finalizada la selección de las áreas de entrenamiento, el ordenador calcula las estadísticas elementales de cada categoría: media, rango, desviación típica, matriz de varianza-covarianza, etc., a partir de los ND de todos los píxeles incluidos en las regiones de entrenamiento asignadas a esa clase. Lógicamente, este cálculo se aplica a todas las bandas que intervendrán en la clasificación. En definitiva, se asume que las áreas de entrenamiento son fieles representantes de las distintas categorías, y que, por tanto, las medidas extraídas a partir de sus ND definen convenientemente a esas clases. De aquí que sea crucial la correcta selección de estas regiones, pues de lo contrario la clasificación estaría viciada desde el inicio, al pretender discriminar categorías con escaso significado espectral.

Un último aspecto que considerar en la selección de las regiones de entrenamiento se refiere a los requisitos estadísticos que garantizan su grado de representatividad de las distintas categorías. Como se ha comentado anteriormente, este proceso es una forma peculiar de muestreo espacial. Por ello, conviene tener en cuenta algunos criterios habituales en este tipo de técnicas para elegir el tamaño y la distribución más idónea de la muestra, así como para realizar estimaciones a partir de ella.

En cuanto al tamaño, se requiere seleccionar un mínimo M + 1 píxeles por categoría, siendo M el número de bandas que integran el análisis en nuestro caso 356 bandas. No obstante, se recomienda superar con creces este límite mínimo, el cual se relaciona estrechamente con el grado de asociación espacial entre píxeles. Aunque el muestreo convencional considera que las muestras seleccionadas son aleatorias e independientes, para este caso esto no es válido puesto que una región de entrenamiento alberga a píxeles vecinos, afectados por el fenómeno de autocorrelación espacial. En pocas palabras, esta asociación supone que la información original extraída de un número de píxeles contiguos es menor que si fuese extraída de otros dispersos. En resumen, resulta más conveniente elegir varias regiones de pequeño tamaño, que uno solo de mayores dimensiones, ya que tenderá a infravalorarse la variabilidad de esta clase para nuestra escena con una imagen de 360 bandas con 4663 columnas y 4306 filas y un tamaño de pixel de 2 metros (Manolakis, Lockwood, & Cooley, 2016).

Respecto a la distribución, conviene tener en cuenta las propias características de la imagen, intentando abarcar las variaciones espaciales que se presentan en cada categoría: su orientación, pendiente, densidad, vigor, contenido de humedad, tipo de suelo, etc. En este sentido, varios autores han subrayado que la variabilidad de una cubierta es directamente proporcional a la resolución del sensor. Dicho de otro modo, cuanto mayor sea el detalle espacial registrado en la imagen, mayor será también su sensibilidad para detectar las variaciones internas de una categoría, antes ocultas bajo un píxel de mayor tamaño. Por tanto, a mayor heterogeneidad, mayor mezcla con clases similares, y por ello, mayor riesgo de confusiones en la asignación posterior.

9.8. Análisis de estadísticas de entrenamiento

Independientemente del método empleado en definir la fase de entrenamiento, antes de abordar el proceso de clasificación propiamente dicho conviene analizar la separabilidad de las categorías seleccionadas, esto es, evaluar la viabilidad de que esas categorías puedan clasificarse sin grave riesgo de error. Por ejemplo, si se comprueba que dos o más son muy similares, habría una gran probabilidad de confusión entre ellas, por lo que resultaría aconsejable: confirmar que las estadísticas de entrenamiento han sido correctamente deducidas; adoptar una leyenda más general, con nuevas categorías que supongan una mezcla de las que ofrecen mayor riesgo de confusión; recabar información auxiliar o imágenes de otras fechas (Xue, Du Peijun, Li, & Su, 2017).

Existen varios métodos, tanto gráficos como numéricos, para evaluar las estadísticas de entrenamiento. En este apartado, se tratarán con más detalle los criterios cuantitativos que permiten evaluar numéricamente la posibilidad de discriminar las distintas categorías (Huang, 2006).

Uno de estos métodos es la divergencia estadística, el cual asume que los ND en una categoría se distribuyen normalmente, tomando la separabilidad como la medida del solape entre categorías vecinas. Puesto que se trata de calcular ese valor para un espacio multivariado (tantas variables como bandas intervienen en el proceso), se considera el vector de medias y matriz de varianza-covarianza entre pares de categorías. La fórmula de cálculo se sintetiza de la siguiente forma: Ecuación 1:

$$D_{ij} = \frac{1}{2} tr\left[\left(c_i - c_j\right)\left(c_i^{-1} - c_j^{-1}\right)\right] + \frac{1}{2} tr\left[\left(c_i^{-1} + c_j^{-1}\right)(m_i - m_j)(m_i - m_j)^T\right] \quad (3)$$

Donde D_{ij} indica la medida de la divergencia entre las categorías i y j; tr se refiere a la traza o suma de los elementos de la diagonal de la matriz indicada [ ]; c_i y c_j son las matrices de varianza-covarianza de las categorías i y j; m_i y m_j son los vectores de medias correspondientes a las mismas categorías y bandas, además $(\ )^T$ indica la matriz traspuesta de la indicada entre corchetes. Cuanto mayor sea el valor de la divergencia, mayor también la separabilidad entre clases, basada, lógicamente, sobre las bandas que se han considerado en su cálculo (Gázquez, 2018).

Además de esto también podemos utilizar la ecuación (1) que algunos autores soportan para escalar de acuerdo con el rango conocido, utilizando como base la transformada: Ecuación 2:

$$DT_{ij} = 2\left(1 - e^{-D_{ij}/8}\right) \quad (4)$$

Donde la constante de valor 2 es introducida para escalar el resultado entre unos rangos conocidos. Algunos autores recomiendan emplear un valor de 2.000 o 100. Además de la divergencia, se han propuesto otras medidas de separabilidad como la distancia de Jeffries-

Matusita (JM), también llamada de Bhattacharyya. La distancia JM entre un par de distribuciones de probabilidad (clases espectrales) se define como:

$$J_{ij} = \int \left(\sqrt{p(r \mid w_i)} - \sqrt{p(r \mid w_j)} \right)^2 dr \quad (5)$$

Esta expresión cuantifica la suma de las distancias al cuadrado entre pares de valores de las distribuciones de probabilidad para el par de clase w_i, w_j. Para las clases de distribución normal se convierte en:

$$j_{ij} = 2\left(1 - e^{-B_{ij}}\right)$$

Donde

$$B_{ij} = \frac{1}{8}(m_i - m_j)^T \left[\frac{c_i + c_j}{2} \right]^{-1} (m_i - m_j) + \frac{1}{2} ln \left[\frac{\left| (c_i + c_j)/2 \right|}{\left| c_i \, c_j \right|^{1/2}} \right] \quad (6)$$

que se refiere a la distancia de Bhattacharyya. La distancia JM la distancia de Jeffries-Matusita está acotada a 2, lo que significa que el par de clases que posea un valor igual a 2 tendrá una separabilidad perfecta.

Para calcular la separabilidad entre clases en este ejercicio se han empleado la divergencia transformada y la distancia JM Jeffries- Matusita (Gázquez, 2018).

9.9. SuperPixel

La definición de SuperPixel nace de la validación en 3 dimensiones que soporta las características de las imágenes Hiperespectrales, donde sabemos que no solo se está trabajando 2 dimensiones para cada una de las imágenes bases, sino que el montaje y captura de las diferentes capas que dan lugar al enriquecimiento espectral genera un modelamiento en 3 dimensiones donde cada una de las bandas genera una pirámide de información de un mismo objeto y que se determinan los factores físicos y espectrales de cada una de las bandas teniendo en cuenta los perfiles espectrales de cada uno de los elementos (Atkinson, Kamalabadi, & Jones, 2003) en cuanto más bandas se presentes en la imagen mayor será el detalle espectral del objeto y se recopilara mejor información de sus propiedades vistas desde su resolución espectral.

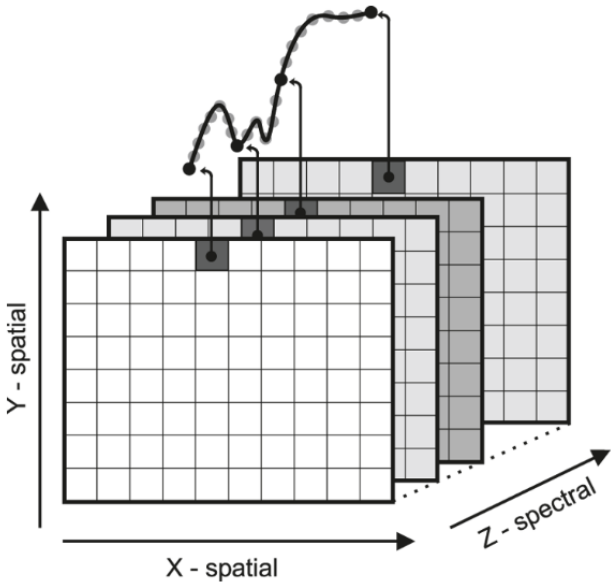


Ilustración 14. Cubo Hiperespectral

Fuente: (Gázquez, 2018)

9.10. NDVI

El índice de vegetación más conocido y usado es el Índice Normalizado Diferencial de Vegetación (NDVI Normalized Difference Vegetation Index). Este índice fue introducido con el objetivo de separar la vegetación del brillo que produce el suelo

El Índice de Vegetación Diferencial Normalizado es el más utilizado para todo tipo de aplicaciones. La razón fundamental su sencillez de cálculo y disponer de un rango de variación fijo (entre –1 y +1), lo que permite establecer umbrales y comparar imágenes.

Los valores del NDVI están en función de la energía absorbida o reflejada por las plantas en diversas partes del espectro electromagnético. La respuesta espectral que tiene la vegetación sana muestra un claro contraste entre el espectro del visible, especialmente la banda roja, y el Infrarrojo Cercano (NIR). (Subira Biosca, 2011)

Mientras que en el visible los pigmentos de la hoja absorben la mayor parte de la energía que reciben, en el NIR, las paredes de las células de las hojas, que se encuentran llenas de agua, reflejan la mayor cantidad de energía. En contraste, cuando la vegetación sufre algún tipo de estrés, ya sea por presencia de plagas o por sequía, la cantidad de agua disminuye en las paredes celulares por lo que la reflectividad disminuye el NIR y aumenta paralelamente en el rojo al tener menor absorción clorofílica. Esta diferencia en la respuesta espectral permite separar con relativa facilidad la vegetación sana de otras cubiertas.

La ecuación que describe el cálculo de NDVI se describe como:

$$NDVI = \frac{\varphi^{NIR} - \varphi^{ROJO}}{\varphi^{NIR} + \varphi^{ROJO}} \quad (7)$$

Donde NIR es la reflectancia espectral del canal infrarrojo cercano y ROJO representa la reflectancia en el canal rojo del visible. Esta fórmula indica que existe una relación inversa entre el valor de reflectancia de estas bandas, por lo que es posible su uso para discriminación de cubiertas vegetales. Cuando trabajamos imágenes Hiperespectrales con muchas bandas y posibles soluciones se debe determinar el ancho de la banda infrarroja y rojo visible para que de estar forma podamos obtener un resultado más optimo del proceso.

9.11. Elementos para la clasificación de Minerales

Como base para el estudio y la clasificación de minerales expuestos y sabiendo la geología base del lugar que es en su mayoría arcillas y depósitos aluviales, verificaremos 4 elementos que se presentan de manera cotidiana dentro de este tipo de suelos, el primero es la **Calcita (**del grupo de los **Carbonatos)** es un mineral formado por carbonato cálcico ($CaCO_3$), de la clase 05 de la clasificación de Strunz, los llamados minerales carbonatos y nitratos. A veces, se usa como sinónimo a la caliza, aunque es incorrecto pues esta última es una roca, no un mineral. Su nombre viene del latín calx, que significa cal viva. Es el mineral más estable que existe de carbonato de calcio es muy común y tiene una amplia distribución por todo el planeta, se calcula que aproximadamente el 4 % en peso de la corteza terrestre es de calcita (Smyth, 2000).

La segunda será un mineral con propiedades oxidantes y componentes metálicos, **la Hematita** es la forma mineral del óxido férrico, cuya fórmula es Fe_2O_3. En griego 'piedra de sangre'. Traducido en el año 79 por Plinio el Viejo como *haematites* ('parecida a la sangre'), en alusión al vívido color rojo de su polvo; la hematita tiene una apariencia muy variable: color pardo rojizo, masas ocres, masas oscuras de color gris plateado, cristales de color gris plateado a negro o masas de color gris oscuro. Todas tienen en común la raya color rojo teja. Presenta brillo sub-metálico, metálico, apagado o terroso (Manosalva, 2007).

Y los últimos dos componentes principales de las arcillas de la zona el primero **la Caolinita** es un mineral de arcilla que forma parte del grupo de minerales industriales, con la composición química $Al_2Si_2O_5(OH)_4$. Se trata de un mineral tipo silicato estratificado, con una lámina de tetraedros unida a través de átomos de oxígeno en una lámina de octaedros de alúmina, Este tipo de arcilla es utilizada de forma calcinada, en temperaturas entre 500°C y 900°C para producir metacaulin, un material de propiedades puzolánicas dentro del hormigón a base de cemento portland. Así mismo, en un reciente concepto de hormigón eco sostenible, los llamados geo polímeros. Siendo explotada con fines de consumo a nivel nacional para substituto parcial y total del cemento portland. En función del ambiente donde sea explotada puede adquirir coloración rojiza hasta blanca. El según material es **la Moscovita** mineral del grupo de los silicatos, subgrupo filosilicatos y dentro de ellos pertenece a las micas lumínicas. Químicamente es un aluminosilicatos de potasio y aluminio, que puede llevar magnesio, cromo y una gran variedad de otros elementos en sus numerosas variedades. Es la especie más común del grupo de las micas, es conocida como **mica blanca** o **mica potásica** por el color plateado y su brillo nacarado. Presenta un hábito laminar, en cristales tabulares de contorno hexagonal o en láminas flexibles y elásticas (Chen, Zhao, Tang, & Zhou, 2017).

Nos basaremos en los perfiles de la IGCP International Geoscience and Geoparks Programme (IGCP), El Programa Internacional de Geociencias (PICG) sirve como centro de conocimientos de la UNESCO para facilitar la cooperación científica internacional en las geociencias. La misión del IGCP incluye promover el uso sostenible de los recursos naturales, promoviendo nuevas iniciativas relacionadas con la geodiversidad y el geo-patrimonio y la mitigación de riesgos de geo-peligros. Las librerías de la IGCP se publicaron originalmente en Laboratory Reflectance Spectral con 160 Minerales de 0.4 a 2.5 Micrómetros, por C.I. Grove, S.J. Hook y E.D. Paylor II. La siguiente descripción de la biblioteca, la preparación y medición de las muestras que contiene se extrae de ese mismo informe. El informe se refiere a las mediciones realizadas con el espectrómetro Beckman. Se utilizó el mismo procedimiento de preparación y medición de la muestra con el espectrómetro Nicolet (Datta, Ghosh, & Ghosh, 2017).

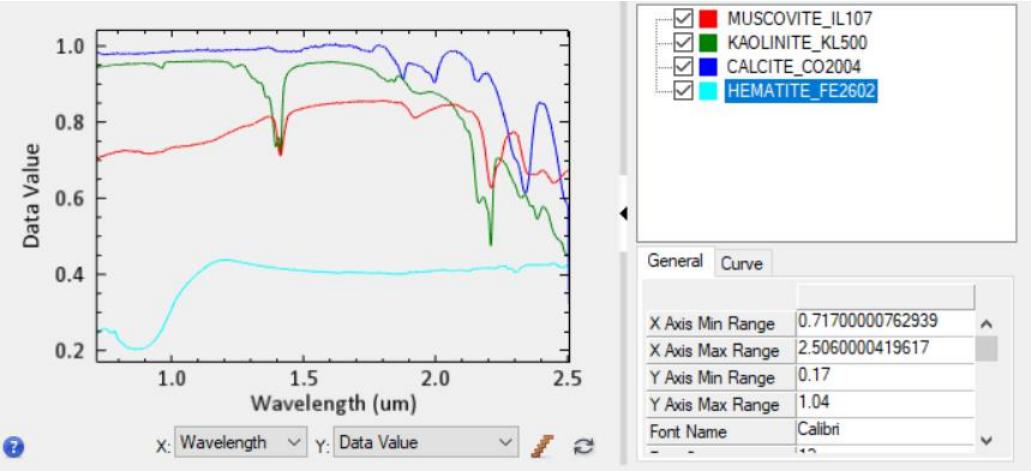


Ilustración 15. Perfiles espectrales base.

Fuente: Programa Internacional de Geociencias y Geoparques (International Geoscience and Geoparks Programme (IGCP))

En la Ilustración 15 vemos los perfiles espectrales de los elementos que clasificaremos, este corresponderá a la estadística de entrenamiento para posteriormente realizar la búsqueda de su coeficiente Kappa como base para determinar el mejor resultado de clasificación utilizando diferentes métodos.

9.12. *Clasificación por divergencia de información* espectral

Dado un píxel Hiperespectral (vector) $x = (x_1, x_2, \ldots x_D)^T$, cada elemento x_i y x_j es un valor de la banda B_i adquirido en una determinada longitud de onda (wavelength) λ_i. De hecho, todos los componentes x_i en x_j no son negativos. Por tanto, definimos una medida de probabilidad P para x. Debido a la naturaleza de la radiancia o reflectancia, podemos definir una probabilidad de medida P para x donde:

$$pi = p(x_i) = \frac{x_i}{\sum_{i=1}^{D} x_i} \tag{8}$$

El vector $P(x) = (p_1 + p_2 + \dots p_D)^T$ es el vector de probabilidad deseado resultante del vector de píxeles $x = (x_1, x_2, \dots x_D)^T$. Como sabemos, cualquier píxel x en una HSI (Imagen Hiperespectral) puede ser visto como una única fuente de información que consta de D bandas, por lo que su variabilidad espectral se puede describir mediante estadísticas gobernado por $P(x)$ (Zhang, 2014).

Suponga que otro píxel y en una HSI, y su vector $Q(x) = (q_1 + q_2 + \dots q_D)^T$, donde:

$$q_i = q(y_i) = \frac{y_i}{\sum_{i=1}^{D} y_i} \tag{9}$$

Con base en la teoría de la información, podemos definir la auto información de los píxeles x y y, respectivamente, que es una combinación de la auto información de la i-enésima banda de la siguiente manera:

$$I_i(x) = -\log(p_i),$$
$$I(x) = (I_1(x), I_2(x), \dots I_D(x))^T \tag{10}$$
$$I_i(y) = -\log(q_i),$$
$$I(y) = (I_1(y), I_2(y), \dots I_D(y))^T \tag{11}$$

La entropía relativa de y con respecto a x se puede definir por

$$CE(x,y) = \sum_{i=1}^{D} p_i CE(x_i, y_i) = \sum_{i=1}^{D} p(I_i(y) - I_i(x))$$
$$= \sum_{i=1}^{D} p_i \log\left(\frac{p_i}{q_i}\right) = P^T(x) * (I(y) - y(x)) \tag{12}$$

En la ecuación 9, $CE(x,y)$ también se conoce como Kullback-Leibler medida de información de divergencia dirigida o entropía cruzada (Kullback, 1959). Como resultado de la ecuación 9, podemos obtener un sistema Hiperespectral simétrico con una medida de similitud, denominada SID. SID se puede utilizar para medir la similitud espectral entre dos píxeles x y y,

$$SID(x,y) = CE(x,y) + CE(x,y)$$
$$= P^T(x) * (I(y) - I(x)) + Q^T(y) * (I(x) - I(y)) \tag{13}$$

Este ofrece una nueva visión de la similitud espectral desde la perspectiva de la teoría de la información, que calcula la entropía relativa para tener en cuenta la información espectral proporcionada por cada píxel y de esta forma generar una mejor clasificación no basándonos en 3 bandas sino basados en el perfil espectral y todas las bandas que componen la imagen sin importar la cantidad de elementos que componen la imagen (ZHANG, 2007).

9.13. Máquina de Vectores de Soporte SVM

Las SVMs (Support Vectorial Machine) pertenecen a la categoría de clasificadores lineales, puesto que inducen separadores lineales o hiperplanos, ya sea en el espacio original de los ejemplos de entrada, si éstos son separables o cuasi-separables (ruido), o en un espacio transformado (espacio de características), si los ejemplos no son separables linealmente en el espacio original. La búsqueda del hiperplano de separación en estos espacios transformados, normalmente de muy alta dimensión, se hará de forma implícita utilizando las denominadas funciones kernel (Sindhumol & Wilscy, 2007).

La idea es seleccionar un hiperplano de separación que equidista de las muestras más cercanas de cada clase para, de esta forma, conseguir lo que se denomina un margen máximo a cada lado del hiperplano. Además, a la hora de definir el hiperplano, sólo se consideran las muestras de entrenamiento de cada clase que caen justo en la frontera de dichos márgenes. Estas muestras reciben el nombre de vectores de soporte y son los elementos críticos del conjunto de entrenamiento (Gázquez, 2018).

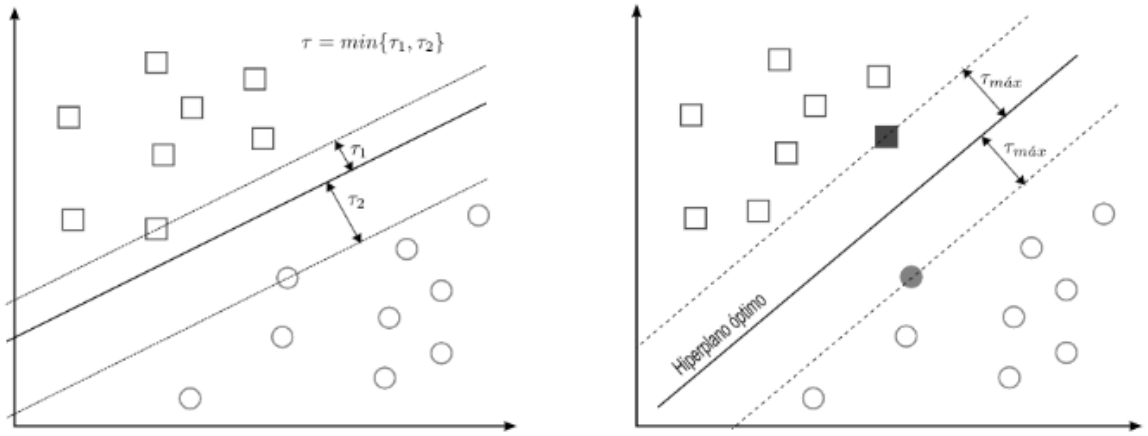


Ilustración 16. Margen de un hiperplano de separación: a) Hiperplano de separación no-óptimo y su margen asociado, b) Hiperplano de separación óptimo y su margen asociado máximo

Fuente: (Gázquez, 2018)

Mientras SVM es un clasificador binario en su forma más simple, puede funcionar como un clasificador multiclase mediante la combinación de varios clasificadores SVM binarios (creando un clasificador binario para cada posible par de clases). Asimismo, SVM incluye un parámetro de penalización que permite un cierto grado de error de clasificación, lo cual es particularmente importante para los conjuntos de entrenamiento no separables. Este parámetro controla la compensación entre errores de entrenamiento y márgenes rígidos (*hard margin*). Así, se crea un margen blando (*soft margin*) que permite algunos errores de clasificación a la vez que los penaliza. El incremento del valor del parámetro de penalización aumenta el coste de los puntos de clasificación errónea y obliga a la creación de un modelo más preciso que no puede generalizarse con claridad (Su, Cai, & Du Qian, 2017).

Como se comentó anteriormente, las funciones kernel son las que permiten convertir lo que sería un problema de clasificación no lineal en el espacio dimensional original, a un sencillo problema de clasificación lineal en un espacio dimensional mayor. Algunos ejemplos de funciones kernel son:

$$K(x_i, x_j) = x_i^T x_j \tag{14}$$

Si la distribución de las observaciones es tal que se pueden separar linealmente de forma perfecta en las dos clases ($+1$ y -1), entonces, un hiperplano de separación cumple que:

$$\begin{aligned} &\beta_0 + \beta_1 x_1 + \beta_2 x_2 + ... + \beta_p x_p > 0, \ si\ y_i = 1 \\ &\beta_0 + \beta_1 x_1 + \beta_2 x_2 + ... + \beta_p x_p < 0, \ si\ y_i = -1 \end{aligned} \tag{15}$$

Al identificar cada clase como +1+1 o −1−1, y dado que multiplicar dos valores negativos resultan en un valor positivo, las dos condiciones anteriores pueden simplificarse en una única:

$$\beta_0 + \beta_1 x_1 + \beta_2 x_2 + ... + \beta_p x_p > 0 \text{ para } i = 1...n \tag{16}$$

Bajo este escenario, el clasificador más sencillo consiste en asignar cada observación a una clase dependiendo del lado del hiperplano en el que se encuentre. Es decir, la observación $\mathbf{x}\wedge*$ se clasifica acorde al signo de la función $f(x^*) = \beta 0 + \beta 1 x*1 + \beta 2 x*2 + ... + \beta p x* p$. Si $f(x^*)$ es positiva, la observación se asigna a la clase $+1$, si es negativa, a la clase -1. Además, la magnitud de $f(x*)$ permite saber cómo de lejos está la observación del hiperplano y con ello la confianza de la clasificación (Díaz, 2017).

La solución a este problema consiste en seleccionar como clasificador óptimo al que se conoce como máximo margen de hiperplano o hiperplano óptimo de operación, que se corresponde con el hiperplano que se encuentra más alejado de todas las observaciones de entrenamiento. Para obtenerlo, se tiene que calcular la distancia perpendicular de cada observación a un determinado hiperplano. La menor de estas distancias (conocida como margen) determina como de alejado está el hiperplano de las observaciones de entrenamiento. El máximo margen de hiperplano se define como el hiperplano que consigue un mayor margen, es decir, que la distancia mínima entre el hiperplano y las observaciones es lo más grande posible. Aunque esta idea suena razonable, no es posible aplicarla, ya que habría infinitos hiperplanos contra los que medir las distancias (Díaz, 2017).

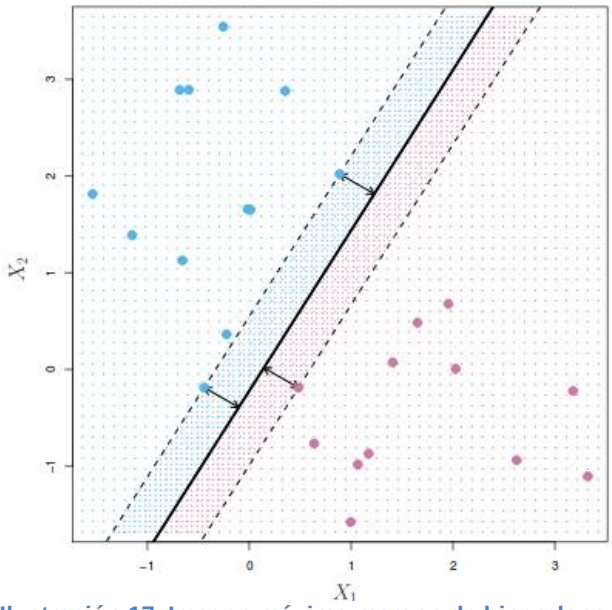


Ilustración 17. Imagen máximo margen de hiperplanos

Fuente: (Witten, 2013)

La imagen anterior muestra el máximo margen de hiperplanos para un conjunto de datos de entrenamiento. Las tres observaciones equidistantes respecto al máximo margen de hiperplanos se encuentran a lo largo de las líneas discontinuas que indican la anchura del margen. A estas observaciones se les conoce como vectores soporte, ya que son vectores en un espacio *X*-dimensional y soportan (definen) el máximo margen de hiperplanos. Cualquier modificación en estas observaciones (vectores soporte) conlleva cambios en el máximo margen de hiperplanos. Sin embargo, modificaciones en observaciones que no son vector soporte no tienen impacto alguno en el hiperplano (Chávez, 2010).

9.14. Kernels

En una MSV, el hiperplano óptimo es determinado para maximizar su habilidad de generalización. Pero, si los datos de entrenamiento no son linealmente separables, el clasificador obtenido puede no tener una alta habilidad de generalización, aun cuando los hiperplanos sean determinados óptimamente, para maximizar el espacio entre clases, el espacio de entrada original es transformado dentro de un espacio altamente dimensional llamado “espacio de características” (Guo, Gunn, Damper, & Nelson, 2005).

La idea básica en diseño de MSV no lineales es transformar los vectores de entrada $x \in \mathbb{R}^n$ dentro de los vectores $\phi(x)$ de un espacio de características altamente dimensionales (J. C. Canales, 2009) donde ϕ representa el mapeo de $\mathbb{R}^n \rightarrow \mathbb{R}^f$ y resolver el problema de clasificación lineal en este espacio de características donde:

$$x \in \mathbb{R}^n \rightarrow \phi(x) = \{\phi_1(x), \phi_2(x), \dots \phi_n(x)\}^T \in \mathbb{R}^f \quad (17)$$

Entonces las funciones de tipo no lineal serán:

$$f(x) = \sum_{i=1}^{i} w_i \phi_i(x) + b \tag{18}$$

Donde $\phi = X \rightarrow F$ es un mapeo no lineal desde un espacio de entrada a un espacio de clasificación, el procedimiento de aprendizaje consiste en dos pasos: primero, un mapeo no lineal transforma los datos dentro de un espacio de características F y después, una máquina lineal es utilizada para clasificar los datos en un espacio de características. Como se vio anteriormente, una propiedad de las máquinas de aprendizaje lineal es que éstas pueden ser expresadas en una representación dual, esto significa que la ecuación (15) puede ser expresada como una combinación lineal de los puntos de entrenamiento. Por lo tanto, la regla de decisión puede ser evaluada usando productos punto.

$$f(x) = \sum_{i=1}^{i} \alpha_i y_i (\phi_i(x_i).\phi(x)) + b \tag{19}$$

Si se tiene una forma de capturar el producto $(\phi_i(x_i).\phi(x))$ en el n el espacio de características, directamente como una función de los puntos de entrada originales, esto hace posible unir los dos pasos necesarios para construir una máquina de aprendizaje no-lineal. A este método de cómputo directo se le llama función kernel (J. C. Canales, 2009)

Definición 1: un kernel es una función K, tal que para todo $x, z \in X$

$$K(x, z) = \{\phi(x).\phi(z)\} \tag{20}$$

Donde ϕ es un mapeo de X a un espacio de características F.

La clave del enfoque es encontrar una función kernel que pueda ser evaluada eficientemente. Una vez que tenemos tal función de decisión, la regla puede ser evaluada

$$f(x) = \sum_{i=1}^{i} \alpha_i y_i K(x_i, x) + b \tag{21}$$

9.15. Clasificación basada en algoritmo de codificación Binaria para imágenes Hiperespectrales

La regla de codificación define cómo traducir toda la información útil en códigos binarios. Explicaciones específicas para las dos partes del código se puede encontrar de la siguiente manera.

a) **Imagen Hiperespectral:** Los espectros: La regla de codificación de los espectros sigue el método tradicional de codificación binaria. Sin embargo, en lugar de los espectros del píxel individual, los espectros promedio de La región segmentada se utiliza basándose en el trabajo de MAZER Y LEE (Mazer & Lee , 1988) donde

asumimos que $\overrightarrow{X_{ij}}$ representa las L-dimensiones vectoriales de un pixel o super pixel (i, j) en una imagen Hiperespectral con un numero de niveles espectrales L, dado que v_{ij} representa el promedio espectral de los pixeles (i, j), estos códigos de vector binario $\overrightarrow{Y_{ij}^{sa}}$ con un tamaño de L-bits donde:

$$\overrightarrow{Y_{ij}^{sa}} = H\left\{\overrightarrow{X_{ij}} - v_{ij}\right\} \tag{22}$$

Donde $H(v)$ es definido por:

$$H(v) = \begin{Bmatrix} o, v < 0 \\ 1, v \geq 0 \end{Bmatrix} \tag{23}$$

Además, un vector de código $\overrightarrow{Y_{ij}^{ss}}$ con un tamaño de L-bits es introducido por un contador local de cobertura en correspondencia de cada Ondícula como:

$$\overrightarrow{Y_{ij}^{ss}} = H\left\{\left[X_{ij}(l+1) - X_{ij}(l-1)\right]\right\}, l = 1, 2\ldots, L \tag{24}$$

Donde $\overrightarrow{Y_{ij}^{ss}} = H\left\{\left[X_{ij}(2) - X_{ij}(L)\right]\right\}$ cuando $l = 1$ y $\overrightarrow{Y_{ij}^{ss}} = H\left\{\left[X_{ij}(1) - X_{ij}(1)\right]\right\}$ cuando $l = L$.

Por lo tanto, al combinar los $\overrightarrow{Y_{ij}^{sa}}$ y $\overrightarrow{Y_{ij}^{ss}}$ representados en las ecuaciones (19) y (21) con un vector $\overrightarrow{Y_{ij}}$ y un tamaño de 2L-bits es construido y representado en el espectro de un los pixeles (i, j) en una imagen Hiperespectral (Xie, 2014).

b) **Textura, forma y altura:** en el método PIBE (Probability-Based Improved Binary Encoding) propuesto, por sus siglas en inglés, define el tamaño del código de textura, forma y altura es variable según al número de funciones totales en (N). Cada característica está descrita por cinco códigos binarios, y cada código corresponde a un contenedor que es un grupo de valores de cada característica. Los grupos se dividen por igual por el número de píxeles, por ejemplo, un quinto, dos quintos, tres quintos, y cuatro quintos del total de píxeles (Mazer & Lee , 1988), o se obtienen de los valores mínimos de los histogramas de características. En cada código, el contenedor se establece en "1" si el valor de la función "pertenece a"; de lo contrario, el contenedor está configurado en "0".

Además, los códigos para la textura, forma y altura están combinados en un vector $\overrightarrow{Z_i}$ con un tamaño de 5N-bits:

$$\overrightarrow{Z_i} = \left[Z_i(1), Z_2(2), \ldots, Z_i(5N)\right]^T \tag{25}$$

c) Clases de Referencia: para que sean compatibles con los códigos binarios de entrada, las clases de destino deben presentarse de la misma manera. Los datos de entrenamiento y el conocimiento general son dos formas disponibles para obtener estos valores. Este documento combinó ambas formas de formar el código objetivo (datos de entrenamiento para los espectros y conocimiento general de la forma, textura y altura de los perfiles espectrales que elementos de búsquedas).

En las zonas urbanas, la mayoría de las carreteras forman redes ramificadas, con un ancho de 15 a 50 m y una longitud mucho más larga, incluso en el caso de calles estrechas interrumpidas por copas de árboles en la imagen. En áreas con vegetación, los árboles / arbustos y el césped rara vez tienen bordes rectos, mientras que las tierras de cultivo son más regulares y compactas. Además, los espacios abiertos (por ejemplo, estacionamientos y campos deportivos) tienen formas similares a los edificios. Las áreas edificadas (por ejemplo, edificios y áreas industriales) tienen una gran variación de textura y un amplio rango de textura, mostrando una alta densidad en una imagen de variación de textura (Song, Cai, Lin, An, & Chang, 2016).

d) Espectro de Probabilidad de Permanencia: En el estudio, la distancia de Hamming se utiliza para medir la similitud de coincidencias de firmas espectrales:

$$D_{sp}(\overrightarrow{Y_i}, \overrightarrow{Y_m}) = \sum_{l=1}^{2L} Y_i(l)(XOR)Y_m(l) \tag{26}$$

Donde i y m representan una región de la imagen y los ROI de clasificación (Land Cover Types) respectivamente, y D_{sp} representa la disimilitud, entre el código binario construido a partir de la imagen y el correspondiente obtenido de las clases objetivo durante la clasificación. Seguidamente la definición generar dos códigos cuando D_{sp} está cercano a cero.

Además, para cada segmento de la imagen, la probabilidad de pertenencia a los espectros se define mediante:

$$P_{sp}(i) = \frac{P_0 - P_1}{\max D - \min D} D_{sp}(i) + \frac{P_1 \max D - P_0 \min D}{\max D - \min D} i = 1, 2, \ldots, n \tag{27}$$

Donde $P_{sp}(i)$ es la probabilidad de pertenencia espectral del segmento de la imagen al objetivo i, n es el número de targets, $D_{sp}(i)$ es la distancia del espectro a los targets i, min D es el mínimo valor de $D_{sp}(i)$, max D es el máximo valor de $D_{sp}(i)$ y $[P_0, P_1]$ es la probabilidad de rango. El segmento de imagen tiene la probabilidad de pertenencia más baja para el objetivo P_0 si, $D_{sp}(i) = \max D$ y el segmento de imagen tiene la probabilidad de pertenencia más alta P_1 para el objetivo $D_{sp}(i) = \min D$ si en la práctica, P_0 suele ser mayor que 0 y P_1 menor que 1. En el estudio, adoptamos $P_0 = 0.2$ y $P_1 = 0.9$ (Hamming, 1950).

9.16. Matriz de Confusión

Como resultado de la fase de muestreo se tiene un listado de puntos de prueba para los que se posee tanto su cobertura real como la deducida por la clasificación. Con estos datos puede formarse una matriz, denominada de confusión puesto que recoge los conflictos que se presentan entre categorías. Se trata de una matriz bidimensional, en donde las columnas se ocupan por las clases de referencia, y las filas por las categorías deducidas de la clasificación.

Lógicamente ambas tendrán el mismo número y significado, por lo que se trata de una matriz cuadrada: n × n, donde n indica el número de clases (Hamming, 1950).

La fiabilidad global del mapa (*overall accuracy*) se calcula sumando el número de píxeles clasificados correctamente y dividiendo por el número total de píxeles. Por una parte, el número total de píxeles es la suma de todos los píxeles de todas las clases reales en el terreno (áreas de evaluación). Por otra parte, los píxeles clasificados correctamente indican el número de píxeles que fueron clasificados en la clase real a la que pertenecen. Éstos se encuentran a lo largo de la diagonal principal de la matriz de confusión. En cambio, los situados fuera de la diagonal principal suponen errores de asignación (marginales). Por un lado, los residuales en filas representan los errores de comisión, por otro, los residuales en columnas expresan los errores de omisión.

Los errores de comisión representan los píxeles clasificados en una categoría a la que no pertenecen. Se plantea como riesgo del usuario. Los errores de omisión constituyen los píxeles que conforman una determinada categoría, pero no han sido clasificados en dicha categoría. Se plantea como riesgo del productor (Pramod & Manoj, 2004).

Otra forma de medir la precisión total de la clasificación es el cálculo del coeficiente kappa (κ). Este coeficiente mide la concordancia entre los píxeles clasificados y los pertenecientes a la clase real. Un coeficiente kappa (Cohen, 1960) de valor igual a 1 representa una concordancia perfecta, mientras que un valor igual a 0 representa concordancia nula. Se calcula aplicando la siguiente expresión:

$$k = \frac{N\sum_{i=1}^{n} m_i - \sum_{i=1}^{n}(G_i, C_i)}{N^2 - \sum_{i=1}^{n}(G_i, C_i)} \tag{28}$$

donde *i* es el número de clases; *N* es el número total de píxeles clasificados que son comparados con la clase real; M_i es el número de píxeles perteneciente a la clase real *i*, que también ha sido clasificada con una clase *i* (es decir, los valores que se encuentran en la diagonal de la matriz de confusión); C_i es el número total de píxeles clasificados que pertenecen a la clase *i*; y G_i es el número total de píxeles de la clase real (verdad-terreno, áreas de evaluación) que pertenecen a la clase *i*. A diferencia de la fiabilidad global, este coeficiente tiene en cuenta los errores de comisión y omisión (Díaz, 2017).

9.17. Segmentación y Clasificación de Texturas

Se representa como un atributo que representa la disposición espacial de los niveles de gris de los pixeles en una región Si el nivel de gris es constante en toda la región de un objeto, se

dice que el objeto no tiene textura. Si el nivel de gris varia significativamente dentro del objeto, entonces el objeto tiene textura. Cuando tratamos de medir la textura, se trata de cuántica la naturaleza de la variación del nivel de gris dentro de un objeto (Chuvieco, 2000).

Una característica de textura es un valor, calculado a partir de la imagen de un objeto, que cuántica en algún sentido la variación de nivel de gris en el objeto. Por esta razón cobran especial interés las técnicas de análisis de textura, mediante las cuales se describe la distribución de niveles de gris relativa al vecindario de cada píxel calculando variables estadísticas que describan propiedades como la variabilidad, el contraste, valor medio, etc. y que permitan obtener nuevas imágenes o bandas de textura que puedan utilizarse de forma aislada o combinadas con bandas espectrales para clásica las imágenes originales (Fernandez-Sarria, 2002)

Como dijimos antes la textura hace referencia a la heterogeneidad con la que aparecen los tonos de gris en una imagen; los índices numéricos de textura se dirigen a medir la variedad espacial entre los ND (niveles de gris) de los pixeles que forman la imagen. Podemos dividir estos índices entre aquellos que operan sobre toda la imagen, por ejemplo: Desviación estándar, Dimensión fractal, Autocorrelación espacial y Semi-variograma, y los que se apoyan en ventanas móviles, que se desplazan consecutivamente afectando al pixel central en cada paso, por ejemplo: *Desviación estándar local, Diferencias absolutas, entropía, Medidas sobre la matriz de coincidencias y Dimensión textual* (Chuvieco, 2000) donde:

$$T = \left| ND_{\max,i} - ND_{\min,i} \right| \tag{29}$$

Siendo ND los niveles digitales máximo y mínimos e i cualquiera de los pixeles adyacentes al central de la ventana Esta medida se ha empleado para estimar la textura en zonas afectadas por diversos procesos ambientales. La información sobre la textura de una imagen se utiliza tanto para la segmentación como para la clasificación de imágenes. En teledetección, en la práctica, el análisis de textura se basa en a la extracción de características estadísticas.

Si deseamos un sistema para distinguir entre objetos de diferente tipo, primero debemos decidir que características de los objetos deben ser medidas para producir parámetros descriptivos. Los atributos particulares que se miden se llaman características (feature) del objeto, y los valores resultantes de los parámetros conforman el vector característico de cada objeto. La selección adecuada de los parámetros es importante, ya que serían utilizados para identificar los objetos. El valor medio y la desviación estándar son dos características muy utilizadas para la clasificación (Theodoridis, 2002).

En el caso general, si se tienen l características $x_i, i = 1, 2 \ldots, l$ se usa como vector característico

$$x = \left[x_1, x_2 \ldots, x_l \right]^T \tag{30}$$

Donde T denota transposición. Cada uno de los vectores característicos identifica de manera única al objeto (Theodoridis, 2002)

9.17.1. Segmentación basada en el uso de un umbral

El uso de umbral es una técnica de segmentación ampliamente utilizada. Se dice que es un método de producción de regiones de uniformidad dentro de una imagen basada en algún criterio de umbral. La operación de umbral puede ser vista como una operación que implica realizar comprobaciones frente a una función T de la forma:

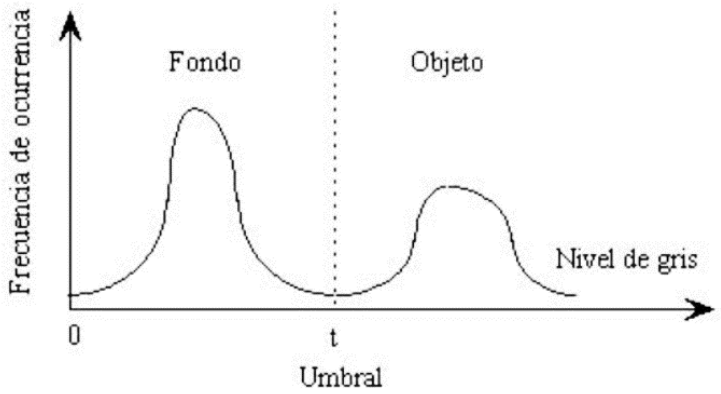
$$T = T\{x, y, A(x, y), f(x, y)\} \tag{31}$$

Donde $f(x, y)$ es un nivel de gris del punto (x, y), y $A(x, y)$ representa alguna propiedad local en el vecindario de este punto, por ejemplo, la media del nivel de gris de una vecindad centrada en (x, y) (Melendez, 2003) entonces una imagen se definiría basado en el umbral como:

$$g(x, y) = \begin{cases} 1 \rightarrow f(x, y) \geq T \\ 0 \rightarrow f(x, y) < T \end{cases} \tag{32}$$

Esta técnica se emplea cuando hay una clara diferencia entre los objetos a extraer respecto del fondo de la escena. Los principios que rigen son la similitud entre los pixeles pertenecientes a un objeto y sus diferencias respecto al resto. Por tanto, la escena debe caracterizarse por un fondo uniforme y por objetos parecidos. Al aplicar un umbral, la imagen de niveles de gris quedará binaria; etiquetando con 1, los pixeles correspondientes al objeto y con 0, aquellos que son del fondo

La selección del valor del umbral se realiza generalmente a partir del histograma de la imagen. así si una imagen está compuesta de un objeto que aparece en la escena sobre un fondo, entonces es de esperar que el histograma sea bimodal. Por ejemplo, si el objeto es más claro que el fondo, en el histograma aparecerán dos picos, el ubicado en los valores de gris más elevados correspondientes al objeto y otro pico para niveles de gris más bajos, correspondientes al fondo. Mostrando un histograma bimodal, en el cual el umbral se ubica entre los dos picos del histograma (Melendez, 2003)



9.18. Tratamiento de imágenes de Radar

Para reconstruir la evolución de la deformación del terreno se han desarrollado diferentes técnicas que estudian la información de deformación (diferencias de fases) de estos píxeles que existen en los interferogramas diferenciales. Todas las técnicas propuestas, se diferencian principalmente en cómo se seleccionan los elementos puntuales o blancos coherentes de los interferogramas, para desarrollar nuestro proyecto se uso 3 imágenes de diferentes épocas 2011, 2016 y una de 2019, como base para la obtención de un interferograma base para el estudio de los desplazamientos entendiendo el tipo de suelo y composición geológica presente en la zona, ya que se cuenta con diferentes métodos generales de generación de interferogramas nos basaremos en la técnica usada por el ingeniero Gonzales (González, 2010) como se muestra en la Ilustración 18 donde dependeremos de algunos elementos como DTM modelos digitales de terreno para determinar el interferograma de la zona

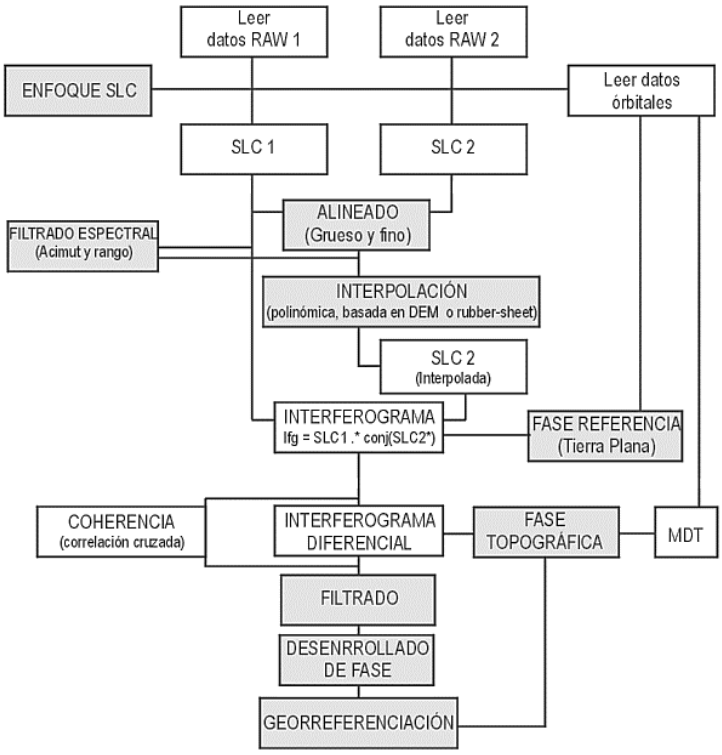


Ilustración 18. Diagrama de flujo esquemático ilustrativo del procesado interferométrico diferencial de imágenes SAR

Fuente: (González, 2010)

9.19. Radar de Apertura Real (RAR)

El principio de funcionamiento de un radar, particularizado para un radar en un satélite, es relativamente simple. Un pulso electromagnético (Ilustración 1) emitido en un instante por una antena radar en un satélite viaja por la atmósfera hasta encontrar un objeto con el que interacciona. Esta interacción hará que parte de la energía del pulso se absorba y otra arte se refleje. Así, una parte de la energía reflejada se dirigirá en la dirección de la antena emisora,

a la que llegará transcurrido un lapso. La energía recibida en la antena radar se registrará como un valor de fase y otro de intensidad, que se asignan a un número complejo. La fase nos informa del tiempo transcurrido, que es proporcional a la distancia recorrida, y la intensidad nos informa de la rugosidad, de la pendiente y de las propiedades eléctricas del objeto, que a su vez dependen de la temperatura, humedad, etc.

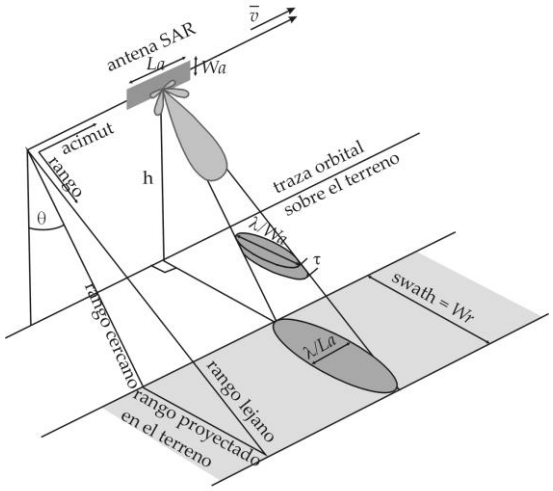


Ilustración 19. Geometría de adquisición de un sistema RAR instalado en un satélite artificial.

Fuente: (Méndez, 2010)

En la Ilustración 19, se muestra una antena radar de apertura real (RAR), de visión lateral rectangular de dimensiones La y Wa, instalada en un satélite que viaja a una velocidad ($\bar{v}$) en la dirección de avance del satélite (acimut), y a una altitud sobre el terreno (h). Los pulsos son enviados desde la antena hacia el terreno en una dirección ($rango$) que forma un cierto ángulo de inclinación (θ) con respecto a la vertical. Esto hace que el área iluminada tenga una anchura proporcional al patrón de la antena RAR en la dirección de rango $w_r = \lambda / W_a$, que proyectada sobre el terreno ($swath$) (Méndez, 2010):

$$W_r = \frac{\lambda R}{W_a \cos\theta} \tag{33}$$

donde W_r es la anchura del área iluminada en rango, λ es la longitud de onda y R es la distancia a un punto sobre el terreno. Así, la resolución espacial para la dirección de rango (Entendida como la distancia mínima a la que dos objetos diferentes se pueden distinguir.) depende de la diferencia en tiempo entre pulsos, siendo la diferencia de tiempos mínima igual a la duración del pulso (t). Entonces la resolución en rango $\delta_r = CT/2$ proyectada sobre el terreno será:

$$\delta_r = \frac{CT}{2\sin\theta} \tag{34}$$

En realidad, separar pulsos a esta frecuencia no es posible dada la poca cantidad de energía que se devuelve al sensor en relación con el ruido del sistema (Curlander, 1991). En su lugar,

se usa una frecuencia modulada o pulso $chirp$, con un ancho de banda de B_w, con lo que se logran resolver diferencias de tiempo de $1/B_w$, lo que se traduce en una resolución en rango proyectada sobre el terreno de

$$\delta_r = \frac{c}{2B_w \sin\theta} \tag{35}$$

Para los satélites SAR de la ESA (ERS-1/2 y Envisat), que poseen un ancho de banda $B_w \approx$ 15,5 MHz, se consigue una resolución $\delta_r \approx$ 25 m (Lanari, 1999)

En la dirección (acimut) de avance, dado que los objetos que están situados a la misma distancia en rango son devueltos al mismo instante a la antena, la distancia mínima a la que dos puntos se pueden discriminar es proporcional a la longitud del pulso del patrón de la antena RAR ($w_a = \lambda / L_a$) y, en consecuencia, a la longitud del área iluminada.

$$\delta_a = \frac{\lambda h}{L_a \cos\theta} = \frac{\lambda}{L_a} R \tag{36}$$

Esto equivale a unos 5 km para un sensor del tipo de los satélites SAR de la ESA. Si se quiere obtener una $\delta_a \approx \delta_t, L_a$ debería ser del orden de unos 500 m. Para superar esta limitación se desarrolló el concepto de radar de apertura sintética (SAR).

9.20. Radar de Apertura Sintética SAR

Al finalizar la Segunda Guerra Mundial, el uso y perfeccionamiento de los sistemas radar permitieron desarrollar los denominados procesados coherentes, en los que la información de fase y amplitud se preservaban desde la emisión hasta la recepción Wiley en 1965, (Méndez, 2010). descubrió que usando el efecto Doppler se podía conseguir sintetizar una antena real de grandes dimensiones.

Así, el concepto de radar de apertura sintética se basa en que un punto en el terreno, por ejemplo P_o, puede recibir un cierto número de pulsos durante el paso orbital de la antena SAR. De esta forma según se muestra en la Ilustración 20 a) es el punto P_o recibiendo los pulsos en la trayectoria del satélite desde el punto P_1 hasta P_2 hora, dado que la frecuencia emitida varía dependiendo de la posición relativa entre emisor y receptor debida al movimiento (véase Ilustración 20 c) efecto Doppler), entonces la diferencia Doppler se utiliza para separar los pulsos reflejados por P_0 durante el trayecto $P_1 - P_2$ y obtener una imagen con una resolución espacial equivalente a la de una antena real (RAR) de dimensión en acimut L_s (véase Ilustración 20 b))así, la resolución en acimut de un sensor SAR es tal que:

$$\delta_a = \frac{\lambda}{L_s} R \tag{37}$$

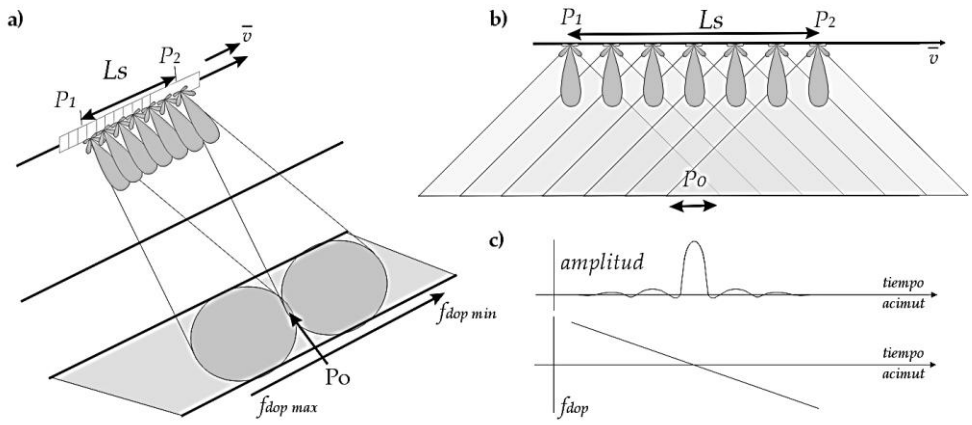


Ilustración 20. a) Concepto de un radar de apertura sintética. b) Principio del SAR en la dirección de avance del satélite. c) Relación de la amplitud normalizada del patrón de la antena SAR, donde la función seno cardinal es una función analítica sinusoidal con amplitud que se amortigua con la distancia, es la Transformada de Fourier de una señal rectangular.

Fuente: (Méndez, 2010)

Entonces sí $L_s = 2\lambda R / L_a$ que es equivalente a la resolución en el terreno del sensor en modo RAR, entonces la ecuación 30 se puede escribir simplemente como:

$$\delta_a = \frac{L_a}{2} \tag{38}$$

Como pudimos comprobar la δ_a de un sistema SAR solo dependerá de la longitud de la antena SAR en la dirección al acimut L_a

9.21. Ruido de Speckle

Las imágenes de Radar de apertura sintética (SAR), se han vuelto una importante fuente de información sobre la superficie de la Tierra y han sido ampliamente usadas en muchos campos, como la ecología, hidrología, geología y oceanografía. Sin embargo, las imágenes SAR, por su naturaleza, siempre exhiben una alteración en su calidad fotográfica. Esta modificación, se le denomina “ruido Speckle”. El ruido Speckle se manifiesta en imágenes con iluminación coherente, como las de scanner ultrasónico, sonar y Radar de apertura sintética (SAR). Este fenómeno se desvía del modelo clásico, en el que se supone que el ruido es Gaussiano e independiente de la señal y adicionado al verdadero valor (modelo aditivo de ruido gaussiano). El Speckle, en cambio, es multiplicativo y no Gaussiano (en los formatos intensidad y amplitud), y dificulta la interpretación de las imágenes porque el “efecto de sal y pimienta” degenera la información (Herranz, 2015).

El Speckle es creado por las dispersiones de la iluminación del Radar por ser demasiado pequeñas con respecto a longitud de onda como para ser capturadas individualmente. Dado

que la señal de radar se dice que es coherente (es transmitida en un rango estrecho de onda), la energía dispersada tiende a ser reforzada (interferencia constructiva) o a ser suprimida (interferencia destructiva). Cuando picos altos de amplitud de onda coinciden, se crea un retorno con brillo; contrariamente, cuando picos de amplitud alto coinciden con los valores de picos de baja amplitud tienden a cancelarse entre sí, creando un retorno oscuro. Debido a que el Speckle constituye una forma de ruido (porque no transmite información útil), generalmente se procesan bien mediante procesos MultiLook que iluminan la escena con frecuencias ligeramente diferentes que producen retornos independientes que luego pueden ser promediadas para reducir el efecto de la Speckle (Zozayaa, 2017).

Estas dos estrategias de filtrado se caracterizan ya sea como no adaptativas o adaptativas. Los filtros no adaptativos requieren menos computo ya que se aplica un solo filtro a toda la imagen de manera uniforme, mientras que los filtros adaptativos complejos se ajustan a las propiedades locales del entorno, con enfoque en la preservación de los bordes y los límites. Todas las estrategias, tienen la intención de extraer estimaciones precisas de la dispersión, pero siempre se corre el riesgo de eliminar la información original de la escena, así que siempre hay que equilibrar los beneficios y las perdidas dentro de cada imagen en particular (Resources, 2016). Por este motivo, para tener un mayor control del filtrado, se aborda utilizar filtros adaptativos. Siempre es deseable reducir o filtrar el ruido previamente a una interpretación para luego realizar el análisis de esta. La mayoría de los filtros para reducción de Speckle comúnmente utilizados, tienen buenos resultados para suavizar el ruido. Aunque, las imágenes resultantes siempre están sujetas a una previsible degradación de la resolución tanto espacial como radiométrica. Este deterioro concluye en una pérdida de información de la imagen en mayor o menor medida, dependiendo del comportamiento del filtro utilizado. La cantidad deseada de reducción de Speckle debe estar balanceada con la cantidad de detalle requerido para la escala espacial y para la naturaleza de la aplicación en cuestión. Para interpretaciones a gran escala, los detalles minuciosos pueden ser en muchos casos ignorados. Así, un filtrado amplio del ruido Speckle y, consecuentemente, con pérdida de detalles de la imagen puede ser aceptable o apropiado. Mientras que para aplicaciones donde los detalles finos y de alta resolución son necesarios, el filtro de Speckle debe enfocarse en la preservación de detalles. Este aspecto puede ser tan importante como a su vez la reducción del ruido Speckle. A continuación, se presentan una serie de filtros conocidos para la reducción de ruido Speckle (Herranz, 2015).

9.21.1. Modelos Básico Matemático de Corrección de Filtros

Se supone el modelo multiplicativo,

$$I(t) = R(t).u(t) \tag{39}$$

donde:

- t = (x, y), representan las coordenadas espaciales de la imagen,
- I(t), es el valor de intensidad observado en la imagen,
- R(t), es la reflectividad correspondiente al terreno,
- u(t), es ruido Speckle multiplicativo estadísticamente independiente de R(t), con media u y varianza.

9.21.2. Filtro de Kuan

En el filtro desarrollado por Kuan, el modelo multiplicativo es transformado a un modelo aditivo dependiente de la señal. Luego se aplica una minimización al criterio de error cuadrático

medio (MMSE), obteniendo como resultado la misma ecuación que Lee, pero diferente función de ponderación (Curlander, 1991).

$$R(t) = I(t).W(t) + \bar{I}(t).(1 - W(t)) \tag{40}$$

La ecuación refleja una suma ponderada de los valores observados I(t) y la media local I(t). La función de ponderación utilizada es:

$$W(t) = \frac{1 - C_u^2 / C_l^2(t)}{1 + C_u^2} \tag{41}$$

donde Cu = u/u es el coeficiente de variación del ruido, u y u son la desviación estándar y la media del ruido respectivamente.

9.21.3. Filtro de Lee

En el filtro formulado por Lee, se aproxima el modelo multiplicativo con un modelo lineal. Luego también se minimiza el criterio de error cuadrático medio (MMSE) aplicado al modelo lineal dando como resultado:

$$R(t) = I(t).W(t) + \bar{I}(t).(1 - W(t)) \tag{42}$$

donde la función de ponderación es:

$$W(t) = 1 - C_u^2 / C_l^2(t) \tag{43}$$

Y

$$C_u = \frac{\delta_u}{\bar{u}}, C_l = \frac{\delta_{\bar{I}(t)}}{\bar{I}(t)} \tag{44}$$

son los coeficientes de variación del ruido Speckle u(t) y de la imagen I(t) respectivamente.

9.21.4. Filtro de Frost

El filtro de Frost difiere de la definición de Lee y de Kuan con respecto a que la reflectividad de la escena es estimada realizando una convolución entre la imagen observada y la respuesta a un impulso de un sistema SAR. La respuesta a un impulso del sistema SAR, se obtiene realizando una minimización del error cuadrático medio (MMSE) entre la imagen observada y el modelo de reflectividad de la escena que se asume como un proceso autorregresivo. El filtro resultante luego de algunas simplificaciones queda como:

$$m(t) = e^{-KC(t_0)|t|} \tag{45}$$

Donde:

- K, es una constante que controla el factor de amortiguamiento o *damping* factor de la función de respuesta a un impulso,
- t0, denota el píxel a ser filtrado,
- Cl(t0), denota el coeficiente de variación dentro de la ventana con centro t0.

Se puede ver que si Cl(t0) tiene un valor pequeño, el filtro se comporta como un filtro de paso bajo, filtrando el ruido Speckle, pero cuando Cl(t0) tiene un valor alto, el filtro tiene tendencia a preservar el valor original observado de la imagen (Belmonte, 2009).

9.22. Interferometría Diferencial (DinSAR)

La interferometría diferencial (DinSAR, por sus siglas en ingles), es una variante del InSAR para medir deformaciones, desplazamientos o cambios sobre la superficie a partir de la obtención de dos imágenes complejas tomadas en distintos momentos. Producto de esta técnica, se generan mapas de desplazamiento del terreno y el cálculo de la coherencia relativa.

Existen distintas técnicas para el procesado DinSAR; por ejemplo, la obtención de los desplazamientos se realiza a partir de las zonas alejadas del fenómeno (volcán, falla, deslizamiento), zonas que se suponen libres de cambios y con geometría constante, lo que permite filtrar ciertas diferencias “no reales”, producidas por cambios atmosféricos. A partir de las zonas alejadas se van “integrando” hacia el centro de la zona de estudio, obteniendo los desplazamientos totales (Camacho, 2018).

La fase que se asocia al desplazamiento del terreno debe ser extraía del interferograma generado con el par interferométrico. Si se aísla la fase, es posible estimar la componente del movimiento. La ecuación para generar el interferograma a partir de un par interferométrico satisface la forma:

$$\phi_{\text{int}} = \phi_{Topo} + \phi_{Mov} + \phi_{Atm} + \phi_{Ruido} \tag{46}$$

Donde ϕ_{int} corresponde al interferograma, ϕ_{Topo} es la componente irregular de la topografía del terreno, ϕ_{Mov} es la componente de la deformación o movimiento que sufre el terreno por desplazamiento en cualquier dirección XYZ, ϕ_{Atm} es la componente de contribución de la atmosfera a la señal cuando atraviesa las diferentes capas, ϕ_{Ruido} que es la componente de ruido o perturbación de la señal. Suponiendo que la geometría en el suelo cambia ligeramente su posición relativa en el intervalo de tiempo de dos observaciones SAR (subsidencias del suelo, deslizamientos de tierra, sismos, etc.). En estos casos, el término de la fase aditiva, que es independiente de la línea base, aparece en la fase interferométrica de la forma:

$$\Delta\phi_d = \frac{4\pi}{\lambda} d \tag{47}$$

Donde $\Delta\phi_d$ es la fase interferométrica, λ es la longitud de inda del sensor y d es el desplazamiento de dispersión relativa proyectada en la dirección del rango inclinado (Silleco, 2010), Después de la remoción de la fase topográfica, se obtienen las contribuciones de altitud y movimiento de la forma:

$$\Delta\phi = -\frac{4\pi B_n q}{\lambda R \sin\theta} + \frac{4\pi}{\lambda} d \tag{48}$$

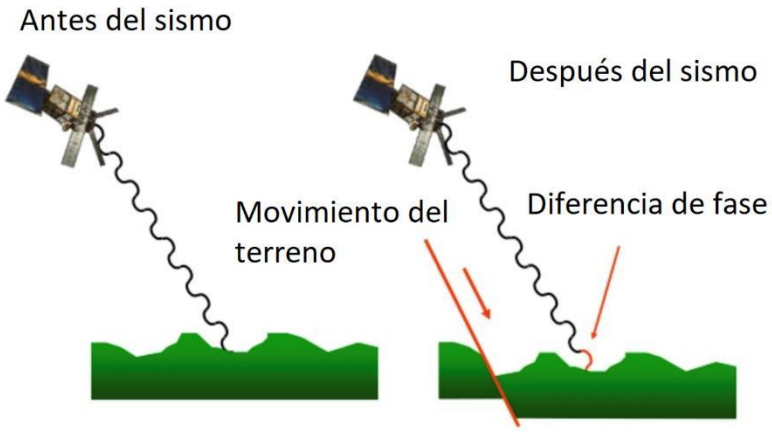


Ilustración 21. Aumento de la fase en la dirección del rango por desplazamiento del terreno asociado a un sismo

Fuente: (Silleco, 2010)

Además, si está disponible un modelo de elevación digital (DEM), la contribución de altitud se puede restar de la fase interferométrica (generando el llamado interferograma diferencial) y se puede medir el componente de movimiento del terreno. En el caso de ERS (European Remote Sensing Satellite, por sus siglas en inglés) con λ = 5,6 cm y suponiendo una línea base perpendicular de 150m (un valor bastante común), se cumple la siguiente expresión:

$$\Delta\phi = -\frac{q}{10} + 225d \tag{49}$$

9.22.1. Contribución de fase debida a la topografía con cambios de altura

Si la topografía no es llana, a la componente de Tierra plana se le añade una fase que es proporcional a la diferencia de altitud entre los puntos a y b del interferograma, así (Lanari, 1999):

$$\phi_{Topo} = \frac{4\pi B_{\perp}}{\lambda R \sin\theta}\delta h \tag{50}$$

Donde, δh es la diferencia de altitud entre los puntos a y b. además que si la componente topográfica $B_{\perp}$ = 0 la componente también tendera a cero y por consecuencia no se tendrá un valor de fase verdaderamente sustancial en el interferograma.

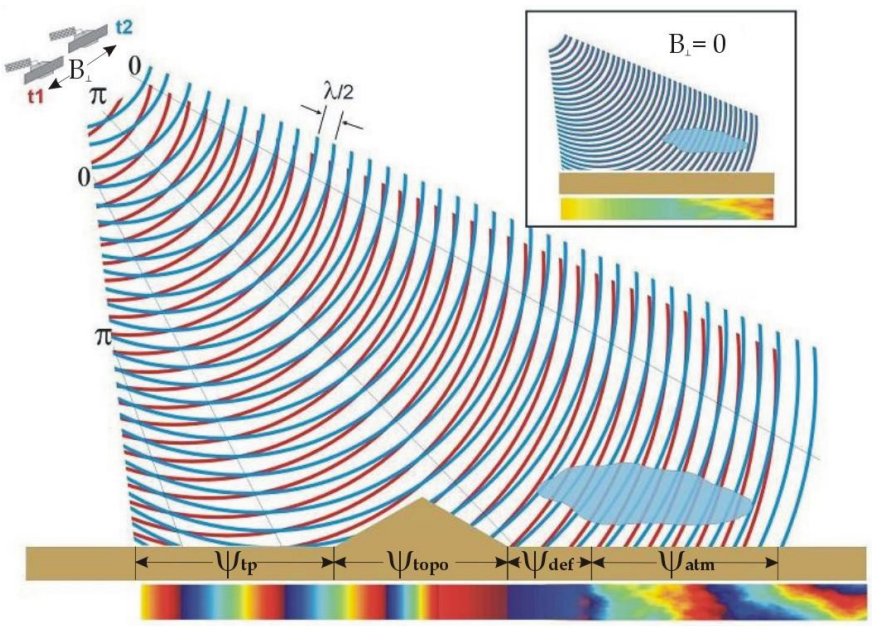


Ilustración 22. Contribuciones a la fase de un interferograma, donde los componentes corresponden con las geometrías de la imagen Máster y Slave, B corresponde con línea base a la perpendicular igual a cero, quedando solo la distribución por deformación del terreno y atmosférica.

Fuente: (Méndez, 2010)

Finalmente, debemos introducir un parámetro conveniente para evaluar las propiedades estadísticas de los interferogramas, el coeficiente de correlación interferométrica. El coeficiente de correlación interferométrica nos cuantifica el grado de la similitud entre las fases de las imágenes SAR (Máster M, Slave S), donde la variable fase se considera circular estacionaria gaussiana y con media cero, así el coeficiente de correlación interferométrica se describe como

$$p = \frac{E\left\{MS^*\right\}}{\sqrt{E\left\{\left|M.M^*\right|^2\right\}E\left\{\left|S.S^*\right|^2\right\}}} \tag{51}$$

Donde E indica la esperanza matemática, y el símbolo * indica el conjugado complejo. Este coeficiente de correlación no se puede calcular pixel a pixel, por eso, se suele aproximar espacialmente con el estimador ($\left(\left|\overline{p}\right|\right)$ basados en el estimador de máxima verosimilitud de la fase interferométrica $\left(\sum_{i=0}^{N.M} M_i S_i^*\right)$ encontrando que:

$$p = \left| \frac{\frac{1}{NM}\sum_{i=0}^{N.M} M_i S_I^*}{\sqrt{\frac{1}{NM}\sum_{i=0}^{N.M} M_i M_I^* \frac{1}{NM}\sum_{i=0}^{N.M} S_i S_I^*}} \right| \tag{52}$$

Donde N.M pixeles es el entorno del estimador de coherencia, que puede tomar valores entre $[0,1]$ donde 1 representa la correlación máxima y 0 la mínima. Este estimador esta sesgado para entorno de estimaciones pequeñas (Méndez, 2010).

9.23. ISO 19157 La gestión de la calidad de la Información Geográfica

Las bases conceptuales de la calidad de datos son básicamente las normas ISO 19100 que establecen cómo describir de manera normalizada la calidad de la IG, sus metadatos y especificaciones. En el caso de la calidad de servicios, consideraremos esencialmente los estándares OGC y las Normas de Ejecución para servicios de la Directiva INSPIRE, un intento muy serio de caracterizar la calidad de geo servicios, que se está llevando a cabo en un universo de más de 100.000 servicios. El tratamiento de la calidad en los productores de datos se ofrece desde una perspectiva centrada en la IG y no en los sistemas de gestión de la calidad (Ariza, 2018).

El modelo de calidad de datos actualmente más extendido a nivel internacional es el propuesto en la norma internacional ISO 19157. De manera resumida, se propone un modelo basado en distintos aspectos de la calidad, los denominados elementos de la calidad (p.ej. exactitud posicional absoluta, exactitud posicional relativa, comisiones y omisiones, corrección de la clasificación, etc.). Estos elementos son cuantitativos y para su evaluación la norma internacional ISO 19157 propone un conjunto de medidas normalizadas de calidad, y unos procesos básicos de evaluación. Con elementos de calidad y ámbitos concretos en los que se aplican, se pueden crear las especificaciones de productos de datos (ISO 19131) e informar sobre la calidad de unos datos en sus metadatos (ISO 19115). Los elementos de calidad que se proponen son bastante limitados, pero ISO 19157 también propone un elemento denominado usabilidad, que permite soslayar, en parte, esa limitación. Además, esta norma también permite evaluar la meta calidad (la calidad de las evaluaciones de la calidad) (López, 2017) la ilustración 23 muestra el modelo de solución para cumplir con la ISO 19157.

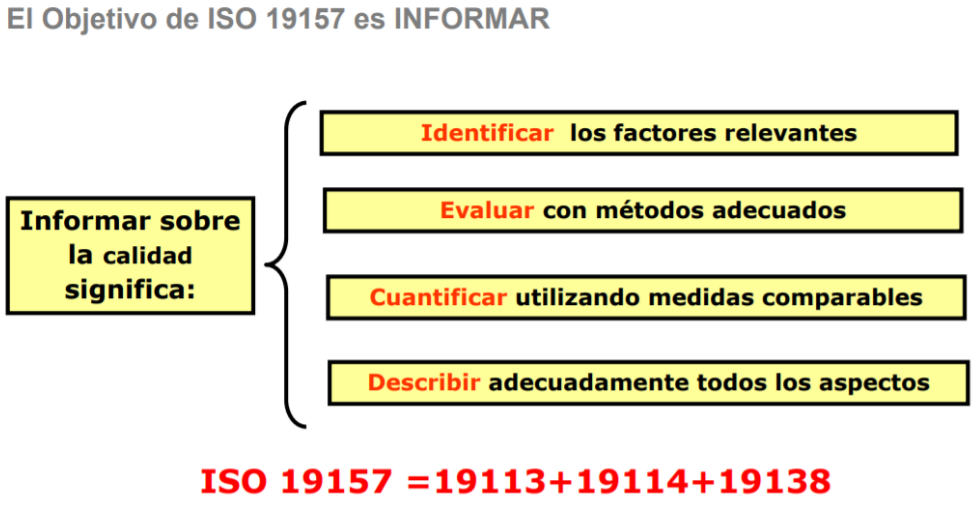


Ilustración 23. Modelo ISO 19157

Fuente: (López, 2017)

10. METODOLOGÍA Y RESULTADOS

La ilustración 24 describe la metodología propuesta para desarrollar los objetivos de la investigación basándonos en toda la teoría propuesta y el análisis de los resultados.



Ilustración 24. En la gráfica se describe la metodología emplear basados en el cumplimiento de los objetivos planteados para la presente investigación.

10.1. Adquisición de imágenes

Se requieren imágenes Hiperespectrales las cuales cuentan con gran cantidad de bandas, además se debe obtener de la misma zona de estudio perfiles espectrales de los elementos presentes para correlación de las imágenes y clasificación basadas en su riqueza espectral, a partir de un sensor Aero tripulados con 350 bandas SPECTIR; las imágenes de radar se basaran en Sentinel 3, Sentinel 1 y radar SAR que pueden ser descargadas directamente de internet en la página https://www.eodms-sgdot.nrcan-rncan.gc.ca/index_en.jsp propiedad de la organización de recursos naturales de Canadá y Sentinel 3 que están en la página https://earthexplorer.usgs.gov/ de la agencia nacional de ciencias de los estados unidos.

Para esta investigación se trabajo imágenes Hiperespectrales que cuentan con 365 bandas del sensor SPECTIR, peso base de 14 Gb, 4663 Columnas y 4304 filas, con un tamaño de pixel de 2 metros, sistema de coordenadas UTM 18N GCS WGS 1984, capturada el día 25 de octubre de 2019 ver Anexo 2.



Ilustración 25. Área de estudio, región de Magdalena Medio, San Martin Cesar

Se define como área de estudio la región de San Martin, Cesar El municipio de San Martín se encuentra localizado entre las coordenadas geográficas a 8°00′00″N 73°30′37″O, en la parte del bloque sur del Cesar, comprendida por los municipios de San Alberto, San Martín, Aguachica, Río de Oro, Gamarra y La Gloria; debido a la lejanía entre este municipio y la capital del departamento del Cesar (Valledupar), a una distancia de 354 kilómetros, existe una relación comercial importante con el departamento de Santander, especialmente con Bucaramanga; se evidencia una integración con los municipios de San Alberto y Aguachica, debido a su proximidad. Su extensión total de 905.55 Km2 aproximadamente, con una temperatura media que oscila entre los 28°C y 30º.

La región se encuentra ubicada al sur del departamento del Cesar, limitando: al sur con el Municipio de San Alberto, al oriente con el Municipio de Ocaña en el departamento de Norte de Santander, al norte con los Municipios de Aguachica y Río de Oro, al occidente con Santander con límites en el río Lebrija principalmente zona de explotación de hidrocarburos y yacimientos de minerales.

Se cuenta con información geológica de la zona, planos geológicos regionales con información estructural donde se muestra una falla inferida cercana al sitio de estudio. Geológicamente esta región corresponde a una franja de depósitos aluviales que se describe geomorfológicamente como abanico aluvial del cuaternario (depósitos recientes) como se muestra en la Ilustración 25, provenientes de la acción de ríos y cauces fluviales que han depositado sedimentos y sepultado material orgánico a lo largo del tiempo, lo cual servirá como referencia de estudio para la búsqueda de minerales indicadores y junto con las imágenes de radar tendremos la posibilidad de verificar el posible desplazamiento de la falla por año.

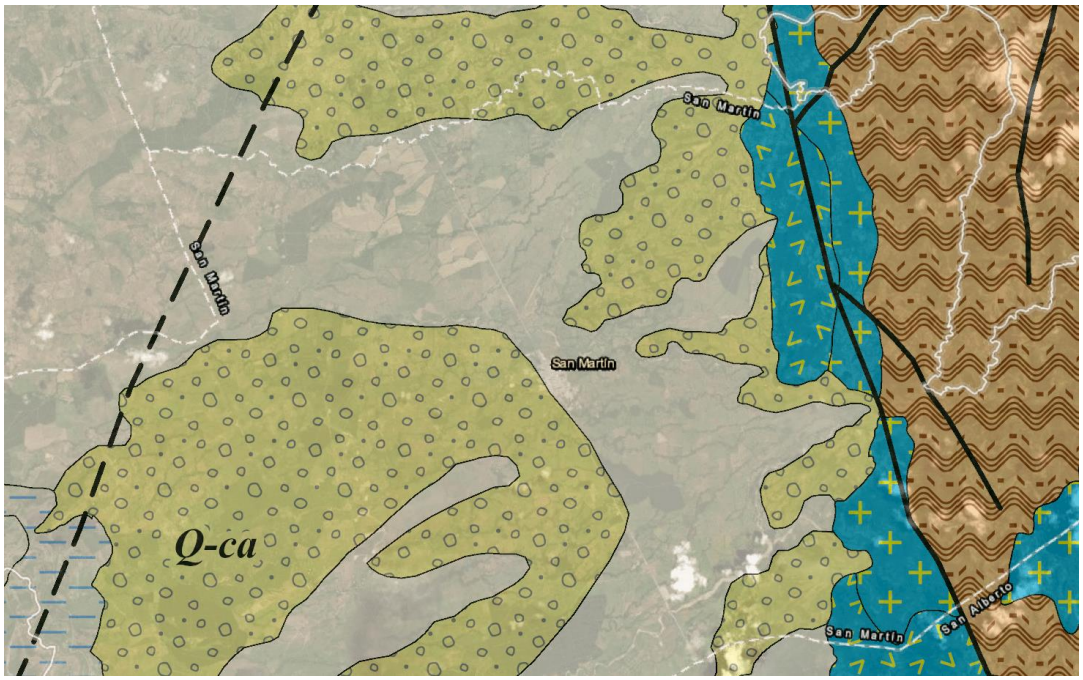


Ilustración 26. Unidades Cronoestratigráficas de la zona.

Fuente: Servicio Geológico Colombiano (SGC) Atlas Geológico de Colombia

En la Ilustración 26 se puede notar los dos tipos de estratigrafía presentes en el área de estudio, el primero (Q-al) un depósito aluvial y el según un abanico aluvial (Q-ca), con la presencia de una falla inferida.

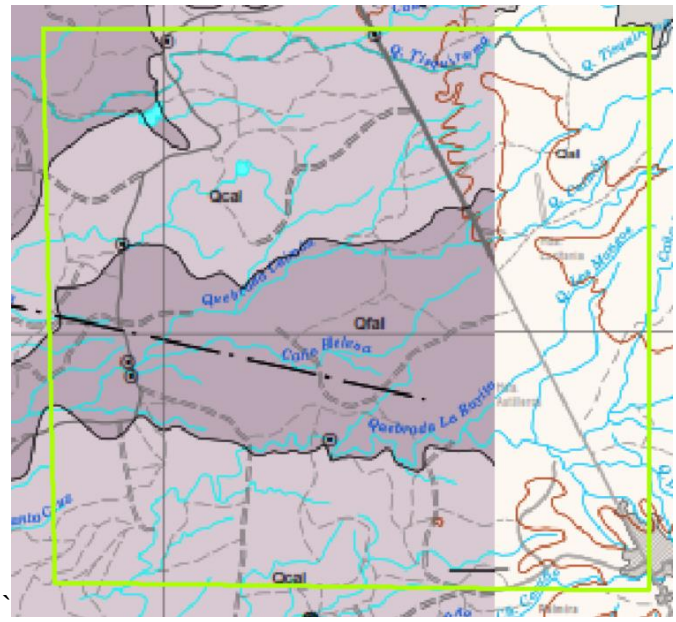


Ilustración 27. Geología de la Plancha 85 y 86 SIMITI

Fuente: Servicio Geológico Atlas Geológico de Colombia

Como se especifica en las planchas geológicas 85 y 86 del servicio geológico colombiano SIMITI las principales composiciones del suelo en la zona son en su gran mayoría llanura de inundación: Arenas Lodos de colores gris o gris oscuro, ocasionales paleocanales de gravas y cantos, depósitos de Abanico y terrazas aluviales, bloques y cantos de rocas volcáno-sedimanetarias, ígneas y metamórficas con diámetros de 15 cm. Localmente de grava en matriz areno-limosa ver Anexo 1.

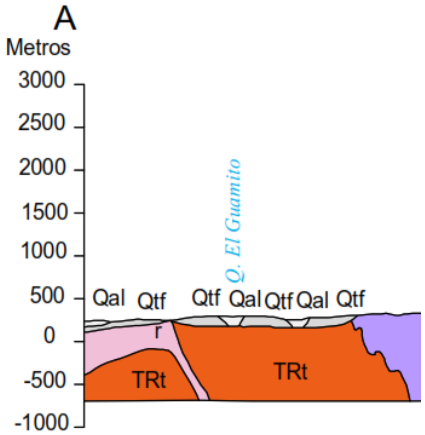


Ilustración 28. Geología de la Plancha 85 y 86 SIMITI corte del suelo

Fuente: Servicio Geológico Atlas Geológico de Colombia

En la ilustración 27 y 28 encontraremos las diferentes capas según el servicio geológico, donde Qal, Qtf hacen referencia a la llanura de inundación y abanico aluvial antes descritos los cuales son el objeto de estudio. El basamento corresponde a un cuerpo intrusivo de r

Riolita (roca ígnea) y TRt que corresponde a una Tonalita de composición Biotitica hombledica, verdosa, de grano fino o mediano.

10.1.1. OIF Factor de índice óptimo

Una vez realizadas las correcciones básicas para las imágenes Hiperespectrales como saturación, emitancia y error atmosférico procede a realizar mediante lenguaje de programación Matlab, el OIF para determinar la mejor combinación de bandas quitando la mayor ambigüedad de información. Ya que las imágenes con las que contamos son superiores a 300 bandas se debe programar para que permita leer las 300 bandas y se puede verificar cuál de estas será la mejor combinación se usó para esto el software Matlab .

Tabla 5. Mejor combinación Basados en modelo OIF

Banda 1	Banda 2	Banda 3	OIF
91	350	353	90.86%
81	269	354	78.81%
119	273	352	77.92%
77	258	353	34.97%
97	272	354	34.66%

Fuente: Propia

En la tabla 5 se muestran los mejores resultados para clasificación basada en modelo OIF, esto corresponde a la mejor combinación para la mayor riqueza espectral para las imágenes Hiperespectrales en la zona de estudio

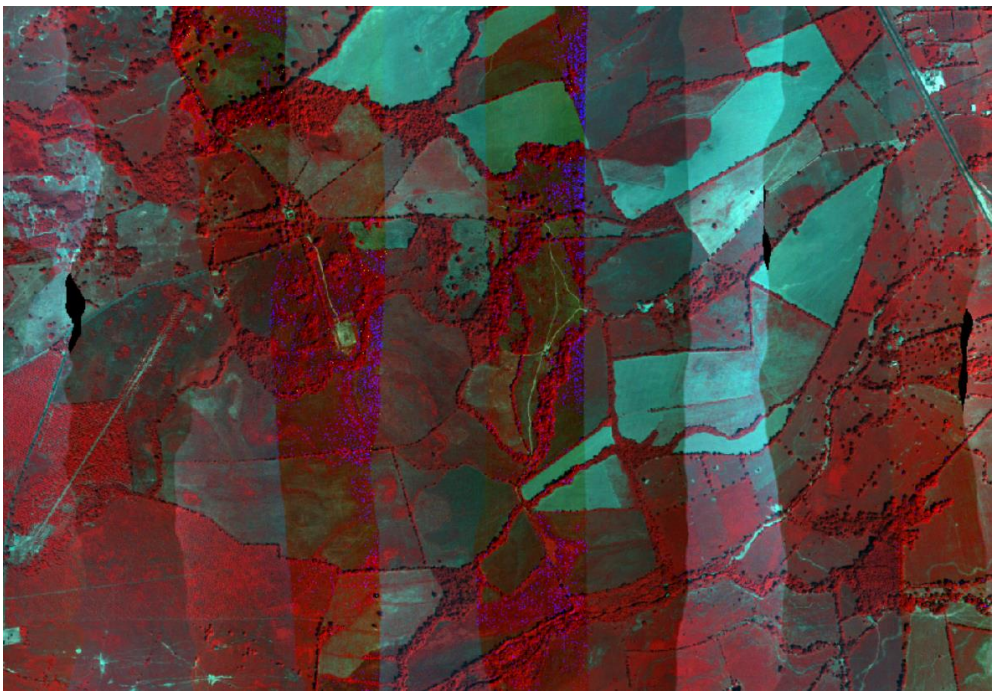


Ilustración 29. Mejor combinación basado en modelo OIF RGB 91-350-353 SPECTIR

Fuente: Propia

En la ilustración 29 se muestra la mejor combinación de bandas RGB para no incurrir en redundancia de información espectral, procederemos a aplicar los diferentes métodos de clasificación para esta mejor combinación según el factor de índice óptimo .

10.1.2. NDVI

En la ilustración 30 tenemos el mejor resultado de NDVI basados en las 360 bandas de nuestro sensor de los 25 NDVI calculados usando los 25 rojos.

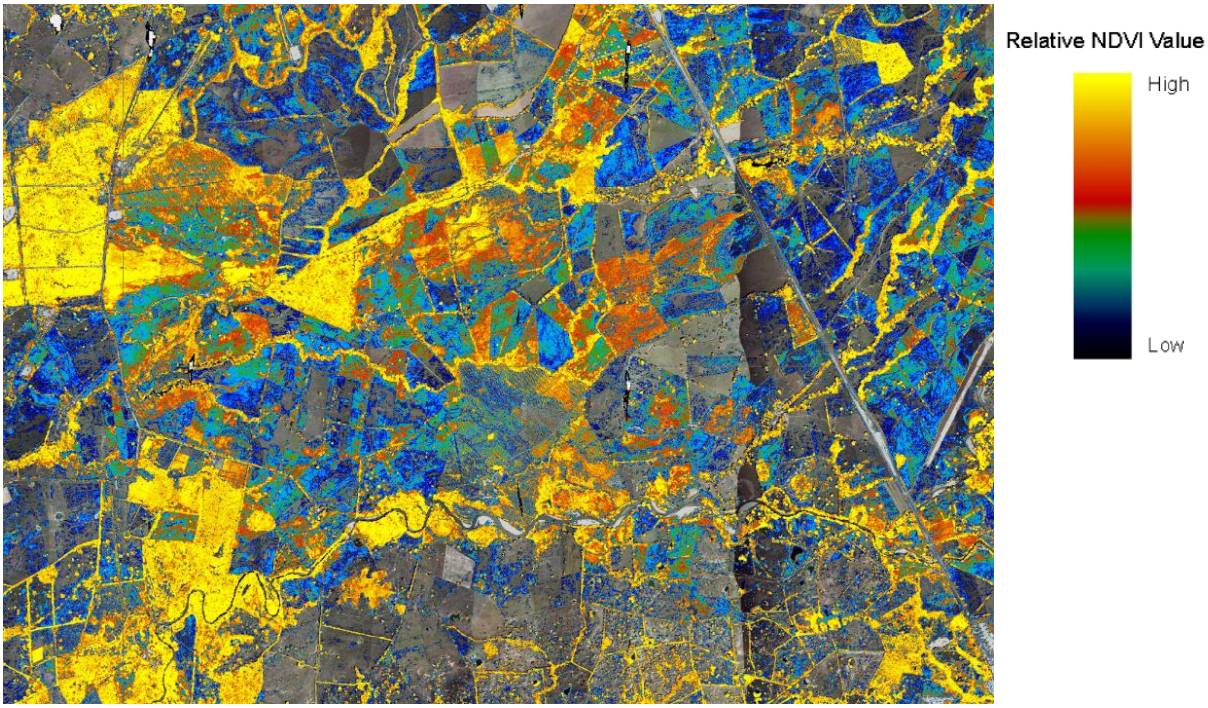


Ilustración 30. Índice de vegetación normalizado basado en imágenes Hiperespectrales

Fuente: Propia

Los índices se basaron en el criterio de zonificación de la cobertura vegetal mediante los valores bases presentados en la Tabla 6 que separa los valores según el tipo de suelo, objeto o presencia de vegetación dispersa, densa o escasa en la zona de estudio, ver Anexo 3.

Tabla 6. Criterios de Zonificación de la cobertura vegetal mediante los valores de NDVI

Rangos de NDVI	
< 0	Presencia de agua y/o áreas con sombra
0 - 0.2	Suelo desnudo
0.2 - 0.4	Vegetación Escasa + Suelo
0.4 - 0.6	Vegetación dispersa
> 0.6	Vegetación densa

Fuente: (Villamizar, 2015)

Según la tabla 6 y dependiendo de los valores de NDVI generados se puede inferir los tipos de vegetación en la zona, la presencia de agua y suelo descubierto, donde se realizó los ROI para la clasificación de minerales expuestos.

Basados en los valores del histograma y la definición de clases según el valor de NDVI generando mapas según los rangos de valores bases del plano basados en <0 hasta >0.6 que es la vegetación densa de la zona de estudio



	Vegetación Escasa
	Vegetación Densa
	Suelo Descubierto

Ilustración 31. Clasificación según los valores de NDVI para coberturas vegetales

Fuente: Propia

En la ilustración 31 se denota la presencia de vegetación dispersa o baja en gran parte de la imagen y en color verde más oscuro se denota la presentación de vegetación densa que no permite la verificación de suelo descubierto en la zona, se profundizo en el estudio de zonas de suelo descubierto en color blanco para evitar píxel mixto.

10.1.3. Implementación de clasificación de imágenes basados en Maquinas de Soporte Vectorial

El primer método de clasificación será las máquinas de soporte vectorial en este caso la zona de trabajo designa asociaciones orientadas hacia la búsqueda de hidrocarburos, oro y plata, aunque podríamos orientar a búsqueda de cualquier tipo de elemento en el suelo descubierto, lo que nos da como base de exploración la búsqueda de Moscovita IL107, Caolinita KL500, Calcita CO2004 y Hematita FE2602 como elementos indicadores,

En la ilustración 32 determinamos los perfiles de materiales expuestos basados en máquinas de soporte vectorial, este proceso será verificado usando matriz de confusión para determinar el mejor resultado en kappa y análisis global de todos los métodos expuestos para este proceso se utilizara el OIF como soporte y también se realizara RGB verdadero color para comparar resultados .

Tabla 7. Análisis de Matriz de confusión para la clasificación de máquinas de soporte vectorial

Clases	MUSCOVITE	KAOLINITE	CALCITE	HEMATITE	TOTAL
Unclassified	560	450	245	280	1535
MUSCOVITE_IL1	4652	1	4	2	4659
KAOLINITE_KL5	0	500	0	0	500
CALCITE_CO200	0	0	112	0	112
HEMATITE_FE26	0	0	0	187	187
TOTAL	5212	951	361	469	6993

En el resultado tenemos una precisión global de 88.31%, debemos además de este realizar el análisis de omisión y error para hallar el valor de kappa (capítulo 9.2.12). Ver anexo 4.

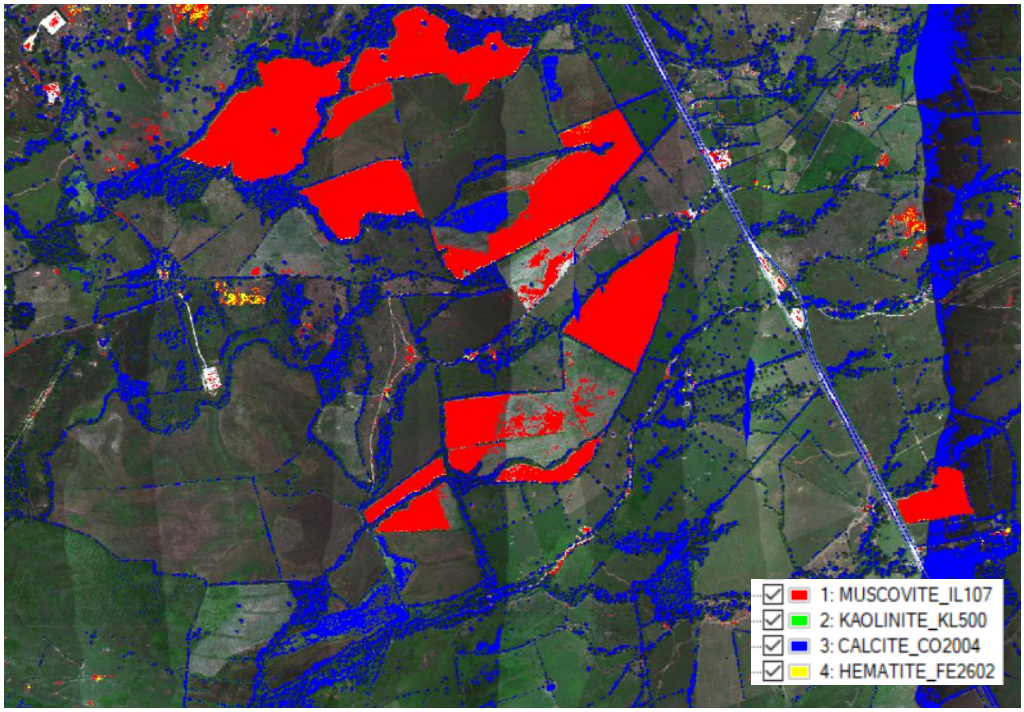


Ilustración 32. Clasificación basados en máquinas de soporte Vectorial

Fuente: Propia

Tabla 8. Análisis de Matriz de confusión para la clasificación de máquinas de soporte vectorial, Precisión del productor (medida del error de omisión, error de comisión)

Clases	Producer	%	Omisión Error	%	Comisión	%
Muscovite_Il1	4652/5212	89.26	560/5212	10.74	4652/4659	0.05
Kaolinite_Kl5	500/951	52.57	451/951	47.43	6/500	0.05

Calcite_Co200	**112/361**	**31.02**	**249/361**	**68.98**	**65/112**	**58.04**
Hematite_Fe26	**187/469**	**39.87**	**282/469**	**60.13**	**4/187**	**0.02**

Fuente: Propia

Tenemos como resultado un coeficiente kappa de 82.33% basados en el método de máquinas de soporte vectorial utilizando la combinación de bandas del OIF.

Se genera el mismo proceso utilizando verdadero color RGB para determinar si los datos cambian o continúan siendo iguales para ambos casos.

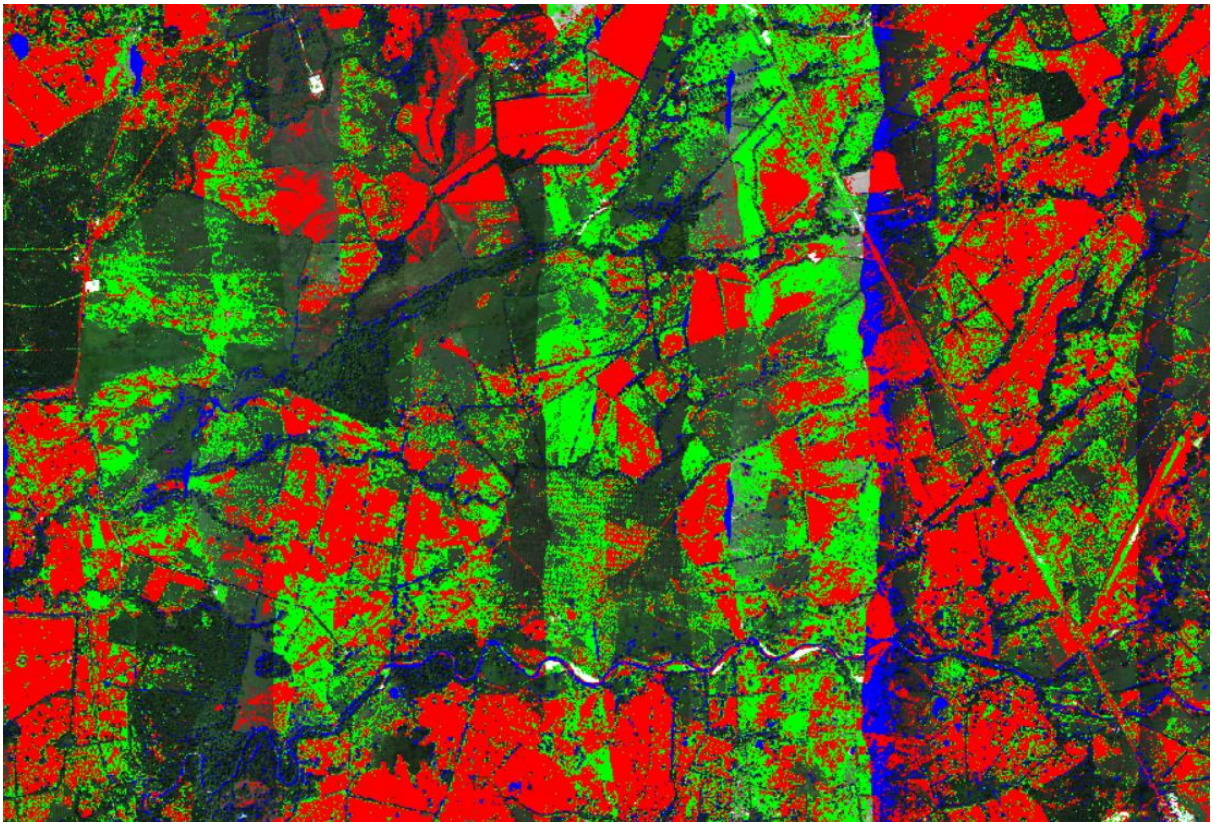


Ilustración 33, Clasificacion usando maquinas de soporte vectorial RGB

En la ilustración 33 tenemos los resultados visuales de la implementación de la clasificación por maquinas de soporte vectorial usando verdadero color RGB Rojo 54, Verde 35, Azul 17.

Tabla 9. Análisis de Matriz de confusión para la clasificación de máquinas de soporte vectorial RGB

Clases	MUSCOVITE	KAOLINITE	CALCITE	HEMATITE	TOTAL
Unclassified	**1689**	**700**	**300**	**350**	**3039**
MUSCOVITE_IL1	**3560**	**1**	**4**	**2**	**3567**
KAOLINITE_KL5	**0**	**200**	**0**	**0**	**200**
CALCITE_CO200	**0**	**0**	**22**	**0**	**22**
HEMATITE_FE26	**0**	**0**	**0**	**23**	**23**
TOTAL	**5249**	**901**	**326**	**375**	**6851**

Fuente: Propia

Ilustración 34. Análisis de Matriz de confusión para la clasificación de máquinas de soporte vectorial, Precisión del productor (medida del error de omisión, error de comisión) RGB

Clases	Producer	%	Omisión Error	%	Comisión	%
Muscovite_Il1	5249/6851	72.23	1689/5249	16.32	5235/5623	0.02
Kaolinite_Kl5	200/951	45.23	700/901	50.23	6/500	0.04
Calcite_Co200	22/361	40.23	300/326	70.25	65/112	32.26
Hematite_Fe26	23/469	40.56	326/375	62.32	4/187	0.02

La combinación para RGB obtuvo un resultado en precisión global de 68.75% y Coeficiente kappa = 63.11%.

10.1.4. Algoritmo de Codificación Binaria

El segundo método que se usó será el algoritmo de codificación binaria (capitulo 8.2.11) como método de clasificación, se utilizaran los mismos elementos en todos los algoritmos con una cantidad de puntos cercano a los 350 para tener una mejor comparación con cada una de las bandas espectrales de las imágenes y definiremos el mejor resultado basados en sus coeficientes.

En la Ilustración 35 se observa la clasificación basada en algoritmo de codificación binaria, se basa en los ROI para generar los coeficientes Kappa y Globales respectivamente se genera en esta presencia de Caolinita la que en máquinas de soporte vectorial no se definió. Ver anexo 5.

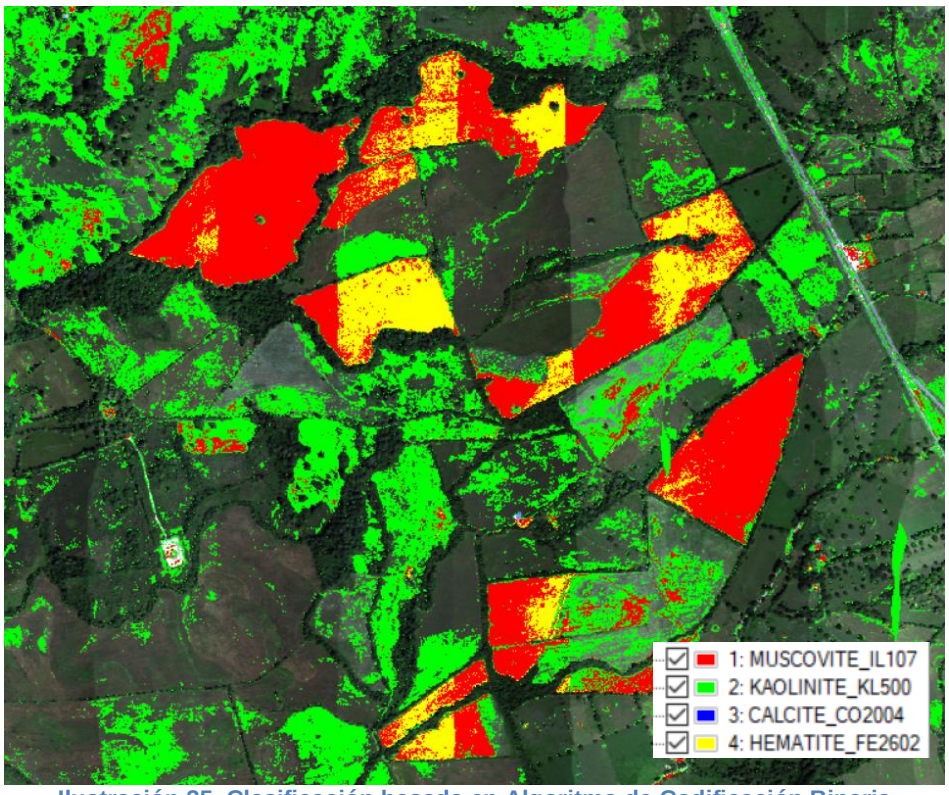


Ilustración 35. Clasificación basada en Algoritmo de Codificación Binaria

Fuente: Propia

Tabla 10. Análisis de Matriz de confusión para la clasificación por Algoritmo de Codificación Binaria

Clases	MUSCOVITE	KAOLINITE	CALCITE	HEMATITE	TOTAL
Unclassified	0	0	56	23	79
MUSCOVITE_IL1	4230	1	89	2	4322
KAOLINITE_KL5	12	500	0	0	512
CALCITE_CO200	5	0	45	0	50
HEMATITE_FE26	0	23	0	256	279
TOTAL	4247	524	190	281	5242

Fuente: Propia

En la Tabla 10 se encuentra la matriz de confusión para la clasificación por algoritmo de codificación binaria con una precisión global del 82.99% lo que representa un valor bajo con respecto a la anterior de máquinas de soporte vectorial

En la Tabla 11 se encuentra la matriz de omisión, error y el valor del coeficiente Kappa para el modelo de clasificación de codificación Binaria.

Tabla 11. Análisis de Matriz de confusión para la clasificación de divergencia espectral basado en Algoritmo de Codificación Binaria, Precisión del productor (medida del error de omisión, error de comisión)

Class	Producer	%	Omission Error	%	Commission
Muscovite_Il1	4720/5900	80.25	890/5843	15.23	5900/5843
Kaolinite_Kl5	652/1441	45.23	690/1758	39.23	1441/1758
Calcite_Co200	126/344	36.56	360/512	70.23	126/512
Hematite_Fe26	250/794	31.45	350/562	62.23	794/562

Tenemos como resultado un coeficiente kappa de 87.50% basados en el método de divergencia espectral en algoritmos de codificación binaria.

10.1.5. Divergencia de Información Espectral

El tercer método se basa en el capítulo 8.2.8, este método utiliza el perfil espectral de los materiales y todas las bandas sin importar la cantidad o el tamaño del SuperPixel, en la Ilustración 36 se encuentra los resultados del uso de este algoritmo de clasificación. Ver anexo 6.



Ilustración 36. Clasificación Basada en Divergencia Espectral

En la tabla 12 denotamos la matriz de confusión de la clasificación basada en Divergencia Espectral, este arroja un alto valor de precisión global con un 98.847%.

Tabla 12. Análisis de Matriz de confusión para la clasificación de divergencia espectral basado en perfiles espectrales

Class	MUSCOVITE	KAOLINITE	CALCITE	HEMATITE	TOTAL
Unclassified	0	0	4	18	0
MUSCOVITE_IL1	5005	1	7	2	5015
KAOLINITE_KL5	0	916	40	0	956
CALCITE_CO200	0	0	112	0	112
HEMATITE_FE26	0	0	0	143	143
TOTAL	5005	921	177	145	6248

Precisión Global= (6176/6248) = 98.8476%

En la tabla 13 se encuentra la relación de error, omisión y coeficiente kappa de la clasificación por divergencia espectral con un valor de coeficiente Kappa de 96.54% siendo el más alto entre los clasificadores,

Tabla 13. Análisis de Matriz de confusión para la clasificación de divergencia espectral basado en perfiles espectrales, Precisión del productor (medida del error de omisión, error de comisión)

Clases	Producer	%	Omisión Error	%	Comisión	%
Muscovite_Il1	5005/5005	99.8	10/5015	0.2	0/5005	0.00

Kaolinite_Kl5	916/921	95.82	40/956	4.18	5/921	0.54
Calcite_Co200	112/177	100	0/112	0	65/177	36.72
Hematite_Fe26	143/145	100	0/143	0	2/145	1.38

Coeficiente kappa = 96.54%

10.1.6. Procesamiento de imágenes de radar

Para este trabajo se usa el software SNAP el cual cuenta con una amplia variedad de herramientas que permite aplicar los diferentes filtros de corrección para imágenes de radar SAR, estas se basan en un SENTINEL 1 de la notación SLC que contiene información de corteza uno de los elementos a usar se describe con la siguiente notación: S1B_IW_SLC__1SDV_20191014T230603_20191014T230630_018478_022D10_83D8

Las imágenes espaciales SAR en formato complejo (SLC), poseen un componente imaginario (q) y un componente real (i), a partir de los cuales se puede determinar los valores de intensidad/amplitud y la fase, empleados en diferentes aplicaciones como análisis multitemporal o interferometría radar. La notación SDV orienta que es una imagen tomada por radar de apertura sintética y termina con la fecha de captura.

Comenzaremos el proceso con las correcciones para mejorar la correspondencia de las imágenes, comenzamos aplicando la información de las orbitas que ayudaran a la corrección de coordenadas de las imágenes de radar



Ilustración 37. Diagrama de Trabajo en el software SNAP para tratamiento de imágenes de Radar e interferometría

Primero realizamos las correcciones basados en los filtros, capitulo 9.2.16 posteriormente pasamos a interpolar las imágenes una sobre otra para verificar cualquier tipo de anomalía o cambio que se genere directamente sobre las imágenes, una vez terminado estos filtros generamos el interferograma o cambio de fase capítulo 9.2.17, para terminar, generando un mapa de cambio de fases los resultados de este primer proceso se muestran en la Ilustración 35 donde se generó una banda de cambio de fase directo.

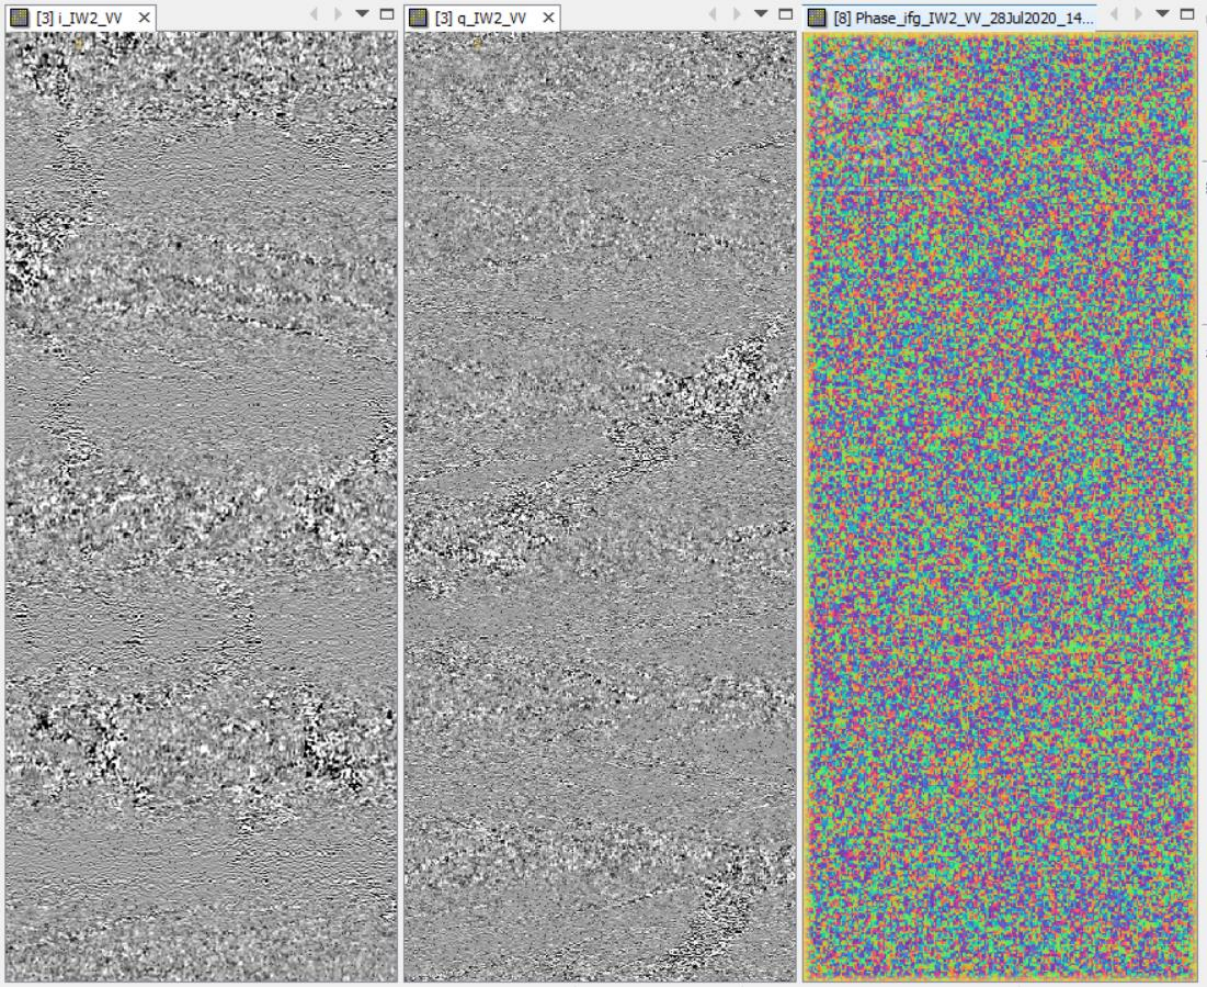


Ilustración 38. Cambio de Fase entre las imágenes de Radar basados en el interferograma usando SNAP

Posterior a que ya tengamos el interferograma debemos generar un último paso para verificar la diferencia de fase que se presenta directamente sobre las alturas del terreno, capitulo 9.2.17.1 , en este caso se procesa la topografía del sitio y se corrige el filtro de multi camino para evitar que la información sea ambigua o que presente dentro de la misma un error por mala distribución de las fases como se muestra en la Ilustración 38, donde basados en lenguaje SNAP procederemos a crear la solución de multi camino o ruido.

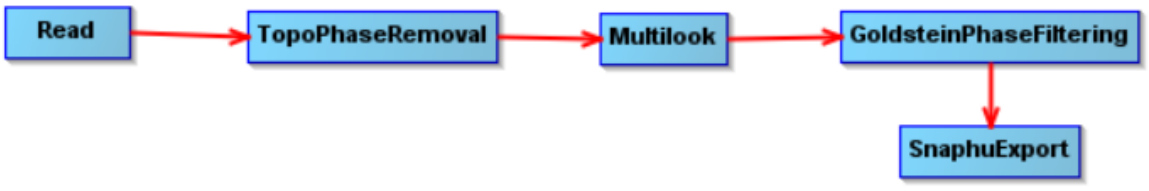


Ilustración 39. Análisis de Interferograma y corrección de Fase para Altura

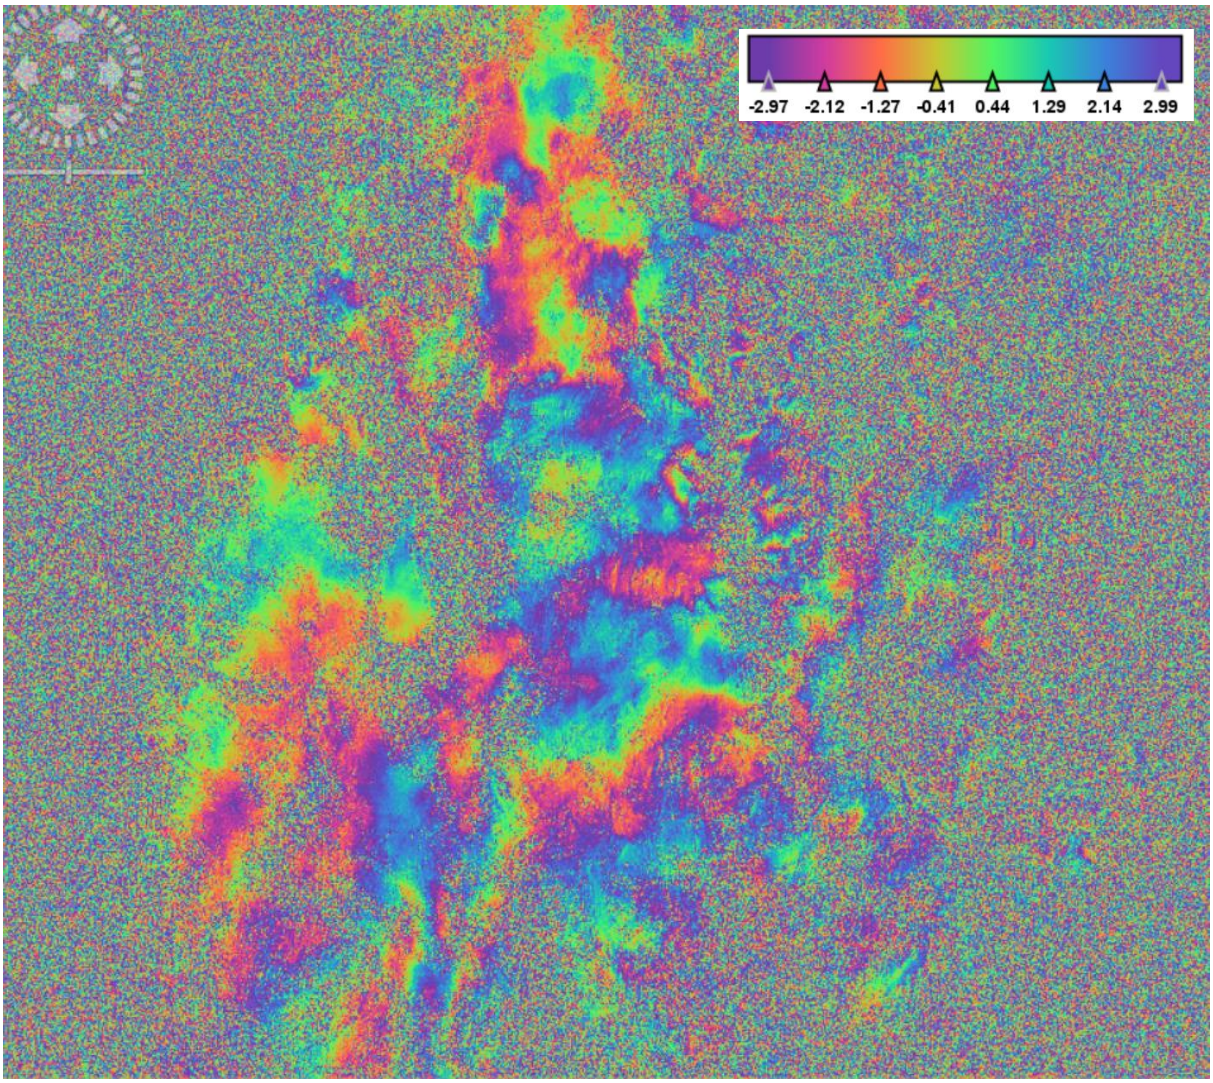


Ilustración 40. Interferometría del lugar de estudio medida en centímetros por año

En la Ilustración 40 tenemos nuestro interferograma terminado para generar el mapa de alturas basados en las deformaciones del interferograma y la fase como se muestra en la Ilustración 41 donde creamos la imagen SnapHu basados en el código CMD de la plataforma SnapHu y la procesaremos para verificar los desplazamientos finales Ver anexo 7.

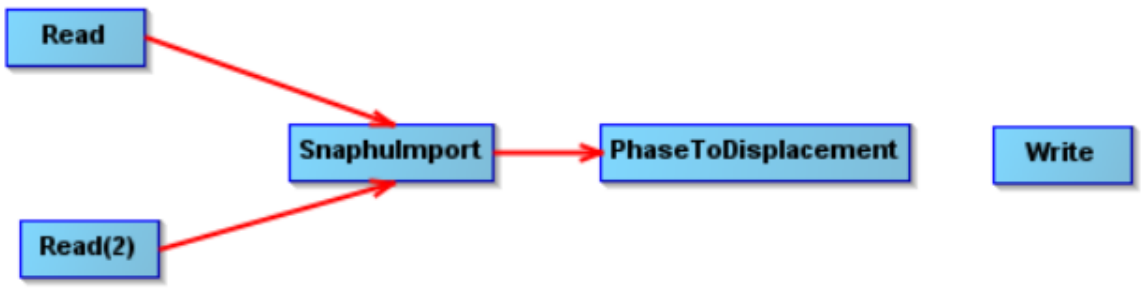


Ilustración 41. Mapa de desplazamientos basado en interferogramas

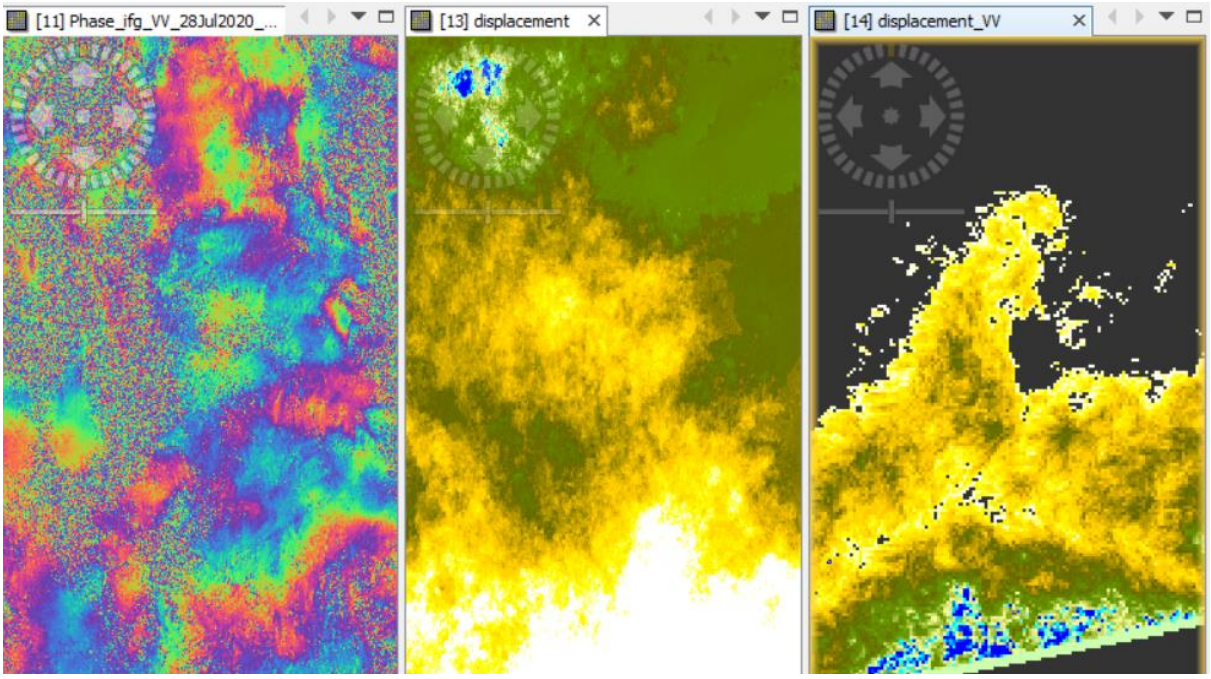


Ilustración 42. Desplazamiento Total basados en imágenes de Radar e interferogramas

En la ilustración 42 una vez realizado el proceso de corrección de Doppler obtenemos el desplazamiento final de la zona de estudio.

11. ANÁLISIS DE RESULTADOS

- Los resultados obtenidos según la matriz de confusión y en busca de sus índices globales y coeficiente Kappa para sustentar la mejor clasificación según la ISO 19157, dando como resultado Maquinas de soporte vectorial con una precisión global de 88.3% y Coeficiente kappa = 82.33%, se determina como mejor clasificador de imágenes Hiperespectrales el método de clasificación por divergencia Espectral con una precisión global de 98.84% y coeficiente kappa de 96.54%.

- Se validaron materiales que son de gran abundancia sobre el manto superficial de la tierra, esto como base para determinar la respuesta espectral de los materiales dentro de las imágenes Hiperespectrales se tomó como base los mapas geológicos y geoquímicos de la zona y se buscó los mismos elementos obteniendo como resultado mapas base para la exploración mineralógica de la zona.

- Se genero mapa de interferometría de la zona con desplazamientos no mayores a 2 cm en 5 años lo que corresponde a la zona y el tipo de materia encontrado en la zona.

- Se encontraron grandes extensiones de suelo desnuda basados en el NDVI que muestra un valor alto de dispersión con color amarillo sobre gran parte de la extensión, esto ayudara a que el estudio se pueda centrar en zonas de suelo descubierto y vegetación baja.

- Se obtienen mejores resultados utilizando la combinación de OIF, al usar el clasificador de máquinas de soporte vectorial, con un mejor resultado en precisión global de 88.3% y Coeficiente kappa = 82.33% mientras la configuración RGB obtuvo un resultado en precisión global de 68.75% y Coeficiente kappa = 63.11%.

- Basados en información de la interferometría se observaron desplazamientos de poca profundidad propios de los depósitos de abanicos aluviales debido a su inestabilidad y compactación ya que son materiales muy recientes, el máximo desplazamiento es de más menos 3 cm por año en zonas muy específicas donde en su mayoría corresponden a zonas planas y arcillosas donde los desplazamientos no se consideran significativos o que afecten la estabilidad de terreno.

- Los valores de NDVI índice de vegetación normalizado se encuentran en el orden de 0.1, corresponden a áreas rocosas, arenosas o nevados mientras los valores de 0.2 a 0.3 pueden corresponder a áreas pobres con arbustos o pasturas naturales este determinador nos ayudó a especificar zonas de suelo descubierto lejos de vegetación de la zona para determinar mejor el índice que los minerales de búsqueda y los ROI de referencia.

- No se encuentran grandes depósitos de Caolinita utilizando el método de máquinas de soporte vectorial, se define muy fáciles elementos abundantes como vegetación, agua o caminos entre otros, pero el análisis de entrenamiento por más detallado que sea no ayuda a mejorar los resultados del proceso utilizando máquinas de soporte vectorial.

- En el algoritmo de codificación binaria no se encontró gran cantidad de calcita siendo uno de los elementos más abundantes en el tipo de formación general del suelo y que ayuda a determinar minerales indicadores para hidrocarburo, oro y plata, en los demos elementos se generaron mejores resultados que con los demás métodos de clasificación.

12. CONCLUSIONES

Basados en imágenes Hiperespectrales y de Radar es posible realizar el análisis e identificación de características mineralógicas para grandes extensiones, esto ya que las multibandas posibilitan el análisis de los perfiles espectrales y los elementos necesarios para una fase de exploración, teniendo como base la identificación superficial, las asociaciones, las concentraciones y la caracterización mineralógica del área de estudio.

Se generan mapas de identificación mineralógica como aportes a Geología base de la región de estudio (ver anexo 8), basados en la información espectral, para la obtención de mapas de composición de suelos e índices de vegetación normalizados mediante imágenes Hiperespectrales.

Se lograron clasificar los diferentes materiales expuestos en suelo descubierto, basándonos en imágenes Hiperespectrales y los perfiles espectrales de los materiales presentes en el área de estudio basado en los perfiles del IGCP; con este proceso se mejorará la clasificación y el comportamiento de cada de los materiales dentro de las diferentes bandas espectrales,

además de determinar la posición y asociación mineral que ayudará a determinar zonas de alta riqueza mineralógica y exploración.

Se implemento el análisis radiométrico y espectral de los diferentes tipos de materiales expuestos, generando mapas de composición mineralógica del suelo, composición de rocas bases y asociaciones minerales presentes en la zona de estudio, se realizó la búsqueda de materiales comunes en la zona de estudio como la Hematita, la Calcita, Caolinita y Moscovita, además de análisis de desplazamientos basados en la interferometría de la zona con imágenes de Radar donde se buscaban fallas que pudieran generar subducción o anomalías en los depósitos de material indicador.

Basados en la geología local se pudo correlacionar, verificar y acotar los minerales presentes en área de estudio de acuerdo con los resultados arrojados en la clasificación supervisada y la interferometría de la zona, correspondiendo con los materiales y la geoquímica descritos en los informes geológicos.

El OIF o Factor de Índice Optimo en imágenes Hiperespectrales no determino una mejoría de la información en cuanto al uso de la clasificación por Divergencia Espectral, ya que este método toma en consideración toda la riqueza espectral de las bandas sin que importe la redundancia de información, este índice se utiliza en el método de máquinas de soporte vectorial y los resultados no fueron los mejores contra otros métodos.

12.1. Trabajo Futuros

El manejo y la aplicación de imágenes Hiperespectrales abre la posibilidad a miles de soluciones de clasificación, el uso de estas podrá ser utilizado no solo en geología como el presente trabajo, sino además en estudios de vegetación, aguas, determinación de zonas de alto riesgo, todo esto basado en la riqueza espectral que poseen y donde podemos llegar a detalles con alta confiabilidad utilizando herramientas de sensores remotos como base para la investigación de fenómenos.

Realizar pruebas con otros sensores Hiperespectrales de amplio espectro, teniendo como base la clasificación por divergencia espectral como mejor resultado para el manejo de cientos de bandas al mismo tiempo, la utilización de estas imágenes como valores matemáticos para clasificadores en R o Matlab para un mejor control del método de clasificación.

Validar las firmas espectrales en sitio o con la geoquímica de la zona, esto requiere un espectro radiómetro y una prueba de geoquímica en la zona para determinar con un mayor detalle cuales son las características propias de los suelos descubiertos antes de realizar las tomas con imágenes Hiperespectrales y posterior clasificar usando este espectro para cada material presente en mayor cantidad.

13. BIBLIOGRAFÍA

Hernández, C. A. (2010). Adquisición, Procesamiento Completo E Interpretación De Imágenes De Sensores Remotos Que Permitan Definir Áreas De Interés Con Enfoque Exploratorio De Hidrocarburos Sobre Un Sector Del Suroriente Colombiano Perteneciente A Las Cuencas Vaupés - Amazonas Y Caguán - Putumayo".

Ariza, F. J. (2018). *Calidad En Datos Geográficos, Geoservicios Y Productores De Datos: Análisis Crítico.* Santiago De Chile: Revista Cartográfica.

Atkinson, I., Kamalabadi, F., & Jones, D. L. (2003). Wavelet-Based Hyperspectral Image Estimation.

Ayerdi, B., & Romay, M. G. (2016). Hyperspectral Image Analysis By Spectral–Spatial Processing And Anticipative Hybrid Extreme Rotation Forest Classification. *IEEE Transactions On Geoscience And Remote Sensing, 54*(5), Págs. 2627–2639.

Barisione, F., Solarna, D., Giorgi, A. D., Moser, G., & Serpico, S. B. (2016). Supervised Classification Of Thermal Infrared Hyperspectral Images Through Bayesian, Markovian, And Region-Based Approaches.

Bashevoy, M., Jonsson, F., Abajo, F. J., & Santos, I. P. (2007). Hyperspectral Imaging Of Gold Dimers.

Bedeli, R. L. (2013). Hyperspectral Image Calssification For Mineralogical Identification.

Belmonte, S. C. (2009). *Una Aplicacion Basada En Imagenes De Radar Para Prevencion De Inundaciones.* Buenos Aires, Argentina: Facultad De Matematica, Astronomıa Y Fısica.

Biescas, A. M. (2002). *APLICACIONES DE LA INTERFEROMETRÍA SAR PARA LA MEDIDA DE DEFORMACIONES DEL TERRENO.* Castelldefels, España: Instituto De Geomática.

Bioucas-Dias, A. P.-V. (2013). *Hyperspectral Remote Sensing Data Analysis And Future Challenges.* IEEE Geoscience And Remote Sensing Magazine, Vol. 1, No. 2, Pp. 6-36.

Calvo, C. G. (2011). Procesamiento A Bordo De Imágenes Hiperespectrales De La Superficie Terrestre Mediante Hardware Reconfigurable. Madrid: Universidad Complutense De Madrid.

Camacho, G. D. (2018). *INTERFEROMETRÍA RADAR PARA LA DETECCIÓN DE CAMBIO, DESPLAZAMIENTOS Y POSIBLES AFECTACIONES A CAUSA DEL SISMO DEL 19 DE SEPTIEMBRE DEL 2017 EN EL PROYECTO DEL NUEVO AEROPUERTO INTERNACIONAL DE MÉXICO (NAIM).* Ciudad De Mexico,: Universidad De Salamanca.

Chávez, J. L. (2010). *Tratamiento Digital De Imágenes Multiespectrales* (Universidad Nacional Autónoma De México Ed., Vol. Segunda Edicion). Universidad Nacional Autónoma De México .

Chen, F., Zhao, P., Tang, T. F., & Zhou, Y. (2017). Fast Low-Rank Decomposition Model-Based Hyperspectral Image Classification Method. *IEEE Geoscience And Remote Sensing Letters, PP*(99), Págs. 1–5.

Chuvieco, E. (2000). *Fundamentos De Teledeteccion Espacial.* Madrid: Ediciones Rialp S.A.

Cohen, J. (1960). *Educational And Psychological Measurement.* New York: New York University.

Curlander, J. Y. (1991). *Synthetic Aperture Radar: Systems And Signal Processing.* New York: John Wiley & Sons, Inc.

Datta, A., Ghosh, S., & Ghosh, A. (2017). Supervised Feature Extraction Of Hyperspectral Images Using Partitioned Maximum Margin Criterion. *IEEE Geoscience And Remote Sensing Letters, 14*(1), Págs. 82–86.

Davis, C. O. (2012). *Hyperspectral Imaging Of River Systems.* PN.

Díaz, A. L. (2017). *Fundamentos Matematicos De Los Metodos Kernel Para Aprendizaje Supervisado.* (U. D. Sevilla, Ed.) Sevilla: DEPARTAMENTO: CIENCIAS DE LA COMPUTACION E INTELIGENCIA ARTIFICIAL.

Donovan, S. (2002). *Efficient Materials Mapping Using Hyperspectral Imaging Data.* Master Od Science In Geology And Geophysics, University Of Hawai.

Ekrem, E. T. (2012). Mineral Exploration With Hyperspectral Image.

Ekrem, S. E. (2012). Mineral Exploration With Hyperspectral Image.

El-Darymli, K. M. (2012). *Understanding The Significance Of Radiometric Calibration For SAR Imagery: A Radar Equation Perspective.* Newfoundland, Canada.

Erdem, Y. (2009). *ALTERATION IDENTIFICATION BY HYPERSPECTRAL REMOTE SENSING IN SISORTA GOLD PROSPECT (SİVAS-TURKEY).* MIDDLE EAST TECHNICAL UNIVERSITY. MIDDLE EAST TECHNICAL UNIVERSITY.

Fernandez, Y. J.-R. (2016). Imagenes SAR Y Conceptos De Polarimetria. *Climate Change*, 42-65.

Fernandez-Sarria, A. A. (2002). *Analisis De Imagenes Mediante Texturas: Aplicacion A La Clasificacion De Unidades De Vegetacion.* Madrid: UPC.

Friðrik, L. (2009). *Hyperspectral Imaging For Diffuse Optical Tomography.* Master Of Science Electrical And Computer Engineering, TUFTS UNIVERSITY.

Gázquez, J. D. (Febrero De 2018). Clasificación De Imágenes Multiespectrales E Hiperespectrales De Alta Resolución . Págs. 59-158.

González, M. P. (2010). *Medida Y Caracterización De Deformaciones Usando Técnicas Geodésicas Y De Teledetección. Aplicación En Volcanología Y Sismotectónica.* Madrid: Universidad Complutence De Madrid.

Guo, B., Gunn, S., Damper, B., & Nelson, J. (2005). Hyperspectral Image Fusion Using Spectrally Weighted Kernels.

Gupta, M. R., & Jacobson, N. P. (2006). Wavelet Principal Component Analysis And Its Application To Hyperspectral Images.

Hamming. (1950). Error-Detecting Error-Correcting Codes. *Bell Systems And Tech. J.*, Vol. 29, Pp. 147–160.

Henderson, F. M. (1998). *Principles And Applications Of Imaging Radar. Manual Of Remote Sen-Sing, 3rd Ed. Vol. 2.* John Wiley And Sons. ISBN 0-471-29406-3. .

Herranz, J. T. (2015). *Filtros De Ruido Speckle Y Tecnicas De Clasificacion De Imagenes SAR.* Cordoba Argentina: Universidad Nacional De Cordoba.

Huang. (2006). Hyperspectral Image Classification Using Multi-Class SLEX Model.

J. C. Canales, X. L. (2009). *"Clasificación De Grandes Conjuntos De Datos Vía Máquinas De Vectores Soporte Y Aplicaciones En Sistemas Biológicos.* Mexico: Politécnico Nacional.

Kratt, C., Coolbougth, M., & Pepping, I. (2012). Identification Of A New Blind Gepthermal System With Hyperspectral Sending And Shaloow Temperature Measurements At Columbia.

Lanari, R. Y. (1999). *Synthetic Aperture Radar Processing .* CRC Press : Volumen 24 De Electronic Engineering Systems Series.

López, F. J. (2017). *La Gestión De La Calidad De La Información Geográfica.* Santa Fe De Bogotá: Universidad De Jaén.

Manolakis, D. G., Lockwood, R. B., & Cooley, T. W. (2016). *Hyperspectral Imaging Remote Sensing: Physics, Sensors, And Algorithms* (1 Ed.). Cambridge University Press.

Manosalva, S. R. (2007). *CARACTERIZACION METALOGRÁFICA DE LAS MANIFESTACIONES DE MINERAL DE HIERRO, PAIPA.* Medellin: BOLETÍN DE CIENCIAS DE LA TIERRA.

Marinoni, A., & Gamba, P. (2016). Accurate Detection Of Anthropogenic Settlements In Hyperspectral Images By Higher Order Nonlinear Unmixing. *IEEE Journal Of Selected Topics In Applied Earth Observations And Remote Sensing, 9*(5), Págs. 1792–1801.

Mazer, M., & Lee , J. (1988). Image Processing Software For Imaging Spectrometry Data Analysis. *Remote Sens. Env*, Vol. 24, No. 1, Pp. 201–210.

Mccullum, A., Torres-Pérez, J., & Bengtsson, Z. (2021). *Datos Hiperespectrales Para Sistemas Terrestres Y Costeros.* Houston: NASA Applied Remote Sensing.

Melendez, I. A. (2003). *Estimacion De Fondo Y Primer Plano N Secuencias De Imagenes Para La Deteccion De Objetos En Movimiento.* Barcelona: ANIEI.

Méndez, P. J. (2010). *Medida Y Caracterización De Deformaciones Usando Técnicas Geodésicas Y De Teledetección.* Madrid: Universidad Complutense De Madrid.

Noomen, S. (2010). *Detecting The Influence Of Gas Seepage On Vegetation, Using Hyperspectral Remote Sensing.* Houston, USA: 3rd Earsel Workshop On Imaging Spectroscopy.

Podest, E. (2017). *Procesamiento De Imágenes SAR.* Miami, EEUU: National Aeronautics And Space Administration NASA.

Pramod, V., & Manoj, A. (2004). *Advance Image Processing Techniques For Remotely Sensed Hyperspectral Data.* New York: Springer-Verlag Berlin Heidelberg 2004.

Resources, N. (2016). *Material Educativo Para Teledetección Mediante Radares .* Ontario, Canada : Natural Resources .

Rickeer, V. (1997). Fundamentals Of Geological And Environmental Remote Sensing. *Prentice Hall*, 366.

Saral, L., & Esra, G. (2016). Mineral Exploration With Hyperspectral Image Fusion.

Silleco, M. M. (2010). *A Técnica Dinsar: Bases Y Aplicación A La Medición De Subsidencias Del Terreno En Construcción.* Madrid: Aboratorio De Topografía Y Geomática Dpto. De Ingeniería Y Morfología Del Terreno, E.T.S.I. Caminos, Canales Y Puertos (U.P.M.).

Sindhumol, S., & Wilscy, M. (2007). Hyperspectral Image Analysis--A Robust Algorithm Using Support Vectors And Principal Components.

Smyth, J. R. (2000). *The Crystal Structure Of Calcite III.* Boulder: Geophysical Research Letters.

Song, M., Cai, L., Lin, B., An, J., & Chang, C. I. (2016). Hyperspectral Oil Spill Image Segmentation Using Improved Region-Based Active Contour Model.

Spectir. (2008). Mineral Exploration In The Western United States For Using Visible – Short Wave Infrared And A Mid Wave – Long Wave Infrared Hyperspectral Imagers: Joint Airborne Collection Using Hyperspectral Systems (JACHS).

Su, H., Cai, Y., & Du Qian. (2017). Firefly-Algorithm-Inspired Framework With Band Selection And Extreme Learning Machine For Hyperspectral Image Classification. *IEEE Journal Of Selected Topics In Applied Earth Observations And Remote Sensing, 10*(1), Págs. 309–320.

Subira Biosca, C. (2011). *Zonificación De Parcelas Frutícolas A Partir De Índices De Vegetación De Imágenes Del Satélite Worldview-2 Con Fines De Agricultura De Precisión.* Madrid: Universidad Complutense De Madrid.

Tarabalka, Y. (2011). Classification Of Hyperspectral Data Using Spectral-Spatial Approaches.

Theodoridis, S. A. (2002). *Satellital Image General Proccess.* Seul: Academic Press.

Valsesia, D., & Magli, E. (2017). Fast And Lightweight Rate Control For Onboard Predictive Coding Of Hyperspectral Images. *IEEE Geoscience And Remote Sensing Letters, PP*(99), Págs. 1–5.

Villamizar, J. R. (2015). SISTEMAS MULTIESPECTRALES E HIPERESPECTRALES PARA LA OBSERVACIÓN DEL TERRITORIO. ANÁLISIS Y APLICACIÓN A LA PROSPECCIÓN DE HIDROCARBUROS. ESCUELA TÉCNICA SUPERIOR DE INGENIEROS EN TOPOGRAFÍA, GEODESIA Y CARTOGRAFÍA.

William A. Pappin. (2009). Determination Of Mineralogical Singatures In The Trinity Mine Pit Using An Hyperspectral Sensor. *Junio*.

Witten, T. H. (2013). *An Introduction To Statistical Learning: With Applications In R.* New York: Gareth James.

Xie, H. (2014). *A Probability-Based Improved Binary Encoding Algorithm For Classification Of Hyperspectral Images.* Xinchao: IEEE Journal Of Selected Topics In Applied Earth Observations And Remote Sensing.

Xue, Z., Du Peijun, Li, J., & Su, H. (2017). Sparse Graph Regularization For Hyperspectral Remote Sensing Image Classification. *IEEE Transactions On Geoscience And Remote Sensing, PP*(99), Págs. 1–16.

Yang. (1999). *Phd Thesis: Imaging Spectrometry For Hidrocarbon Microseepage.* Seul, Corea: Instituto Tecnologico De Corea Del Sur Publishers.

Yang, M., Hoog, F. D., Fan, Y., & Hu, W. (2016). Adaptive Sampling By Dictionary Learning For Hyperspectral Imaging. *IEEE Journal Of Selected Topics In Applied Earth Observations And Remote Sensing, 9*(9), Págs. 4501–4509.

Yang, Y., Huang, H., & Luo, F. (2016). Classification Of Hyperspectral Image Via Spatial-Spectral Manifold Reconstruction.

Yan-Ping, T. M.-L. (2016). Analyzing Stains On Calligraphy And Painting Using Hyperspectral Imaging.

Ye, Z., Li, H., Song, Y., Benediktsson, J. A., & Tang, Y. Y. (2017). Hyperspectral Image Classification Using Principal Components-Based Smooth Ordering And Multiple 1-D Interpolation. *IEEE Transactions On Geoscience And Remote Sensing, 55*(2), Págs. 1199–1209.

Yehuda, P. (2010). *Compressive Sensing For Hyperspectral Imaging.* Israel Institute Of Technologies. Electrical Engineering.

ZHANG, S. X. (2007). *Identifying Hydrocarbon Leakage Induced Anomalies Using Landsat-7 /ETM+ Data.* Shanguia, China: Asian Association Of Remote Sensing.

Zhang, X. Z. (2014). *Improving Hyperspectral Image Classification Using Spectral Information Divergence.* Berlin: IEEE Geoscience And Remote Sensing Letter.

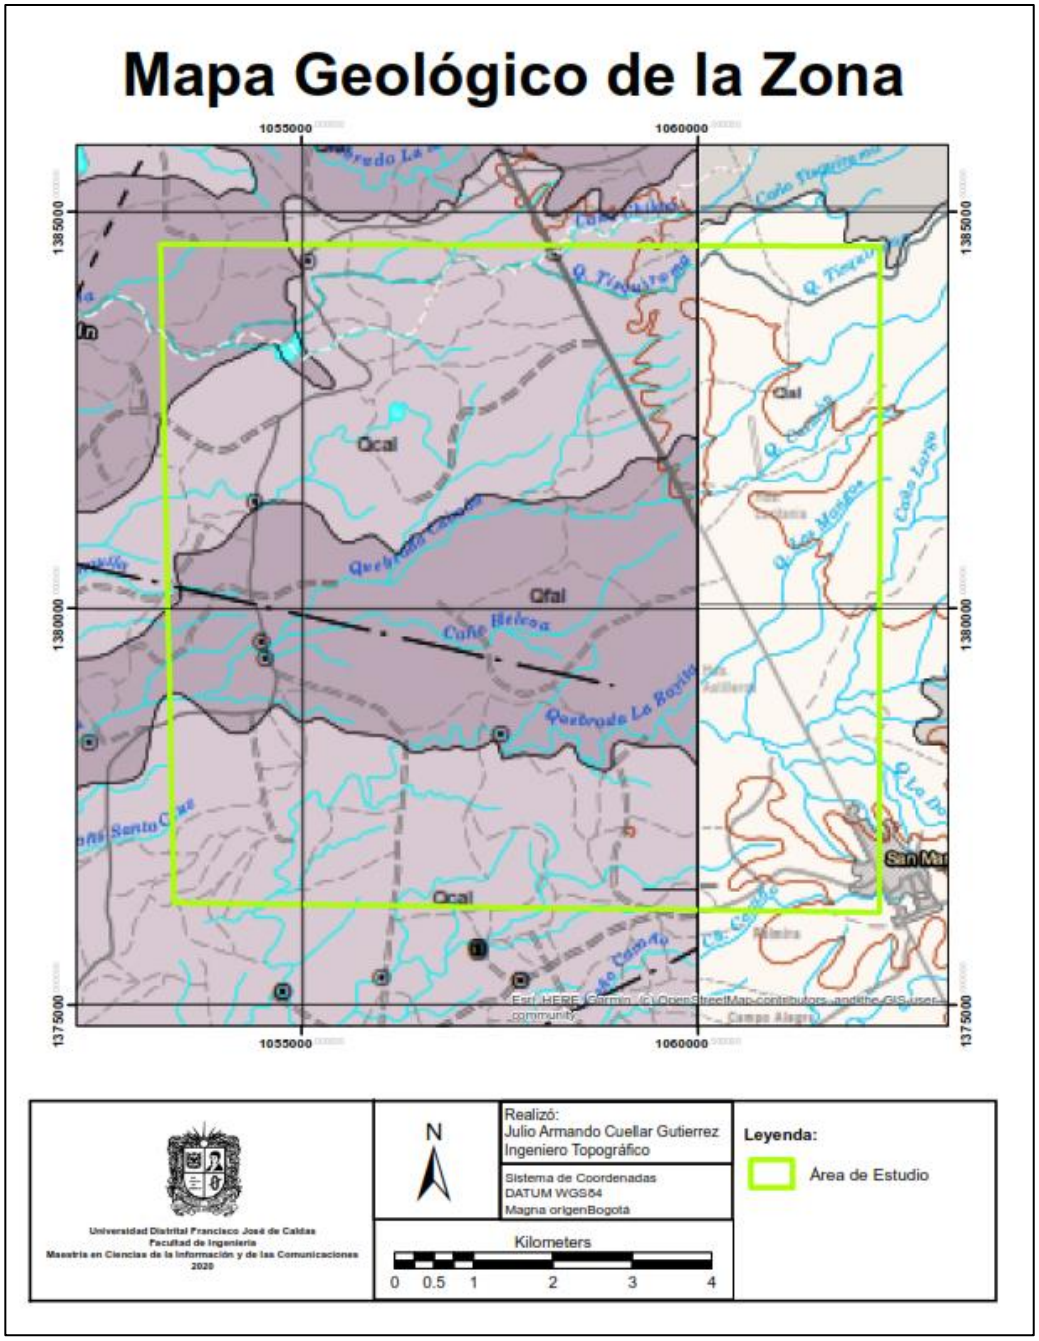
Zhou, X., Prasad, S., & Crawford, M. M. (2016). Wavelet-Domain Multiview Active Learning For Spatial-Spectral Hyperspectral Image Classification. *IEEE Journal Of Selected Topics In Applied Earth Observations And Remote Sensing, 9*(9), Págs. 4047–4059.

Zozayaa, F. C. (2017). Radar Imaging Basics. *Revista Ingenieria UC*, 73-80.

14. ANEXOS

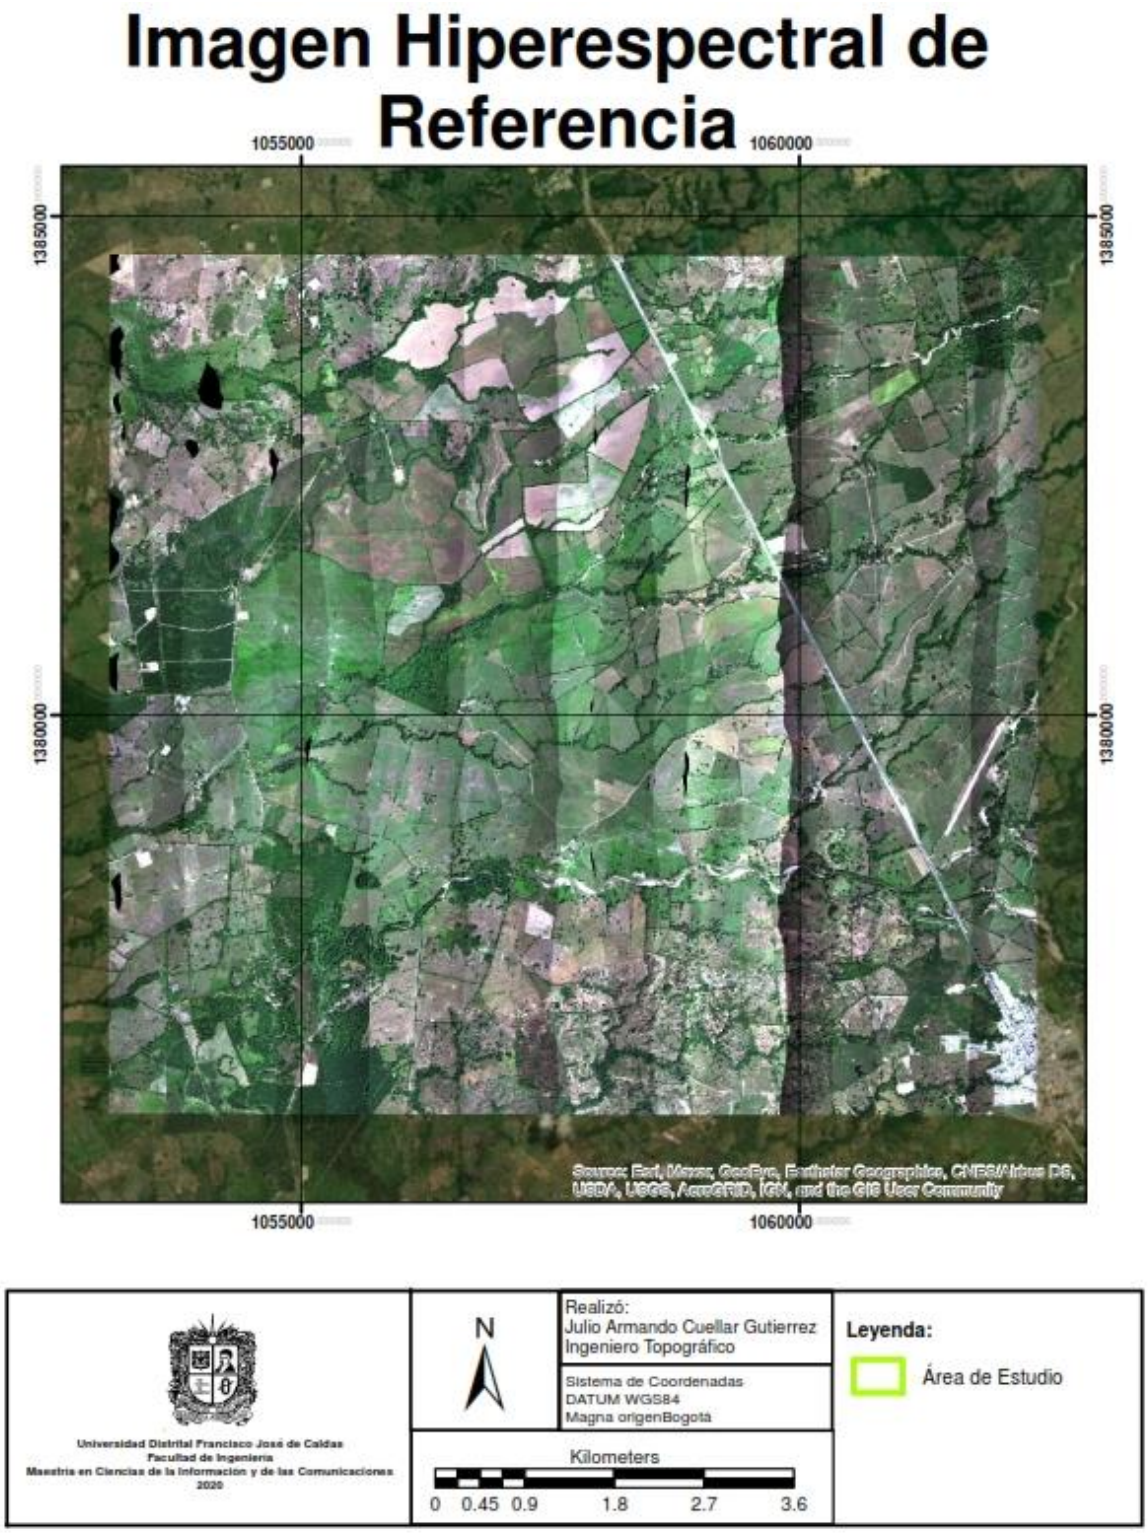
Se presentan los mapas generados para la siguiente investigación estos están centrados en la búsqueda de recursos basados en imágenes Hiperespectrales y de Radar como base para la teledetección

Anexo 1. Mapa Geológico base



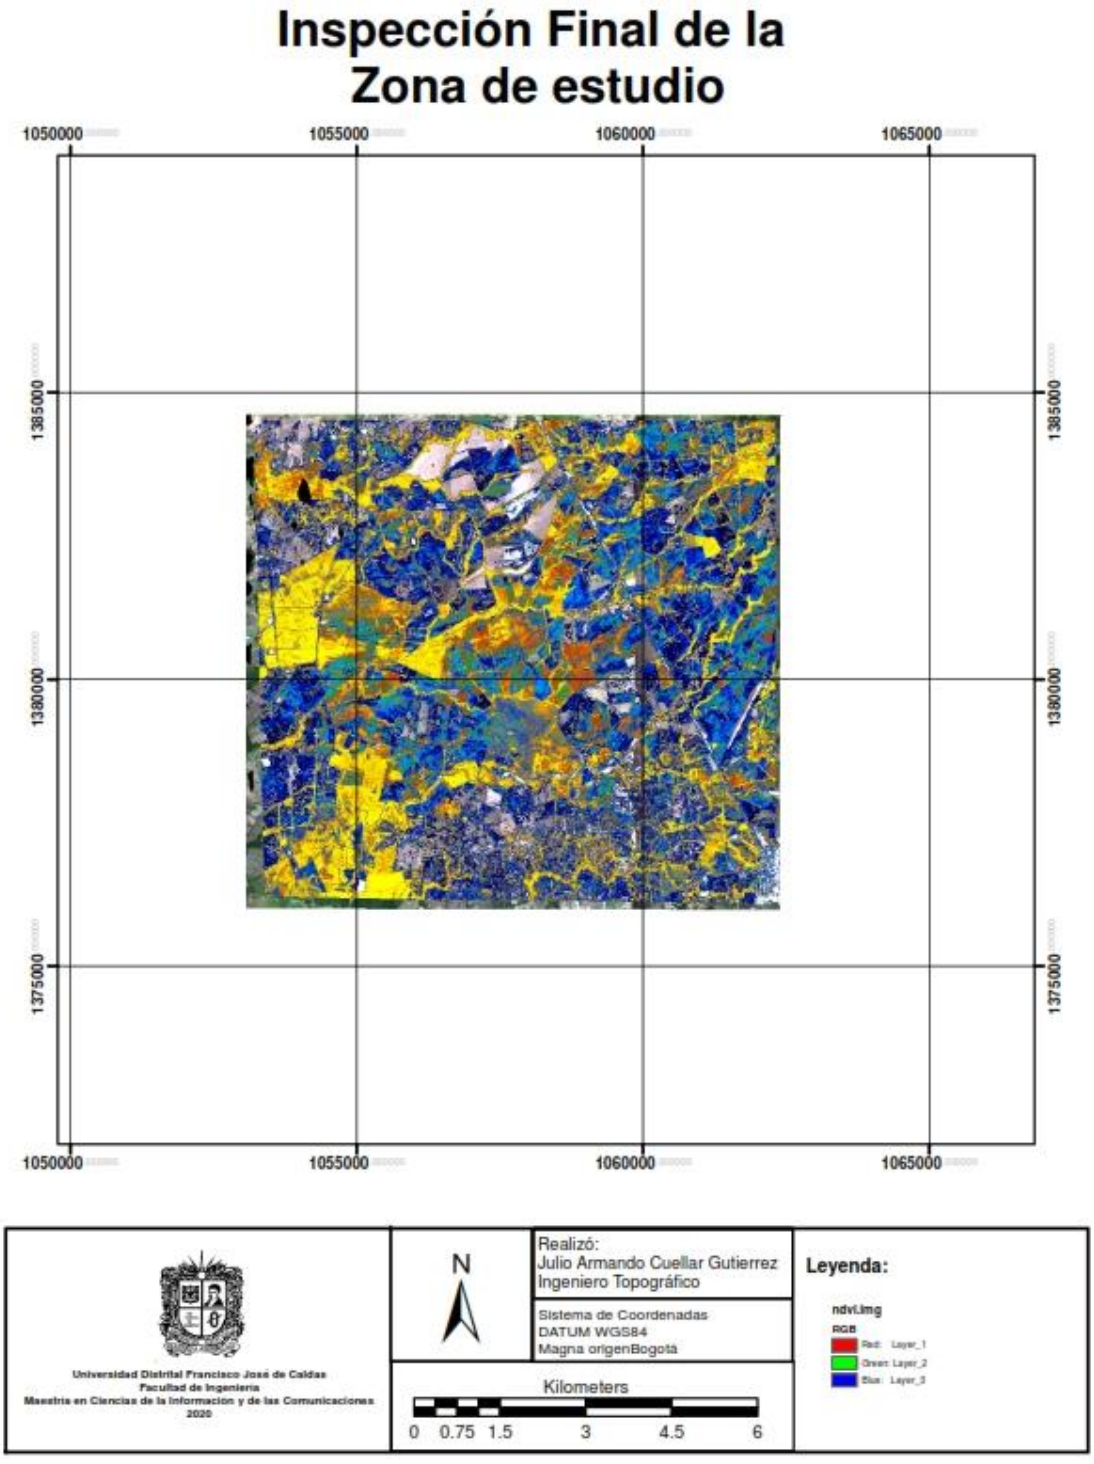
El anexo 1 presenta el mapa geológico base de la zona de estudio donde se muestra la composición base del suelo presente.

Anexo 2. Imagen Hiperespectral Base



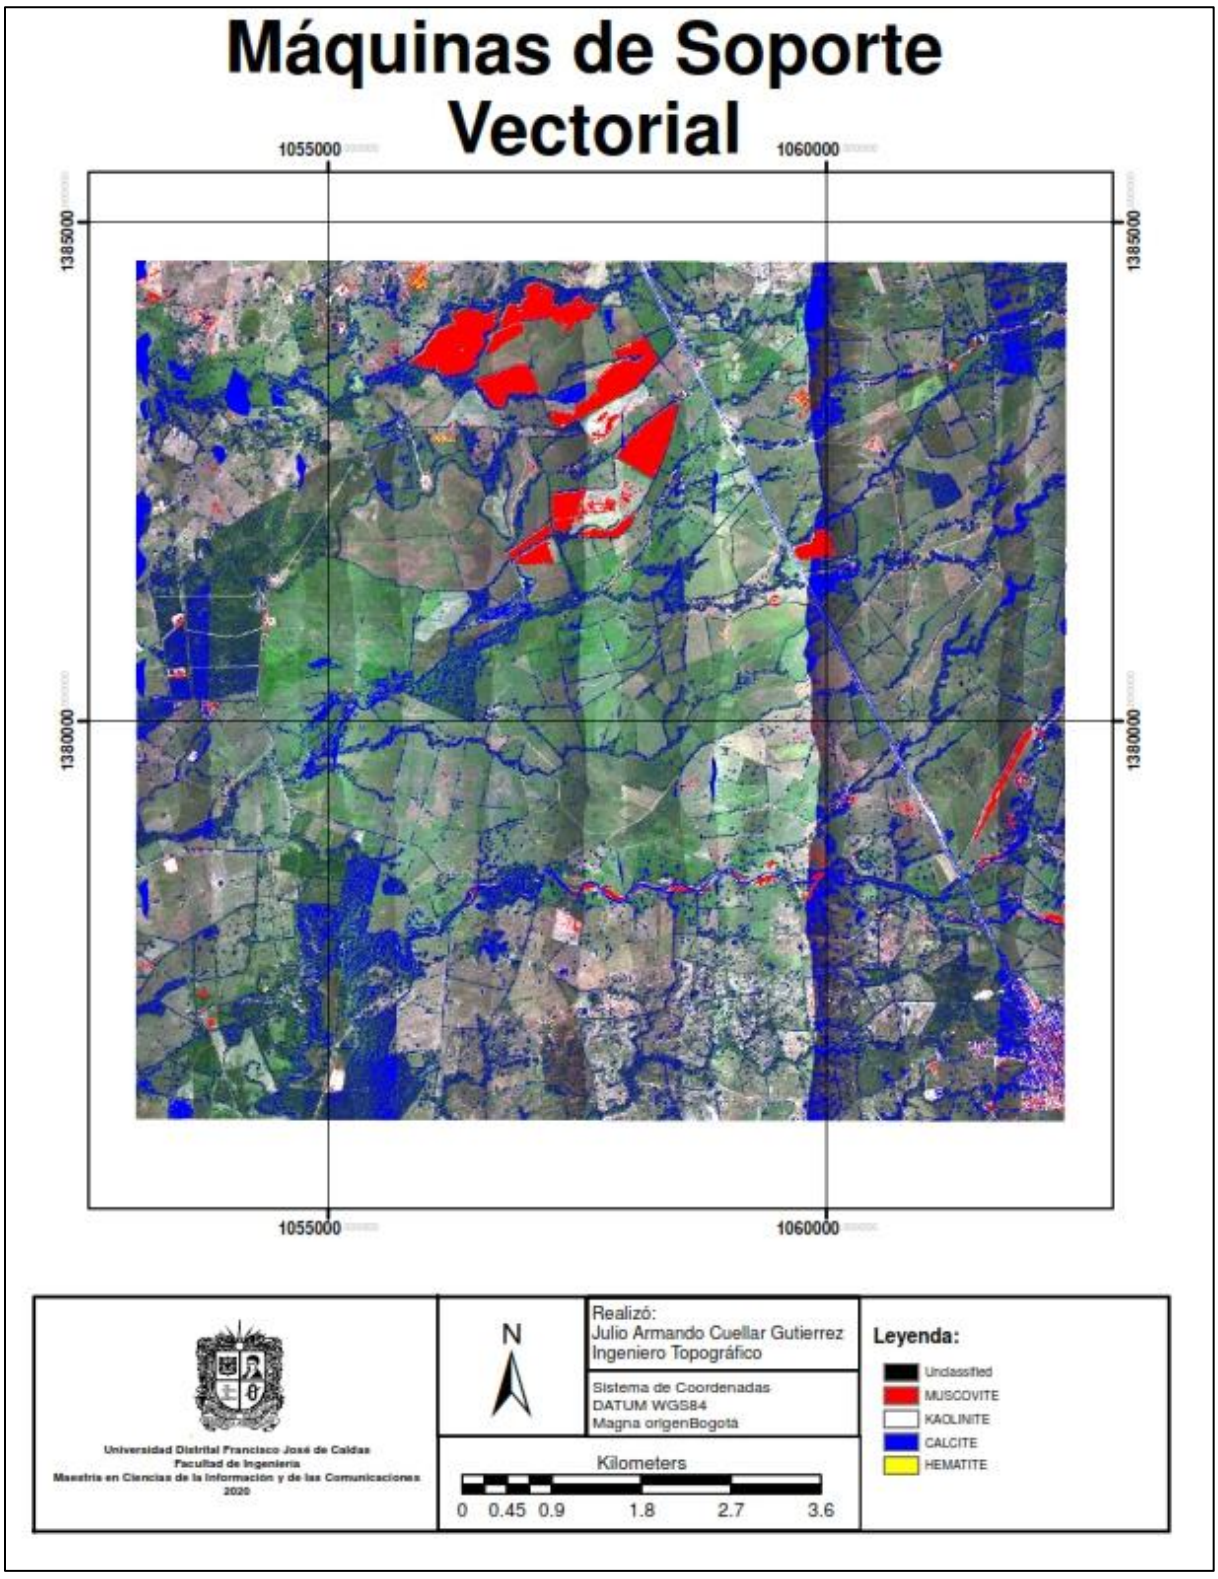
El anexo 2 presenta las imágenes Hiperespectrales del sensor SPECTIR con 365 bandas en verdadero color RGB.

Anexo 3. Índice de Vegetación normalizado NDVI



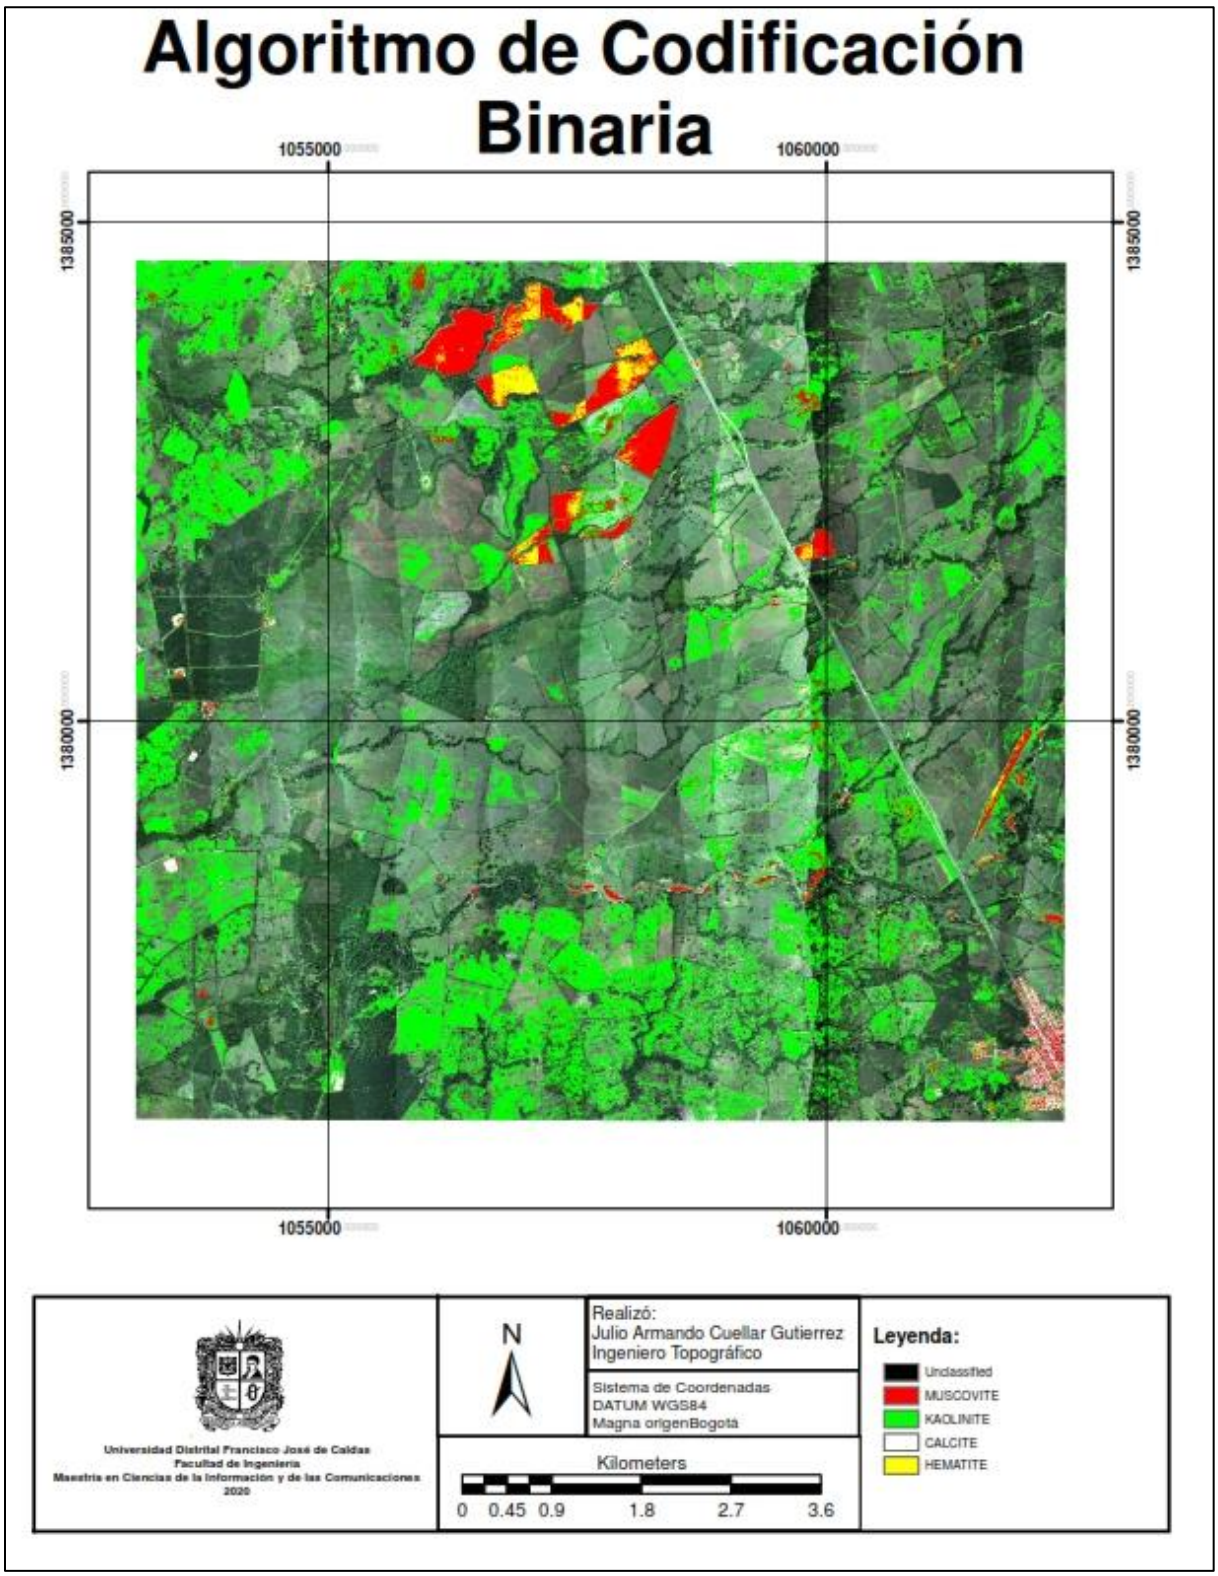
El anexo 3 los resultados de índice de vegetación normalizado donde se puede identificar de manera sencilla las zonas con presencia de vegetación y suelo descubierto

Anexo 4. Máquinas de Soporte Vectorial



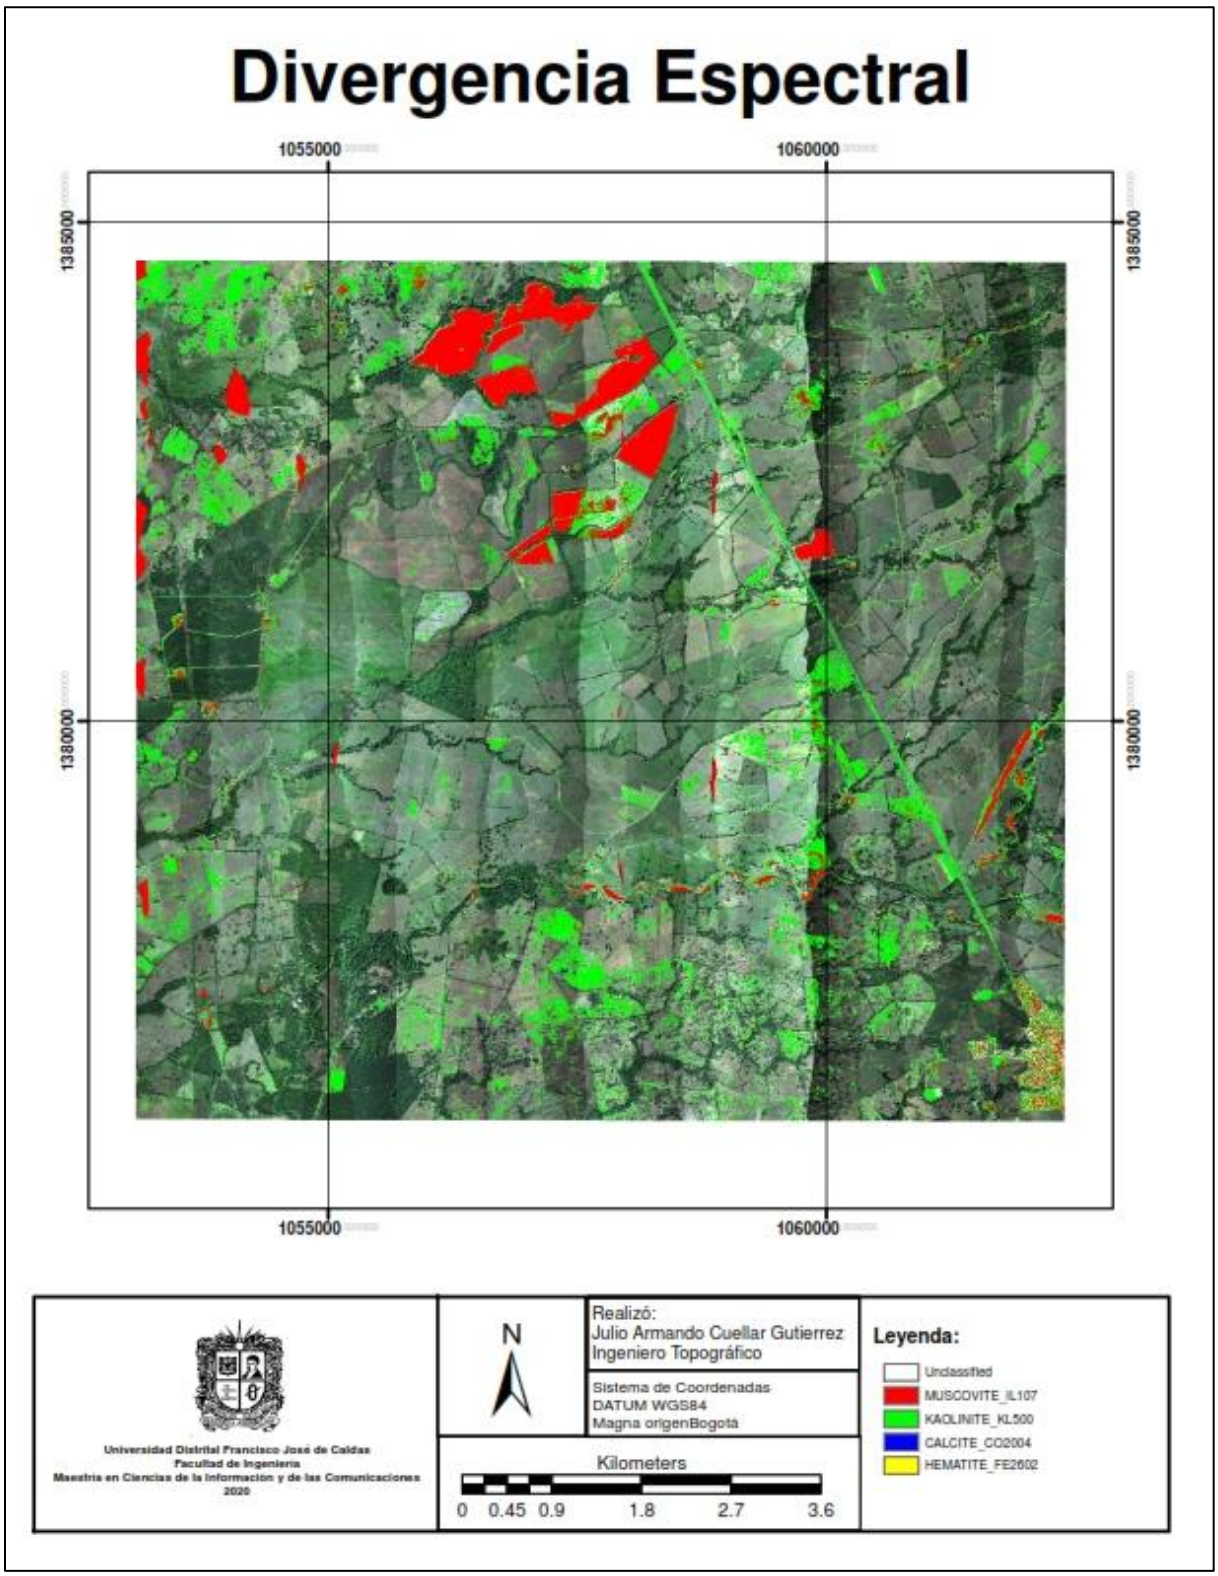
El anexo 4 muestra la clasificación basados en maquinas de soporte vectorial para los elementos Moscovita, Caolinita, Calcita y Hematita presentes en la zona.

Anexo 5. Algoritmo de Codificación Binaria



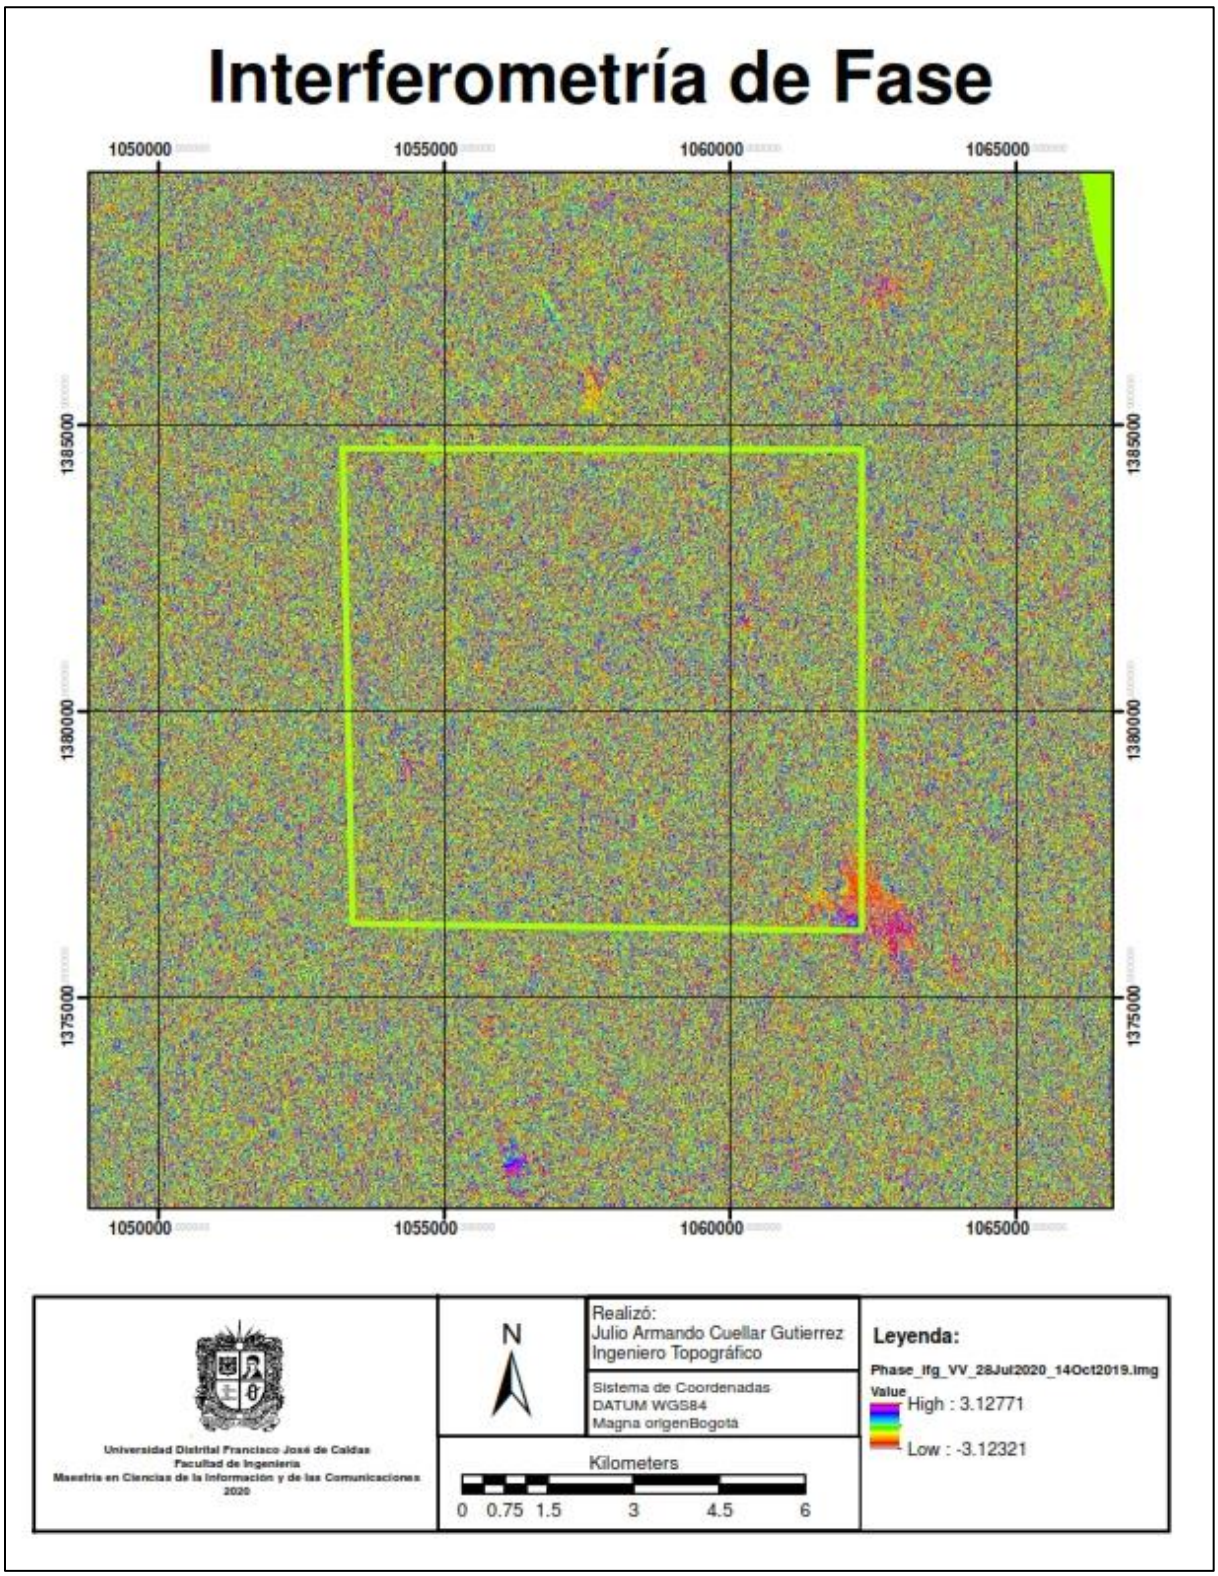
El anexo 5 muestra la clasificación basados en Algoritmo de codificación primera para los elementos Moscovita, Caolinita, Calcita y Hematita presentes en la zona.

Anexo 6. Divergencia Espectral



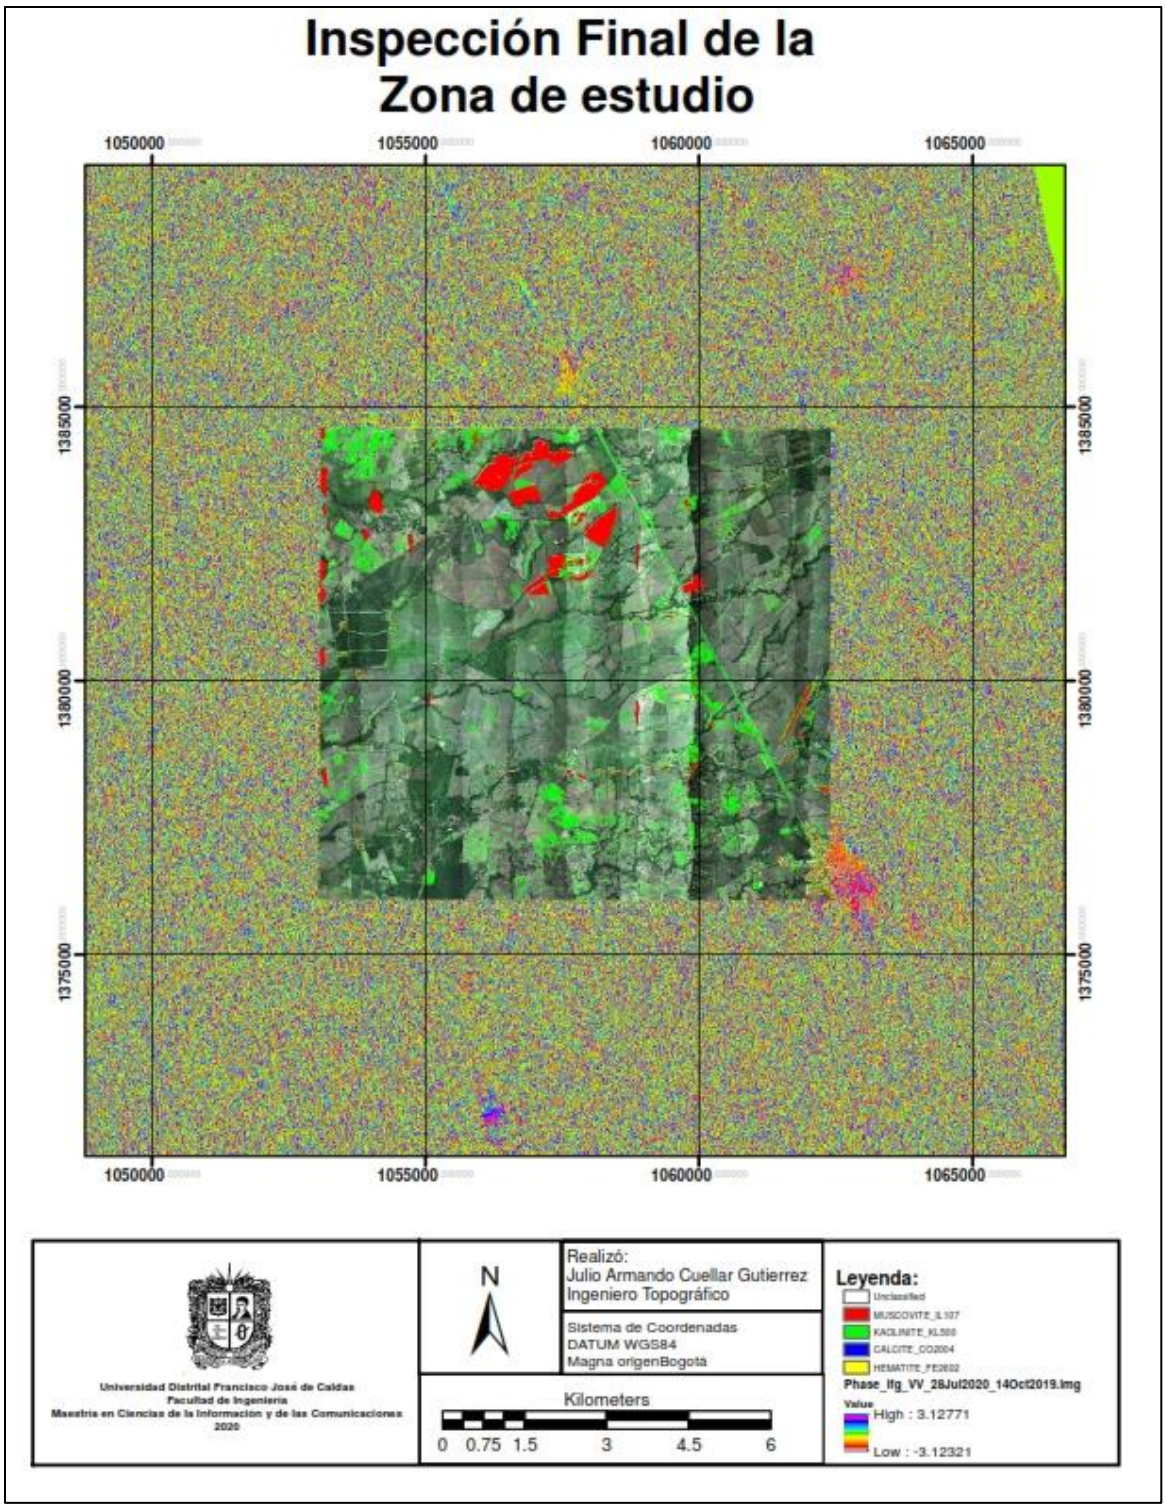
El anexo 6 muestra la clasificación basados en Divergencia Espectral para los elementos Moscovita, Caolinita, Calcita y Hematita presentes en la zona.

Anexo 7. Interferometría de Fase



El anexo 7 muestra los resultados de la interferometría de fase en la zona de estudio donde se muestra el desplazamiento anual no superior al 3.12 cm por año.

Anexo 8. Inspección Final de la Zona de estudio



El Anexo 8 se generó la unión de mapas con el mejor clasificador (divergencia espectral) y el interferometría de fase para la interpretación de sitios con alta concentración mineralógica para estudio de exploración y mejoramiento de los mapas geológicos base de la región.

Anexo 9. Código Matlab para la generación de OIF

Se genera una metodología en código MATLAB para mejorar el proceso de cálculo de OIF factor de índice óptimo para el cálculo de la mejor combinación de bandas

- Cargamos la Imagen

```
vRaster = imread('imagen.tif');
format shortG;
```

- Contamos el número de Bandas de la Imagen

```
vSize = size(vRaster,3);
vStdDev = zeros(vSize,2);
```

- Calculamos la Desviacion Estandar

```
disp('Desviacion Estandar');
disp('');
```

- Matriz de Correlación

```
disp('Matriz de Correlacion');
disp('');
disp(vMatCorrel);
```

- Calculamos el OIF

```
vBandas = zeros(1,vSize);
for b = 1:vSize
   vBandas(1,b) = b;
end
```

- Combinación de Bandas

```
vComBand = nchoosek(vBandas,3);
```

- Cálculo de OIF

```
disp('Matriz OIF');
disp('');
vOIFdes = zeros(size(vComBand,1),1);
for d = 1:size(vComBand,1)
   vSumStdDev = (vStdDev(vComBand(d,1),2) + vStdDev(vComBand(d,2),2) +
vStdDev(vComBand(d,3),2));
   vSumCorrel = (vMatCorrel(vComBand(d,1),vComBand(d,2)) +
vMatCorrel(vComBand(d,1),vComBand(d,3)) +
vMatCorrel(vComBand(d,2),vComBand(d,3)));
   vOIFdes(d,1) = vSumStdDev / vSumCorrel;
end
vMaxOIF = 0;
vOIF = zeros(size(vComBand,1),4);
end
```