

**METODOLOGÍA PARA LA IDENTIFICACIÓN DE MINERÍA ILEGAL A TRAVÉS DE
IMÁGENES ÓPTICAS Y DE RADAR EN EL SUROCCIDENTE DEL VALLE DEL
CAUCA**

SEBASTIAN SIERRA SAMBONI

DIRECTOR:

FRANCISCO L. HERNANDEZ, M.Sc.

UNIVERSIDAD DEL VALLE

FACULTAD DE INGENIERÍA

ESCUELA DE INGENIERÍA CIVIL Y GEOMÁTICA

SANTIAGO DE CALI, VALLE DEL CAUCA

2025

**METODOLOGÍA PARA LA IDENTIFICACIÓN DE MINERÍA ILEGAL A TRAVÉS DE
IMÁGENES ÓPTICAS Y DE RADAR EN EL SUROCCIDENTE DEL VALLE DEL
CAUCA**

SEBASTIAN SIERRA SAMBONI

DIRECTOR:

FRANCISCO L. HERNANDEZ, M.Sc.

Trabajo de grado en la modalidad de Investigación e Innovación para optar por el título de:

INGENIERO TOPOGRÁFICO

UNIVERSIDAD DEL VALLE

FACULTAD DE INGENIERÍA

ESCUELA DE INGENIERÍA CIVIL Y GEOMÁTICA

SANTIAGO DE CALI, VALLE DEL CAUCA

2025

DEDICATORIA

Dedico este trabajo a mis padres, cuya motivación constante y apoyo incondicional han sido fundamentales para tener valentía y seguir adelante incluso levantándome de los momentos difíciles, impulsándome siempre a alcanzar mis objetivos. De igual manera, hago mención especial de mis amigos Juan Camilo, Juan Esteban, Jonathan y Sergio, quienes constantemente me motivaron durante todo mi progreso. Hoy por fin puedo hacerles mención que he culminado.

AGRADECIMIENTOS

A pesar de ser un trabajo realizado individual, no hubiese sido posible terminarlo sin el respaldo de las personas mencionadas dentro de este apartado. Eternamente doy gracias a mi padre y mi madre, por brindarme fuerzas y motivación por su apoyo incondicional bajo momentos difíciles o confusos.

Por otra parte, agradezco a Francisco Luis Hernandez. M.Sc. Por su dirección y por ser un verdadero mentor a lo largo de este proceso. Gracias a su guía y compromiso no solo me ayudaron a comprender mejor los desafíos académicos, sino que también logré tener una perspectiva diferente de las cosas que me inspiraron a crecer personal y profesionalmente. Gracias por compartir su conocimiento con generosidad y por creer en mí incluso para plasmar una idea mediante este proyecto.

Sí bien, nunca pensé llegar a este punto y menos bajo esta carrera, hoy en día me siento orgulloso de presentar este trabajo.

CONTENIDO

1. RESUMEN.....	4
2. INTRODUCCIÓN.....	5
3. PLANTEAMIENTO DEL PROBLEMA	7
4. OBJETIVOS.....	9
4.1 Objetivo General	9
4.2 Objetivos Específicos.....	9
5. JUSTIFICACIÓN.....	10
6. MARCO TEÓRICO	12
6.1 Marco conceptual.....	12
6.2 Marco Teórico.....	15
6.3 Marco referencial	19
7. METODOLOGÍA.....	23
7.1 Materiales y zona de estudio	24
7.1.1 Zona de estudio.....	24
7.1.2 Imágenes utilizadas.....	24
8. RESULTADOS	36
9. ANÁLISIS DE LOS RESULTADOS	45
10. DISCUSIÓN DE LOS RESULTADOS	48
11. CONCLUSIONES.....	50
12. PRÓXIMOS TRABAJOS	52
13. BIBLIOGRAFÍA.....	53
14. ANEXOS.....	57

FIGURAS

Figura 1. Diagrama de procesos.	23
Figura 2. Zona de estudio.	24
Figura 3. Composición en “Color Real” (Izquierda) e índice de Diferencia Normalizada de Agua Modificado (Derecha).	26
Figura 4. Composición en “Color Real” (Izquierda) e Índice de Vegetación Diferencial Normalizada (Derecha).	27
Figura 5. Composición en “Color Real” (Izquierda), Índice de Vegetación Diferencial Normalizada (Centro) e Índice de Vegetación Ajustado al Suelo (Derecha).	27
Figura 6. Composición en “Color Real” (Izquierda), Índice de Vegetación Diferencial Normalizada (Centro medio) e Índice de Vegetación Ajustado al Suelo (Derecha).	27
Figura 7. Composición en “Color Real” (Izquierda), Visualización cercana (Centro) e Índice de Vegetación Ajustado al Suelo (Derecha).	27
Figura 8. Composición en “Color Real” (Izquierda) e índice normalizado diferencial de construcción (Derecha).	28
Figura 9. Cuadrícula de actividad minera ilegal EVOA superpuesta con la clasificación realizada.	29
Figura 10. Visualización de clasificación original (Izquierda) y clasificación suavizada (Derecha).	30
Figura 11. Visualización de las imágenes de Amplitud T1 (Mes más antiguo), Amplitud T2 (Mes más actual), y la imagen de coherencia (Derecha).	31
Figura 12. Imágenes normalizadas.	32
Figura 13. Imagen resultante tras la resta de las amplitudes normalizadas.	32
Figura 14. Píxeles resultantes de la resta de amplitudes con el filtro de zonas con coherencia baja (≤ 0.35).	33
Figura 15. Densidad de cambios a partir de las zonas con valores negativos.	34
Figura 16. Clasificación realizada a partir de NDVI, MNDWI, SAVI y NDBI para la validación de información.	34
Figura 17. Píxeles de zonas con amplitudes negativas (Verdes), áreas sugeridas con presencia de la actividad (Rojas) y zonas con potencial actividad tras el cruce de áreas (Azules).	35
Figura 18. Clasificación Sentinel Random Forest (Izquierda) e imagen suavizada (Derecha).	36
Figura 19. Clasificación Planet Random Forest (Izquierda) e imagen suavizada (Derecha).	36
Figura 20. Visualización de los cuadrados EVOA superpuestos a la clasificación suavizada.	39
Figura 21. Píxeles resultantes tras la resta y filtrado de coherencia (Izquierda) y cambios negativos (Derecha), periodo 1.	40
Figura 22. Densidad de cambios entre Junio 2021 y Julio 2022.	41
Figura 23. Visualización de zonas con amplitudes negativas y zonas rojas (Izquierda) y áreas con potencial actividad minera ilegal producto del cruce de información (Derecha), periodo 1.	41
Figura 24. Píxeles resultantes tras la resta y filtrado de coherencia (Izquierda) y cambios negativos (Derecha), periodo 2.	42
Figura 25. Densidad de cambios entre Diciembre 2021 y Julio 2022.	42
Figura 26. Visualización de zonas con amplitudes negativas y zonas rojas (Izquierda) y áreas con potencial actividad minera ilegal producto del cruce de información (Derecha), periodo 2.	43
Figura 27. Representación de valores asociados a cambios entre amplitudes.	43
Figura 28. Resultados de área preliminar y potencial tras el cruce de información entre índices espectrales vs diferencias de amplitud negativas de radar.	44

TABLAS

Tabla 1. Imágenes utilizadas.	24
Tabla 2. Clasificación base de coberturas.	28
Tabla 3 Matriz de Confusión Random Forest con imagen Sentinel.	37
Tabla 4. Porcentajes de Aciertos de la Matriz de Confusión Random Forest a partir de imagen Sentinel.	37
Tabla 5. F1-Score a partir de la Matriz de Confusión Random Forest a partir de imagen Sentinel.	37
Tabla 6. Matriz de Confusión Random Forest con imagen Planet.	38
Tabla 7. Porcentajes de Aciertos de la Matriz de Confusión Random Forest a partir de imagen Planet.	38
Tabla 8. F1-Score a partir de la Matriz de Confusión Random Forest a partir de imagen Planet.	38
Tabla 9. Áreas identificadas con minería ilegal de Sentinel y Planet comparadas con los cuadrados EVOA.	40
Tabla 10. Cantidad de píxeles con cambios por categorías.	43
Tabla 11. Área con potencial actividad minería ilegal.	44

LISTA DE ACRÓNIMOS

InSAR	Interferometría SAR.
SAR	Radar de Apertura Sintética.
EVOA	Explotación de Oro de Aluvión.
UNDOC	Oficina de las Naciones Unidas contra la Droga y el Delito.
ANM	Agencia Nacional de Minería.

1. RESUMEN

El sector minero energético es la columna vertebral de la economía colombiana, contribuyendo en gran parte a las exportaciones y la generación de empleo. Pero, la minería ilegal en aumento es un problema para sostener y legalizar este trabajo en el país. Información de la Defensoría del Pueblo en 2022 indicaron que aproximadamente el 86% del oro producido en Colombia viene de la minería ilegal, lo cual pone preocupaciones sobre la ley y los efectos dañinos a naturaleza. Un lugar que ha sufrido los golpes de la minería ilegales son Bajo Calima, en el suroccidente del Valle del Cauca. La creciente cantidad de actividades extractivas en esta zona ha provocado una crisis ambiental muy grande con efectos malos en los ecosistemas locales cada vez que avanza el tiempo. Con el objetivo de identificar estos problemas usando sensores remotos, se sugiere un método con técnicas de teledetección e implementación de imágenes ópticas de radar para detectar tempranamente la actividad minera ilegal. Esto implicó la caracterización de la zona mediante índices espectrales en imágenes ópticas, implementando el uso del algoritmo de aprendizaje Random Forest logrando clasificar las áreas con presencia de la actividad junto con las coberturas relacionadas con la minería ilegal y su posterior validación de precisión que superaron un 80% dejando como producto el límite de estudio. A su vez, con la implementación de imágenes SAR se realizó la diferencia entre imágenes de amplitud filtrado en el límite de la actividad, obteniendo cambios físicos y también, se empleó la metodología InSAR haciendo uso de las imágenes de coherencia, las cuales fueron base para un filtrado de zonas decorrelacionadas. Este proyecto se centró en el cruce temático entre imágenes ópticas y radar, generando un flujo para una identificación oportuna ante la presencia de la problemática usando como recursos a dos pares de imágenes SAR, con las que se obtuvieron áreas con potencial actividad reciente de 1.41 ha y 1.02 ha para líneas base temporales grandes y cortas respectivamente.

Palabras clave: Minería ilegal, Teledetección, Random Forest, metodología InSAR, Detección de cambios.

2. INTRODUCCIÓN

El sector minero-energético es uno de los mayores impulsos del crecimiento económico de Colombia, contribuyendo significativamente al PIB, la creación de trabajos y la llegada de inversión extranjera. En cuanto a exportaciones, la minería representa una porción considerable de los ingresos nacionales no tradicionales siendo el carbón, oro y níquel los metales más importantes, donde especialmente el oro ha tenido éxito con un número que llegó a las 47.6 toneladas en el año 2020 que fue un gran aumento por 29.9% en comparación con el año antes (Agencia Nacional de Minería, 2021). Pero, este crecimiento ha sido alto con actividades ilegales. Se estima que cerca del 65 % de las minas auríferas del país operan sin los permisos requeridos, lo que ha derivado en la degradación de más de 100.000 hectáreas para el año 2020, involucrando afectaciones a las fuentes hídricas, representando un aumento del 2.78% con respecto a las 98.028 hectáreas reportadas en el año 2019 (Tarazona, 2023).

La minería ilegal de oro, particularmente la de aluvión, tiene impactos ambientales severos, incluyendo deforestación, contaminación por mercurio y sedimentación de cuerpos de agua. A esto se suma su vínculo con economías ilegales asociadas al narcotráfico, la extorsión y el financiamiento de grupos armados ilegales (BBC, 2011). Esta situación se agrava por la falta de herramientas oficiales para el monitoreo eficaz de esta actividad en tiempo real (Defensoría del Pueblo, 2018). En respuesta, han surgido iniciativas académicas como la plataforma CoMiMo, desarrollada por la Universidad del Rosario, la cual emplea imágenes satelitales y modelos de aprendizaje profundo para identificar posibles focos de minería ilegal (URosario, 2022). De igual forma, investigaciones como la de Chamorro (2021) utilizaron Google Earth Engine (GEE) y sensores ópticos Sentinel-2 para detectar áreas de minería en El Bagre, Antioquia, con resultados altamente precisos.

No obstante, el uso exclusivo de imágenes ópticas presenta limitaciones debido a la frecuente cobertura de nubes en zonas tropicales, lo cual puede generar falsos positivos. En este contexto, el uso de imágenes SAR (Radar de Apertura Sintética) surge como una alternativa, ya que permite capturar información de la superficie terrestre sin depender de las condiciones atmosféricas (Villegas, 2019).

Dado el comportamiento altamente dinámico de la minería ilegal de aluvión, es necesario establecer métodos de monitoreo multitemporal que permitan detectar cambios recientes y evaluar patrones de expansión. En este sentido, la combinación de imágenes de radar, particularmente aquellas derivadas de coherencia InSAR y de amplitud, ofrece ventajas significativas al proporcionar distintos tipos de información complementaria (Murdaca et al., 2023). Mientras que la coherencia permite detectar zonas con pérdida de similitud estructural entre adquisiciones sucesivas, asociadas a actividad reciente, la amplitud facilita la detección de alteraciones físicas abruptas en la superficie terrestre. Esta complementariedad ha sido destacada en estudios como los de Murdaca et al. (2023) y Wang et al. (2021), quienes han demostrado que el uso combinado mejora sustancialmente la sensibilidad y especificidad de los métodos de detección.

No obstante, las imágenes SAR por sí solas pueden presentar limitaciones en zonas con alta vegetación o humedad, donde la pérdida natural de coherencia puede dificultar la interpretación, es por ello, que se recomienda incorporar imágenes ópticas como apoyo para validar y reforzar los resultados obtenidos mediante radar. Esta fusión metodológica ha sido aplicada con éxito por Closson et al. (2017) y Wang et al. (2020), quienes integraron información óptica para mejorar la discriminación entre cambios naturales y antrópicos, permitiendo una interpretación más precisa de la problemática. Las imágenes ópticas aportan además información espectral útil para identificar

coberturas vegetales, cuerpos de agua y áreas descubiertas, lo cual es importante para clasificar correctamente las zonas afectadas.

La integración de imágenes ópticas y SAR brinda un enfoque oportuno para la detección y seguimiento de minería ilegal. Este tipo de metodologías integradas cobra importancias en contextos dinámicos, donde las condiciones atmosféricas, la cobertura vegetal y la variabilidad pueden ser impedimento para ser estudiado a partir de un único producto desde el monitoreo remoto (Closson et al.,2017).

Este trabajo recoge un proyecto de investigación orientado hacia la unión de información de imágenes ópticas y de radar, con el fin de realizar la identificación de la minería ilegal de tipo aluvión. La ejecución de la metodología implicó caracterizar la problemática y delimitación del área afectada a través de un algoritmo de aprendizaje Random Forest junto con su validación a partir de métricas. Además, a partir del límite identificado, se hizo uso de la metodología InSAR dentro del límite identificado obteniendo la imagen de coherencia que, junto con las imágenes de amplitud y su posterior cruce con clasificación a partir de índices espectrales, se logró estimar zonas con potencial actividad reciente. A través de esta metodología, se obtuvo un área potencialmente afectada de 1.41 hectáreas entre el periodo de Junio 2021 a Julio 2022 y 1.02 hectáreas entre Diciembre 2021 y Julio 2022, reflejado en una reducción del 39.6% al acortar el intervalo de análisis. El documento se organiza en capítulos principales que abarcan desde el contexto y formulación del problema hasta la presentación de resultados, análisis, conclusiones y futuros trabajos. Se incluye una descripción detallada de la metodología aplicada, así como un marco teórico que sustenta el enfoque adoptado. A lo largo del texto, se incorporaron figuras y tablas con sus respectivas descripciones, que permiten visualizar y comprender de forma clara los procesos y hallazgos del estudio.

3. PLANTEAMIENTO DEL PROBLEMA

La subregión del Bajo Calima de Buenaventura, Valle del Cauca, se encuentra bajo una grave emergencia ambiental provocada por la expansión de la minería ilícita en los últimos años, especialmente la minería a cielo abierto, en particular la minería de aluvión, reflejada a través de las Evidencias de Explotación de Oro de Aluvión (EVOA). Los sistemas productivos locales también se han visto modificados por esta ilegalidad que imprime una profunda afectación en los ecosistemas locales, reflejado en la reducción de áreas de bosques y conflictos sociales (El País, 2023). La deforestación en la zona alcanzó niveles altos al reducir drásticamente la cobertura vegetal y fracturar los hábitats naturales. Solo en 2023 Buenaventura ha perdido 65 hectáreas de cobertura arbórea, lo que equivale a 42.1 kt de emisiones de CO₂ (Global Forest Watch, 2023). Además, entre 2002 y 2023, el área perdió 3.66 kha (equivalentes a 3.660 hectáreas) de bosque húmedo primario, lo que equivale al 58% de la pérdida total de cobertura arbórea para ese período (Global Forest Watch 2023).

La contaminación por mercurio, una de las prácticas comunes relacionadas con la extracción de oro en la minería de EVOA, ha alcanzado altos niveles. Recientemente, un estudio realizado por la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO, 2023) reveló la estrecha relación entre la minería ilegal de oro y los cultivos ilícitos en Colombia, destacando que el 38% de las áreas mineras ilegales tienen cultivos ilícitos. El desarrollo de la violencia, los conflictos sociales y el deterioro ambiental son algunos de los efectos asociados con esta problemática. En el caso del Bajo Calima, donde los reportes de minería ilegal en su zona rural comienzan a aumentar, se espera que los niveles de contaminación por mercurio sean significativamente altos con los que se pondrá en riesgo la salud de las comunidades locales y la biodiversidad acuática (Fuerza Aérea Colombiana, 2023).

La persistencia de reportes sobre la actividad minería ilegal en Bajo Calima es atribuida a una compleja interacción de diversos factores, entre los que destacan la pobreza, la desigualdad, la debilidad institucional, la corrupción y la demanda de minerales. La falta de oportunidades económicas ha llevado a muchas personas a involucrarse en actividades ilícitas, mientras que la corrupción y la complicidad de actores armados han facilitado la operación de redes criminales dedicadas a la explotación minera dificultando el acceso para la pronta identificación (Méndez, 2024).

Para el reconocimiento de este tipo de actividades, normalmente se realizan vuelos de patrullaje y, a través de la perspectiva aérea se observan características de la superficie o patrones que permiten establecer ubicaciones con presencia de la problemática (Fuerza Aérea Colombiana, 2023). La detección de cambios en la cobertura vegetal, la presencia de infraestructura o equipo minero y la identificación de zonas con alteración del suelo son algunos de los indicadores que permiten identificar áreas con alta probabilidad de actividad minera ilegal (Chamorro, 2021). No obstante, esta técnica se vuelve poco práctica en términos económicos, considerando los altos costos de realizar un vuelo fotogramétrico, que rondan los 5000 pesos por hectárea (FAL S.A.S, 2019). A raíz de ello, valorar el desarrollo de la minería a escala municipal incrementaría considerablemente estos costos, proporcionando únicamente datos de una fecha específica.

Ante este hecho, las autoridades intensificaron sus esfuerzos para dismantelar las operaciones de minería ilegal en el Bajo Calima. En un operativo en 2023, la Armada, el Ejército y la Policía Nacional destruyeron dos unidades de producción minera en esta región, que eran canales de recursos que movían cerca de 350 millones de pesos mensuales para los grupos armados ilegales (Armada de Colombia, 2023). Aún con esta iniciativa, la minería ilegal de oro continúa y los niveles de

contaminación por mercurio aún alcanzan impactos altamente adversos sobre las comunidades locales y la biodiversidad (Semana, 2023).

En los últimos años solo se manejan supuestos respecto a los grados de afectaciones presentes en esta zona, donde mayormente se atribuyen a la presencia de actividad minera ilegal, no obstante, no se presenta cartografía sobre puntos afectados ni recorridos puesto que se estima gran presencia de grupos armados ilegales que dificultan la toma de información y la seguridad del personal. Además, la presencia de cobertura boscosa complica el acceso y la rápida identificación de la actividad minera. Pero, en ciertas temporadas estacionales por la presencia de nubes, la disponibilidad de información es limitada, lo que puede llevar a una percepción errónea de actividad minera. Dado el alto riesgo involucrado en la evaluación en campo del avance y los efectos de la minería ilegal, resulta fundamental examinar el desarrollo de esta problemática de manera remota desde etapas tempranas. Bajo este contexto, surgen las siguientes preguntas de investigación: ¿Cuál sería la metodología más adecuada para identificar zonas con actividad minera ilegal utilizando sensores remotos? ¿Cómo se pueden combinar técnicas de detección de cambios en la cobertura vegetal para mejorar la precisión en la identificación de zonas afectadas por minería ilegal en áreas como Bajo Calima? Finalmente, ¿De qué manera el uso de modelos de clasificación supervisada puede optimizar el monitoreo continuo de la actividad minera ilegal, incluso en condiciones de alta cobertura boscosa y presencia de interferencias atmosféricas?

4. OBJETIVOS

4.1 Objetivo General

Desarrollar una metodología que combine imágenes ópticas y radar para identificar áreas afectadas por minería ilegal en el Bajo Calima.

4.2 Objetivos Específicos

- Caracterizar las zonas con actividad minera ilegal en el Bajo Calima utilizando técnicas de percepción remota y análisis espacial.
- Desarrollar un modelo computacional para la identificación espacial de la minería ilegal de aluvión.
- Validar los resultados obtenidos mediante la comparación con registros y datos oficiales de las autoridades competentes.

5. JUSTIFICACIÓN

La minería ilegal en Colombia tiene un impacto significativo en el crecimiento económico y el medio ambiente. Esta actividad no solo destruye ecosistemas y fuentes de agua, sino que también fortalece a grupos armados al margen de la ley (El Tiempo, 2024).

La falta de información precisa sobre dónde se encuentran y cuán grandes son las áreas afectadas por la explotación de recursos naturales hace que sea difícil controlar y mitigar los impactos ambientales y sociales. La combinación de falta de datos precisos y un desarrollo económico no regulado puede llevar a la sobreexplotación, a menudo en detrimento de las comunidades locales y de la degradación ecológica (Galindo, 2020). Por lo tanto, es importante implementar medidas efectivas para regular y supervisar las actividades relacionadas que garantizarán la identificación oportuna de las áreas afectadas y junto con la intervención temprana para minimizar los daños.

El uso de tecnologías avanzadas como lo son la información proveniente de índices espectrales en las imágenes ópticas, el uso de técnicas con las imágenes de radar como InSAR y modelos de segmentación para la detección de minería ilegal ofrece una serie de beneficios clave para el monitoreo eficiente y a gran escala de áreas afectadas por esta actividad en la región de Buenaventura, Valle del Cauca. Según Liu et al. (2019), los sensores remotos tienen la ventaja de adquirir rápidamente información sobre grandes superficies, permitiendo el monitoreo de zonas extensas sin la necesidad de recorrer físicamente cada área. Esto supera las limitaciones de los métodos tradicionales de seguimiento, que requieren inspección directa, y permite realizar un monitoreo continuo y preciso a lo largo del tiempo con la unión de los dos tipos de imágenes satelitales.

Bajo este contexto, el uso de los índices espectrales permite detectar y monitorear cambios en la cobertura mediante la combinación de diferentes bandas espectrales de una imagen satelital. Gracias a ellos, es posible destacar en las coberturas la presencia de la vegetación, el suelo o el agua, lo que facilita entender mejor lo que está pasando en un área determinada. Por otra parte, la metodología InSAR es particularmente útil para la detección de cambios superficiales orientado hacia la detección de afectaciones producto de minería ilegal, ya que permite obtener información sobre los cambios del terreno sin conocer la ubicación exacta de las minas. Chaussard et al. (2016) resaltan que, en el caso de la minería ilegal, las técnicas tradicionales son limitadas debido a la falta de conocimiento sobre la ubicación de las minas. Por esta razón, la interferometría de radar (InSAR) se presenta como una herramienta eficaz para identificar de manera temprana las áreas afectadas por minería ilegal y las zonas con cambios repentinos en las coberturas. Además, la coherencia InSAR ha demostrado ser un enfoque efectivo para identificar zonas afectadas por minería ilegal, como se evidencia en el estudio de Wang et al. (2020), que destacó el uso de la coherencia del radar permitiendo detectar alteraciones en la superficie terrestre, como el desplazamiento del suelo o la destrucción de la vegetación, sin la necesidad de información detallada sobre la ubicación de la mina.

Los avances en la implementación de algoritmos de aprendizaje, como el enfoque propuesto por Chamorro (2021), mejorarán la precisión de la detección de actividad a partir del óptico, delimitando las áreas donde de manera preliminar está presente la actividad. Este enfoque integrará datos complementarios, como imágenes satelitales de radar, para mejorar aún más la detección y realizar la caracterización de zonas con actividad minera ilegal.

Los productos generados gracias a esta aproximación, tal como la identificación de cambios tras la metodología InSAR y clasificaciones de áreas mineras, serán de gran ayuda para las autoridades locales y nacionales, tales como alcaldías, gobernaciones, la Agencia Nacional Minera (ANM) y las

corporaciones autónomas regionales (CAR). A partir de estos productos, dichos modelos podrán identificar las áreas de mayor riesgo en poco tiempo y tomar decisiones en torno a la regulación minera en dichas zonas basada en información crítica. Al identificar las áreas afectadas, las autoridades podrán optimizar la búsqueda de recursos para la vigilancia y control de dicha actividad, sin necesidad de desplazamientos físicos a campo, lo que reduce los costos operativos.

6. MARCO TEÓRICO

6.1 Marco conceptual

A continuación, se presentan los conceptos básicos necesarios para una comprensión adecuada del trabajo.

Inicialmente, se define por minería al proceso de explotación de recursos naturales, para el caso de la minería ilegal, se considera a la explotación de manera no regulada o realizada en zonas sin permiso estatal por entidades oficiales. Para el caso de este estudio, se refiere como minería de hecho a la explotación de oro tipo aluvial asociada a la terminología de Explotación de oro de aluvión (EVOA).

La minería de oro aluvial se refiere a la extracción de oro que se encuentra debajo de la superficie en el lecho de ríos y arroyos (UNODC, 2020). Este tipo de minería aprovecha el oro que, debido a su alta densidad, se ha depositado en los cursos de agua a lo largo del tiempo, en forma de polvo, escamas finas o pepitas, mientras el agua erosiona y transporta las partículas de roca circundante (GeologyScience.com, 2023).

A diferencia de la minería subterránea, la minería aluvial a cielo abierto es generalmente considerada menos invasiva ambientalmente, ya que no requiere perforación profunda ni generación de túneles. No obstante, genera diversas afectaciones en la zona donde se esté realizando al estar relacionada con procesos de deforestación y destrucción del suelo por el uso de maquinarias o uso de material tóxico.

Este estudio propone el uso de imágenes satelitales ópticas como medio para analizar y brindar una base para identificar esta problemática. Las imágenes satelitales ópticas son representaciones visuales de la información capturada por sensores a través de la radiación electromagnética emitida o reflejada por la superficie terrestre (GEO SAT, 2011). Estas imágenes ofrecen una visión detallada de la topografía y configuración del paisaje, aspectos importantes para el análisis geográfico.

Entre los diversos tipos de imágenes satelitales, destacan las imágenes Planet del programa NICFI, producto de la constelación de satélites de Planet Labs. Estas imágenes se caracterizan por su resolución espacial de aproximadamente 3 a 5 metros con gran extensión de cobertura, lo que permite un análisis detallado de áreas de interés (NICFI, 2022). Por otro lado, la misión Sentinel-2, parte del programa Copernicus de la ESA, está compuesta por una constelación de satélites equipados con sensores multispectrales que capturan imágenes en 13 bandas espectrales con resoluciones de 10, 20 y 60 metros (European Space Agency, 2015). A partir de estas imágenes, se tiene una cobertura global cada cinco días, brindando información útil para estudios y monitoreos.

Además del uso de imágenes ópticas, también se emplean imágenes de radar, que proporcionan información sobre la estructura de los objetos en la superficie y las propiedades dieléctricas de dicha superficie. En este estudio se hizo uso de las imágenes Sentinel-1C, que es el tercer satélite de la misión Copernicus Sentinel-1. Forma parte de una constelación de dos satélites en órbita polar, proporcionando imágenes radar de alta resolución con una frecuencia de revisita de 12 días. Equipado con un radar de apertura sintética (SAR) de banda C, ofrece imágenes en todas las condiciones climáticas y durante el día y la noche (European Space Agency, 2024).

Una imagen de radar es una representación visual obtenida al iluminar una escena con ondas electromagnéticas (microondas) y registrar la energía reflejada o retrodispersada por los objetos presentes en esa escena. La señal retrodispersada, es decir, la señal reflejada, está influenciada por parámetros tanto del radar como de la superficie terrestre. Tres parámetros del radar tienen un efecto significativo en las características de esta señal retrodispersada: la longitud de onda, la polarización y el ángulo de incidencia (Villegas, 2019).

La longitud de onda se refiere a la distancia entre dos crestas consecutivas de una onda. En la teledetección radar, la longitud de onda determina cómo interactúa la señal con la superficie. Por otra parte, la polarización hace referencia al plano de propagación del campo eléctrico de la señal o a la orientación del plano con respecto al envío de la señal. Las señales de radar pueden transmitirse y recibirse en diferentes polarizaciones tomando como terminologías verticales (V) y horizontales (H). Algunas de las polarizaciones son HH, HV, VH y VV junto con la consideración de polarizaciones cruzadas, es decir, la combinación en envío y recepción de información como lo son VV+VH, representando la forma que es transmitida y recibida la señal (Villegas, 2019).

El ángulo de incidencia es el ángulo entre la dirección de iluminación del radar y la vertical de la superficie. Los ángulos pequeños permiten una mayor penetración y generan una mayor retrodispersión, lo que se refleja en tonos más brillantes en la imagen. A medida que el ángulo de incidencia aumenta, la retrodispersión disminuye, ya que la superficie parece más lisa (Villegas, 2019).

Tanto las imágenes ópticas como las imágenes de radar se procesaron utilizando técnicas de percepción remota, las cuales permiten obtener información de los objetos mediante un análisis de datos sin contacto físico directo. Para ello, se empleó el uso de índices espectrales para las ópticas, mientras que para las imágenes de radar (SAR) se realizó acorde con la metodología InSAR.

Un índice espectral es una medida matemática utilizada para resaltar ciertas características de la superficie terrestre a partir de las bandas espectrales de una imagen satelital (EOS, 2024). Estos índices se calculan mediante combinaciones de diferentes longitudes de onda para identificar y analizar propiedades específicas, como la vegetación, el agua o el suelo.

Entre los índices espectrales implementados, se encuentra el Índice de Vegetación Diferencial Normalizada (NDVI), ampliamente utilizado para evaluar la salud y densidad de la vegetación en una región específica, con valores adimensionales en el rango de -1 a 1. Los valores altos (0.6–1) indican vegetación densa y saludable, mientras que los valores bajos (0–0.2) reflejan áreas con poca o ninguna vegetación. Los valores negativos suelen asociarse con cuerpos de agua o zonas desnudas (Jin, 2019). El índice Normalizado Diferencial de Construcción (NDBI), orientado para identificar áreas urbanas y construidas, donde sus valores positivos indican superficies construidas o alteradas, mientras que los negativos corresponden a vegetación o agua (Zha et al., 2003). Además, el Índice de Vegetación Ajustado al Suelo (SAVI) que minimiza la influencia del suelo en áreas con baja cobertura vegetal, considerando la influencia del suelo en la reflectancia de la radiación electromagnética. Los valores cercanos a 1 representan vegetación vigorosa, mientras que valores bajos (0–0.3) indican suelos desnudos o con vegetación dispersa (Huete, 1988). Finalmente, el índice Diferencial de Agua Normalizado Mejorado (MNDWI), para resaltar los cuerpos de agua. Los valores positivos

generalmente representan agua superficial, mientras que los negativos corresponden a vegetación o suelo (Yang et al., 2017).

La Interferometría de Radar de Apertura Sintética (InSAR) se basa en el análisis de interferogramas para detectar cambios en la superficie terrestre con precisiones que pueden llegar al margen de los centímetros. Un interferograma es una representación gráfica que resulta de la comparación de dos imágenes SAR tomadas en diferentes momentos, donde se observa la interferencia de las ondas de radar debido a los desplazamientos del terreno entre ambas adquisiciones (UPM, 2022). A diferencia del Sistema de Posicionamiento Global (GPS), que ofrece un muestreo discreto, InSAR proporciona un muestreo casi continuo y sinóptico de la superficie terrestre, esta técnica, al aprovechar el fenómeno de interferencia de ondas, permite obtener información detallada sobre el terreno, destacándose por su capacidad para medir la deformación del terreno con alta precisión y ofrecer valiosa información sobre la superficie terrestre en un contexto específico.

Para implementar la metodología InSAR, se requiere realizar varias correcciones. Inicialmente, se lleva a cabo el co-registro para alinear espacialmente dos o más imágenes adquiridas en momentos diferentes. Este proceso es importante para el cálculo de la interferencia de fase, que representa la diferencia de fase de las ondas electromagnéticas en ambas imágenes reflejado en información de desplazamientos o deformación del terreno. Este proceso también genera una imagen de coherencia, que indica la calidad y fiabilidad de la interferencia entre las imágenes donde se refleja el cambio en los elementos presentes de la imagen, todo esto a través de los rangos de valores tomando en consideración que una coherencia alta implica mayor precisión en las mediciones de deformación (Fielding et al., 2019).

Después de obtener la interferencia de fase y los mapas de coherencia, se procede con un ajuste de los datos resultantes para eliminar o reducir los efectos no deseados o errores introducidos durante la adquisición o procesamiento de datos hasta finalmente tener estos insumos espacialmente ubicados. Este proceso implica varias correcciones, incluidas las correcciones atmosféricas, topográficas y geométricas.

Una de las principales fuentes de error son las perturbaciones atmosféricas, que introducen variaciones en la señal de radar debido a diversos cambios dentro de los que destacan la humedad, presión y temperatura. Para abordar esto, se aplican modelos atmosféricos para eliminar estos efectos junto con la inferencia atmosférica de los datos (Paz, 2018).

Centralizado en las imágenes en modo burst o generado por ráfagas, comúnmente se aplican técnicas para corregir las discontinuidades en los productos procesados causado por los cambios de frecuencia en la señal. Además, se aplican técnicas de reducción de ruido blanco o speckle presente en las escenas de imágenes SAR, para ello se aplican técnicas como el multilooking y filtrado Goldstein. El multilooking es una técnica que consiste en promediar los valores de varios píxeles adyacentes para obtener un nuevo píxel de valor promedio reduciendo el ruido, pero a su vez, disminuyendo la resolución espacial. Por otra parte, el filtrado Goldstein, promedia los valores de píxeles adaptando su comportamiento a características propias de la escena (Shah, 2022).

Finalmente, se considera que la topografía del terreno también contiene variaciones en los productos resultantes, por ello se deben realizar correcciones topográficas utilizando modelos digitales de elevación (DEM) para corregir la geometría de las imágenes y compensar variaciones en los productos. También se aplican correcciones geométricas debido a diversos factores, como la geometría de la plataforma de observación y la curvatura de la tierra (Ambrosio et al., 2002). Estas correcciones garantizan que el interferograma esté calibrado y que se puedan realizar mediciones precisas de la deformación del terreno.

Para evaluar cómo funciona el modelo resultante, se usan métricas clásicas como precisión y F1-score. La precisión muestra el porcentaje de predicciones correctas entre todas las positivas, indicando cuán confiable es el modelo al identificar coberturas a partir de las muestras. Por otro lado, la métrica F1-score combina precisión y sensibilidad (recall) en una medida armónica, equilibrando cuando es necesario minimizar tanto falsos positivos como negativos (Jin, 2019).

El coeficiente kappa se utiliza para evaluar el nivel de acuerdo (o discordancia) entre las predicciones del modelo y las etiquetas verdaderas conciliadas para la probabilidad de acuerdo aleatorio. Es comúnmente útil aplicado a varios contextos geográficos, ya que permite un estudio de la consistencia en las predicciones por medio de distintas áreas. El valor de Kappa cercano a 1 representa una fuerte concordancia entre las predicciones y los valores reales, y los valores cercanos a 0 representan una concordancia aleatoria que puede usarse para proporcionar una idea general sobre la calidad de un modelo en contextos geográficamente diversos (Jin, 2019).

6.2 Marco Teórico

A continuación, se presentan todas las ecuaciones bases implementadas para la ejecución del trabajo.

6.2.1 NDVI

La técnica NDVI o Índice de Vegetación Diferencial Normalizada basado en la reflectancia de la luz, permite analizar la distribución espacial de la vegetación y el suelo a través de evaluar su estado y dinámica (Rouse et al., 1973).

$$NDVI = \frac{NIR-RED}{NIR+RED}; \quad \text{Dónde } (-1 < NDVI < 1) \quad (1)$$

Donde "Red" se refiere a la reflectancia en el espectro visible en rojo y "NIR" se refiere a la reflectancia en el infrarrojo cercano.

6.2.2 SAVI

El Índice de Vegetación Ajustado al Suelo (SAVI), utilizado debido a su capacidad para detectar cambios sutiles en la vegetación, especialmente en áreas con baja cobertura vegetal o suelos con alta variabilidad (Huete et al., 1988).

$$SAVI = \left(\frac{NIR-RED}{NIR+RED+L} \right) * (1 + L) \quad (2)$$

Donde "Red" se refiere a la reflectancia en el espectro visible en rojo, "NIR" se refiere a la reflectancia en el infrarrojo cercano y L es la constante de ajuste por el brillo del suelo.

6.2.3 MNDWI

El índice de Diferencia Normalizada de Agua Modificado (MNDWI), se utiliza para resaltar la reflectancia de cuerpos de agua, permitiendo obtener áreas con identificación de zonas de agua (Yang et al., 2017).

$$MNDWI = \frac{GREEN - MIR}{GREEN + MIR}; \quad \text{Dónde } (-1 < MNDWI < 1) \quad (3)$$

Dónde "GREEN" representa la reflectancia en el espectro verde y "MIR" se refiere al infrarrojo medio.

6.2.4 NDBI

El índice normalizado diferencial de construcción, que lo permite la caracterización de características urbanas o asociadas a edificaciones, separándolo de otros tipos de cobertura, como suelos con plantas o suelos desnudos (Zha et al., 2003).

$$NDBI = \frac{SWIR - NIR}{SWIR + NIR}; \quad \text{Dónde } (-1 < MNDWI < 1) \quad (4)$$

Donde "NIR" representa la reflectancia en el infrarrojo cercano y "SWIR" hace referencia al infrarrojo de onda corta o infrarrojo medio.

6.2.5 Random Forest

El Random Forest es un clasificador que construye múltiples árboles de decisión a partir de subconjuntos aleatorios de los datos y predictores. La clasificación final se determina mediante votación mayoritaria entre los árboles generados (Breiman, 2001). Formalmente, para un conjunto de entrenamiento $\{(X_i, Y_i)\}_{i=1}^n$, la predicción para una nueva muestra X se contiene en la ecuación (5).

$$\hat{Y} = \text{moda}\{h_1(X), h_2(X), \dots, h_T(X), \}$$
 (5)

Dónde $h_T(X)$ es la predicción del árbol t entre los T árboles del bosque.

6.2.6 Matriz de confusión

La matriz de confusión es una herramienta utilizada para evaluar el rendimiento de un modelo de clasificación, proporcionando una visión detallada del rendimiento del modelo de clasificación (Powers, 2011). En el caso de una clasificación binaria, se estructura como está presente en la ecuación (6).

$$\begin{bmatrix} VP & FP \\ FN & VN \end{bmatrix} \quad (6)$$

Dónde los VP son casos positivos correctamente clasificados; los FP, casos negativos clasificados erróneamente como positivos; los FN, positivos clasificados como negativos; y los VN, negativos correctamente clasificados.

6.2.7 Precisión total

La precisión total o exactitud global indica el porcentaje de elementos correctamente clasificados en relación con el total de elementos evaluados (Congalton, 1991).

$$Presición\ Total = \frac{\sum_{i=1}^k C_{ii}}{\sum_{i=1}^k \sum_{j=1}^k C_{ij}} \quad (7)$$

Donde C_{ii} representa los valores de la diagonal de la matriz de confusión (aciertos) y C_{ji} representa cada valor dentro de la matriz.

6.2.8 Matriz Kappa

La estadística kappa, también conocida como coeficiente kappa, es una medida de concordancia o acuerdo entre dos evaluadores o métodos de clasificación (Cohen, 1960).

$$K = \frac{P_o - P_e}{1 - P_e} \quad (8)$$

Dónde P_o es la proporción de acuerdo observado entre los evaluadores o métodos, P_e es la proporción de acuerdo esperado por azar. Se calcula como la suma de los productos de las proporciones marginales de las categorías de las filas y columnas de la matriz de confusión.

6.2.9 F1-Score

El F1-Score es la media armónica entre la precisión (precision) y la sensibilidad (recall) (Powers, 2011).

$$F1 = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (9)$$

Dónde

- Precisión: $\frac{TP}{TP+FP}$, exactitud de las predicciones positivas.
- Sensibilidad: $\frac{TP}{TP+FN}$, capacidad de detectar casos positivos.

6.2.10 Co-registro

El co-registro es el proceso de alinear espacialmente dos o más imágenes, asegurando que se tenga correspondencia píxel a píxel entre ambas imágenes. Esto permite realizar análisis comparativos y generar productos derivados como el interferograma (Curlander et al., 1991).

$$\begin{bmatrix} x' \\ y' \end{bmatrix} = \begin{bmatrix} a & b \\ c & d \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} + \begin{bmatrix} e \\ f \end{bmatrix} \quad (10)$$

Dónde (x, y) son las coordenadas del píxel en la imagen esclava, (x', y') son las coordenadas del píxel correspondiente en la imagen de muestra, $\begin{bmatrix} a & b \\ c & d \end{bmatrix}$ es la matriz de transformación (afín) que incluye rotación, escalado y sesgo. Finalmente, $\begin{bmatrix} e \\ f \end{bmatrix}$ es el vector de traslación (desplazamiento en x y y).

6.2.11 Corrección de fase atmosférica

La corrección de fase atmosférica basada en el contenido de vapor de agua (Wet, Tropospheric Path Delay), es usada generalmente mediante un modelo de troposfera húmeda que estima la contribución de la atmósfera al retraso de la fase debido a la variabilidad del vapor de agua (Hanssen, 2001).

$$\Delta\phi_{atm} = \frac{\lambda}{4\pi} * Refr(h) \quad (11)$$

Dónde $\Delta\phi_{atm}$ es el retraso de fase atmosférica, λ es la longitud de onda de la señal SAR, $Refr(h)$ corresponde a la refractividad atmosférica que depende de la altura h .

6.2.12 Creación del interferograma

El interferograma es utilizado para medir el cambio de fase entre dos imágenes SAR, reflejando los desplazamientos en la superficie. La fase diferencial entre dos imágenes SAR también incluye información de la topografía (Hanssen, 2001).

$$\Delta\phi = \arg(S_1 * S_2^*) \quad (12)$$

Dónde S_1 y S_2 son los valores complejos de las señales SAR en el mismo píxel para dos fechas distintas.

6.2.13 Remoción de fase topográfica

La remoción de la fase topográfica elimina el componente de fase relacionado con la topografía, facilitando la identificación de deslizamientos en la superficie (Massonnet et al., 1998).

$$\Delta\phi_{top} = \frac{4\pi h}{\lambda \sin \theta} \quad (13)$$

Dónde h es la altura del terreno, λ es la longitud de la onda y θ es el ángulo de incidencia.

6.2.14 Filtrado Goldstein

El filtro de Goldstein se utiliza para suavizar el interferograma, minimizando ruido en la señal de la fase (Goldstein et al., 1998).

$$I_{filtrado} = I_{original} * W(k) \quad (14)$$

Dónde $I_{original}$ es el interferograma sin filtrar, $W(k)$ es una ventana de peso basado en la frecuencia espacial k , que controla la cantidad de suavizado en el dominio de la fase.

6.2.15 Multilooking

El multilooking es una técnica que reduce el ruido en interferometría SAR mediante promedios espaciales. Consiste en dividir la imagen en “looks” o subventanas y promediar (Ferretti et al., 2001).

$$M = \frac{1}{N} \sum_{i=1}^N I_i \quad (15)$$

Dónde N es el número de subventanas aplicados.

6.2.16 Corrección topográfica

Mediante el uso de un modelo digital de elevación (DEM) junto con parámetros pertenecientes a las imágenes SAR, se calcula la diferencia de distancia entre el sensor SAR y la superficie terrestre en cada punto de la escena (Small, 2011).

$$\Delta r = \frac{2h \sin \theta}{\lambda} \quad (16)$$

Dónde Δr es la diferencia de distancia entre el sensor y la superficie, h es la elevación en el DEM del punto de interés, θ es el ángulo de incidencia del radar y λ es la longitud de onda del radar.

6.3 Marco referencial

La minería ilegal ha tomado mucha fuerza, especialmente en países en vías de desarrollo como Colombia, que está ligado a la demanda mundial del oro (OEA, 2022). Esta actividad, aunque impulsa economías locales en el corto plazo, genera serias afectaciones sociales, económicas y ambientales. La falta de regulación, la exposición de riesgo a las comunidades y el impacto ambiental relacionado con la deforestación junto con la contaminación por metales pesados son algunas de las consecuencias más notables (Hernández, 2016). Además, la minería ilegal suele estar asociada con grupos armados que utilizan esta actividad como fuente de financiación, agravando la inseguridad en las regiones afectadas (BBC, 2011).

Según Rojas et al. (2020), la detección y monitoreo de actividades mineras se ha basado en levantamientos topográficos junto con la identificación física a través de recorridos (Contraloría de Santiago de Cali, 2016). Pero, estas técnicas tienen limitaciones importantes, como el difícil acceso a las zonas remotas donde se presenta la problemática, los costos elevados, el riesgos y exposición para los operadores en zonas controladas por grupos armados junto con una cobertura espacial y temporal limitada. Estas restricciones han impulsado la búsqueda de soluciones tecnológicas más eficientes, que permitan tener una identificación temprana y seguras a partir de la percepción remota.

La percepción remota ha emergido como una herramienta clave para abordar la identificación de coberturas en diversas regiones. Mediante el uso de las imágenes ópticas, las cuales son proporcionadas por los satélites Sentinel-2, Landsat o Planet, son ampliamente utilizadas para el cálculo de índices espectrales como el SAVI, NDVI y MNDWI; que permiten diferenciar entre

vegetación, cuerpos de agua y suelos expuestos, elementos clave con los que se logra caracterizar e identificar áreas con actividad minera (Yang et al., 2017). Como caso directo, Castellanos (2016), implementó el uso de imágenes satelitales con el fin de evaluar presencia de actividad minera mediante el uso de índices espectrales, logrando reconocer y definir características pictórico-morfológicas que fueron bases para la identificación de zonas con actividad minera. Tomando como referente la investigación de Castellanos (2016), la investigación realizada por Chamorro (2021) destacó el uso de imágenes ópticas aplicados a una región con una actividad minera ilegal continua. Chamorro (2021) recurrió a los índices espectrales por su capacidad para definir características pictóricas y morfológicas fundamentales, permitiendo categorizar las coberturas presentes y realizar la caracterización en su zona de estudio. Ambos enfoques brindaron bases para distinguir y relacionar coberturas afectadas por la actividad desde las imágenes ópticas. No obstante, estas imágenes son limitadas por la nubosidad y las condiciones de iluminación dificultando su aplicación, lo que ha llevado a explorar el uso de imágenes de radar (SAR) para complementarlas (Murdaca et al., 2023).

El radar de apertura sintética (SAR) tiene la ventaja de operar independientemente de las condiciones climáticas y de luz, lo que lo hace ideal para monitorear regiones remotas con alta cobertura de nubes (Villegas, 2019). Dentro de las metodologías SAR, la interferometría (InSAR) se ha consolidado como una técnica poderosa para detectar deformaciones en el terreno con la incorporación de análisis a través de los productos resultantes, destacando principalmente al uso de las imágenes de coherencia. A raíz de ello, Chaussard et al. (2016) demostraron que InSAR permite identificar movimientos del suelo causados por actividades mineras, proporcionando información precisa incluso en áreas de difícil acceso.

La coherencia InSAR, que mide la similitud entre imágenes SAR consecutivas, destaca como una herramienta efectiva para identificar cambios bruscos en la superficie terrestre aplicados a la identificación de cambios producto de actividad minera (Wang et al., 2020). Por ello, Wang et al. (2020), demostraron que la coherencia InSAR puede utilizarse para identificar excavaciones recientes asociadas a minería ilegal a cielo abierto. Al comparar pares de imágenes Sentinel-1, detectaron áreas con bajos valores de coherencia provocado por cambios abruptos en la superficie. Tomando como referente lo anterior, Murdaca et al. (2023) evaluaron la viabilidad de utilizar la coherencia e imágenes de amplitud provenientes de TerraSAR-X para detectar minería ilegal, encontrando que las áreas con pérdida de coherencia suelen coincidir con zonas de actividad minera reciente, relacionando la información de retrodispersión del terreno con las imágenes de amplitud. Dentro de esta metodología se destacó que, si bien la amplitud SAR por sí sola proporciona una base para detectar cambios superficiales producto de minería, su combinación con coherencia y estrategias de aprendizaje semi-supervisado permite realizar un monitoreo de alteraciones superficiales continuas.

Relacionado con el uso de la coherencia, Closson et al. (2017) procesaron escenas de ERS Envisat, aplicando clasificación no supervisada sobre series temporales de imágenes de intensidad e imágenes de coherencia. A diferencia de la coherencia, sensible a la vegetación y a la pendiente del terreno, las imágenes de intensidad permitieron identificar elementos estructurales del paisaje como caminos, parcelas activas y zonas de abandono. Mediante estas imágenes de intensidad, lograron complementar la detección de cambios antrópicos en zonas boscosas o húmedas donde la coherencia se pierde rápidamente. Los resultados, fueron validados de forma cruzada con imágenes aéreas y mapas de peligrosidad, obteniendo que áreas clasificadas como de alta variabilidad en intensidad

correspondieron con zonas efectivamente utilizadas por la población. En un caso similar, Wang et al. (2021) utilizaron la coherencia InSAR como base para calcular el Índice de Actividad de Diferencia Normalizada (NDAI), con el fin de detectar y monitorear la actividad superficial en minas de carbón a cielo abierto. Mediante esto, se logró identificar zonas con pérdida de similitud entre imágenes SAR sucesivas, asociadas directamente a excavaciones o movimiento de materiales relacionado con la decorrelación por actividad minera.

Avances recientes en aprendizaje automático han transformado significativamente la capacidad de análisis de datos satelitales permitiendo la identificación de coberturas donde se encuentra las asociadas como minería ilegal. Dentro de este panorama, destacó la investigación de Chamorro (2021), donde se implementó un enfoque comparativo utilizando algoritmos supervisados como Random Forest, SVM, Naive Bayes y Mínima Distancia con la implementación de índices espectrales. Además, los resultados fueron validados mediante métricas aplicadas al desempeño del modelo, como matrices de confusión. A través de los resultados se logró presentar el uso del aprendizaje automático como herramienta para el análisis a gran escala enfocado en la identificación de la problemática.

En el caso de imágenes de radar, Murdaca et al. (2023) ampliaron este enfoque al proponer un marco semi-supervisado que combina mapas de coherencia SAR con técnicas avanzadas de aprendizaje profundo para la detección de cambios en minas a cielo abierto. Su metodología integró las imágenes de coherencia y de amplitud con un modelo U-Net modificado, este marco semi-supervisado permitió realizar la detección de áreas mineras activas y minimizando los falsos positivos. A través de esto, se demostró que esta integración no solo mejoró la detección de minería ilegal, sino que también ofreció una metodología eficiente para la clasificación y monitoreo continuo de actividades mineras. En un caso de optimización con imágenes de coherencia Wang et al. (2025), desarrollaron un modelo que optimizó la selección de interferogramas al predecir la coherencia SAR en función del NDVI, la línea base espacial y, especialmente, la línea base temporal. A diferencia del enfoque tradicional que descarta pares con largos intervalos temporales por riesgo de decorrelación, su método identificó cuándo era posible mantener estos pares si la vegetación (NDVI) se mantiene estable. Todo con la finalidad de conservar más interferogramas con mayor separación temporal sin comprometer la calidad.

La integración de datos ópticos y SAR mediante técnicas avanzadas de aprendizaje automático representa un enfoque prometedor para superar las limitaciones de los métodos tradicionales en la detección de minería ilegal. Las imágenes ópticas proporcionan información detallada con la implementación de índices espectrales, brindando información base de coberturas donde se puede hacer relación para la extracción de áreas afectadas por la minería. Pero por el otro lado, los datos SAR ofrecen una ventaja única al ser capaces de operar en condiciones climáticas adversas, como nubosidad o iluminación insuficiente, y en áreas de difícil acceso. Así, el cruce de información óptica y de radar mejora significativamente la detección de minería ilegal, como lo demuestran los estudios de Closson et al. (2017), Chaussard et al. (2016) y Mudaca et al. (2023), con lo que se vió una oportunidad en la vinculación entre la información óptica y radar con la finalidad de identificar correctamente la actividad minera, especialmente en regiones con alta cobertura boscosa.

Dentro del presente proyecto implementó el uso de las imágenes de radar junto con la vinculación de información óptica destacando el uso de imágenes para la identificación de la actividad según la investigación de Wang et al. (2022). Por ello, se realizó la integración de ambos tipos de información tomando, conociendo la gran limitación de estudios internacionales con respecto al ambiente local ligada a la gran cobertura boscosa presente. Tomando como consideración esto último, fue necesario utilizar información óptica con la finalidad de delimitar la zona para evitar identificar erróneamente cambios superficiales en zona donde no estuviese presente la problemática, todo esto implementando el uso de índices espectrales acorde con lo realizado por Chamorro (2021). Además, pensando en la optimización de procesos y dando un paso más a partir de la investigación de Chamorro (2021), se optó por la implementación del modelo de aprendizaje automático Random Forest con la finalidad de poder segmentar las coberturas. Para evaluar el desempeño del modelo, inicialmente se propusieron tres métricas; por otra parte, para evaluar a la identificación global se implementaron tanto la matriz Kappa junto con los porcentajes de aciertos y el F1-Score.

Por otro lado, a partir del límite atribuido con presencia de minería desde el óptico, se optó por el uso de metodología InSAR acorde con Mudaca et al. (2023), principalmente en el uso de imágenes de amplitud e imágenes de coherencia. Acorde con Mudaca et al. (2023), con las imágenes de amplitud se obtiene una representación directa de la energía retrodispersada, que puede ser altamente sensible a alteraciones físicas como excavaciones, factores climáticos o acumulaciones de material. No obstante, para este caso se consideró que la diferencia simple entre amplitudes actúa como un detector rápido de cambio físico, útil en entornos donde se espera una alteración entre dos fechas, procedimiento que es beneficioso para la identificación de la minería a cielo abierto. Esta técnica resulta ventajosa para una detección preliminar o una delimitación de áreas con alta probabilidad de intervención reciente, ya que reduce la complejidad computacional sin sacrificar la capacidad de respuesta ante transformaciones reales del terreno.

También, acorde con la investigación de Mudaca et al. (2023) se destacó que no solo basta con el uso de pares de amplitud para diferenciar cambios en la zona de estudio por lo que se incorporó la coherencia como un filtro en la identificación de cambios especialmente en zonas decorrelacionadas, acorde con Wang et al. (2021), Wang et al. (2020). Todo realizado con la finalidad de obtener las áreas con potencial actividad minera ilegal reciente.

7. METODOLOGÍA

El esquema metodológico contenido en la Figura 1 resume cada una de las actividades desarrolladas y necesarias para dar cumplimiento con los objetivos propuestos.




Figura 1. Diagrama de procesos.

7.1 Materiales y zona de estudio

7.1.1 Zona de estudio

La zona de estudio está ubicada en la región rural del noroeste del municipio de Buenaventura, Valle del Cauca, y comprende un área aproximada de 13 km². Esta área incluye los corregimientos de Bajo Calima, Córdoba y Gamboa. Dentro de esta región, destaca el corregimiento de Bajo Calima, situado a orillas del río Calima, con coordenadas 3.9582096°N y 76.97666°W, y una población estimada de 1,164 habitantes (DANE, 2019), la cual se visualiza a través de la Figura 3.




Figura 2. Zona de estudio.

7.1.2 Imágenes utilizadas

Se usaron imágenes Planet y Sentinel, partiendo por la imagen recopilatoria mensual de junio del 2022 proveniente de Planet. PlanetScope captura imágenes satelitales con una resolución espacial de aproximadamente 3 a 5 metros. Tiene una frecuencia de adquisición diaria, lo que permite monitorear cambios casi en tiempo real (NICFI, 2022). Por otra parte, las imágenes de Sentinel-1, es un satélite de radar de apertura sintética (SAR) que opera en banda C. Tiene una resolución espacial de hasta 5x20 metros, según el modo de adquisición, y una frecuencia de revisita de 6 a 12 días combinando los satélites Sentinel-1A y 1B (European Space Agency, 2015). La información de días de diferencia entre los dos pares de imágenes Sentinel-1, se encuentra en la Tabla 1.

Tabla 1. Imágenes utilizadas.

Pares de imágenes de Radar		Diferencia de días
22-jun-21	5-jul-22	378
19-dic-21	5-jul-22	198

7.1.3 Google Earth Engine

Google Earth Engine (GEE) es una plataforma en la nube desarrollada por Google para el procesamiento, análisis y visualización de grandes volúmenes de datos geoespaciales. Permite acceder a catálogos globales de imágenes satelitales, aplicar algoritmos de teledetección y generar productos geográficos mediante scripts con visualización instantánea (Gorelick et al., 2017).

7.1.4 Google Colab

Google Colab es un entorno de programación en la nube basado en Jupyter Notebooks, que permite ejecutar código en lenguaje Python con acceso a recursos computacionales gratuitos. A través de Colab se realizan procesamientos utilizando las CPU a gran velocidad con resultados casi inmediatos. (Bisong, 2019).

7.1.5 SNAP (Plataforma de Aplicaciones Sentinel)

Es un software de código abierto desarrollado por la Agencia Espacial Europea (ESA) para el procesamiento de datos provenientes de los satélites Sentinel. Incluye herramientas específicas para análisis óptico y radar, entre ellas el módulo InSAR (Interferometric Synthetic Aperture Radar), utilizado para la generación de interferogramas y la detección de variaciones en la superficie terrestre (European Space Agency, 2023).

A continuación, se presenta la descripción de cada uno de los pasos presentados previamente para dar claridad sobre el desarrollo planteado.

Preparación de la información

Inicialmente, se realizó la búsqueda de zonas con presencia de actividad a partir de los archivos de identificación minería EVOA por parte de la UNODC. A partir de ello, se visualizaron zonas potenciales para el desarrollo del trabajo destacando principalmente la expansión que ha estado sufriendo la zona rural del corregimiento de Bajo Calima, la que fue seleccionada como zona de estudio. A partir de esta selección, se extrajo el área límite de trabajo que fue base para el recorte de información y fue comparada con la información del visor Geográfico Agencia Nacional de Minería, encontrando que toda la extensión para la zona de estudio está contenida bajo el título de área de reserva forestal.

Selección de las imágenes ópticas e imágenes de radar

Luego de definir la zona de estudio, se realizó una selección de imágenes ópticas mediante un análisis visual dentro de la plataforma Google Earth Engine (GEE). Para este proceso, se utilizaron imágenes provenientes de los sensores Planet y Sentinel. Como criterio principal para su elección, se procuró que las imágenes tuvieran baja nubosidad tomando como referencia a imágenes con nubosidades inferiores al 20% y posteriores al año 2017, fecha que marca la disponibilidad base de información para ambos sensores.

Adicionalmente, considerando la frecuencia mensual de las imágenes Planet y la alta disponibilidad temporal de las imágenes Sentinel, se seleccionó una fecha específica que cumpliera con las

condiciones anteriores. La imagen seleccionada de Planet correspondió a la imagen mensual de junio de 2022, mientras que para Sentinel se empleó una escena del 3 de mayo de 2022, que presentó la menor nubosidad en la zona de estudio. Ambas imágenes fueron utilizadas como base para la identificación del límite de afectación minera ilegal a partir de imágenes ópticas.

Por otro lado, teniendo como referencia que el cambio en coberturas no se ve reflejado de manera instantánea por la actividad, sino que se da de manera gradual, se usaron tres imágenes Sentinel-1 para hacer la comparativa entre ellas o procesamiento de identificación de cambios con técnicas de radar. Las imágenes utilizadas fueron las escenas del 22 de junio de 2021, 19 de diciembre de 2021 y 5 de julio de 2022. A partir de estas se conformaron dos pares con diferencias temporales de 378 y 198 días, que fueron bases en el procesamiento de detección de cambios mediante el análisis de amplitud y coherencia, con el fin de identificar transformaciones en superficie vinculadas con la actividad minera ilegal.

Procesamiento óptico

Con las imágenes ópticas bases seleccionadas, en GEE se realizaron dos scripts para la carga junto con la visualización de cada imagen y el uso de los índices espectrales expresado en las ecuaciones (1), (2), (3) y (4), con la finalidad de obtener una categorización de coberturas. Tomando como referencia la caracterización óptica realizada por Chamorro (2021), se consideraron 6 coberturas presentes en la imagen satelital, las clases se definieron con base en su relevancia temática y espacial, apoyándose en sus características visuales y los índices espectrales facilitando su interpretación y clasificación.

Dentro de la imagen satelital, se consideró la presencia inicialmente de cuerpos de agua, donde se generalizaron ríos y lagos. Además, bajo la actividad de explotación minera ilegal de aluvión se tiene una gran relación con los cuerpos de agua puesto que las afectaciones se ven aledañas al curso de los ríos. Para la identificación de estos cuerpos de agua, se tomó como base al umbral mencionado por Chamorro (2021), considerando su presencia con valores mayores o iguales a 0.35 e implementado el cálculo de la ecuación (2).




Figura 3. Composición en “Color Real” (Izquierda) e índice de Diferencia Normalizada de Agua Modificado (Derecha).

En el caso de la vegetación, se tomaron como base los valores mayores o iguales a 0.6, con base en lo realizado por Castellanos (2016), con lo que se facilitó la identificación y relación con presencia de coberturas boscosas, herbáceas y arbustivas.




Figura 4. Composición en “Color Real” (Izquierda) e Índice de Vegetación Diferencial Normalizada (Derecha).

Para identificar zonas con minería ilegal, se tuvo en cuenta la presencia de piscinas de sedimentación cerca de áreas con suelos desnudos de tonos claros y brillantes, tal como lo señala Chamorro (2021). También se consideraron patrones espaciales donde estos suelos aparecen próximos a ríos, siguiendo lo planteado por Castellanos (2016). A partir de características se logró reconocer áreas con actividad minera ilegal.




Figura 5. Composición en “Color Real” (Izquierda), Índice de Vegetación Diferencial Normalizada (Centro) e Índice de Vegetación Ajustado al Suelo (Derecha).

En el caso de las Nubes y sombras, se evidenciaron al usar la imagen en color natural, respaldado de sus diversas tonalidades en cada índice espectral. Fue necesario tomarlos en consideración para evitar tener clasificaciones erradas.




Figura 6. Composición en “Color Real” (Izquierda), Índice de Vegetación Diferencial Normalizada (Centro medio) e Índice de Vegetación Ajustado al Suelo (Derecha).



Figura 7. Composición en “Color Real” (Izquierda), Visualización cercana (Centro) e Índice de Vegetación Ajustado al Suelo (Derecha).

La identificación de suelo urbano dentro de la zona de estudio se realizó mediante interpretación visual, considerando texturas intermedias asociadas a superficies de rugosidad media (frecuentes variaciones tonales sin uniformidad), formas irregulares y tonalidades gris oscuro. Estos criterios se establecieron tomando como referencia los patrones visuales y umbrales espectrales propuestos por Chamorro (2021) para la identificación de suelos urbanos, complementados con las características morfológicas descritas por Lamprea (2017) para zonas urbanas en imágenes satelitales.



Figura 8. Composición en “Color Real” (Izquierda) e índice normalizado diferencial de construcción (Derecha).

Para el proceso de entrenamiento del algoritmo, inicialmente se tomó a la imagen de base y se realizó el recorte con base al límite de la zona de estudio en GEE, con lo que se delimitó la extensión de la imagen visualizada en la interfaz del programa junto con el recorte de cada imagen de índice espectral. Una vez realizado los recortes, se procedió a crear y posicionar muestras de geometría tipo punto con una propiedad de “landcover” con códigos asociados diferentes para cada cobertura, se siguió la nomenclatura propuesta de Chamorro (2021), contenido en la Tabla 2.

Tabla 2. Clasificación base de coberturas.

Código (Cobertura)	Descripción	Ubicación
0	Agua	Ríos, Lagos.
1	Vegetación	Bosques, vegetación herbácea.
2	Minería Ilegal	Áreas afectadas por minería ilegal.
3	Nubes	Regiones con presencia de nubes.
4	Sombras	Sombras proyectadas.
5	Urbano	Áreas con presencia urbana.

Se utilizó como base la distribución de las clasificaciones de la Tabla 2 y se realizó la creación de muestras para el entrenamiento. Tomando como base los parámetros considerados por Chamorro (2021) en su metodología, se adoptó un valor máximo de 5000 píxeles para generación de muestras de entrenamiento, seleccionándose 4985 muestras para el entrenamiento del modelo. Las muestras fueron tomadas a partir de los productos de los índices espectrales para cada imagen relacionando cada cobertura presente. Para ello, se utilizaron los índices espectrales contenidos en las ecuaciones (1) a (4). Partiendo por el NDVI, que fue empleado para diferenciar vegetación y otras coberturas Chamorro (2021), el SAVI para resaltar suelos expuestos (Qi et al., 1994), y el MNDWI para identificar cuerpos de agua, especialmente piscinas de sedimentación características de zonas mineras

(Yang et al., 2017). Además, se aplicó el NDBI para mejorar la distinción entre suelos desnudos y construcciones o zonas urbanas (Vihn, 2019), evitando confusiones por similitudes espectrales.

El conjunto de muestras tras el cruce e identificación con cada índice espectral estuvo compuesto por 1733 píxeles de cobertura de vegetación, 422 píxeles de cobertura asociada a urbano, 2296 píxeles de cobertura de minería ilegal, 200 píxeles de nubes, 145 píxeles de sombras y 189 píxeles de agua. Se optó por tener gran cantidad de muestras asociadas a minería ilegal por la importancia en la identificación y generación del límite adecuado para el desarrollo del proyecto. Para entrenar el modelo de clasificación, se usaron las clases mencionadas previamente. Todas estas muestras se juntaron en una sola colección y luego fueron divididas aleatoriamente, utilizando el 60% del total para el entrenamiento del modelo y el 40% restante para su validación.

El modelo elegido acorde con las altas precisiones presentadas por Chamorro (2021), fue un Random Forest (ecuación 5) con 500 árboles, utilizando como información de entrada las bandas visibles e infrarrojas (Red, Green, Blue y Nir), además usaron los índices para la extracción de valores de píxel a partir de NDVI, MNDWI, NDBI y SAVI. Una vez generada la clasificación, se aplicó un filtro para suavizarla y eliminar grupos pequeños de píxeles aislados, lo que ayudó a reducir el ruido visual.

Por otra parte, se evaluó el rendimiento del modelo usando las muestras que no se usaron en el entrenamiento. A partir de eso, se implementaron métricas como la matriz de confusión (ecuación 6), la precisión total (ecuación 7), el coeficiente Kappa (ecuación 8) y los valores del F1-score (ecuación 9) por clase, con el fin de medir el desempeño del modelo (véase Anexo 14.1 para Sentinel y 14.2 para Planet).

Con la imagen clasificada, mediante un script de Python en Google Colab (véase Anexo 14.3) se realizó un proceso de suavizado y corrección para asociar píxeles que estuvieron distantes a categorías aledañas. También, la clasificación suavizada se cruzó con la cuadrilla de identificación minera EVOA por parte de la UNODC y se calculó el área de minería ilegal suavizada para cada cuadrícula. Este proceso se realizó con cada una de las imágenes clasificadas.




Figura 9. Cuadrícula de actividad minera ilegal EVOA superpuesta con la clasificación Sentinel realizada.

A partir de esto, se compararon únicamente las áreas oficiales registradas dentro de cada cuadrado con las áreas calculadas a partir de la clasificación de minería ilegal ya procesada y suavizada.




Figura 10. Visualización de clasificación original (Izquierda) y clasificación suavizada (Derecha).

Procesamiento radar

El procesamiento de radar partió con la carga de cada primer par de imágenes correspondientes al intervalo máximo de fechas comprendido entre 21 de junio de 2021 y 5 julio de 2022 en el software de La Plataforma de Aplicaciones Sentinel (SNAP). Dentro del software, se aplicó la metodología InSAR (Radar de Apertura Sintética Interferométrico) para generar las imágenes de coherencia, junto con el paso de imágenes de intensidad a amplitud.

Inicialmente, se llevó a cabo el proceso de coregistro con ESD (Diversidad del Espectro Electromagnético) (ecuación 10), donde se delimitó la zona de procesamiento SAR. Se estableció un umbral de coherencia espectral y se aplicaron órbitas precisas para corregir errores de posicionamiento (ecuación 11), acorde con las recomendaciones de la ESA (2022).

Una vez el stack estuvo conformado y con las correcciones preliminares realizadas, se dio paso a la formación del interferograma (ecuación 12), dónde se configuraron los parámetros orbitales e interferométricos adecuados y se activó la remoción de la fase topográfica (ecuación 13), mediante el uso del DEM SRTM 1sec (30m), aplicándolo a toda la extensión del mosaico con el fin de evitar afectaciones en los bordes (Ferretti et al., 2001). El parámetro de estimación de coherencia se realizó con una ventana adaptativa para mantener el equilibrio entre reducción de ruido y preservación de detalles espaciales. Posteriormente, se eliminó la separación en ráfagas mediante el proceso de deburst, obteniendo una imagen continua en lugar de subdividida. Con la imagen unida se creó una nueva banda mediante el cálculo de la amplitud (ecuación 14) tomando como recurso cada imagen de intensidad.

Seguidamente, se aplicó el multilooking (ecuación 15) para optimizar la relación señal-ruido sin comprometer excesivamente la resolución espacial (Li et al., 2020). Finalmente, se realizó la corrección geométrica del terreno (ecuación 16) implementando nuevamente el DEM SRTM 1sec (30m) para mantener la consistencia del proceso, mediante el método Range-Doppler con el parámetro de proyección al sistema UTM WGS84. Las imágenes obtenidas de amplitud junto con la

de coherencia fueron exportadas en formato Geo TIFF. Este proceso fue repetido también para el par de imágenes del 19 de diciembre del 2021 y el 5 de julio de 2022, manteniendo la configuración mencionada anteriormente para ambos pares de imágenes.

Cruce temático entre resultados ópticos y radar

Se realizó una integración temática entre los resultados de clasificación obtenidos a partir de imágenes ópticas Sentinel-2 mediante un modelo de Random Forest y los productos derivados del procesamiento radar Sentinel-1 (coherencia y amplitud), que fueron mencionados anteriormente. Por tanto, la integración entre ambas fuentes se dio en un nivel de decisión o postclasificación, a través de un cruce temático y análisis de coincidencia para cada uno de los pares de imágenes SAR (véase el Anexo 14.3, 14.4 y 14.5).

Recorte de clasificación minera ilegal

Luego de tener la clasificación de coberturas realizada y suavizado, se cargó el archivo inicialmente de origen tipo ráster y se realizó la conversión a polígono dejando solamente a los polígonos de la clasificación 2 asociada a minería ilegal. Con esto, se logró tener el límite base con el que fueron recortados los ráster de amplitud y coherencia con la finalidad de solo seguir con el procesamiento centralizado la zona donde se presenció la actividad.

Posterior a tener el límite de minería ilegal, se realizó la carga de las imágenes de amplitud, la imagen de coherencia y el límite en formato shapefile al script principal del procesamiento en Google Colab. Previo a realizar cualquier procesamiento con las imágenes de amplitud, se les aplicó el filtrado de ruido speckle Lee Sigma, ampliamente usado para imágenes SAR por su capacidad de preservar bordes y estructuras finas (Lee, 1986). Se empleó una ventana 7x7 píxeles, considerado un tamaño estándar para lograr un equilibrio entre la reducción de ruido y conservación de detalles espaciales en escenas heterogéneas. Tras aplicar el filtrado, se realizó el recorte de las imágenes.




Figura 11. Visualización de las imágenes de Amplitud T1 (Mes más antiguo), Amplitud T2 (Mes más actual), y la imagen de coherencia (Derecha).

Normalización de las imágenes

Fue necesario normalizar a las imágenes con el fin de realizar comparativas y para tener una facilidad de manejo, por ello, se estandarizaron los valores de cada imagen de 0 a 1.




Figura 12. Imágenes normalizadas.

Resta de amplitudes

Se realizó la resta de amplitudes con la finalidad de detectar los cambios en la superficie reflejado en una disminución de la retrodispersión en el límite de minería ilegal.




Figura 13. Imagen resultante tras la resta de las amplitudes normalizadas.

Filtrado por zonas decorrelacionadas y amplitudes negativas

Con el fin de identificar los cambios superficiales, se realizó un filtro para obtener los valores decorrelacionados, específicamente con valores menores o inferiores a 0.35 que pudieron estar asociados a zonas de alta alteración superficial. Acorde con lo planteado por Murdaca et al. (2023), la detección de cambios asociados a minería de tipo aluvión requiere no solo identificar diferencias de amplitud, sino también considerar la coherencia como una capa auxiliar que refuerce la identificación de cambios de interés. Bajo este contexto, las diferencias negativas de amplitud fueron relacionadas con las coherencias bajas, dejando de manera preliminar áreas relacionadas con actividades de remoción de material, colapsos o expansión de frentes mineros. Por otro lado, las diferencias positivas se interpretaron como acumulación de desechos o estructuras recién expuestas. Los cambios que fueron negativos fueron seleccionados y exportados.




Figura 14. Píxeles resultantes de la resta de amplitudes con el filtro de zonas con coherencia baja (≤ 0.35).

Determinación de densidad de cambios negativos

De acuerdo con Murdaca et al. (2023), el análisis espacial de la distribución de cambios en minería a cielo abierto no solo se basa en la segmentación de zonas afectadas, sino también en la evaluación de la densidad de cambios, entendida como la concentración relativa de píxeles alterados dentro de un área específica. Esta métrica permite identificar sectores con alta intensidad de transformación superficial, típicamente asociados a operaciones activas como acumulación de estéril o excavaciones recientes. Aplicado a este trabajo, la densidad fue estimada a partir de los centroides de los polígonos resultantes de cambios negativos mediante una estimación de densidad por núcleo (KDE) con núcleo gaussiano, lo cual permitió identificar zonas con mayor concentración de cambios negativos. Este método fue empleado debido a su capacidad para resaltar los sectores donde los cambios se agrupan espacialmente, permitiendo reconocer concentraciones o focos de actividad minera ilegal rápidamente comparado con un análisis puntual o un conteo.

El resultado fue una superficie continua de densidad, la cual fue normalizada entre 0 y 1 para facilitar su interpretación visual.




Figura 15. Densidad de cambios a partir de las zonas con valores negativos.

Cruce de zonas con cambios negativos con índices espectrales

Con la finalidad de reducir la mayor cantidad de falsos positivos se realizó el cruce con índices espectrales. Murdaca et al. (2023) señala que el realizar este cruce temático mejora la detección minera al combinar la sensibilidad del radar a cambios estructurales con la capacidad del óptico para identificar tipos de cobertura. Por ello, en Colab se cargó a la imagen base RGB y nuevamente se calcularon los índices espectrales de NDVI, MNDWI, SAVI y NDBI usados por Chamorro (2021) y se generaron intervalos para determinar una nueva clasificación con el fin de identificar áreas potencialmente asociadas a actividad minera, áreas con cambio gradualmente notorios, áreas con leves cambios y áreas sin cambios.




Figura 16. Clasificación realizada a partir de NDVI, MNDWI, SAVI y NDBI para la validación de información.

Determinación de áreas potencialmente con actividad minera ilegal reciente

La capa de clasificación espectral fue cruzada con las zonas de cambios negativos en amplitud y baja coherencia, obteniendo zonas con cambios considerados potencialmente relacionados con actividad minera ilegal. Por último, se calculó la cantidad de área identificada.




Figura 17. Píxeles de zonas con amplitudes negativas (Verdes), áreas sugeridas con presencia de la actividad (Rojas) y zonas con potencial actividad tras el cruce de áreas (Azules).

8. RESULTADOS

A partir de la metodología propuesta, el primer producto fue la clasificación realizada sobre la imagen óptica junto con la imagen suavizada presente en la Figura 18 y 19, aplicado a las imágenes de Planet y Sentinel respectivamente. En la imagen suavizada, se aplicó un filtro de mayoría para reasignar píxeles aislados a las clases predominantes en su vecindad, reduciendo errores en la identificación de coberturas. Las áreas representadas en color morado correspondieron a zonas clasificadas como minería ilegal o de interés minero, cuya distribución espacial permitió identificar y caracterizar los principales focos de actividad en el Bajo Calima.




Figura 18. Clasificación Sentinel Random Forest (Izquierda) e imagen suavizada (Derecha).




Figura 19. Clasificación Planet Random Forest (Izquierda) e imagen suavizada (Derecha).

A partir de la clasificación realizada con la imagen Sentinel, el clasificador obtuvo una precisión de 0.89 y un índice Kappa de 0.83, reflejando buenos resultados para distinguir las clases analizadas. Además, se destacaron valores altos en la diagonal como los 1361 aciertos en la clase 2 y 941 en la clase 1 reflejan una adecuada identificación de las coberturas asociadas a minería ilegal y vegetación. En contraste, se observan la clasificación 3 con una porción de datos asignados a otra clase, específicamente la clase 1, indicando una confusión en su delimitación. También hay dispersión en

la clase 5, reflejado en una confusión con varias otras clases, lo que sugiere límites menos definidos entre ciertas coberturas.

Tabla 3 Matriz de Confusión Random Forest con imagen Sentinel.

Clasificación								
Comprobación	Clase	Agua	Veget	Miner	Nubes	Sombra	Urban	Total
	Agua	57	18	44	0	0	0	119
	Veget	4	941	27	28	16	10	1026
	Miner	7	19	1361	4	1	14	1406
	Nubes	0	12	10	96	0	10	128
	Sombra	0	6	1	0	83	0	90
	Urban	0	12	72	9	0	149	242
	Total	68	1008	1515	137	100	183	0.89
Kappa 0.83								

Kappa 0.83

En términos porcentuales, las clases 0, 2, 4 y 5 superaron el 80% de aciertos, consolidando la consistencia del modelo en la diferenciación de las coberturas principales. Por otro lado, las clases 3 y 4 presentaron mayor dispersión, especialmente hacia la clase 1, con lo que indica cierta similitud espectral o superposición de firmas entre estas categorías.

Tabla 4. Porcentajes de Aciertos de la Matriz de Confusión Random Forest a partir de imagen Sentinel.

		Clasificación					
Comprobación	Clase	Agua	Veget	Miner	Nubes	Sombra	Urban
	Agua	84%	2%	3%	0%	0%	0%
	Veget	6%	93%	2%	20%	16%	5%
	Miner	10%	2%	90%	3%	1%	8%
	Nubes	0%	1%	1%	70%	0%	5%
	Sombra	0%	1%	0%	0%	83%	0%
	Urban	0%	1%	5%	7%	0%	81%

Los valores de F1-Score corroboraron el buen desempeño del modelo, con las clases 1 y 2, ambas con valores superiores al 92%. No obstante, la clase 0 que obtuvo un buen porcentaje de acierto, tuvo el valor de F1 más bajo (60.96%), confirmando sus dificultades de clasificación. Las clases 3, 4 y 5 se mantienen en un rango medio (entre 70% y 87%), reflejando un desempeño razonable, pero con cierta confusión aún presente.

Tabla 5. F1-Score a partir de la Matriz de Confusión Random Forest a partir de imagen Sentinel.

Clase	F1-Score
Agua	0.6096 (60.96%)
Veget	0.9253 (92.53%)
Miner	0.9319 (93.19%)
Nubes	0.7245 (72.45%)
Sombra	0.8737 (87.37%)
Urban	0.7012 (70.12%)

Por otra parte, con las imágenes de Planet la clasificación tuvo una buena precisión de 0.88 y Kappa de 0.80, valores que reafirman la robustez del modelo Random Forest frente a diferentes resoluciones espaciales. Las clases 1 y 2 destacaron con gran cantidad de aciertos. Pero, la clase 0 mostró confusión hacia la clase 2 y 5, también, la clase 5 se mezcló bastante con la clase 1 y 2, reflejando problemas para distinguir claramente la presencia de la cobertura urbana.

Tabla 6. Matriz de Confusión Random Forest con imagen Planet.

Comprobación	Clasificación				
	Clase	Agua	Veget	Miner	Urban
	Agua	35	15	53	11
	Veget	1	1219	26	2
	Miner	6	44	1262	19
	Urban	6	24	134	96
	Total	48	1302	1475	128
					0.88

Kappa 0.80

Tomando como base la matriz de confusión, la clase 1 tuvo la mejor precisión con 94% de aciertos. La clase 0 logra un 73%, pero presentó confusión principalmente con la clase 5 (9%). La clase 2 acertó el 86%, aunque tiene mezcla con las clases 0 y 5. La clase 5, con 75% de aciertos, muestra cierta dispersión hacia las clases 0 y 2.

Tabla 7. Porcentajes de Aciertos de la Matriz de Confusión Random Forest a partir de imagen Planet.

Comprobación	Clasificación			
	Clase	Agua	Veget	Miner
	Agua	73%	1%	4%
	Veget	2%	94%	2%
	Miner	13%	3%	86%
	Urban	13%	2%	9%
				75%

Mediante el F1-Score, se logró visualizar que las clasificaciones 0 y 5 tuvieron los menores porcentajes de aciertos con un valor en promedio de 0.45 (45%), reflejando dificultades en la clasificación de estas coberturas. En cambio, el modelo tuvo un buen porcentaje de identificación y acierto para las clasificaciones 1 y 2.

Tabla 8. F1-Score a partir de la Matriz de Confusión Random Forest a partir de imagen Planet.

Clase	F1-Score
Agua	0.4320 (43.20%)
Veget	0.9560 (95.50%)
Miner	0.8995 (89.95%)
Urban	0.4948 (49.48%)

Los resultados de precisión, Kappa y F1-Score, en general, indicaron que el modelo computacional que se desarrolló, el cual estaba constituido por Random Forest y se ejecutó con imágenes Sentinel y

Planet, pudo identificar y discriminar de manera correcta, las zonas de minería ilegal de aluvión en el Bajo Calima.

En fase de validación, se realizó una intersección de la clasificación suavizada con los cuadrados EVOA que se muestra en la Figura 20, para comprobar la coherencia de los resultados con la información oficial de referencia. El cruce de la superficie obtenida a partir de este cruzamiento llevó al cálculo de las áreas reconocidas como minería ilegal en cada cuadrado (tabla 3) y la comparación de su relación con la información reportada en los metadatos, mostrando el nivel que el modelo desarrollado ajustó a la realidad observada.




Figura 20. Visualización de los cuadrados EVOA superpuestos a la clasificación suavizada.

Para cada cuadrado, se igualaron los valores de áreas identificadas como minería ilegal pertenecientes a la clasificación 2 con las áreas correspondientes de los 13 cuadrados de referencia. Se observó que, en general, los valores de áreas asociadas a minería ilegal tendieron a ser mayores en la clasificación Sentinel con respecto a Planet, aunque en varios casos se encontraron muy cercanos. El cuadrado 12 presentó las áreas más altas en las tres columnas con un valor promedio de 23 hectáreas, mientras que el cuadrado 15 contuvo las áreas más bajas con un promedio de 1.6 hectáreas.

En total, hubo 4 casos (cuadrados 3, 10, 14 y 15) donde los valores son menores o cercanos a 2 ha en al menos una de las fuentes, representando leve presencia de la actividad comparado con los otros cuadrados. Las diferencias entre las clasificaciones lograron superar el 30% en varios casos, destacando variabilidad entre los dos tipos.

Tabla 9. Áreas identificadas con minería ilegal de Sentinel y Planet comparadas con los cuadrados EVOA.

Comparación de áreas en hectáreas asociadas a minería ilegal			
Cuadrado	Clasificación Planet	Clasificación Sentinel	Registros EVOA
3	2.09	3.16	4.1
4	17.38	20.24	22.59
5	2.91	5.33	3.63
6	3.8	6.64	11.54
7	12.74	16.29	26.87
8	2.37	5.43	7.7
9	6.2	7.9	9.2
10	1.52	2.48	2.59
11	5.9	8.43	9.17
12	19.42	23.55	26.19
13	5.12	7.88	1.83
14	1.98	1.96	1.7
15	1.6	1.23	2.16

En complemento al análisis multiespectral, se incorporó el procesamiento de imágenes SAR con el propósito de analizar los cambios estructurales y temporales ocurridos dentro del área clasificada como minería ilegal a partir del modelo Random Forest aplicado sobre la imagen Sentinel. Se obtuvieron 3.891 píxeles tanto positivos como negativos con la resta de amplitudes y filtrado para las zonas de coherencia bajas para el intervalo entre junio 2021 y julio 2022, presente en la Figura 20. De estos, solo se consideraron los 712 píxeles negativos relacionados de manera preliminar con cambios en la superficie (diferencias negativas <-0.1). Estos píxeles fueron segmentados, dando como resultado 435 polígonos que representaron zonas preliminarmente asociadas a cambios negativos en la zona de estudio.




Figura 21. Píxeles resultantes tras la resta y filtrado de coherencia (Izquierda) y cambios negativos (Derecha), periodo 1.

A partir de los 435 polígonos segmentados, el mapa de densidad en WGS84 reveló acumulaciones claras de cambios entre junio 2021 y julio 2022, centrados entre latitudes 3.92 a 3.96 y longitudes -76.98 y -76.96.




Figura 22. Densidad de cambios entre Junio 2021 y Julio 2022.

Se realizó el cruce de los polígonos segmentados con los 236 polígonos de zonas rojas producto de la clasificación de índices espectrales posterior, dando como resultado 166 polígonos asociados con potencial actividad minera para el primer periodo de análisis, contenido en la Figura 23.




Figura 23. Visualización de zonas con amplitudes negativas y zonas rojas (Izquierda) y áreas con potencial actividad minera ilegal producto del cruce de información (Derecha), periodo 1.

Por otra parte, en el periodo comprendido entre diciembre del 2021 y julio de 2022, se obtuvieron 3.733 píxeles tanto positivos como negativos con la resta de amplitudes y filtrado para las zonas de coherencia bajas, visible en la Figura 24. A diferencia del periodo anterior, se consideraron 592 píxeles negativos relacionados de manera preliminar con cambios en la superficie (diferencias negativas <-0.1),

representado en una reducción de píxeles. A partir de los píxeles segmentados, se obtuvieron 156 polígonos de zonas preliminarmente asociadas a cambios negativos en la zona de estudio




Figura 24. Píxeles resultantes tras la resta y filtrado de coherencia (Izquierda) y cambios negativos (Derecha), periodo 2.

A partir de los 156 polígonos negativos, el mapa de densidad en WGS84 reveló acumulaciones claras de cambios entre diciembre 2021 y julio 2022, concentrado entre latitudes 3.95 a 3.96 y longitudes -76.97 y -76.96.




Figura 25. Densidad de cambios entre diciembre 2021 y julio 2022.

En el cruce de los polígonos segmentados con los 236 polígonos de zonas rojas producto de la clasificación de índices espectrales posterior, con un resultado de 133 polígonos asociados con potencial actividad minera para el segundo periodo de análisis, contenido en la Figura 26.




Figura 26. Visualización de zonas con amplitudes negativas y zonas rojas (Izquierda) y áreas con potencial actividad minera ilegal producto del cruce de información (Derecha), periodo 2.

La cantidad de píxeles con cambios se consignó en la Tabla 10, dentro de la que estuvo presente la cantidad total desagregada por cada categoría atribuida a un aumento o disminución. Además, los datos fueron representados por medio de una gráfica en la Figura 27 para dar claridad sobre la distribución de la información obtenida.

Tabla 10. Cantidad de píxeles con cambios por categorías.

Cantidad de píxeles con cambios en amplitudes			
Fecha	Categoría	Píxeles tras diferencia de amplitudes	Píxeles filtrados (<0.35 coherencia)
Jun 21 - Jul 22	Disminución (<-0.1)	1,870	712
	Aumento (>0.1)	2,021	690
Dic 21 - Jul 22	Disminución (<-0.1)	1,733	592
	Aumento (>0.1)	2,000	667




Figura 27. Representación de valores asociados a cambios entre amplitudes.

Por último, el área obtenida tras el cruce de datos se consignó en la Tabla 11. En esta tabla, el periodo más grande comprendido entre junio 2021 y julio 2022, contuvo una reducción de 1.38 hectáreas de área potencial con el periodo de estudio más corto reflejado.

Tabla 11. Área con potencial actividad minería ilegal.

Área obtenida tras el cruce de cambios en radar y clasificación con índices espectrales		
Fecha	Área con potencial actividad (Ha)	Área preliminar (Ha)
Jun 21 - Jul 22	1.41	3.28
Dic 21 - Jul 22	1.02	2.61

Además, la información de la Tabla 11, se representó gráficamente en la Figura 28, reflejando la tendencia de una reducción promedio de 2.34 veces entre cada periodo.




Figura 28. Resultados de área preliminar y potencial tras el cruce de información entre índices espectrales vs diferencias de amplitud negativas de radar.

9. ANÁLISIS DE LOS RESULTADOS

La clasificación con imágenes Sentinel presentó áreas mayores que la clasificación con imágenes Planet. Al analizar ese patrón, el cuadrado 13 en la clasificación de Sentinel se detectó un 53.9% más área que Planet, y en el cuadrado 5, un 83% más, reflejando la sobreestimación de áreas. No obstante, también se visualizaron excepciones como en el cuadrado 15, donde en la clasificación Planet detectó un 30% más área que la de Sentinel. En la mayoría de los cuadrados (como el 4, 5, 6, 7 y 12), Sentinel detectó áreas mayores que Planet y más cercanas a EVOA, que fue relacionado con su mayor cobertura, pero menor precisión espacial. En cambio, Planet mostró clasificaciones más conservadoras, relacionados con su resolución espacial que permitió una mejor discriminación de patrones, aunque estuvieron ligadas con riesgo de subestimaciones, como en los cuadrados 6 y 8 con valores 3 y 1.4 veces menores respectivamente con respecto a los registros EVOA. A través de estas diferencias se visualizó que Planet ofreció una delimitación más precisa, pero con menor alcance, destacando así las fortalezas y limitaciones de cada sensor en la identificación para la minería ilegal. Lo que dejó como un promedio general que Sentinel reportó aproximadamente un 31% más de área que Planet relacionado con la actividad minera ilegal. Estos resultados permitieron caracterizar espacialmente las zonas de actividad minera ilegal en el Bajo Calima, cumpliendo así con el primer objetivo específico mediante el uso de las imágenes ópticas y análisis espacial.

Al contrastar las dos matrices de confusión obtenidas a partir de clasificaciones Random Forest con imágenes Sentinel (Tabla 4) y Planet (Tabla 7), se observó que, si bien ambas presentan una precisión global alta de 0.89 y 0.88 respectivamente, existieron diferencias notables en el comportamiento por clase reflejando la influencia del sensor en la calidad de la clasificación. Además, esto se respaldó con valores de índices kappa de 0.83 para la clasificación Sentinel y 0.80 para Planet. No obstante, si bien se consideró que los valores altos en la precisión total e índice kappa reflejan un modelo confiable, esto no llegó a garantizar precisión absoluta en todas las predicciones y pudieron existir sesgos no detectados en ciertas clases o escenarios. Esto estuvo relacionado con la distribución de muestras entre aprendizaje y validación, puesto que, al aumentar los datos de entrenamiento las métricas mejoraron al ajustarse mejor a las clases, aunque con posible riesgo de comprometer la evaluación si la validación es muy reducida. En conjunto, este análisis permitió evidenciar el cumplimiento del segundo objetivo específico, al desarrollar un modelo computacional mediante el algoritmo Random Forest que alcanzó valores de precisión superiores al 88% y un índice Kappa mayor a 0.80, demostrando su efectividad en la identificación espacial de la minería ilegal de aluvión.

La matriz de confusión en la clasificación a partir de la imagen Sentinel evidenció una clara diferencia en las capacidades clasificatorias de los modelos, que se ajustaron a los valores de F1-Score obtenidos. La clasificación de cuerpos de agua (clase 0) presentaron el desempeño más bajo, reflejados en un F1-Score de 60.96%, relacionado con la confusión general con la clase 2, donde 44 de las 119 muestras reales fueron clasificadas erróneamente (37%). Esta tendencia puede ser indicativa de una posible subrepresentación de cuerpos de agua en el conjunto de entrenamiento, así como la influencia de la amplia cobertura arbórea que rodea al río en el área de estudio. Por el contrario, las clases vegetación y minería ilegal (clases 1 y 2) obtuvieron buen desempeño, alcanzando F1-Scores de 92.53% y 93.19% respectivamente, respaldados por los altos valores en los elementos de la diagonal principal de la matriz (941 y 1361 aciertos). A pesar de ello, se evidenció que la clase 2 fue centro de múltiples errores de clasificación, especialmente con las clases 5 (72 errores) y 0 (44

errores), lo cual puede ser indicativo del posible carácter demasiado genérico de esta categoría, o bien que el modelo ha generado un sesgo hacia ella dada la mayor representatividad en el conjunto de datos (1406 muestras). Por su parte, la clase de nubes (clase 3), con un F1-Score de 72.45%, tendió a confundirse con las clases 1 y 5 (12 y 10 errores respectivamente), lo que refleja la ambigüedad de sus características espectrales. La clase de zonas urbanas (clase 5), con un F1-Score de 70.12%, mostró dificultades notables al distinguirse de la clase 2, perdiendo 72 de 242 muestras (30%), lo cual sugiere similitudes en sus firmas espectrales. Por último, la clase de sombras (clase 4) obtuvo un desempeño positivo (F1-Score de 87.37%), con solo 7 errores de clasificación, evidenciando que, a pesar de su reducido tamaño (90 muestras), sus características bien definidas favorecieron una clasificación precisa en comparación con otras clases minoritarias.

En el caso de la clasificación de Planet, los resultados revelaron un marcado contraste en la capacidad clasificatoria del modelo entre las diferentes categorías. Las clases 1 y 2 demostraron un rendimiento sobresaliente, con F1-Scores del 95.5% y 89.95% respectivamente, relacionado con los altos valores en la diagonal principal de la matriz (1,219 y 1,262 aciertos). Pero, el modelo tuvo serias dificultades con las clases con poca cantidad de muestras, especialmente con la clase 5 que presentó el valor mínimo de F1-Score con 49.48%, más de la mitad de sus muestras (134 de 260) fueron incorrectamente asignadas a la clase 2. La clase 0 también reflejó un desempeño deficiente (F1-Score 43.2%), con el 46% de sus instancias confundidas con la clase 2. Este patrón recurrente de confusión hacia la clase 2 se interpretó como una superposición significativa de características entre estas clases.

A pesar de la diferencia en áreas entre ambas imágenes y precisiones, se consideró beneficioso el uso de imágenes Sentinel en este trabajo con el fin de abarcar mayor área aledaña a la presencia de la actividad, permitiendo analizar tanto el área límite de la minería ilegal junto con coberturas aledañas para visualizar posibles procesos de expansión. No obstante, si el foco es solo delimitar cambios dentro una extensión delimitada, las imágenes de Planet por su identificación más precisa de coberturas en el terreno, mejorando la capacidad de detectar patrones, aunque se debe considerar que este tipo de imágenes son de acceso restringido bajo un plan de suscripción o licencia paga. Además, con base en los resultados de las clasificaciones la elección de un tipo de imágenes sobre el otro debe considerar las limitaciones o problemas para identificar coberturas específicas, como los problemas en diferenciación de cobertura urbana para las imágenes de Planet.

Al comparar las áreas obtenidas en la clasificación de minería ilegal mediante las imágenes de Planet y Sentinel respecto a las evidencias de explotación de oro de aluvión (EVOA), se observó una tendencia general en la que ambas clasificaciones subestimaron los valores reportados oficialmente reflejados en un valor promedio de -3.6 hectáreas de la clasificación de Planet y el valor promedio de -1.4 hectáreas de Sentinel. No obstante, se consideró que los registros oficiales EVOA reportados correspondieron a los valores tras todo el año de análisis de 2022. Por ello, resultó coherente que los valores estimados mediante las clasificaciones fuesen inferiores o incluso levemente superiores en algunos casos a los registros finales. Estas subestimaciones se interpretaron como detecciones temporales o fluctuaciones estacionales que no necesariamente llegó a ser consolidada como una actividad sostenida durante todo el año. De manera general, la validación externa mostró una coincidencia espacial promedio del 85% entre las áreas clasificadas como minería ilegal y las zonas registradas oficialmente, lo que respalda la fiabilidad de los resultados obtenidos y su correspondencia con la zona de estudio, sirviendo además como base para el desarrollo del modelo y la investigación.

A través de los resultados de radar contenidos en la Tabla 10, se logró identificar patrones temporales y espaciales en los cambios detectados mediante imágenes SAR, específicamente a partir de diferencias de amplitud y filtrado por coherencia baja. Entre junio 2021 y julio 2022 hubo un mayor número de píxeles con diferencia significativa tanto de disminución (<-0.1) como de aumento (>0.1) en la amplitud del radar (1.870 y 2.021 respectivamente), en comparación con el periodo diciembre 2021 y julio 2022 (1.733 y 2.000), estableciendo que los cambios acumulados en un intervalo más largo son apenas ligeramente superiores. No obstante, al aplicar el filtrado por coherencia baja (<0.35), lo que ayudó a reducir la cantidad de falsos positivos relacionados con vegetación dinámica o factores climatológicos, la cantidad de píxeles disminuyó notablemente en ambos periodos. La reducción más acentuada fue obtenida en el periodo entre diciembre 2021 y julio 2022 (de 1.733 a 592 píxeles de disminución reflejado en una reducción de 2.9 veces la cantidad de píxeles), reflejando que muchos de los cambios detectados inicialmente podrían no estar relacionados con modificaciones estructurales o persistentes del terreno.

La integración con la clasificación multiespectral permitió identificar zonas con probable actividad, combinando los índices espectrales y las diferencias negativas de amplitud. Durante diciembre 2021–julio 2022 se detectó una mayor área con potencial actividad (3.28 ha) que en junio 2021–julio 2022 (1.02 ha), pese a un número ligeramente inferior de píxeles con cambio. Esto se explica por una mayor coincidencia entre los cambios radar y las categorías espectrales asociadas con actividades antrópicas, lo que sugiere que el segundo periodo captó un evento más localizado, pero de mayor impacto. Además, la proporción de cambios confirmados fue superior en el segundo intervalo (3.28 ha frente a 2.61 ha), mientras que en el primero el área preliminar (1.41 ha) superó a la potencial (1.02 ha), con una diferencia del 38.24 %.

Parte de los cambios detectados por diferencias negativas no se asociaron directamente con clases críticas, ya que las variaciones en amplitud no siempre representan modificaciones físicas del terreno, sino también efectos electromagnéticos, geométricos o ambientales propios del sistema SAR. En conjunto, la combinación de diferencias de amplitud, coherencia baja y clasificación óptica permitió depurar y priorizar zonas de cambio con mayor probabilidad de corresponder a transformaciones humanas.

Además, el análisis SAR mostró una perspectiva temporal y estructural de la problemática al evidenciar patrones de cambios coherentes en las zonas clasificadas con presencia de minería ilegal a partir de las imágenes ópticas. Aunque no constituyó o tuvo influencia principal en el modelo, complementó la interpretación espacial y temporal de los resultados, facilitando la fácil identificación y obteniendo los puntos específicos donde se puede estar generando expansiones de la actividad.

10. DISCUSIÓN DE LOS RESULTADOS

Comparando los resultados de la clasificación Random Forest de Sentinel con la investigación de Chamorro (2021), la clasificación obtenida tras el procesamiento tuvo un desempeño superior en comparación con su investigación, reflejado en temas de precisión. Mientras que la primera clasificación de Chamorro obtuvo una precisión con el mismo modelo e igual cantidad total de muestras totales del 82.6 % y un índice Kappa de 0.77, lo cual reflejó una gran concordancia entre la clasificación y las coberturas, la clasificación obtenida tras el procesamiento tuvo una precisión del 89 % y un Kappa de 0.83, reflejado en un aumento del 7.75% y 7.8% respectivamente. Mediante este comportamiento, no solo se infirió que el modelo obtenido no solo clasificó correctamente una gran cantidad de muestras, sino que fue más confiable para diferenciar entre las clases, reduciendo aún más la probabilidad de aciertos por coincidencia. No obstante, en su investigación no se especificó la distribución de las muestras entre aquellas de entrenamiento y las de validación, que es un aspecto importante para la interpretación de los resultados de precisión. Un mayor número de muestras de entrenamiento puede aumentar la capacidad del desempeño del modelo (por la optimización del aprendizaje interno del modelo), pero incluso, al reducir la cantidad de datos con los que son designados como datos de validación, también se estaría reduciendo la capacidad de análisis sobre la generalización de esos datos o, incluso, llevar a una sobreevaluación de esa precisión real.

Al comparar el desempeño por clases, se evidenciaron diferencias notables que explican en parte el comportamiento global de ambos modelos. El modelo de Chamorro obtuvo una alta precisión en las clases de agua, vegetación y nubes, reflejado en un 97 % y 100 % respectivamente, mientras que el modelo obtenido en este proyecto tuvo valores más bajos en esas mismas clases de agua y vegetación 84 % y 93 %. A partir de esto, se destacó que el modelo de Chamorro estuvo especializado en identificar correctamente estas categorías, lo cual se relacionó a su alta precisión global. Pero, en la clase de urbano el modelo obtenido demostró un desempeño considerablemente superior, evidenciado en la clase coberturas urbanas, donde se alcanzó un 81 % frente a solo 69 % del modelo de Chamorro (una mejora del 12%), y en la clase de nubes que logró un valor de 83 % frente a 58 % (una mejora del 15%). Además, en la clasificación de minería el modelo de Chamorro obtuvo un 76.8% de precisión, un valor menor comparado con el 90% tras la clasificación obtenida en este proyecto. Tomando en cuenta estas diferencias, se estableció que, si bien el modelo obtenido en este proyecto tuvo mayor cantidad de aciertos reflejado en los porcentajes, el modelo de Chamorro logró caracterizar de manera más adecuada los cuerpos de agua y las sombras, comparado con el desempeño y el proceso de muestras para el aprendizaje del modelo, se infirió una mayor presencia de estas coberturas en su zona de estudio, facilitando la identificación. Por el contrario, la zona analizada bajo esta investigación en Bajo Calima tuvo poca presencia de cuerpos de agua y el único río estuvo densamente rodeado de vegetación, lo que dificultó realizar la caracterización y posterior clasificación.

Luego de realizar la diferencia de amplitudes se evidenció gran cantidad de valores que reflejaron las variaciones de retrodispersión en la zona de estudio para cada par de imágenes. El enfoque fue útil para resaltar cambios abruptos visualizado en valores positivos y negativos que dieron indicios de un aumento o disminución de la señal reflejada. No obstante, tal como fue mencionado por Murdaca et al. (2023), estos resultados no fueron suficientes por si solos para ser diferenciados entre cambios reales y cambios aparentes o temporales. Por ello, con la adición en la identificación de zonas

decorrelacionadas se logró reducir la cantidad de valores analizados a zonas con una potencial presencia más acercada a la realidad.

Adicionalmente, la reducción de cambios significativos obtenidos con las imágenes de amplitud y filtrados con el umbral de baja coherencia reflejada en un 63.8% y 66.3% a partir de 3.870 y 3.733 píxeles, apoyó la idea de hacer uso de información de respaldo para la obtención de un resultado acorde con lo analizado, como es mencionado por Murdaca et al. (2023) y Wang et al. (2020). Comparado con el caso de Wang et al. (2020), se identificaron 81 áreas con pérdida de coherencia, de las que 60 (74.1%) fueron clasificadas como minas a cielo abierto, y 49 de ellas (81.6%) coincidieron con sitios legales verificados en campo. Se estableció una relación en que una gran proporción de los cambios detectados inicialmente pudieron atribuirse a ruido o variaciones no estructurales, además, mientras Wang et al. (2020) trabajaron directamente sobre la coherencia para detectar excavación, en este desarrollo la amplitud funcionó como primer indicio ante la presencia de afectaciones, y la coherencia como criterio de validación, generando un mejor producto interpretable. Además, acorde con Closson et al. (2017), la unión de imágenes provenientes de radar combinadas con capas temáticas permitió reducir significativamente el área y los falsos positivos. Mediante los resultados, se respaldó a la idea de realizar una integración de datos ópticos con productos SAR como la intensidad o la amplitud, no solo para depurar las zonas de cambio preliminar, sino focalizar la atención en superficies con alta probabilidad de actividad reciente.

La línea base temporal entre las imágenes dejó como resultado una reducción de 2.79 veces en la cantidad de polígonos representados en las densidades de las Figuras 22 y 25, se contrastó con la investigación de Wang et al. (2025). En la investigación de Wang et al. (2025), se demostró que la línea base temporal es un factor dominante en la degradación de la coherencia, definieron que una línea de base temporal pequeña genera imágenes de coherencia mejor definidas en comparación con pares con grandes líneas de base temporales. En contraste, en este proyecto los pares de corta línea base temporal reflejaron 156 polígonos segmentados con diferencia de amplitudes y filtrado de coherencia, los pares con mayor separación temporal revelaron más de 400 polígonos, indicando una mayor capacidad para capturar cambios significativos o acumulativos en la superficie. Sí bien, los pares cortos preservan la coherencia general, los pares largos aportan mayor sensibilidad espacial a los procesos de transformación, tal como es demostrado por Wang et al. (2025). No obstante, si bien Wang et al. (2025) proporcionaron una base para el uso de pares temporalmente amplios manteniendo suficiente coherencia, en casos de no contar con una información auxiliar o modelos predictivos, lo ideal sería priorizar las líneas base temporales cortas puesto que conservan mejor la coherencia interferométrica. Aunque un enfoque mixto, que combine bases temporales cortas y largas, permitiría establecer una comparación coherente para determinar si los resultados son consistentes y útiles en el análisis de cambios asociados a la temática.

11. CONCLUSIONES

Este estudio se centró en la identificación de manera oportuna la minería ilegal de aluvión, integrando imágenes ópticas y SAR como parte de una metodología a partir de sensores remotos. A través de índices espectrales y clasificación con Random Forest, se logró segmentar las zonas con presencia de actividad minera y coberturas asociadas, alcanzando una precisión superior al 80%. Complementariamente, el análisis SAR incluyó diferencias de amplitud y coherencia InSAR para detectar cambios físicos y zonas decorrelacionadas. La unión de ambos enfoques permitió identificar áreas con potencial actividad reciente de 1.41 ha y 1.2 ha para líneas base temporales largas y cortas, respectivamente, demostrando la efectividad del flujo propuesto para el monitoreo de esta problemática en zonas de difícil acceso como el Bajo Calima.

La comparación entre imágenes Sentinel y Planet permitió identificar diferencias relevantes en la extensión de las áreas clasificadas. En promedio, Sentinel reportó un 31% más de área minera que Planet, con resultados más cercanos a las zonas reportadas oficialmente por el EVOA, atribuible a su mayor cobertura y frecuencia temporal. En contraste, las imágenes Planet, gracias a su mayor resolución espacial, ofrecieron clasificaciones más precisas y conservadoras, reduciendo confusiones en coberturas cercanas, pero con tendencia a subestimar áreas. Estas diferencias reflejaron las fortalezas complementarias de ambos sensores: Sentinel aportó una visión más amplia del territorio y Planet una mejor delimitación de patrones mineros. En conjunto, esto permitió caracterizar espacialmente las zonas con actividad minera ilegal.

La comparación entre las imágenes Sentinel y Planet ha permitido observar diferencias relevantes entre las coberturas clasificadas. De media, las imágenes Sentinel tuvieron un 31 % más de superficie minera clasificada que Planet, resultando más coherentes con los datos presentados oficialmente por el EVOA, lo que se podría explicar por su mayor capacidad de cobertura y frecuencia temporal. Las imágenes de Planet, que en este caso contaron con una resolución espacial mayor, tuvieron clasificaciones de áreas más conservadoras, al ser capaces de discernir las coberturas más cercanas, aunque subestimaron las superficies identificadas como minera ilegal. Las discrepancias evidencian las fortalezas complementarias que ofrecen ambos sensores, puesto que Sentinel podría ofrecer una mayor extensión, pero sin la delimitación del patrón minero que se obtuvo clasificando las imágenes de Planet. En conjunto, esto permitió caracterizar espacialmente zonas con presencia de la actividad.

La implementación de algoritmos de aprendizajes automáticos permitió fortalecer el proceso de detección y clasificación temática a la zona de estudio, especialmente al aplicar modelos supervisados sobre las imágenes ópticas de Sentinel y Planet para generar mapas detallados de coberturas. El uso del clasificador Random Forest aportó un soporte para caracterizar las áreas con potencial. No obstante, a pesar de que ambas clasificaciones superaron el 88% de precisión y con índices Kappa superiores al 0.80, lo que evidenció la efectividad del modelo desarrollado para la identificación espacial de la minería ilegal. Además, se destacó una gran diferencia en área identificada para cada tipo de imagen lo que podría estar asociado al tamaño del píxel de cada imagen. Esto se visualizó en la cobertura de minería ilegal donde se obtuvo en promedio un 31% de mayor área con las imágenes Sentinel comparadas con Planet.

La validación externa con registros EVOA mostró una coincidencia promedio del 85% entre las áreas clasificadas y las zonas reportadas oficialmente, con subestimaciones promedio de -3.6 ha para Planet

y -1.4 ha para Sentinel. Estas diferencias se interpretaron como resultado del carácter temporal de las detecciones frente a los registros anuales oficiales, reforzando la fiabilidad y correspondencia de los resultados con la realidad territorial.

La integración de imágenes ópticas y radar ha demostrado ser altamente efectiva para la detección y caracterización de actividades mineras. Mientras que las imágenes ópticas permitieron clasificar coberturas superficiales con base en sus propiedades espectrales identificando vegetación, suelo desnudo, cuerpos de agua o áreas urbanizadas, con la unión de características de imágenes SAR, el conjunto de información forma una visión estructural del terreno, capaz de detectar transformaciones físicas incluso en condiciones atmosféricas adversas o durante la noche.

El uso de la amplitud SAR fue clave, ya que es muy sensible a cambios bruscos en la superficie, como los que provoca la actividad minera. Al analizar las diferencias entre fechas, se pudieron identificar aumentos o disminuciones relacionados con transformaciones del terreno, aunque también se detectaron pseudo-cambios causados por la humedad o variaciones ambientales. Por eso, al combinarlo con zonas decoherentes (coherencia <0.35), se logró descartar falsos positivos y enfocar la detección en áreas con pérdida estructural real, lo que aumentó la fiabilidad del análisis.

El cruce entre los cambios detectados por amplitud y baja coherencia con la clasificación óptica redujo el área preliminar de 3.28 ha a 1.41 ha y de 2.61 ha a 1.02 ha para los pares de junio 2021–julio 2022 y diciembre 2021–julio 2022, lo que equivale a reducciones del 57% y 60%. Aunque los pares temporales largos ofrecieron mayor sensibilidad, también introdujeron más ruido, por lo que se recomienda usar líneas base cortas junto con filtros de coherencia para asegurar resultados consistentes y confiables.

Los resultados confirmaron que la estrategia para la detección de actividad minera reciente a través de una integración de datos entre clasificación óptica para contextualizar el uso del suelo, diferencia de amplitudes para captar cambios físicos, coherencia para validar la consistencia estructural de esos cambios, y cruce final entre capas para delimitar zonas de alta probabilidad de intervención, permite una identificación oportuna de minería ilegal en la zona de estudio. El producto se consideró como una opción económica, eficiente y preciso desde la perspectiva remota. Además, este proyecto de investigación es versátil brindando resultados que pueden ser útiles para un monitoreo también, con que es una base para el desarrollo de investigaciones futuras donde se pretenda disponer de información enfocada al seguimiento de cambios superficiales.

12. PRÓXIMOS TRABAJOS

El presente estudio se centró en el análisis de dos momentos contrastantes, utilizando principalmente imágenes ópticas y pares de imágenes de radar. No obstante, este enfoque puede optimizarse ampliando la cantidad de pares de imágenes, ya sea extendiendo la línea base temporal o incorporando intervalos más cercanos. Esto permitiría realizar un seguimiento multitemporal más detallado, capaz de evidenciar no solo afectaciones puntuales, sino también logrando encontrar y relacionar la dinámica de expansión de la actividad minera con la posibilidad de obtener vectores de expansión.

Se puede maximizar el análisis mediante el posible uso de una red neuronal convolucional centrada en identificar patrones de coherencia asociados a zonas con variaciones significativas de amplitud. No obstante, se debe considerar que para este escenario se debe contar con un número considerable de muestras pero que se puede realizar a partir de muestras entrenadas con características semejantes o en común a la que se quiere analizar.

Como proyección de esta línea de investigación, se propone el desarrollo de una plataforma web interactiva para el monitoreo de la minería ilegal de aluvión, basada en las técnicas implementadas en el presente estudio. Esta plataforma podría integrar capas de datos ópticos y SAR procesadas previamente, junto con herramientas de visualización de cambios, alertas tempranas y vectores de expansión de minería ilegal. Además, permitiría a usuarios técnicos y no técnicos consultar áreas de interés, descargar resultados y aportar información en campo.

También, se puede ampliar la base de datos espacial y temporal utilizado en este estudio, incorporando imágenes multitemporales de distintos periodos y zonas con diferentes condiciones. Esto permitiría realizar análisis más robustos del comportamiento de las coberturas afectadas por la minería ilegal. Paralelamente, se plantea evaluar otros clasificadores supervisados, con el fin de comparar su desempeño frente al algoritmo Random Forest.

13. BIBLIOGRAFÍA

- Agencia Nacional de Minería. (2022). Ficha Colombia 01 - 2022. <https://mineriaencolombia.anm.gov.co/sites/default/files/2022-02/Ficha%20Colombia%2001%202022.pdf>
- Armada de Colombia. (2023). Destruídas dos unidades de producción minera que afectaban medio ambiente en Bajo Calima. Armada Nacional. <https://www.armada.mil.co/es/content/destruidas-dos-unidades-produccion-minera-que-afectaban-medio-ambiente-en-bajo-calima>
- Bisong, E. (2019). Google Colaboratory. In *Building Machine Learning and Deep Learning Models on Google Cloud Platform* (pp. 59–64). Apress. https://doi.org/10.1007/978-1-4842-4470-8_7
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Castellanos Quiroz, H. (2016). Diseño metodológico para clasificar zonas mineras a cielo abierto a través del procesamiento digital de imágenes de sensores remotos, aplicado en el nor-oriente del Departamento de Antioquía. Universidad Nacional de Colombia.
- Chamorro, F. (2021). Metodología para determinar las áreas afectadas por minería ilegal por medio de imágenes satelitales Sentinel y técnicas de percepción remota en el Bagre, Antioquía. Universidad del Valle.
- Chaussard, E., Amelung, F., & Lopez, Q. (2016). Remote Sensing of the Surface Deformation Due to Illegal Mining Activities. *Environmental Research Letters*, 11(3), 034019. <https://doi.org/10.1088/1748-9326/11/3/034019>
- Closson, D., & Milisavljevic, N. (2017). InSAR Coherence and Intensity Changes Detection. InTech. doi: 10.5772/65779
- Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 20(1), 37–46. <https://doi.org/10.1177/001316446002000104>
- Congalton, R. G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37(1), 35–46. [https://doi.org/10.1016/0034-4257\(91\)90048-B](https://doi.org/10.1016/0034-4257(91)90048-B)
- Contraloría de Santiago de Cali. (2016). Informe anual sobre el estado de los recursos naturales y del ambiente Municipio de Santiago de Cali - vigencia 2015. Dirección Técnica ante Recursos Naturales y Aseo. <https://archivos.contraloriacali.gov.co/colecciones/ver/1643>
- DANE. (2019). Información general. <https://sitios.dane.gov.co/cnpv/>
- El País. (2023). Autoridades destruyen siete dragas para la minería ilegal en zona rural de Buenaventura. <https://www.elpais.com.co/judicial/autoridades-destruyen-siete-dragas-para-la-mineria-ilegal-en-zona-rural-de-buenaventura.html>
- El Tiempo. (2024). Ejército presenta las pruebas de cómo las disidencias de las Farc se dedican a la minería ilegal en Cañón del Micay. El País. <https://www.elpais.com.co/judicial/ejercito-presenta-las-pruebas-de-como-las-disidencias-de-las-farc-se-dedican-a-la-mineria-ilegal-en-canon-del-micay-3043.html?form=MG0AV3>
- EOS. (2024). Índices de vegetación en la agricultura digital. EOS Data Analytics. Tecnología Agrícola. <https://eos.com/es/blog/indices-de-vegetacion/>

European Space Agency. (2015). SENTINEL-2 User Handbook. https://sentinel.esa.int/documents/247904/685211/Sentinel-2_User_Handbook

European Space Agency. (2024). Copernicus Sentinel-1C Earth observation satellite successfully launched. https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-1/Sentinel-1C_Earth_observation_satellite_successfully_launched

European Space Agency. (2023). Sentinel Application Platform (SNAP) – ESA Sentinel Toolboxes. <https://step.esa.int/main/toolboxes/snap/>

FAO. (2023). Plan de Acción Nacional - Sobre el mercurio en la minería artesanal y de pequeña escala en Colombia (2023). Food and Agriculture Organization: FAO. Ministerio de Minas y Energía. <https://faolex.fao.org/docs/pdf/col227994.pdf>

Fielding, E. J., Lundgren, P. R., Burgmann, R., & Funning, G. J. (2019). Shallow fault-zone dilatancy recovery after the 2014 Mw 6.0 South Napa earthquake. *Geophysical Research Letters*, 46(2), 521-529. <https://doi.org/10.1029/2018GL081252>

Fuerza Aérea Colombiana. (2023). Ofensiva contra la minería ilegal en el Valle del Cauca. <https://www.fac.mil.co/index.php/es/noticias/ofensiva-contra-la-mineria-ilegal-en-el-valle-del-cauca>

Galindo, M. (2020). Minería ilegal: estos son los tentáculos que impactan lo social, ambiental y promueven la violencia. *El Tiempo*. <https://www.eltiempo.com/economia/sectores/mineria-ilegal-estos-son-los-tentaculos-que-impactan-lo-social-ambiental-y-promueven-la-violencia-465118?form=MG0AV3>

GeologyScience.com. (2023). Gold: Mineral | Properties, Formation, Mining, Occurrence, Uses. <https://geologyscience.com/minerals/gold/>

Goldstein, R. M., & Werner, C. L. (1998). Radar interferogram filtering for geophysical applications. *Geophysical Research Letters*, 25(21), 4035-4038. <https://doi.org/10.1029/1998GL900033>

Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18–27. <https://doi.org/10.1016/j.rse.2017.06.031>

Hernández Mares, P. (2016). La minería ilegal en Colombia crece velozmente y pone en riesgo la biodiversidad. <https://es.mongabay.com/2016/12/mineria-ilegal-en-colombia/>

Jin. (2019). 7 methods to evaluate your classification models. *Analytics Vidhya*. Medium. <https://medium.com/analytics-vidhya/everything-you-need-about-evaluating-classification-models-dfb89c60e643>

Lamprea. (2017). zonificación de las coberturas de la tierra mediante la aplicación de herramientas SIG para la revisión y ajuste del P.O.T. en el marco del crecimiento urbano y conurbanización norte: caso municipio de Zipaquirá. Universidad distrital francisco josé de caldas. https://ciaf.igac.gov.co/sites/ciaf.igac.gov.co/files/files_ciaf/LampreaAvellanea-Ferdy.pdf

Lee, J. S. (1986). Speckle suppression and analysis for synthetic aperture radar images. *Optical Engineering*, 25(5), 255636.

- Méndez L. (2024). Fuerza Pública denuncia disidencias envenenando río Micay con minería ilegal en Cauca. El País. <https://www.elpais.com.co/fuerza-publica-denuncia-disidencias-envenenando-rio-micay-con-mineria-ilegal-cauca>
- Murdaca, B., Ceglia, L., & Maschio, M. (2023). A Semi-Supervised Deep Learning Framework for Change Detection in Open-Pit Mines Using SAR Imagery. *Remote Sensing*, 15(24), 5664. <https://doi.org/10.3390/rs15245664>
- NICFI. (2022). Guía de usuario del programa de datos satelitales de NICFI. Planet Labs. https://assets.Planet.com/docs/NICFI_User_Guide_v4_ES.pdf
- Oficina de las Naciones Unidas contra la Droga y el Delito (UNODC) (2020). EVIDENCIAS A PARTIR DE PERCEPCIÓN REMOTA 2020. Explotación de oro de Aluvión en Colombia. https://www.unodc.org/documents/colombia/2021/Julio/PRESENTACION_EVOA_2020.pdf
- Organización de los Estados Americanos (OEA). (2022). Tras el dinero del oro ilícito: Fortalecimiento de la lucha contra las finanzas de la minería ilegal: Colombia. Departamento contra la Delincuencia Organizada Transnacional. Recuperado de <https://www.oas.org/es/sms/ddot/docs/Tras-el-dinero-del-oro-ilicito-El-caso-de-Colombia.pdf>
- Paz, M. C. (2018). Atmospheric effects on radar interferometry: Methodologies for correction and modeling. *Advances in Space Research*, 61(5), 1195-1207. <https://doi.org/10.1016/j.asr.2017.12.012>
- Rojas, M., & Romero, J. (2020). Análisis de la minería mediante la generación de cartografía por medio de drones (UAV) como implementación de análisis de riesgos en el Municipio de Une Cundinamarca - hdl:11349/25632 [Universidad Distrital Francisco José de Caldas]. <https://repository.udistrital.edu.co/handle/11349/25632>
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1973). Monitoring vegetation systems in the Great Plains with ERTS. Third ERTS Symposium, NASA SP-351, 1, 309-317. <https://ntrs.nasa.gov/api/citations/19740022614/downloads/19740022614.pdf>
- Semana. (2023). Autoridades desmantelan dos unidades de extracción ilegal de oro con las que grupos armados obtenían cerca de 350 millones mensuales. *Semana*. <https://www.semana.com/nacion/articulo/autoridades-desmantelan-dos-unidades-de-extraccion-ilegal-de-oro-con-las-que-grupos-armados-obtenian-cerca-de-350-millones-mensuales/202333/>
- Shah, A. (2022). Mapping Volcano Deformation using InSAR. *Mapmyops*. <https://www.mapmyops.com/Mapping-Volcano-Deformation-using-InSAR>
- Small, D. (2011). Flattening gamma: Radiometric terrain correction for SAR imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 49(8), 3081-3093. <https://doi.org/10.1109/TGRS.2011.2120616>
- Tarazona, D. (2023). Colombia: Parque Nacional Farallones de Cali y sus guardaparques amenazados por la minería ilegal. *Mongabay*. <https://es.mongabay.com/2023/05/parque-farallones-guardaparques-amenazados-por-mineria-ilegal-colombia/>
- Wang, L., Yang, L., Wang, W., Chen, B., & Sun, X. (2021). Monitoring mining activities using Sentinel-1A InSAR coherence in open-pit coal mines. *Remote Sensing*, 13, 4485. <https://doi.org/10.3390/rs13214485>

- Wang, L., Li, S., Teng, C., Jiang, C., Li, J., Li, Z., & Huang, J. (2022). Automatic detection method for mining subsidence basins based on InSAR and CNN-AFSA-SVM. *Sustainability*, 14(21), 13898. <https://doi.org/10.3390/su142113898>
- Wang, Y., Li, Z., & Xu, C. (2020). Evaluating the Feasibility of Illegal Open-Pit Mining Identification Using InSAR Coherence. *Remote Sensing*, 12(3), 367. <https://doi.org/10.3390/rs12030367>
- Wang, X., Du, Q., Luo, Y., Mao, W., & Liu, G. (2025). Optimized SAR interferogram selection by modeling SAR coherence with the combined analysis of NDVI and spatiotemporal baseline. *IEEE Geoscience and Remote Sensing Letters*, 22, 4003205. <https://doi.org/10.1109/LGRS.2025.3528759>
- Yang, X., Zhao, S., Qin, X., Zhao, N., & Liang, L. (2017). Mapping of Urban Surface Water Bodies from Sentinel-2 MSI Imagery at 10 m Resolution via NDWI-Based Image Sharpening. *Remote Sensing*, 9(6), 596. <https://doi.org/10.3390/rs9060596>
- Zha, Y., Gao, J., & Ni, S. (2003). Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *International Journal of Remote Sensing*, 24(3), 583–594. <https://doi.org/10.1080/01431160210144570>

14. ANEXOS

A continuación, se adjuntan los enlaces con los códigos implementados en este trabajo. Inicialmente, el código inicialmente del clasificador Random Forest a partir de las imágenes Sentinel-2:

14.1 Clasificador Random Forest aplicado a Sentinel-2:

<https://code.earthengine.google.com/be71353d481e41a6fdec3992795c5092>

14.2 Clasificador Random Forest aplicado a Planet:

<https://code.earthengine.google.com/bd0715bc153f6c6dc8c58fd9dfcb813c>

Por otro lado, se agregan los dos códigos del procesamiento en Python a través de Google Colab. El primero realiza la identificación de áreas acorde con la imagen clasificada Sentinel-2 del paso anterior, en cambio, el segundo ya se centra en la unión entre los datos de imágenes ópticas e imágenes de radar para la identificación de la actividad.

14.3 Identificación de áreas para la imagen óptica clasificada:

<https://colab.research.google.com/drive/1IitPUzMZwcAItT6tUa4ixpFsE5N6cdtJ?usp=sharing>

14.4 Identificación de áreas con potencial actividad minera ilegal (junio 2021 – julio 2022):

<https://colab.research.google.com/drive/1WmuitKhJIoMxodTC71LE699BIn8c3pa2?usp=sharing>

14.5 Identificación de áreas con potencial actividad minera ilegal (diciembre 2021 – julio 2022):

https://colab.research.google.com/drive/1oMQBhBvRKx6SSUD7QDVUYZeUcz-0-MQ_?usp=sharing