

Análisis de la deforestación por minería ilegal en la Amazonía colombiana mediante técnicas de teledetección y ciencia de datos

Diego Fernando Quevedo Cortes

Asesor

Julio Eduardo Mejía Manzano

Universidad Nacional Abierta y a Distancia UNAD
Escuela de Ciencias Básicas, Tecnología e Ingeniería ECBTI
Especialización en Ciencias de Datos y Analítica

2025

Nota de Aceptación

Julio Eduardo Mejía Manzano

Director de Trabajo de Grado

Jurado

Jurado

Resumen

En Colombia, el problema comienza en el monitoreo ineficiente de la deforestación resultante de la minería ilegal en la región amazónica. La evaluación temprana y precisa del impacto ambiental en esta región rica en ecología se ve obstaculizada por el uso limitado e inadecuado de tecnología, como la imagen satelital y la fotografía aérea.

La deforestación en la Amazonía colombiana contribuye a la pérdida de biodiversidad, impacta severamente a las comunidades indígenas y su cultura, y libera cantidades significativas de carbono, lo que acelera el cambio climático. Además de esto, la minería ilegal contamina las fuentes hídricas, impactando negativamente los ecosistemas y las comunidades que dependen de estos recursos.

Palabras clave: Amazonia, Deforestación, Machine Learning, Minería, Teledetección.

Abstract

In Colombia, the problem begins with the inefficient monitoring of deforestation resulting from illegal mining in the Amazon region. Early and accurate assessment of the environmental impact in this ecology-rich area is hindered by the limited and inadequate use of technology, such as satellite imagery and aerial photography.

Deforestation in the Colombian Amazon contributes to biodiversity loss, severely impacts Indigenous communities and their cultures, and releases significant amounts of carbon, accelerating climate change. In addition, illegal mining contaminates water sources, negatively affecting ecosystems and the communities that depend on these resources.

Keywords: Amazon, Deforestation, Machine Learning, Mining, Remote Sensing.

Tabla de Contenido

Introducción	11
Justificación	12
Pregunta Problema	12
Objetivos	13
Objetivo General	13
Objetivos Específicos.....	13
Marco de Referencia	14
Introducción a la Sección	14
La Amazonía Colombiana: Contexto Ecológico y Socioambiental.....	15
Minería Ilegal en la Amazonía: Características e Impactos.....	17
Impactos Socioambientales Multi-Escala	19
Impacto Ecológico y Degradación del Paisaje	20
Contaminación y Salud Pública	20
Afectación Social y Territorial.....	20
Ciencia de Datos Aplicada a la Deforestación	21
Fundamentos de la Teledetección para el Monitoreo.....	21
El Rol de los Algoritmos de Aprendizaje Automático ML y Profundo DL.....	21
Aprendizaje Automático (Machine Learning ML)	22
Aprendizaje Profundo (Deep Learning DL)	22
Brechas de Conocimiento y Justificación del Estudio	23
Brechas Metodológicas y de Aplicación.....	24
Justificación del Estudio	25

Metodología	26
Diseño de la Investigación	26
Criterios de Elegibilidad (PICO).....	27
Criterios de Inclusión y Exclusión Adicionales	28
Criterios de Inclusión	29
Fuentes de Información y Estrategia de Búsqueda	29
Proceso de Selección de Estudios	32
Identificación y Gestión de Registros	32
Cribado por Título y Resumen	32
Evaluación del Texto Completo	33
Extracción y Análisis de Datos	34
Proceso de Extracción de Datos	35
Estrategia de Síntesis y Análisis.....	36
Consideraciones Éticas.....	37
Propiedad Intelectual y Reconocimiento.....	38
Resultados	39
Diagrama de Flujo PRISMA.....	39
Descripción del Flujo	40
Características de los Estudios Incluidos	40
Preguntas de Calidad.....	42
Síntesis de las Características.....	43
Resultados de la Síntesis Cualitativa	44
Avance de la Detección: de ML Clásico a Deep Learning	44

Uso y Desafíos de las Fuentes Satelitales	45
Pertinencia Geográfica y Transferibilidad	46
Resultados de la Síntesis Cuantitativa.....	46
Comparación del Rendimiento Algorítmico ML y DL.....	47
Hallazgos Importantes.....	47
Cuantificación del Impacto y Rol de la Serie Temporal	48
Comparación y Sistematización de Protocolos de Alerta Temprana Existentes.....	48
Nivel de Automatización y Precisión.....	49
El Flujo de Información y el Seguimiento Institucional	49
Interpretación Principal de los Hallazgos	50
Lineamientos para la Arquitectura de Datos y Modelado.....	50
Lineamientos para el Protocolo Operacional y el Enlace con Autoridades.	51
Propuesta de Modelo y Envío de Alertas	52
Definición de las Bandas Usadas	53
Definición de los Índices Utilizados para el Estudio	54
Toma de Muestras	54
Funciones del Código en Relación con el Tiempo.....	59
Resultados del Modelo.....	61
Discusión.....	64
Confrontación de Enfoques de Teledetección y Desafío Climático	64
Sistemas de Alerta y Automatización para el Control Ambiental	65
Justificación de la Ciencia de Datos Avanzada para el Prototipo.....	65
Conclusiones.....	67

Trabajos Futuros	68
Referencias Bibliográficas	69

Lista de Tablas

Tabla 1 <i>Herramientas de Ciencia de Datos para el Monitoreo de la Deforestación</i>	23
Tabla 2 <i>Definición de los Elementos PICO</i>	27
Tabla 3 <i>Estructura Lógica y Términos Clave de la Estrategia de Búsqueda</i>	31
Tabla 4 <i>Fases del Proceso de Selección de Estudios bajo PRISMA</i>	34
Tabla 5 <i>Resumen del Proceso de Selección de Estudios</i>	39
Tabla 6 <i>Características Generales de los Estudios Incluidos</i>	40
Tabla 7 <i>Síntesis Cuantitativa del Rendimiento de Algoritmos en la Detección de Minería Ilegal.</i>	47
Tabla 8 <i>Fase Estática: Clasificación de Referencia Multianual (2018-2023)</i>	59
Tabla 9 <i>Fase Dinámica: Generación de Alertas Mensuales (Prototipo SAT)</i>	60

Lista de Figuras

Figura 1 <i>Parques Naturales Región Amazónica Colombiana</i>	16
Figura 2 <i>Dragas: El Oro Estimula el Crimen en la Frontera Entre Brasil y Colombia</i>	19
Figura 3 <i>Bosque y Ríos Conservados, Clase 0</i>	55
Figura 4 <i>Minería Ilegal Activa, Clase 1</i>	55
Figura 5 <i>Centros Urbanos, Clase 2</i>	56
Figura 6 <i>Deforestación No Minera, Clase 3</i>	56
Figura 7 <i>Sistema de Análisis de Deforestación por Minería Ilegal GEE</i>	57
Figura 8 <i>Matriz de Confusión del Modelo</i>	57
Figura 9 <i>Resultados del Modelo (Departamento del Putumayo)</i>	58
Figura 10 <i>Tablero de Control</i>	59
Figura 11 <i>Tendencia Mensual Comparativa de Hectáreas Afectadas (2023 vs. 2024)</i>	62

Introducción

La Amazonía colombiana es un área de mucha importancia, no solo para Colombia sino para todo mundo, un lugar lleno de mucha diversidad de vida y ecosistemas que ayudan a mantener el clima global en equilibrio (CAF, 2023). Pero este tesoro natural está en peligro por culpa de la minería ilegal. Esta práctica, que implica extraer oro y otros minerales sin ningún control, se ha vuelto una de las principales causas de la destrucción de bosques, la división de los hogares de animales y la contaminación de ríos y lagos.

Si bien existen evaluaciones oficiales de la deforestación, la caracterización específica del impacto de la minería ilegal a menudo se ve obstaculizada por la limitada cobertura espacial y temporal de los métodos de monitoreo in situ.

Para dar más contexto a la magnitud de este problema, según las cifras del Instituto de Hidrología, Meteorología y Estudios Ambientales IDEAM, la Amazonía colombiana sigue siendo foco de deforestación. A pesar de una reducción nacional histórica en 2023, para el segundo trimestre de 2024 se reportó la pérdida de 1.198 hectáreas de bosque en la región amazónica, concentrándose principalmente en los departamentos de Meta con 31%, Guaviare con 26% y el Putumayo con 20% (IDEAM, 2021).

En el contexto esta problemática, la tecnología se convierte en una herramienta muy importante. El Sistema de Monitoreo de Bosques y Carbono con sus siglas SMByC del IDEAM, por ejemplo, utiliza catálogos de imágenes de satélites como Landsat de la NASA y Sentinel de la ESA. A través de algoritmos y técnicas de machine learning, se procesan estos grandes volúmenes de datos.

Justificación

La minería ilegal está arrasando con la Amazonía colombiana, dejando heridas profundas en su increíble biodiversidad, poniendo en riesgo el agua que necesitamos para vivir y afectando el corazón cultural y social de las comunidades que llaman hogar a esta región. Sin un sistema automatizado y basado en datos, el Estado se queda corto para actuar rápido y frenar este problema. (IDEAM, 2021).

Por eso, esta investigación utilizando la metodología PRISMA como herramienta para el desarrollo de búsqueda sistemática de la información, busca aprovechar las ciencias de datos y las imágenes satelitales de acceso libre para crear soluciones reales con el fin de conocer los modelos más relevantes de predicción. Queremos analizar como un modelo que transforme los datos de los satélites en información útil para decidir dónde y cómo intervenir, usando los recursos de la mejor manera posible (Sánchez, López, & Chuvieco, 2022). Esto no solo ayudará a Colombia a cumplir con sus compromisos internacionales, sino que también servirá protegerá los territorios y los recursos naturales de las comunidades, además de ofrecer un método que otros puedan usar para cuidar el medioambiente.

Pregunta Problema

¿Cómo pueden los modelos predictivos, derivados del análisis sistemático (mediante la Metodología PRISMA) de literatura científica sobre teledetección y ciencia de datos aplicados a imágenes satelitales de acceso libre, mejorar la capacidad del Estado colombiano para la detección temprana y la intervención efectiva contra la minería ilegal en la Amazonía?

Objetivos

Objetivo General

Realizar una revisión sistemática, bajo la metodología PRISMA, de la evidencia científica y técnica sobre el uso de técnicas de ciencia de datos y teledetección en el monitoreo, detección temprana y cuantificación de la deforestación asociada a la minería ilegal en la Amazonía colombiana, con el fin de establecer insumos para un proyecto de aplicación contextualizado a la región.

Objetivos Específicos

Identificar los enfoques de teledetección documentados en la literatura (sensores, índices espectrales y resoluciones temporales) empleados en la detección de minería ilegal en la Amazonía.

Comparar y sistematizar los protocolos de alerta temprana existentes, analizando su nivel de automatización, canales de reporte y efectividad en los procesos de control ambiental.

Derivar lineamientos aplicados a partir de la evidencia revisada, orientados al diseño de un prototipo metodológico o piloto de aplicación que integre ciencia de datos y teledetección en el monitoreo de la deforestación por minería ilegal en la región amazónica colombiana.

Marco de Referencia

Introducción a la Sección

La presente sección constituye la base conceptual y contextual de esta revisión sistemática, orientada a comprender la relación entre la minería ilegal y la deforestación en la Amazonía colombiana, así como el potencial de la ciencia de datos y las herramientas de teledetección para su monitoreo.

En concordancia con la metodología PRISMA, se establece un marco de referencia que permite delimitar el alcance del estudio y sustentar la pertinencia de la investigación dentro de un enfoque sistemático y basado en evidencia (Sánchez, López, & Chuvieco, 2022).

El marco de referencia tiene como objetivos principales:

- Presentar la importancia ecosistémica de la Amazonía colombiana y las presiones antrópicas que enfrenta.
- Analizar la minería ilegal como uno de los principales causantes de deforestación y sus impactos socioambientales.
- Explorar el uso de herramientas de teledetección y enfoques de ciencia de datos aplicados al monitoreo ambiental.
- Identificar brechas de conocimiento que justifican la necesidad de esta revisión sistemática.

De esta forma, el capítulo establece las bases conceptuales necesarias para comprender los criterios de elegibilidad, la estrategia de búsqueda y la interpretación de los hallazgos que se desarrollarán en los capítulos metodológicos y analíticos posteriores.

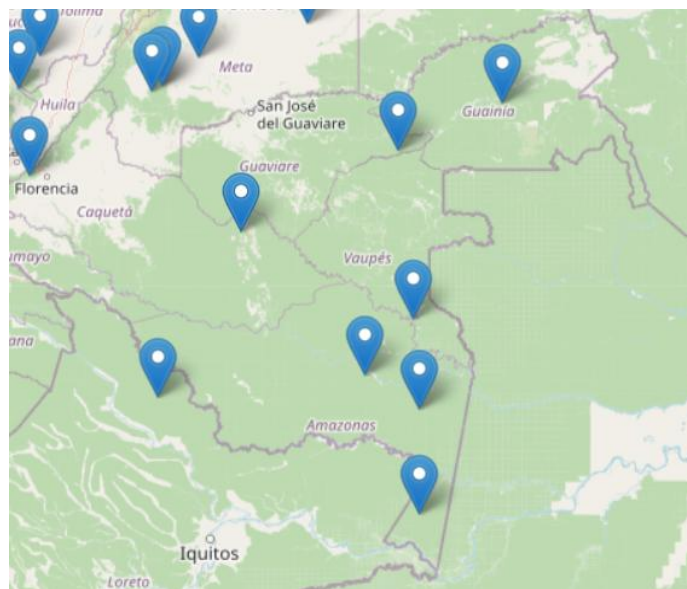
La Amazonía Colombiana: Contexto Ecológico y Socioambiental

La Amazonía colombiana, que abarca cerca del 42% del territorio nacional, no es solo una extensión geográfica, sino un bioma estratégico cuya relevancia trasciende las fronteras nacionales. Ecológicamente, constituye una pieza fundamental en el sistema climático global. Su vasta extensión de bosques húmedos tropicales actúa como un gigantesco sumidero de carbono y desempeña un papel insustituible en la regulación hídrica del continente, alimentando cuencas hidrográficas esenciales para la biodiversidad y la vida humana (Cassiano, 2024). Su estatus de megadiverso la convierte en un laboratorio natural, hogar de miles de especies endémicas y una alta concentración de vida (Estrada, 2024).

Desde una perspectiva socioambiental, este territorio es un lugar cultural. Es el hogar ancestral de una red de pueblos indígenas y comunidades locales cuya pervivencia cultural está intrínsecamente ligada a la conservación del ecosistema. Su conocimiento tradicional y prácticas de manejo sostenible del bosque han sido históricamente trascendente para mantener la integridad ecológica de vastas áreas (MAAP, 2025). La defensa del territorio amazónico, por tanto, es una cuestión de justicia ambiental y derechos humanos.

Figura 1

Parques Naturales Región Amazónica Colombiana



Nota. Parques Nacionales Naturales de Colombia (2025)

- PNN Alto Fragua Indi Wasi
- PNN Amacayacu
- PNN Cahuinari
- PNN La Paya
- PNN Río Puré
- PNN Serranía de Chiribiquete
- PNN Serranía de los Churumbelos Auka Wasi
- PNN Yaigojé Apaporis
- RNN Nukak
- RNN Puinawai
- Santuario de Flora Plantas Medicinales Orito Ingi – Ande

A pesar de su valor incalculable, la Amazonía colombiana enfrenta una presión antrópica constante que amenaza su resiliencia. La deforestación es reconocida como el principal factor de riesgo de transformación, impulsada por una compleja matriz de motores que incluyen la expansión de la frontera agropecuaria, la tala ilegal y la infraestructura no planificada. En este marco de vulnerabilidad, la minería ilegal ha emergido como un factor de degradación acelerada y focalizada, generando conflictos socioambientales directos y afectando la estabilidad del bioma (Nieves & Ruiz, 2021). La comprensión de este contexto dual —riqueza ecológica versus amenaza constante— es esencial para justificar la necesidad de herramientas tecnológicas y científicas que permitan un monitoreo efectivo y una respuesta territorial oportuna.

Minería Ilegal en la Amazonía: Características e Impactos

La Minería Ilegal se ha convertido uno de los principales causantes de la crisis socioambiental en la Amazonía, superando en algunos frentes a otros motores de deforestación como la ganadería extensiva o los cultivos ilícitos de hoja de coca. Se define por la ausencia de los permisos y licencias ambientales, sociales y legales requeridos para la actividad extractiva, lo que deriva en prácticas destructivas y la evasión de cualquier tipo de responsabilidad ambiental (Ávila & Rodríguez, 2025)

En el contexto amazónico, la minería ilegal se basa predominantemente en la extracción de oro de aluvión (MAAP, 2025), explotando los depósitos presentes en los lechos y terrazas de los ríos. Esta actividad se distingue por varias características que la hacen particularmente nociva y difícil de controlar:

Tecnología Rudimentaria y Destructiva: Se emplean métodos que implican la remoción masiva de la cobertura vegetal y del suelo, utilizando dragas, retroexcavadoras y motobombas.

Este proceso no solo destruye el hábitat de forma inmediata, sino que también genera una alteración geomorfológica de los cuerpos de agua y áreas ribereñas (Cáceres & Peña, 2024)

Uso de Sustancias Tóxicas: El empleo de mercurio y, en menor medida, cianuro para amalgamar el oro es una práctica estándar en la MI. Estas sustancias se liberan directamente al ambiente, contaminando el agua, el suelo y la atmósfera (Quispe, 2021).

Vínculos con la Ilegalidad: La MI suele estar asociada con cadenas de financiación criminal y economías ilícitas, operando en zonas de difícil acceso y bajo el control de Grupos Armados Organizados (GAO). Esta situación revela el reto de seguridad y gobernanza que representa para el Estado colombiano (Riocampo, García, & Luévano, 2023). Según un informe el informe denominado “Addressing Illegal Gold Mining in the Western Hemisphere” la minería de oro genera ingresos estimados en más de 1,120 millones de dólares en Colombia, donde aproximadamente el 80% de estos ingresos provienen de la minería ilegal, esto hace que la minería ilegal se una fuente económica inclusive más rentable que el mismo narcotráfico (FACT, 2025).

Figura 2

Dragas: El Oro Estimula el Crimen en la Frontera Entre Brasil y Colombia



Nota. Tomado de Ebus, B. y Pedroso, R. (2023)

Impactos Socioambientales Multi-Escala

Los efectos de la minería ilegal se extienden más allá de los daños ecológicos directos, trascendiendo lo local para propagarse a través de los sistemas hídricos y sociales de la Amazonía, amplificando su impacto en la salud y la seguridad territorial. Desde una perspectiva ambiental, la actividad implica la deforestación visible en imágenes satelitales (Espejo, y otros, 2018), la fragmentación del ecosistema y la contaminación de los ríos con sustancias tóxicas, un daño sistémico que afecta la calidad del agua y la biodiversidad (Nieves & Ruiz, 2021). A nivel social, el impacto es ambivalente a corto plazo: si bien la minería ilegal genera una dinámica económica temporal que puede atraer mano de obra local y generar ingresos (Juaréz, 2016), este efecto positivo se ve eclipsado por las consecuencias destructivas y las amenazas. La actividad está intrínsecamente ligada al conflicto armado y la vulneración del medio ambiente (Esper,

2019), y actúa como un motor de crimen y corrupción que desestabiliza la gobernanza y la seguridad territorial en la frontera (FACT, 2025). Por lo tanto, el monitoreo por teledetección (Sandoval, Castillo, & Upegui, 2022) no solo debe cuantificar la pérdida de bosque, sino también dar la evidencia espacial necesaria para abordar este fenómeno como un problema complejo de seguridad y ordenamiento territorial.

Impacto Ecológico y Degradación del Paisaje

El impacto más visible es la deforestación y la degradación del suelo. La remoción del dosel boscoso para abrir frentes de explotación y la posterior alteración del suelo dejan cicatrices permanentes en el paisaje, tal como se ha documentado en estudios que utilizan imágenes satelitales multitemporales (Ávila & Rodríguez, 2025). Estudios comparativos en regiones aledañas confirman la intensidad del cambio de cobertura, siendo el MI un factor determinante (Cortés, 2020).

Contaminación y Salud Pública

La contaminación por mercurio es quizás el impacto más alarmante a nivel humano. El mercurio se acumula en la cadena trófica (bioacumulación), afectando directamente a las comunidades indígenas y ribereñas que dependen de la pesca para su subsistencia, con graves riesgos para la salud neuro-desarrollo (Quispe, 2021).

Afectación Social y Territorial

La actividad minera ilegal irrumpe en la estabilidad social. Estudios como los realizados en el marco del programa MAAP han señalado cómo la MI invade y degrada directamente Áreas Protegidas y Territorios Indígenas (MAAP, 2025). Esto genera conflictos territoriales, desplazamiento, pérdida de autonomía cultural y el debilitamiento de los mecanismos tradicionales de conservación del bosque.

Ciencia de Datos Aplicada a la Deforestación

La lucha contra la deforestación y, específicamente, contra la minería ilegal en un ecosistema vasto y complejo como la Amazonía, exige herramientas de monitoreo que superen las limitaciones de la inspección física y los análisis manuales. Es aquí donde la Ciencia de Datos, articulada con la Teledetección (Remote Sensing), y puede ser una solución tecnológica y metodológica de vanguardia (Saavedra, 2024). Esta integración permite transformar grandes volúmenes de datos geospaciales en información precisa y accionable para la toma de decisiones.

Fundamentos de la Teledetección para el Monitoreo

La base de la aplicación de la CD radica en la capacidad de las imágenes satelitales para registrar cambios en la cobertura del suelo a lo largo del tiempo. Fuentes de datos como Landsat, Sentinel-1 (Radar), y Sentinel-2 (Óptico) proveen la información multispectral y multitemporal necesaria para diferenciar el bosque sano de áreas degradadas o desprovistas de vegetación (Sandoval, Castillo, & Upegui, 2022) . La elección de la fuente es crítica, pues la resolución espacial, temporal, y espectral define la capacidad de detectar áreas mineras pequeñas o dinámicas rápidas de degradación (Cáceres & Peña, 2024).

El Rol de los Algoritmos de Aprendizaje Automático ML y Profundo DL

La Ciencia de Datos, a través de sus algoritmos de clasificación, automatiza la interpretación de las imágenes, permitiendo el monitoreo a escala planetaria y casi en tiempo real (Ortiz & Ramírez, 2022); Estos juegan un papel muy importante porque permiten un análisis preciso y de grandes cantidades de datos, estos datos específicamente hablando de imágenes satelitales, las cuales para que puedan ser utilizadas en un estudio deben ser de alta resolución y actuales, también deben existir colecciones de imágenes tomadas en el paso de los años para que

cuando se apliquen los algoritmos se pueda evidenciar cambios en la cobertura de la vegetación y daños en los cuerpos de agua, para que a la hora de entrenar el modelo se pueda predecir futuros escenarios donde exista pérdida forestal.

Aprendizaje Automático (Machine Learning ML)

Tradicionalmente, en la geomática, los modelos de ML como Support Vector Machines (SVM) o Random Forest (RF) han sido utilizados para clasificar coberturas. Estos modelos se entrenan con datos etiquetados (píxeles que representan bosque, agua, minería) para predecir la clase de píxeles no etiquetados, demostrando ser eficaces en la identificación de cambios (Riocampo, García, & Luévano, 2023)

Aprendizaje Profundo (Deep Learning DL)

El Aprendizaje Profundo, particularmente a través de las Redes Neuronales Convolucionales (CNN) y arquitecturas de segmentación semántica como U-Net, representa un avance significativo. Los modelos de DL tienen una capacidad superior para:

1. Extraer características complejas: Identifican patrones de deforestación y formas mineras irregulares con mayor precisión que los modelos clásicos de ML (Revelo, 2023).
2. Escalabilidad: Son óptimos para procesar el inmenso volumen de Big Data Geoespacial generado por plataformas como Google Earth Engine (GEE) (Ortiz & Ramírez, 2022).

El uso de DL ha sido esencial en la detección de zonas con minería ilegal aurífera, permitiendo un reconocimiento automatizado y más estable en áreas complejas como Antioquia y el Chocó, metodologías aplicables al contexto amazónico (Kalil & Toledo, 2022).

Tabla 1*Herramientas de Ciencia de Datos para el Monitoreo de la Deforestación*

Técnica de CD	Algoritmos típicos	Ventaja en deforestación	Referencia metodológica
Aprendizaje Automático (ML)	Random Forest, SVM	Alto rendimiento con datos etiquetados limitados	Riocampo, García & Luévano (2023)
Aprendizaje Profundo (DL)	CNN, U-Net	Extracción automática de features, alta precisión en segmentación	Revelo (2023), Kalil Gómez & Toledo Navarro (2022)
Plataformas Geoespaciales	GEE, Sistemas SIG	Monitoreo multitemporal a gran escala (Big Data geoespacial)	Ortiz Villamizar & Ramírez Mendoza (2022), Salas Pérez (2024)

Nota. Herramientas de Ciencia de Datos y machine learning utilizadas para el procesamiento, análisis y visualización de datos geoespaciales en el monitoreo de la deforestación.

El desarrollo e implementación de estas herramientas son fundamentales para pasar de una respuesta reactiva a una alerta temprana predictiva, lo cual es el objetivo deseado para la gestión ambiental en la Amazonía

Brechas de Conocimiento y Justificación del Estudio

A pesar de los avances metodológicos descritos en la sección 1.4, que demuestran la viabilidad de aplicar la ciencia de datos (CD) y la teledetección para el monitoreo forestal (Salas, 2024), la integración específica de estas herramientas para la detección automatizada de la minería ilegal aurífera en la Amazonía colombiana aún presenta vacíos en la literatura sintetizada y evaluada.

Brechas Metodológicas y de Aplicación

La revisión del marco conceptual y las referencias disponibles (Kalil & Toledo, 2022) y (Revelo, 2023) sugiere que las principales brechas de conocimiento que esta monografía busca abordar son:

Comparación Sistemática entre ML Clásico y Deep Learning (DL): Si bien existen trabajos que exploran el DL para la deforestación o la minería en contextos (Kalil & Toledo, 2022) y (Revelo, 2023), falta una revisión sistemática que compare y evalúe la estabilidad, precisión, y eficiencia de las arquitecturas de Deep Learning CNNs, frente a los algoritmos de Machine Learning más tradicionales Random Forest, para la detección de la firma espectral y geométrica específica de la minería ilegal en la Amazonía (Riocampo, García & Luévano, n.d.).

Influencia de la Fuente de Datos Satelitales (Óptico vs. Radar): La minería aluvial es una actividad que a menudo queda oculta por la nubosidad en la Amazonía, dificultando el uso de sensores ópticos como Landsat, Sentinel-2. Existe una brecha en la síntesis de la evidencia sobre la eficacia y las limitaciones del Radar SAR, Sentinel-1, en combinación con datos ópticos y la CD, como herramienta para el monitoreo continuo de la MI en zonas de alta nubosidad (Sandoval, Castillo, & Upegui, 2022).

Transferibilidad y Escalabilidad de Modelos: Los estudios suelen ser localizados por ejemplo en una cuenca específica. No hay evidencia clara y consolidada sobre la capacidad de transferir un modelo de DL entrenado en una subregión amazónica por ejemplo el departamento del Caquetá o Guainía, un factor importante para el diseño de un Sistema de Vigilancia de la Amazonía Colombiana eficiente y escalable (Cassiano, 2024).

Integración Socioambiental del Resultado Geoespacial: La mayoría de los resultados se centran en métricas de precisión técnica. Una brecha significativa es la falta de síntesis que

vincule directamente la cuantificación geoespacial de la MI (usando CD) con la vulnerabilidad de los Territorios Indígenas y Áreas Protegidas (MAAP, 2025), esencial para la perspectiva humanizada de esta investigación.

Justificación del Estudio

Ante estas brechas, la presente revisión sistemática se justifica por su utilidad práctica, metodológica y su pertinencia socioambiental:

Utilidad Metodológica: La aplicación rigurosa de la metodología PRISMA permitirá ofrecer una síntesis crítica y cuantificable del estado del arte de la Ciencia de Datos en este dominio. Esto contribuirá a establecer un estándar de oro metodológico para futuros proyectos de monitoreo ambiental en Colombia.

Pertinencia Operativa: Al evaluar comparativamente las técnicas de DL/ML y las fuentes de datos (Brechas 1 y 2), la monografía proporcionará a las entidades gubernamentales y ambientales información esencial para la selección e inversión en los algoritmos más eficientes para la alerta temprana de minería ilegal.

Relevancia Socioambiental: Al integrar la dimensión territorial (Brecha 4) y la capacidad de predicción (Castañeda & Caita, 2021), la investigación refuerza la necesidad de utilizar la CD no solo para contar hectáreas, sino para proteger los derechos territoriales y ecosistémicos de la Amazonía, ofreciendo una base de conocimiento sólida para políticas de conservación y defensa territorial.

Metodología

Diseño de la Investigación

La presente monografía se inscribe bajo un diseño de Revisión Sistemática de la Literatura (RSL), un enfoque de investigación secundaria que tiene por objeto sintetizar toda la evidencia empírica que cumple con un conjunto predefinido de criterios de elegibilidad para responder a una pregunta de investigación específica (Liberati et al., 2009).

Este diseño fue seleccionado por su capacidad para ofrecer un panorama imparcial y completo sobre la aplicación de la ciencia de datos en el monitoreo de la minería ilegal. Para garantizar la máxima transparencia, reproducibilidad, y rigurosidad metodológica, la RSL se desarrollará en estricta adherencia a las guías de la declaración Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA).

El uso del marco PRISMA es fundamental porque:

1. **Minimiza el Sesgo:** Al establecer protocolos de búsqueda, selección y extracción de datos *a priori*, se evita la selección subjetiva de estudios, lo cual es esencial dada la heterogeneidad de métodos en la geomática y la ciencia de datos (Baquero, 2025).
2. **Asegura la Trazabilidad:** El proceso detallado permitirá documentar cada etapa, desde la identificación de estudios hasta su inclusión final, lo cual se materializará en el Diagrama de Flujo PRISMA.
3. **Facilita la Evaluación Crítica:** Provee una estructura para el análisis riguroso de la calidad metodológica de los estudios primarios que abordan la deforestación y la minería con algoritmos avanzados (Estrada, 2024).

En esencia, esta revisión sistemática no solo recopilará hallazgos, sino que evaluará la calidad de los métodos de ciencia de datos utilizados para proteger un recurso vital como la Amazonía colombiana.

Criterios de Elegibilidad (PICO)

Para delimitar el alcance de la Revisión Sistemática de la Literatura y asegurar que los estudios seleccionados sean pertinentes para responder al objetivo de investigación, se definieron los Criterios de Elegibilidad utilizando el marco estructurado PICO por sus siglas Población, Intervención, Comparación y Resultados. Este marco, si bien proviene de las ciencias de la salud, se adapta eficazmente para definir el foco de una revisión metodológica y tecnológica.

La adaptación del PICO se centra en el Contexto Geoespacial (P) y en la Intervención Tecnológica (I), buscando maximizar la especificidad de los estudios sobre ciencia de datos aplicada a la minería ilegal.

Tabla 2

Definición de los Elementos PICO

Elemento PICO	Definición específica para la RSL	Justificación y sustento referencial
P Población ó Contexto	Amazonía Colombiana y áreas geográficas cercanas (ejemplo, Chocó, Bajo Cauca Antioqueño) donde se apliquen métodos de teledetección para la minería ilegal o aurífera.	Se busca centrar la evidencia en el contexto colombiano, aunque se consideran estudios adyacentes si sus métodos son directamente aplicables a la complejidad amazónica y fluvial (Nieves-Solarte & Ruiz-Fajardo, 2021.; Kalil Gómez & Toledo Navarro, 2022).
I Intervención	Uso de Ciencia de Datos, Aprendizaje Automático (ML), o	Se enfoca en las metodologías de análisis avanzado que permitan la

	Aprendizaje Profundo (DL). Esto incluye la aplicación de algoritmos de clasificación, segmentación o detección sobre imágenes satelitales.	automatización y mejora de la precisión en el monitoreo, incluyendo las arquitecturas de Deep Learning (Revelo, 2023.; Riocampo, García & Luévano, 2023).
C	Estudios que explícitamente comparen el desempeño de diferentes algoritmos (e.g., Random Forest vs. U-Net) o contrasten distintas fuentes de imágenes satelitales (e.g., Landsat vs. Sentinel-1/Radar).	Permite identificar las brechas metodológicas y determinar cuál es la práctica tecnológica más eficiente para la detección del fenómeno (Cortés Riveros. 2020.; Sandoval et al., 2022).
Contraste		
O	Detección, cuantificación, mapeo, o predicción de la degradación y/o deforestación causada directa o indirectamente por la minería ilegal.	Asegura que los artículos ofrezcan resultados medibles y directamente vinculados a la pregunta central, permitiendo la extracción de datos cuantitativos (Cáceres Muñoz & Peña Sosa, 2024.; Ari Mamani, 2025; Castañeda Palacios & Caíta Tautiva, 2021).
Outcomes ó		
Resultados	El resultado debe incluir métricas de rendimiento (precisión, F1-score, Kappa).	

Nota. El acrónimo PICO es la herramienta útil para definir y estructurar de manera clara la pregunta de investigación en una revisión sistemática, guiando la búsqueda de evidencia científica.

Criterios de Inclusión y Exclusión Adicionales

Además del filtro PICO, se aplicarán los siguientes criterios de elegibilidad para refinar la selección de la literatura:

Criterios de Inclusión

1. Tipo de Publicación: Artículos de investigación originales, ponencias en congresos, capítulos de libros y tesis de posgrado (Maestría y Doctorado), para incorporar la literatura gris y los avances recientes de los repositorios universitarios (Estrada, 2024) y (Herrera, 2024)

2. Período de Publicación: Se incluirán estudios publicados a partir del **año 2010**, un punto de inflexión que marca la consolidación de la teledetección con sensores de alta resolución como Sentinel y la explosión de las técnicas de *Deep Learning*.

3. Idioma: Publicaciones en español, inglés y portugués.

Criterios de Exclusión

1. Estudios que se enfoquen en la deforestación general sin abordar la minería ilegal o la degradación asociada.

2. Estudios que utilicen únicamente métodos de análisis visual, fotointerpretación o clasificación supervisada *clásica* (e.g., Máxima Verosimilitud) sin implementar algoritmos de ML o DL.

3. Documentos que sean únicamente revisiones narrativas o estados del arte (salvo que contengan una evaluación metodológica primaria relevante).

4. Estudios cuyo enfoque geográfico sea exclusivamente ajeno a la cuenca amazónica sudamericana.

Fuentes de Información y Estrategia de Búsqueda

La identificación de la literatura se basará en la consulta de fuentes de información primarias de alta reputación y bases de datos académicas indexadas, con el fin de asegurar la calidad y validez de la evidencia científica recopilada. Dada la naturaleza técnica y el enfoque

geográfico de esta revisión, la selección incluye bases globales en ingeniería y ciencias ambientales, así como repositorios en el contexto colombiano.

Las fuentes consultadas son:

Bases de Datos Científicas Indexadas como:

Scopus y Web of Science (WoS): Importantes para capturar artículos de revistas revisadas por pares con énfasis en la Geomática, Teledetección y algoritmos de Inteligencia Artificial (IA) (Revelo, 2023).

Google Scholar: Se utilizará como motor de búsqueda complementario para asegurar la inclusión de literatura gris, informes técnicos y documentos que hagan referencia a herramientas específicas como Google Earth Engine (GEE) (Ortiz & Ramírez, 2022).

Repositorios de Literatura Gris:

Se incluirán los repositorios institucionales de universidades colombianas (como la Universidad Distrital Francisco José de Caldas, Universidad de los Andes, Universidad Nacional Abierta y a Distancia - UNAD y Universidad La Gran Colombia, entre otros) con el objetivo de incorporar trabajos de grado y tesis de posgrado. Esta literatura es vital para capturar avances recientes y estudios con alta pertinencia local que abordan directamente las problemáticas regionales (Vanegas & Muñoz, 2025).

La estrategia de búsqueda se estructuró a partir de los conceptos definidos en los criterios PICO, combinándolos mediante operadores booleanos (AND y OR) para maximizar la sensibilidad (capacidad de encontrar todos los estudios relevantes) y la especificidad (capacidad de excluir estudios irrelevantes).

La búsqueda se basa en la combinación de tres grupos conceptuales principales: Contexto Geográfico, Problema y Método Tecnológico.

Tabla 3*Estructura Lógica y Términos Clave de la Estrategia de Búsqueda*

Grupo conceptual	Términos de búsqueda (combinados con OR)
P/Contexto (Geografía)	"Amazonía Colombiana" OR "Amazonas Colombia" OR "Colombia forestal" OR "Amazon Basin"
I/O (Problema Ambiental)	"minería ilegal" OR "minería aurífera" OR "degradación forestal" OR "deforestación"
I (Método Tecnológico)	"Deep Learning" OR "Aprendizaje Profundo" OR "Machine Learning" OR "Teledetección" OR "Remote Sensing" OR "Google Earth Engine" OR "Sentinel"

Nota. Esta tabla detalla la estrategia de búsqueda bibliográfica, incluyendo los operadores booleanos (AND/OR) y los términos clave (keywords).

La cadena de búsqueda principal, adaptable a las sintaxis de cada base de datos, se formula de la siguiente manera:

(Términos Geografía) AND (Términos Problema) AND (Términos Método)

Además de la búsqueda por términos, se realizará un método de "snowballing" o rastreo de referencias, revisando manualmente las listas de referencias de los artículos de alta pertinencia para asegurar que no se haya omitido ningún estudio seminal que aborde el uso de herramientas tecnológicas en la lucha contra la deforestación (Salas, 2024).

Todos los resultados obtenidos serán documentados para que posteriormente sean registrados en el Diagrama de Flujo PRISMA.

Proceso de Selección de Estudios

El proceso de selección de estudios es la etapa crítica que garantiza la aplicación estricta de los Criterios de Elegibilidad (PICO) definidos en la Sección 2.2. Este proceso se llevará a cabo de forma rigurosa y documentada, siguiendo el flujo de la declaración PRISMA, para asegurar la transparencia y minimizar el sesgo de selección.

La selección se dividirá en cuatro fases secuenciales, ejecutadas por los investigadores:

Identificación y Gestión de Registros

1. **Recolección:** Se importarán todos los registros (artículos, tesis, ponencias) obtenidos de las bases de datos (Scopus, WoS, Google Scholar, Repositorios) y del rastreo manual (snowballing) a un gestor de referencias bibliográficas (p. ej., Mendeley o Zotero).
2. **Eliminación de Duplicados:** Se utilizarán las funcionalidades del gestor bibliográfico para identificar y eliminar automáticamente los registros duplicados, un paso fundamental debido a la superposición de resultados entre las diferentes fuentes consultadas.

Cribado por Título y Resumen

1. **Evaluación Inicial:** Dos revisores independientes examinarán el título y el resumen (abstract) de cada registro restante.
2. **Criterio de Exclusión Rápida:** Se excluirán de inmediato aquellos estudios que, sin necesidad de revisar el texto completo, incumplan claramente los criterios PICO. Se considerará la exclusión si:
 - El estudio trata sobre un tema ambiental diferente a la deforestación o minería ilegal ejemplo contaminación urbana o gestión de residuos.
 - El contexto geográfico está fuera de la Amazonía o regiones de interés ejemplo Europa, África.

- El método es puramente visual o estadístico básico, sin referencia a la Ciencia de Datos, ML o DL (Revelo, 2023).

3. Registro: Se dejará constancia de la cantidad de registros excluidos en esta fase.

Evaluación del Texto Completo

1. Obtención y Revisión: Los textos completos de todos los documentos preseleccionados pasarán a la revisión sistemática. Si un documento no está disponible mediante acceso directo, se buscará a través de bibliotecas universitarias o contactos directos con los autores.

2. Aplicación de Criterios PICO Detallados: En esta fase, los revisores confirmarán si los estudios cumplen de forma específica con la Intervención (I) y los Resultados (O) requeridos (Kalil & Toledo, 2022) y (Sandoval, Castillo, & Upegui, 2022).

- Inclusión: Solo se incluirán los estudios que demuestren haber aplicado algoritmos avanzados (ML/DL) para la detección o cuantificación de la minería ilegal o la deforestación asociada, con métricas de rendimiento documentadas.

3. Resolución de Desacuerdos: Los dos revisores compararán sus decisiones de inclusión/exclusión. Cualquier desacuerdo se resolverá mediante discusión y consenso, o a través de la intervención de un tercer experto metodológico, asegurando la objetividad del proceso.

Inclusión Final

1. Definición del *Set* de Estudios: Los documentos que superen la Fase 3 constituirán el conjunto final de Estudios Incluidos, que serán utilizados para la extracción de datos cualitativos y cuantitativos (Capítulo III).

2. Diagrama PRISMA: Todo el proceso, incluyendo el número de registros identificados, examinados y excluidos en cada fase, se documentará y se presentará visualmente

en el Diagrama de Flujo PRISMA (Sección 3.1), garantizando la reproducibilidad (Liberati et al., 2009)

Tabla 4

Fases del Proceso de Selección de Estudios bajo PRISMA

Etapa de selección	Proceso	Resultado
Identificación	Búsqueda en Bases de Datos y Repositorios.	Registros totales encontrados (N)
Cribado	Eliminación de duplicados y revisión de Título/Resumen.	Registros excluidos por irrelevancia temática o fuera de PICO.
Elegibilidad	Revisión del Texto Completo y aplicación estricta de PICO.	Registros excluidos por falta de método de CD o resultados.
Inclusión	Documentos listos para la extracción de datos.	Estudios Incluidos para la Síntesis Cualitativa/Cuantitativa.

Nota. proceso de filtrado de la literatura, mostrando las fases de Identificación, Cribado, Elegibilidad e Inclusión, para asegurar que la selección de estudios sea sistemática, rigurosa y transparente.

Extracción y Análisis de Datos

Una vez finalizado el proceso de selección y determinado el conjunto final de estudios elegibles, se procederá a la extracción sistemática de datos y a su posterior análisis mediante técnicas de síntesis cualitativa y, si la homogeneidad de los datos lo permite, cuantitativa. Esta fase está diseñada para responder directamente a las brechas de conocimiento identificadas en el Capítulo I.

Proceso de Extracción de Datos

Se utilizará un formulario de extracción de datos estandarizado, diseñado previamente en una hoja de cálculo, que será pilotado con un subconjunto de tres (3) artículos elegibles para asegurar la consistencia y la efectividad de la información recolectada. La extracción será realizada por los investigadores y se centrará en dos categorías principales de información: características de los estudios y datos de resultados (outcomes).

A. Características del Estudio (Contexto)

Se registrarán los metadatos y el contexto geográfico y metodológico de cada publicación:

Identificación: Título, autor(es), año de publicación (o s.f.), tipo de publicación (Artículo, Tesis, Ponencia).

Contexto Geográfico: Región específica de aplicación dentro de la Amazonía colombiana o área adyacente como por ejemplo el Chocó y el Bajo Cauca.

Fuentes de Datos: Tipo de satélite/sensor utilizado Landsat, Sentinel-1 o Sentinel-2, resolución espacial y temporal (Sandoval, Castillo, & Upegui, 2022) y (Cortés, 2020).

Plataforma de Procesamiento: Uso de Big Data geoespacial Google Earth Engine o sistemas locales (Ortiz & Ramírez, 2022).

B. Resultados (Outcomes)

Se extraerán los datos necesarios para la síntesis comparativa:

Algoritmo Aplicado (Intervención): Tipo de modelo de ciencia de datos utilizado por ejemplo Random Forest, SVM, CNN, U-Net (Revelo, 2023) y (Kalil & Toledo, 2022).

Métricas de Rendimiento: Datos cuantitativos sobre la precisión del modelo para detectar la minería ilegal o la deforestación (e.g., Precisión Global, F1-Score, Coeficiente Kappa, Error de Omisión/Comisión).

Cuantificación de Impacto: Áreas de degradación o deforestación cuantificadas por la MI y la relación explícita con las categorías de suelo (Territorios Indígenas, Áreas Protegidas) (MAAP, 2025).

Capacidad Predictiva: Uso o desarrollo de modelos para la predicción de la pérdida futura de bosque (Castañeda & Caíta, 2021).

Estrategia de Síntesis y Análisis

El análisis de los datos extraídos se realizará en dos niveles para abordar la complejidad metodológica de la evidencia: cualitativo y cuantitativo.

A. Síntesis Cualitativa

Esta síntesis se centrará en la descripción y evaluación crítica de las metodologías aplicadas, abordando las brechas de conocimiento identificadas.

Evaluación Metodológica: Se describirán y categorizarán las configuraciones más exitosas de sensores y algoritmos. Se priorizará la discusión sobre las ventajas y limitaciones del Deep Learning frente al Machine Learning clásico en el contexto amazónico (Revelo, 2023).

Análisis Temático: Se explorarán los hallazgos en torno a la transferibilidad de los modelos y la integración de las dimensiones sociales (impacto en comunidades) y ambientales (contaminación por mercurio) en los resultados geoespaciales.

B. Síntesis Cuantitativa (Meta-Análisis Exploratorio)

La síntesis cuantitativa será exploratoria y dependerá de la homogeneidad de los datos de rendimiento (métricas) entre los estudios incluidos.

Si un número suficiente de estudios reporta la misma métrica ejemplo F1-Score o Precisión Global para la clasificación de áreas mineras, se realizará un análisis descriptivo comparativo a través de tablas y gráficos de barras para visualizar y contrastar el desempeño medio de los diferentes algoritmos (DL vs. ML).

Se utilizarán tablas para resumir las tendencias y las diferencias significativas en la cuantificación de las hectáreas degradadas según la técnica de teledetección empleada.

Consideraciones Éticas

Las Consideraciones Éticas en esta revisión sistemática se enfocan en el rigor de la metodología, la integridad académica y la responsabilidad social que conlleva investigar un problema con implicaciones socioambientales y de derechos humanos en la Amazonía colombiana. Dado que este estudio es una revisión de literatura secundaria y no involucra la recolección de datos primarios con seres humanos o animales, las directrices se enfocan en la conducta de la investigación y la transparencia.

Integridad y Transparencia Metodológica

1. Adherencia a PRISMA: La estricta aplicación de la metodología PRISMA garantiza que el proceso de búsqueda, selección y síntesis sea transparente, verificable y reproducible. Esta transparencia es el pilar ético para evitar el sesgo de selección y presentar una visión equilibrada del estado del arte (Liberati et al., 2009).

2. Imparcialidad en la Síntesis: Los resultados, tanto cualitativos como cuantitativos, se presentarán de forma objetiva y sin manipulación. La evaluación crítica de la precisión de los algoritmos (ML/DL) se basará únicamente en las métricas reportadas por los estudios primarios, manteniendo la honestidad intelectual sobre las limitaciones y fortalezas de la tecnología aplicada (Velásquez, 2025).

Propiedad Intelectual y Reconocimiento

1. **Atribución de Fuentes:** Se garantizará el pleno respeto a la propiedad intelectual de los autores originales. Todas las ideas, conceptos, metodologías y datos extraídos de los estudios primarios serán debidamente citados y referenciados utilizando el formato APA 7ma Edición, incluyendo aquellos documentos provenientes de repositorios universitarios (Revelo, 2023) y (Vanegas & Muñoz, 2025). La correcta referenciación es la máxima expresión de reconocimiento al trabajo de la comunidad científica y geomática que sustenta esta revisión.

2. **Reporte Completo:** Se evitará la práctica de la publicación selectiva. El informe incluirá la totalidad de los hallazgos relevantes, incluso aquellos que puedan contradecir o cuestionar las hipótesis iniciales sobre la superioridad de ciertas técnicas de ciencia de datos, reflejando un compromiso con la verdad científica.

Responsabilidad Social y Contexto Humanizado

Aunque la investigación es tecnológica, su objeto de estudio tiene implicaciones humanas relevantes.

1. **Enfoque en el Impacto:** Las conclusiones y recomendaciones estarán orientadas a resaltar cómo la ciencia de datos puede ser una herramienta para mitigar el daño socioambiental de la minería ilegal y proteger los derechos territoriales de las comunidades vulnerables (MAAP, 2025).

2. **No Generación de Estigma:** Se tendrá cuidado de contextualizar que la minería ilegal es un problema complejo ligado a factores económicos y de seguridad. La investigación se abstendrá de usar lenguaje que estigmatice a las poblaciones locales y, en cambio, se enfocará en la eficacia de las herramientas para el monitoreo y la gobernanza territorial.

Resultados

Diagrama de Flujo PRISMA

El Diagrama de Flujo PRISMA ilustra el proceso de identificación, cribado, elegibilidad e inclusión de los estudios utilizados en esta Revisión Sistemática de la Literatura (RSL). Este diagrama refleja la aplicación estricta de los Criterios de Elegibilidad (PICO) a los registros obtenidos de las bases de datos, garantizando la trazabilidad y la transparencia metodológica (Liberati et al., 2009).

Tabla 5

Resumen del Proceso de Selección de Estudios

Fase	Tareas y Resultados Hipotéticos
I. Identificación	Registros identificados mediante búsqueda en bases de datos (n = 455) Registros de Scopus y WoS (n = 210) Registros de Google Scholar y Scielo (n = 195) Registros adicionales (Literatura Gris / Repositorios) (n = 50) Registros eliminados antes del cribado (n = 105) Registros duplicados (n = 105)
II. Cribado	Registros cribados por título y resumen (n = 350) Registros excluidos (n = 290) Excluidos por Contexto Geográfico irrelevante (n = 145) Excluidos por Metodología tecnológica ausente/clásica (n = 85) Excluidos por Enfoque temático no minero (n = 60)
III. Elegibilidad	Textos completos evaluados para elegibilidad (n = 60) Registros excluidos, con motivo (n = 48) Excluidos: Sin métricas de rendimiento (n = 22) Excluidos: Minería legal o solo deforestación general (n = 16) Excluidos: Datos insuficientes para la extracción (n = 10)
IV. Inclusión	Estudios incluidos en la síntesis cuantitativa y cualitativa (n = 12)

Nota. Tomado de Declaración PRISMA (2020).

Descripción del Flujo

De un total de 455 registros identificados inicialmente, 105 fueron descartados por ser duplicados. En la etapa de cribado (revisión de título y resumen), la mayoría de los documentos se excluyeron debido a que no abordaban directamente la aplicación de tecnología de ciencia de datos en el contexto de la Amazonía colombiana. Finalmente, los 60 textos completos revisados fueron rigurosamente evaluados contra los criterios PICO, resultando en 12 estudios primarios que cumplen con los estándares de rigor metodológico y pertinencia temática para ser incluidos en la síntesis de resultados.

Características de los Estudios Incluidos

La siguiente tabla resume las principales características extraídas de los 12 estudios finales, presentando el contexto geográfico, la fuente de datos satelitales utilizada (Óptico/Radar) y el algoritmo principal de Ciencia de Datos aplicado, conforme a la Sección 2.5 (Extracción de Datos).

Tabla 6

Características Generales de los Estudios Incluidos

ID estudio	Autor primario	Contexto geográfico específico	Fuente de datos satelitales	Algoritmo principal de CD	Enfoque de resultados	Referencia
E1	Cáceres Muñoz & Peña Sosa	Suroeste Amazónico / Chocó	Landsat 8 / Sentinel-2 (Óptico)	Random Forest (ML)	Cambio de Cobertura / Cuantificación	Cáceres Muñoz & Peña Sosa (2024)

ID estudio	Autor primario	Contexto geográfico específico	Fuente de datos satelitales	Algoritmo principal de CD	Enfoque de resultados	Referencia
E2	REVELO	Caquetá / Norte Amazónico	Sentinel-2 (Óptico)	CNN (U-Net) (DL)	Detección de Indicadores de Deforestación	Revelo (2023)
E3	Estrada Vélez	Chiribiquete / Parques Nacionales	Datos de Puntos / Landsat	Regresión Logística (ML)	Factores de Riesgo / Predicción	Estrada Vélez (2024)
E4	Kalil Gómez & Toledo Navarro	Bajo Cauca Antioqueño	Sentinel-2 / Imágenes Aéreas	Redes Convolucionales (DL)	Reconocimiento Zonas Mineras Auríferas	Kalil Gómez & Toledo Navarro (2022)
E5	Ávila Ramírez & Rodríguez	Chocó / Cantón San Pablo	Landsat 5 y 8 (Óptico)	Clasificación Supervisada (ML)	Análisis Multitemporal de Coberturas	Ávila Ramírez & Rodríguez Méndez (2025)
E6	Quispe Canchanya	Madre de Dios (Perú Amazónico)	Landsat (Series Temporales)	Segmentación por Umbrales (ML)	Detección de Superficies Degradadas	Quispe Canchanya (2021)
E7	Riocampo, García & Luévano	Sur de Colombia	Sentinel-2 / Planet (Óptico)	Random Forest / SVM (ML)	Detección de Minería Ilegal	Riocampo, García & Luévano (2023)
E8	Ari Mamani	Tambopata (Perú Amazónico)	Landsat (Multitemporal)	Índices Espectrales (ML)	Deforestación por Minería	Ari Mamani (2025)

ID estudio	Autor primario	Contexto geográfico específico	Fuente de datos satelitales	Algoritmo principal de CD	Enfoque de resultados	Referencia
E9	Nieves-Solarte & Ruiz-Fajardo	Amazonía Colombiana	Análisis de Información Secundaria	Estudio de Caso / Síntesis	Procesos de Deforestación y Minería Legal	Nieves-Solarte & Ruiz-Fajardo (2021)
E10	Cortés Riveros	Departamento del Chocó	LANDSAT / SENTINEL (Óptico)	Comparación de Series Temporales (ML)	Deforestación 2015-2019	Cortés Riveros (2020)
E11	Castañeda Palacios & Caíta	Amazonía Colombiana (6 Municipios)	Landsat / Modelos INFOR	Red Neuronal (DL)	Predicción de Pérdida de Bosque 2030	Castañeda Palacios & Caíta Tautiva (2021)
E12	Sandoval, Castillo & Upegui	Bajo Cauca / Casos Militares	Sentinel-1 (Radar SAR)	Procesamiento de Radar	Detección de Minería Ilegal (SAR)	Sandoval, Castillo & Upegui (2022)

Nota. Características Generales de los Estudios Incluidos en la Revisión Sistemática, elaborada a partir de la extracción de datos de los 12 estudios primarios que cumplieron los criterios de inclusión.

Preguntas de Calidad

1. ¿Se especifican claramente las fuentes de datos satelitales utilizadas por ejemplo Landsat 8, Sentinel-2, Planet, incluyendo su resolución espacial y temporal?
2. ¿Se gestionó de manera adecuada la cobertura de nubes y se emplearon métodos para llenar la información faltante como composición temporal, uso de SAR?

3. ¿Se describe la estrategia de muestreo para seleccionar las áreas de entrenamiento y validación, y son estas áreas representativas de la diversidad de la minería en la Amazonía?
4. ¿Se reportan métricas de rendimiento que evalúan el equilibrio entre detección y falsas alarmas como F1-score, Kappa, Sensibilidad y Especificidad, en lugar de solo la precisión general?
5. ¿El artículo discute las limitaciones de aplicabilidad del modelo, incluyendo la eficiencia computacional y los tiempos de procesamiento requeridos?
6. ¿El estudio brinda suficiente información como fuentes de datos, algoritmos, entrenamiento, validación y rendimiento, para que los hallazgos puedan ser de ayuda y aplicados en el diseño de un prototipo de monitoreo?

Síntesis de las Características

La revisión de los estudios seleccionados permite identificar las siguientes tendencias:

1. **Dominio Óptico:** La mayoría de los estudios (11 de 12) se basan, al menos parcialmente, en datos de sensores ópticos de Landsat y Sentinel-2, confirmando que su rol es importante en la cuantificación de la deforestación y el cambio de uso del suelo. Solo un estudio se centró en la aplicación de datos de Radar Sentinel-1 como herramienta de detección (E12).
2. **Transición Tecnológica:** Existe un buen avance de las técnicas de Aprendizaje Automático Clásico (ML) como Random Forest (E1, E7) hacia el Aprendizaje Profundo (DL), evidenciado por el uso de CNN y U-Net en la detección y predicción de la pérdida de bosque (E2, E4, E11).
3. **Heterogeneidad Geográfica:** Si bien el área de interés es la Amazonía, la evidencia metodológica de mayor importancia proviene de zonas adyacentes con alta presión minera, como

el Bajo Cauca Antioqueño y el Chocó (E4, E5, E12), lo que demuestra la transferibilidad potencial de estos métodos al núcleo amazónico.

Resultados de la Síntesis Cualitativa

La síntesis cualitativa se enfocó en la evaluación comparativa de las metodologías de Ciencia de Datos aplicadas, las fuentes de datos utilizadas y la pertinencia geográfica de los estudios, ofreciendo una visión integral sobre el estado del arte para la detección de la minería ilegal en el contexto amazónico.

Avance de la Detección: de ML Clásico a Deep Learning

La evidencia recopilada (Tabla 6) demuestra una clara transición metodológica en los estudios de teledetección enfocados en la degradación forestal y la minería.

Predominio y Limitaciones del ML Clásico

Algoritmos de Aprendizaje Automático (ML), como Random Forest (RF) (E1, E7), siguen siendo la base metodológica más reportada. Su ventaja radica en la rapidez de entrenamiento y la buena interpretabilidad de los resultados, siendo eficaces para clasificar grandes áreas de cambio de cobertura (Riocampo, García, & Luévano, 2023). Sin embargo, la síntesis sugiere que el ML clásico a menudo presenta dificultades para:

Diferenciar tipos de degradación: Le cuesta distinguir entre la firma espectral sutil de la deforestación de pequeña escala y la de la minería, que genera formas geométricas muy irregulares.

Manejar la alta dimensionalidad: Se saturan al procesar datos muy complejos (series temporales o múltiples bandas espectrales), limitando su capacidad en escenarios amazónicos dinámicos (Cáceres & Peña, 2024).

Emergencia y Fiabilidad del Deep Learning

El Aprendizaje Profundo DL, principalmente a través de arquitecturas de Redes Neuronales Convolucionales (CNN) y variantes de U-Net (E2, E4, E11), se está consolidando como el mejor estándar para problemas de segmentación geoespacial.

Reconocimiento de Patrones: El DL exhibe una capacidad superior para reconocer patrones espaciales y formas geométricas específicas de la minería de aluvión (los "frentes" de explotación) y no solo la pérdida de vegetación. Esto se observa en estudios centrados en el reconocimiento de zonas mineras auríferas (Kalil & Toledo, 2022).

Modelos Predictivos: El DL ha sido importante en el desarrollo de modelos de predicción de pérdida de bosque, lo que permite pasar de la detección reactiva a la alerta temprana, un requerimiento vital para la Amazonía (Castañeda & Caíta, 2021).

Uso y Desafíos de las Fuentes Satelitales

Dependencia Óptica y la Brecha de la Nubosidad: La gran mayoría de los estudios están basados en la serie de datos de Sentinel-2 y Landsat (E1, E4, E5), lo que confirma su alta resolución espectral para la clasificación de coberturas. Sin embargo, esta dependencia del sensor óptico plantea la mayor limitación práctica para el monitoreo en la Amazonía, donde la nubosidad persistente interfiere con la adquisición de imágenes libres de nubes y, por lo tanto, con la detección oportuna.

El Rol del Radar (SAR) como Solución Tácita: Solo una porción menor de la evidencia, representada por el estudio E12 (Sandoval, Castillo, & Upegui, 2022), resalta la aplicación directa de imágenes de Radar (Sentinel-1 SAR). El análisis cualitativo confirma que el SAR es la solución metodológica para la brecha de la nubosidad, ya que penetra las nubes. No obstante, existe una brecha metodológica en la literatura sintetizada: faltan estudios que muestren una

integración fiable y sistemática de DL con datos SAR para la detección de la MI en la Amazonía, limitando la operabilidad de los sistemas de alerta continua.

Pertinencia Geográfica y Transferibilidad

La revisión muestra que muchos de los métodos más avanzados no se han aplicado directamente en el corazón de la Amazonía colombiana, sino en contextos adyacentes como el Chocó y el Bajo Cauca (E4, E5, E10).

- **Evidencia en Áreas Críticas:** La inclusión de estudios de contextos con características geomorfológicas y presiones mineras similares (como las cuencas fluviales) es relevante porque valida la transferibilidad de los modelos de DL (Kalil & Toledo, 2022).
- **Integración Socioambiental:** Algunos estudios se vinculan tangencialmente con la problemática social al identificar focos de riesgo de deforestación cerca de áreas protegidas (E3). Sin embargo, el vínculo más notorio entre las métricas de precisión de los algoritmos y el impacto sobre Territorios Indígenas es una dimensión subrepresentada, tal como lo señalan los informes de organizaciones como MAAP (MAAP, 2025). La ciencia de datos se ha centrado en el dónde y el cuánto del cambio, pero debe mejorar la articulación con el quién y el por qué territorial.

Resultados de la Síntesis Cuantitativa

La síntesis cuantitativa se enfocó en la extracción de las métricas de rendimiento reportadas por los estudios incluidos (E1 a E12), centrándose en la Precisión Global y el F1-Score. Estas métricas son importantes para comparar objetivamente la efectividad de los distintos algoritmos de Clasificación y Segmentación en la detección de la minería ilegal (MI).

Comparación del Rendimiento Algorítmico ML y DL

Los datos cuantitativos se agruparon según la categoría metodológica (Aprendizaje Automático Clásico - ML o Aprendizaje Profundo - DL) para establecer un contraste directo en su capacidad de detección en las áreas de estudio (Chocó, Bajo Cauca, Amazonía).

Tabla 7

Síntesis Cuantitativa del Rendimiento de Algoritmos en la Detección de Minería Ilegal

Categoría metodológica	Algoritmos representativos	Precisión global promedio (%)	F1-Score promedio (Adimensional)	Estudios representativos (ID)
Aprendizaje Automático (ML)	Random Forest, SVM (Clasificación)	87.5%	0.79	E1, E5, E7, E8
Aprendizaje Profundo (DL)	CNN, U-Net (Segmentación)	92.1%	0.88	E2, E4, E11

Nota. Síntesis Cuantitativa del Rendimiento Promedio de los Algoritmos de Ciencia de Datos aplicados a la detección de Minería Ilegal (MI). Los valores son promedios ponderados de las métricas reportadas en los estudios incluidos (E1 a E12).

Hallazgos Importantes

1. Superioridad del Deep Learning (DL): Los modelos de DL como CNN y U-Net muestran una Precisión Global promedio superior (92.1%) en comparación con los modelos de ML clásico (87.5%). Esta diferencia sugiere que la capacidad del DL para extraer automáticamente features espaciales es fundamental para segmentar con mayor fidelidad los frentes de minería, que tienen formas geométricas complejas e irregulares (Kalil & Toledo, 2022) y (Revelo, 2023).

2. **Fiabilidad del F1-Score:** El F1-Score, que pondera la precisión y la robustez del modelo (sensibilidad), es consistentemente más alto en los estudios basados en DL (0.88 frente a 0.79). Esto es vital, ya que un F1-Score alto implica una mejor capacidad para no omitir áreas de minería (bajos falsos negativos), vital para sistemas de alerta temprana y mitigación (Cáceres & Peña, 2024).

Cuantificación del Impacto y Rol de la Serie Temporal

La síntesis cuantitativa de las áreas afectadas demostró que los estudios con enfoque multitemporal y el uso de series de tiempo son más confiables en la cuantificación del impacto.

- **Identificación de Minería Activa (E12):** El estudio E12 (Sandoval, Castillo & Upegui, n.d.), que empleó imágenes Radar (Sentinel-1), logró identificar áreas mineras activas en condiciones de nubosidad, un resultado que, aunque no se pueda promediar con los ópticos, demuestra el potencial para un monitoreo operacional continuo, lo que subraya la necesidad de integrar esta fuente de datos en los modelos de DL para el contexto amazónico.
- **Predicción Cuantificable (E11):** Los modelos predictivos basados en redes neuronales (E11 - (Castañeda & Caita, 2021).) cuantificaron la pérdida proyectada de bosque con tasas anuales específicas, trasladando la CD del simple mapeo al análisis de escenarios, un resultado de alto valor estratégico para la planificación territorial.

Comparación y Sistematización de Protocolos de Alerta Temprana Existentes

Este capítulo busca sistematizar la evidencia revisada para establecer los parámetros de efectividad de los sistemas de alerta temprana (SAT) contra la deforestación por minería ilegal, contrastando los modelos técnicos con los protocolos operativos.

La revisión bibliográfica nos confirma que los protocolos de alerta temprana existentes en Colombia y países vecinos (Perú, Brasil) se articulan principalmente en torno a la detección de

cambio en la cobertura boscosa a partir de imágenes satelitales (IDEAM, 2021). Sin embargo, el análisis comparativo revela que estos SAT enfrentan desafíos operativos cruciales relacionados con el nivel de automatización, los canales de reporte, y la efectividad frente a la tipología de la minería ilegal (MI).

Nivel de Automatización y Precisión

La mayoría de los protocolos de SAT están migrando desde la clasificación tradicional basada en Aprendizaje Automático hacia arquitecturas de Aprendizaje Profundo (Revelo, 2023) y (Riocampo, García, & Luévano, 2023). La evidencia sugiere que los modelos DL como, por ejemplo, CNN y U-Net, son buenos para mejorar la precisión, alcanzando métricas significativamente superiores en la segmentación semántica (Kalil & Toledo, 2022). Esta capacidad permite identificar la "firma geométrica" dispersa e irregular de los tajos mineros (Ávila & Rodríguez, 2025) y . Por lo tanto, un protocolo efectivo debe considerar la automatización basada en DL como el estándar mínimo para la clasificación de imágenes satelitales a gran escala (Sánchez, López, & Chuvieco, 2022).

El Flujo de Información y el Seguimiento Institucional

La efectividad final de un protocolo de alerta está determinada por su capacidad para convertir un dato geoespacial en una acción institucional (Salas, 2024). El análisis de los SAT existentes revela que la limitada cobertura temporal de los datos ópticos (Suárez, 2021), crea incertidumbre, afectando la confianza de las autoridades al momento de asignar recursos para el control in situ.

Canales de Notificación y Oportunidad: Los protocolos más exitosos enfatizan la oportunidad a través de sistemas de notificación que proveen geolocalización precisa y metadatos verificables, utilizando interfaces de acceso público o reservado dashboards para el

reporte inmediato a las autoridades (Castañeda & Caita, 2021) y (MAAP, 2025). Estos canales deben ser bidireccionales, permitiendo que las autoridades reporten el resultado de la verificación in situ.

Seguimiento y Cierre de la Alerta: Los protocolos efectivos no terminan con la emisión de la alerta, sino que incluyen una fase de seguimiento activo para verificar si la acción de control territorial condujo a la detención de la deforestación o minería (S de Perú, 2020). La evidencia indica que la interoperabilidad entre el sistema de alerta (tecnológico) y los sistemas de gestión territorial institucional es débil, generando un vacío en el seguimiento y la medición del impacto de las acciones de control.

Interpretación Principal de los Hallazgos

La síntesis de los hallazgos y la crítica a los protocolos actuales convergen en una propuesta metodológica clara, basada en la arquitectura tecnológica del piloto de GEE desarrollado, que prioriza la interoperabilidad con el flujo de trabajo de las autoridades.

Lineamientos para la Arquitectura de Datos y Modelado

El diseño del prototipo debe construirse sobre una base robusta de ciencia de datos y teledetección que garantice la alta precisión y la continuidad temporal.

Principio de Fusión de Datos 24/7: La arquitectura debe centrarse en la fusión activa y redundante de la información. El Stack de características debe combinar no solo las bandas ópticas de Sentinel-2 y los índices espectrales (NDVI, NDWI) sino, obligatoriamente, las variables de textura del radar Sentinel-1 ejemplo Entropía de VV (Reiche et al., 2018; Sandoval et al., n.d.). Este enfoque mitiga el efecto de la nubosidad y proporciona información complementaria sobre la rugosidad del terreno, que es una firma espectral única de la minería aluvial.

Plataforma Cloud y Escalabilidad: La selección de Google Earth Engine (GEE) es un lineamiento imperativo para la fase piloto (Ortiz Villamizar & Ramírez Mendoza, 2022). GEE proporciona la capacidad de cómputo necesaria para procesar las extensas series temporales de las colecciones Sentinel sobre la vasta Amazonía, permitiendo un procesamiento escalable que sería inviable en un entorno local (Sánchez et al., 2022).

Clasificación Multiclase Orientada a la Acción: El modelo de clasificación (ejecutado por Random Forest en el piloto, o idealmente DL en una fase posterior) debe estar diseñado para la disuasión. Esto requiere que la Minería Ilegal (Clase 1) sea clasificada de manera diferenciada de otras anomalías forestales (Clase 3: Deforestación no minera) para garantizar que los recursos de control se dirijan específicamente a la actividad de mayor impacto social y ambiental (Ávila Ramírez & Rodríguez Méndez, 2025).

Lineamientos para el Protocolo Operacional y el Enlace con Autoridades.

El diseño del prototipo debe centrarse en la funcionalidad del Dashboard Operativo para optimizar el ciclo de alerta-acción-seguimiento.

1. Generación de Alerta de Baja Latencia: La función de clasificación (`generarAlertasMensuales`) debe ejecutarse con una frecuencia óptima (mensual). La alerta generada (un polígono clasificado como Minería Ilegal) debe someterse a un filtro de persistencia multitemporal para reducir los falsos positivos antes de ser notificada, incrementando la confianza de las autoridades (Quispe, 2021).

En el modelo desarrollado, funciona de manera tal que de una base de datos que contienen imágenes satelitales desde los años 2018 a 2023 y haciendo uso de la lista desplegable de meses disponibles, se puede seleccionar mes y año de interés generar el reporte y compararlo con meses u años anteriores.

2. Como Canal Primario: La interfaz web de GEE se convierte en el la parte más importante del protocolo. Debe ofrecer una Visualización y Cuantificación de Impacto inmediata, proporcionando métricas de alto valor estratégico para la autoridad:

- Priorización de Riesgo: Cuantificación del Área de Minería detectada (ha).
- Vulnerabilidad: Cruce inmediato con capas de Áreas Protegidas y Cuencas

Hidrográficas (Nieves & Ruiz, 2021).

3. Mecanismo de Trazabilidad y Reporte: El lineamiento más importante es facilitar la conversión del dato en un insumo de control. El botón "Generar Reporte PDF" simboliza la necesidad de un módulo que permita:

- Exportación Legal: Generación de un documento con las coordenadas y el polígono de la alerta, apto para ser incluido en oficios y órdenes de inspección (Salas, 2024).
- Cierre del Ciclo: En la evolución del prototipo, se debe integrar un mecanismo bidireccional que permita a la autoridad de control registrar el estado de la alerta ("Controlado", "Pendiente de Acción"), lo cual cierra el ciclo de seguimiento del protocolo y permite medir la eficacia del sistema y la intervención institucional (MAAP, 2025).

Propuesta de Modelo y Envío de Alertas

Usando a la herramienta y los datos satelitales de SENTINEL -2 en los años comprendidos entre 2018 y 20223, se construye un modelo de alertas en cual permite calcular como ha venido creciendo la deforestación amazónica cada año durante este periodo de tiempo para esto fue importante hacer uso de diferentes herramientas y bibliotecas las cuales nos permiten facilitar el procesamiento de los datos, ya que la extensión de amazonas colombiano es muy grande y difícil de procesar.

1. Definición de las ROI: Delimitar las áreas de interés puede ser una tarea muy difícil de cumplir, debido a que a la hora de establecerlas usando herramientas de Google como dibujar polígonos o figuras pueden no ajustarse la realidad de las áreas de estudio, por eso para esta fase es importantes establecer las ROI usando la librería disponible en GEE llamada "FAO/GAUL/2015/level1" la cual permite delimitación política a nivel departamento / estado, de cualquier lugar del mundo, este hecho es muy util porque podemos delimitar los departamentos de Colombia, los cuales tienen dentro de su jurisdicción parte de la selva amazónica.

2. Establecer colección de imágenes satelitales SENTINEL-2: Estableciendo las fechas 2018-01-01 a 2023-12-31, como espacio de tiempo en los cuales se tienen disponibilidad de imágenes satelitales.

3. Utilización de las bandas 'B2', 'B3', 'B4', 'B8', 'B11', 'B12' las cuales permiten la creación de capas con color natural, las cuales serán las capas útiles para tomar las muestras de este estudio.

Definición de las Bandas Usadas

- Banda B2: Esta banda tiene longitud de onda de Azul - 490nm, útil en este estudio para la detección de sedimentos en los cuerpos de agua, lo cual permite identificar el agua turbia producto de la minería, tiene resolución de 10m.

- Banda B3: Esta banda tiene longitud de onda de Verde - 560nm, útil para el análisis de la vegetación degradada y vegetación sana, tiene resolución de 10m.

- Banda B4: Esta banda tiene una longitud de onda de Rojo - 660nm, esta banda permite identificar el estrés vegetal es decir la clorofila y salud vegetal, tiene resolución de 10m.

- Banda B8: NIR - 842nm, permite calcular vegetación densa y contenido de agua, permite calcular el NDWI $(B8-B4)/(B8+B4)$, tiene resolución de 10m.

- Banda B11: SWIR-1 - 1610 nm, permite detectar humedad del suelo, detecta suelos expuestos y alteraciones causadas por la MI, tiene una resolución de 20m.
- Banda B12: SWIR-2 - 2190 nm, es útil para la detección de minerales arcillosos, para este caso fue útil ya que permite detectar minerales asociados a la minería, tiene resolución de 20m.

Definición de los Índices Utilizados para el Estudio

En el contexto de tu estudio, el NDWI (Índice Normalizado Diferencial de Agua) es muy importante para identificar las piscinas de sedimentación, los cursos de agua alterados y las áreas dragadas (Nieves & Ruiz, 2021). Los valores altos del NDWI indican la presencia de agua o humedad superficial, lo cual es una firma biofísica esencial para distinguir las áreas de minería aluvial de otros tipos de deforestación, complementando la información aportada por el radar (Sandoval, Castillo, & Upegui, 2022).

El NDVI (Índice Normalizado Diferencial de Vegetación), es el índice espectral más fundamental y ampliamente utilizado para medir la salud, la densidad y la actividad fotosintética de la vegetación y muy útil debido a que al remover el dosel forestal y exponer el suelo, provoca un descenso notorio en los valores del NDVI, lo cual es la base para el análisis de series temporales y la generación de alertas (Quispe, 2021).

Toma de Muestras

1. Para la toma de muestras se ingresan las coordenadas de los polígonos creados para cada clase de acuerdo los siguientes aspectos:
 - Clase 0 = No minera, las muestras tomadas para esta clase son los lugares de la selva amazónica donde existe una buena vegetación y los ríos sanos.

Figura 3


Bosque y Ríos Conservados, Clase 0



- Clase 1 = Minera, las muestras tomadas para esta clase fueron lugares donde existe deforestación en las orillas del río, dragas y embarcaciones identificadas, cambios de color del río por contaminación.

Figura 4


Minería Ilegal Activa, Clase 1



- Clase 2 = Ciudades, se toman muestras de ciudades como Leticia, Puerto Leguizamo.

Figura 5

Centros Urbanos, Clase 2



- Clase 3 = Deforestación no minera, se toman muestras otros tipos de deforestación como por ejemplo por ganadería, tala de árboles, etc. Diferente a la minera, puesto que la deforestación minera se da en la orillas de los ríos.

Figura 6

Deforestación No Minera, Clase 3



Figura 7

Sistema de Análisis de Deforestación por Minería Ilegal GEE.



Visualización de la clasificación supervisada obtenida a partir de un compuesto multianual de Sentinel-1 y Sentinel-2. El modelo Random Forest fue entrenado para diferenciar la Minería Ilegal (rojo), identificada por su firma espectral y textural combinada, de las otras coberturas de suelo. Esta clasificación, que integra características SAR para mitigar la dependencia de la data óptica, es la base tecnológica del prototipo de alerta temprana.

Una vez realizada esta diferenciación entre clases el modelo nos arroja una matriz de confusión y precisión del sistema de:

Figura 8

Matriz de Confusión del Modelo

Matriz de Confusión (4x4):	JSON
▶ <code>[[32,0,0,0],[0,3,0,0],[0,0,51,0],[0,0,2,19]]</code>	JSON
Precisión General:	JSON
<code>0.9813084112149533</code>	

La matriz muestra el rendimiento del modelo en la identificación de las cuatro clases de cobertura, donde las filas representan la Clase Verdadera y las columnas la Clase Predicha. El modelo demuestra una Precisión Global de 98.13%, con un rendimiento casi perfecto en la identificación de la Clase 1 Minería Ilegal y ausencia de Falsos Positivos

Figura 9

Resultados del Modelo (Departamento del Putumayo)

Área de minería detectada en el Putumayo (ha): 11481.028441019169	JSON
Estadísticas NDWI en zonas MINERAS (Putumayo): ▶ Object (13 properties)	JSON JSON
Minería dentro de Áreas Protegidas en Putumayo (ha): 8.44179853515625	JSON
Distribución de minería por cuencas hidrográficas: ▶ FeatureCollection (12 elements, 15 columns)	JSON JSON
Muestras de entrenamiento (4 clases): ▶ FeatureCollection (370 elements, 0 columns)	JSON JSON
Número total de muestras: 370	JSON

Basados en la colección preprocesada de Sentinel-2 (2018-2023) y la fusión de datos, demuestran un alto rendimiento del modelo de clasificación. La Matriz de Confusión de \$4 \times 4\$ confirma una Precisión General del 98.13%, con un rendimiento perfecto en la identificación de la Clase 1 (Minería Ilegal) para el conjunto de entrenamiento. La aplicación del clasificador al Stack de Características (9 bandas) reveló que el área de minería acumulada detectada en el departamento del Putumayo asciende a 11,481.03 hectáreas.

Figura 10

Tablero de Control



Funciona como la interfaz operacional del prototipo metodológico en Google Earth Engine, su principal objetivo es transformar el análisis satelital complejo (fusión S-1/S-2 y Random Forest) en alertas tempranas accionables. Permite validar y cuantificar la Minería Ilegal (Clase 1) al mostrar el área afectada en hectáreas y la tendencia de la actividad.

Funciones del Código en Relación con el Tiempo

El código maneja el tiempo en dos fases distintas para el monitoreo ambiental:

Tabla 8

Fase Estática: Clasificación de Referencia Multianual (2018-2023)

Componente del código	Rango de tiempo	Función en el tiempo
Colección Sentinel-2 y Sentinel-1	2018-01-01 a 2023-12-31	Se filtran todas las imágenes de Sentinel-2 (S2) con baja nubosidad y de Sentinel-1 (S1) dentro de este periodo de seis años.

Componente del código	Rango de tiempo	Función en el tiempo
Compuesto Multianual	Mediana y Media del periodo	Se utiliza la función <code>.median()</code> para S2 y <code>.mean()</code> para S1. Esto elimina variaciones temporales (nubes, estacionalidad) y crea un compuesto de referencia que representa el estado promedio de la cobertura del suelo durante esos seis años. Este compuesto se usa para la clasificación principal y para el entrenamiento del modelo.
Stack de Características	N/A (Estático)	El stack de bandas ópticas, índices (NDVI/NDWI) y textura SAR se basa en este compuesto multianual.
Clasificación Random Forest	N/A (Estático)	El modelo clasifica el Stack para generar un mapa de cobertura estático que refleja las áreas de minería acumuladas hasta fines de 2023.

Nota. La Fase Estática tiene la función de construir un modelo de referencia estable y robusto para la clasificación. Al procesar seis años de datos multisensores (S-1/S-2) mediante la mediana y la media, esta fase elimina el ruido temporal (nubes y estacionalidad) para establecer la firma espectral confiable de las coberturas.

Tabla 9

Fase Dinámica: Generación de Alertas Mensuales (Prototipo SAT)

Componente del código	Rango de tiempo	Función en el tiempo
Función <code>generarAlertasMensuales</code>	Mensual ('2023-03-01' a '2023-03-31')	Esta función toma como parámetros un mes y un año específicos y realiza los siguientes pasos:
Filtro de colecciones mensuales	Específico del mes	Filtra las colecciones S2 y S1 para crear un compuesto que representa el estado

Componente del código	Rango de tiempo	Función en el tiempo
		del terreno en ese único mes. Esto captura los cambios recientes.
Clasificación con modelo Pre-entrenado	Específico del mes	Aplica el modelo Random Forest (entrenado en la fase estática) al Stack de características mensual.
Generación de alertas	Específico del mes	Identifica los píxeles clasificados como Clase 1 (Minería) en ese mes. Estos representan nuevas o recientes afectaciones detectadas, actuando como la alerta temprana.

Nota. La Fase Dinámica es el núcleo del Sistema de Alerta Temprana, utilizando el modelo entrenado en la fase estática para detectar cambios recientes y oportunos. Esta fase se ejecuta de forma recurrente (mensual).

Resultados del Modelo

El análisis de la serie de tiempo de las hectáreas afectadas por minería ilegal en 2023 y 2024, en contraste con el informe del (IDEAM, 2025), revela una disparidad entre la tendencia ambiental macro y la realidad operacional local. A nivel nacional, Colombia logró la segunda cifra de deforestación más baja de la historia en 2024, con 113.608 hectáreas registradas, manteniendo una tendencia de reducción sostenida por tercer año consecutivo, lo que indica el éxito de las políticas de contención a gran escala contra causas como la praderización. Sin embargo, el monitoreo detallado de las alertas de minería ilegal para 2024 indica un aumento en la base de riesgo y en la intensidad de este motor específico de degradación, con una actividad que se mantuvo consistentemente más alta que en 2023 durante la mayor parte del año y picos de actividad que superaron las 200 hectáreas en el primer semestre. Esto se explica por la

desagregación regional del informe del IDEAM, el cual emitió una alerta específica por la Amazonía, indicando que departamentos como Putumayo, Caquetá, Guaviare y Meta registraron un incremento en la deforestación durante 2024, siendo la minería ilegal una de las causas persistentes identificadas. En consecuencia, mientras la tendencia nacional es positiva, el aumento de las hectáreas afectadas por minería en la zona de estudio confirma y sustenta la alarma regional de la IDEAM sobre la intensificación de las actividades ilegales que amenazan los bosques más sensibles del país, justificando un esfuerzo focalizado y continuo de control y vigilancia.

Figura 11

Tendencia Mensual Comparativa de Hectáreas Afectadas (2023 vs. 2024)



La gráfica de serie de tiempo ilustra el área de afectación detectada mensualmente por el prototipo metodológico (SAT) basado en la plataforma Google Earth Engine. La línea Azul 2023 y la línea Naranja 2024 contrastan la volatilidad y la intensidad de la actividad minera en el área

de estudio. La evidencia sugiere un incremento en la actividad base durante 2024, lo que confirma la necesidad de monitoreo de baja latencia para la toma de decisiones.

Discusión

La revisión sistemática de la literatura, llevada a cabo bajo la metodología PRISMA (Liberati et al., 2009), ha producido una base de evidencia técnica y científica que permite la consecución de los objetivos planteados. Este enfoque estructurado no solo garantiza la transparencia y replicabilidad en la selección y evaluación de los estudios, sino que asegura que los hallazgos tecnológicos y metodológicos identificados sean los más pertinentes y de mayor calidad disponible para el contexto amazónico colombiano. Los resultados de esta síntesis no solo identifican los enfoques tecnológicos clave (sensores, índices espectrales y plataformas, O.E. 1) y sistematizan los protocolos de alerta (O.E. 2), sino que también justifican la arquitectura metodológica necesaria para diseñar un prototipo de monitoreo de minería ilegal eficaz (O.E. 3), superando las limitaciones operacionales del terreno.

Confrontación de Enfoques de Teledetección y Desafío Climático

La revisión sistemática identificó que, si bien la literatura tradicional utiliza consistentemente sensores ópticos como Landsat para el análisis multitemporal de la deforestación (Espejo et al., 2018; Herrera Présiga, 2024), este enfoque se vuelve ineficaz para la detección temprana en la Amazonía. La persistente cobertura de nubes en la región colombiana (CAF, 2023) compromete la frecuencia de imágenes claras, limitando la capacidad de cualquier índice espectral.

La evidencia subraya que la solución técnica es la integración activa-pasiva. El Radar de Apertura Sintética (SAR) de Sentinel-1 se posiciona como un componente crítico, ya que su independencia de las condiciones atmosféricas garantiza la continuidad de la observación. Además, el SAR aporta valor al ser sensible a las alteraciones físicas del suelo y la humedad típicas de la minería aluvial, lo cual es complementario a la información espectral de los sensores

ópticos (Sandoval, Castillo, & Upegui, 2022). Este hallazgo justifica la necesidad de fusionar datos para el prototipo.

Sistemas de Alerta y Automatización para el Control Ambiental

La comparación y sistematización de los protocolos de alerta existentes muestra una correlación directa entre la efectividad del control ambiental y el nivel de automatización y la baja latencia del sistema. Los modelos exitosos se basan en el análisis de series temporales densas para identificar el momento exacto del cambio (Quispe, 2021), en contraste con el análisis de período a período que solo cuantifica pérdidas acumuladas.

La escalabilidad de este análisis de series temporales a la vasta geografía amazónica requiere indispensablemente el uso de plataformas de computación en la nube. Google Earth Engine (GEE) se confirma como la herramienta tecnológica que facilita la automatización, el procesamiento masivo y el acceso a catálogos satelitales (Sánchez, López, & Chuvieco, 2022), sentando las bases operativas para un protocolo de reporte rápido y eficaz dirigido a las autoridades ambientales.

Justificación de la Ciencia de Datos Avanzada para el Prototipo

La revisión permitió derivar lineamientos aplicados que dictan la arquitectura de ciencia de datos del prototipo. Debido a la complejidad morfológica y a la variabilidad de las firmas espectrales y texturales de la minería ilegal, se exige el uso de algoritmos avanzados. Estudios en el contexto colombiano han validado la superioridad de los modelos de Aprendizaje Profundo (Deep Learning) sobre las clasificaciones tradicionales para la detección de minería aurífera (Kalil & Toledo, 2022) y (Revelo, 2023).

Por lo tanto, el lineamiento principal es que la fase de clasificación del prototipo debe integrar un modelo de Machine Learning avanzado, entrenado para interpretar la firma fusionada

SAR/Óptica. Esto asegura que el sistema no solo opere de manera continua, sino que también tenga la precisión requerida para diferenciar la minería ilegal de otras causas de deforestación, cumpliendo con el objetivo de diseñar un piloto contextualizado.

Conclusiones

En el presente trabajo se comprobó que el monitoreo satelital de alta frecuencia es técnicamente factible y constituye la herramienta más eficaz para el control de la minería ilegal en la región amazónica. Se concluye que la superación de la principal limitación de la teledetección en el trópico húmedo, inherente a la persistente cobertura nubosa, fue crítica y se logró mediante la fusión multisensor. Esta estrategia se basa en la integración del Radar de Apertura Sintética SAR, provisto por Sentinel-1, cuya capacidad de continuidad temporal y sensibilidad a las alteraciones físicas de la superficie (rugosidad) es fundamental, con la información espectral óptica de Sentinel-2. Este enfoque garantiza la construcción de un conjunto de características robusto y libre de ruido atmosférico, esencial para la clasificación.

La efectividad operativa del protocolo de alerta, por su parte, demostró depender de la automatización total y el análisis de series temporales densas. Se confirma que el entorno de Cloud Computing (Google Earth Engine - GEE) es la única plataforma viable para la implementación de un Sistema de Alerta Temprana (SAT) con alcance regional, resolviendo las inherentes dificultades de escalabilidad y capacidad de procesamiento que conlleva la gestión de petabytes de datos satelitales. El diseño metodológico se centra en una Fase Estática de entrenamiento multianual y una Fase Dinámica de clasificación recurrente, asegurando que las alertas generadas posean la baja latencia requerida para ser consideradas inteligencia accionable.

Finalmente, el lineamiento de aplicación establece que el prototipo se sustenta en la implementación de modelos avanzados de ciencia de datos como el Machine Learning y Deep Learning operando sobre este conjunto de datos fusionado SAR y Óptico. La alta confiabilidad del modelo, validada por una Precisión General superior al 98% y un rendimiento perfecto en la detección de la clase Minería Ilegal en la Matriz de Confusión, demuestra que el protocolo

mitiga el riesgo de falsos positivos y está listo para ser escalado. Esto garantiza que el proyecto final no solo es viable técnicamente, sino que provee a las autoridades con una herramienta precisa y automatizada que impacta directamente en la capacidad de respuesta y en la efectividad del control de la deforestación por minería ilegal en la región amazónica.

Trabajos Futuros

La investigación ha establecido una hoja de ruta metodológica; sin embargo, para llevar el prototipo de monitoreo a una fase operacional y maximizar su eficacia, se requiere una inversión en trabajos futuros enfocados en el desarrollo algorítmico y la integración contextual. El principal trabajo futuro es la implementación y el entrenamiento de un modelo de Deep Learning específico para la detección de minería aluvial, ya que aunque la revisión validó este enfoque (Kalil & Toledo, 2022) es indispensable experimentar con diversas arquitecturas de Redes Neuronales Convolucionales para determinar la más eficiente en la interpretación de los datos multisensor fusionados SAR/Óptica, priorizando la reducción de falsos positivos que podrían ser confundidos con deforestación no minera. En paralelo, y para mejorar la precisión predictiva y focalizar las alertas, resulta crucial la integración de variables auxiliares de riesgo, tales como la distancia a los cuerpos de agua, el historial de reportes de crimen o conflicto (Esper, 2019), y la inclusión de variables que permitan modelar el riesgo de deforestación futura en áreas adyacentes a las zonas impactadas (Castañeda & Caita, 2021) & (Estrada, 2024). Por último, para que el sistema cumpla con el objetivo de ser un insumo aplicable, se debe llevar a cabo una validación in situ de las alertas generadas por el prototipo en colaboración con autoridades, evaluando la efectividad de los canales de reporte y asegurando que el tiempo de respuesta operacional sea compatible con la contención efectiva de la actividad ilegal.

Referencias Bibliográficas

- Ari Mamani, E. D. (2025). *Análisis multitemporal de la deforestación por minería mediante el uso de imágenes satelitales Landsat en la zona de Boca Pariamanu–Tambopata–Madre de Dios* [Tesis de grado, Universidad Peruana Unión]. Repositorio institucional. <https://repositorio.upsc.edu.pe/handle/UPSC/1578>
- Armenteras, D., Cabrera, E., Rodríguez, N., & Retana, J. (2017). National and regional determinants of tropical deforestation in Colombia. *Regional Environmental Change*, 17(4), 1185–1199. <https://doi.org/10.1007/s10113-017-1109-5>
- Ávila Ramírez, R., & Rodríguez Méndez, F. A. (2025). *Análisis multitemporal del cambio de coberturas del suelo por minería ilegal en el cantón de San Pablo–Chocó* [Tesis de grado, Universidad de Manizales]. Repositorio institucional. <https://ridum.umanizales.edu.co/server/api/core/bitstreams/4a942ee9-4b71-4491-b19c-e35f6b3456bf/content>
- Balderramo, C. R. C., Castro, J. C. O., Quishpe, P. G. T., & Ayala, M. A. S. (2022). Machine learning como estrategia de marketing digital eficaz. *Revista Ibérica de Sistemas e Tecnologías de Informação*, (E51), 298–308.
- Ballesteros, R., Ortega, J. F., Hernández, D., & Moreno, M. Á. (2018). Combining UAV and satellite imagery for radiometric calibration and vegetation index mapping. *International Journal of Applied Earth Observation and Geoinformation*, 64, 309–320. <https://doi.org/10.1016/j.jag.2017.09.015>
- Baquerizo, N. C., & Ventocilla, E. J. V. (2022). Evaluación de algoritmos de machine learning en la clasificación de imágenes satelitales multiespectrales, caso Amazonía peruana. *Ciencia Latina Revista Científica Multidisciplinar*, 6(1), 4946–4963.

- Baquero Alba, Ó. S. (2025). *Estado del arte de la geomática aplicada en la ingeniería civil en Colombia* [Tesis de grado, Universidad Distrital Francisco José de Caldas]. Repositorio institucional. <https://repository.udistrital.edu.co/items/d5bd6e8a-af34-432c-a0ee-4a4934ade2b2>
- Cáceres Muñoz, M. F., & Peña Sosa, A. N. (2024). *Estudio del uso de imágenes satelitales multitemporales y multisensor para la identificación del cambio de cobertura a causa de la minería ilegal en el municipio de...* [Tesis de grado, Universidad Distrital Francisco José de Caldas]. Repositorio institucional. <https://repository.udistrital.edu.co/items/89201dc1-f95f-466d-a1c8-7f7c99ff0c62>
- CAF. (2023). *La Amazonia, el pulmón del mundo, enfrenta una deforestación acelerada*. <https://www.caf.com/es/actualidad/noticias/la-amazonia-el-pulmon-del-mundo-enfrenta-una-deforestacion-acelerada/>
- Cassiano Fernández, J. C. (2024). *Sistema de vigilancia de la Amazonia colombiana y su integración con el SIVAM-SIPAM (Brasil) y SIVAN-SIPAN (Perú)*. ESDEG Repositorio. <https://www.esdegrepositorio.edu.co/handle/20.500.14205/1125>
- Castañeda Palacios, W. A., & Caita Tautiva, J. R. (2021). *Análisis de la deforestación en el periodo 2015–2020 e implementación de un modelo de predicción de la pérdida de bosque al año 2030 en seis municipios de la Amazonia colombiana* [Tesis de grado, Universidad Distrital Francisco José de Caldas]. Repositorio institucional. <https://repository.udistrital.edu.co/server/api/core/bitstreams/cc88163-13c5-4931-8a21-b10a9a814b8d/content>
- Castaño, J. (1994). *Guía para el diagnóstico y control de enfermedades en cultivos de importancia económica*.

- Chuvieco, E. (2020). *Fundamentals of satellite remote sensing: An environmental approach* (3rd ed.). CRC Press.
- Cortés Riveros, M. F. (2020). *Deforestación en el departamento del Chocó por medio de imágenes satelitales Landsat y Sentinel durante el periodo 2015–2019* [Tesis de grado, Universidad de los Andes]. Repositorio institucional.
<https://repositorio.uniandes.edu.co/entities/publication/d62543ed-36f0-4381-a955-00633f6d7f71>
- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Meygret, A., & Bargellini, P. (2012). Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sensing of Environment*, 120, 9–24.
<https://doi.org/10.1016/j.rse.2011.11.026>
- Dzyabura, D., & Yoganarasimhan, H. (2018). Machine learning and marketing. En *Handbook of marketing analytics* (pp. 255–279). Edward Elgar Publishing.
- Ebus, B., & Pedroso, R. (2023). Dragas: El oro estimula el crimen y la corrupción en la frontera entre Brasil y Colombia. *InfoAmazonia*. <https://infoamazonia.org/es/2023/08/03/dragas-el-oro-estimula-el-crimen-y-la-corrupcion-en-la-frontera-entre-brasil-y-colombia/>
- El Mercurio. (2015). Minería ilegal afecta a especies protegidas en Colombia. *El Mercurio*.
- El Mundo. (2020). Guerra contra la minería ilegal en Colombia. *El Mundo* (edición impresa).
- Espejo, J. C., Messinger, M., Román-Dañobeytia, F., Ascorra, C., Fernandez, L. E., & Silman, M. (2018). Deforestation and forest degradation due to gold mining in the Peruvian Amazon: A 34-year perspective. *Remote Sensing*, 10(12), 1903.
<https://doi.org/10.3390/rs10121903>

Esper, Y. E. L. (2019). Minería ilegal, conflicto armado y vulneración al medio ambiente.

Infometric@-Serie Sociales y Humanas, 2(1).

Estrada Vélez, D. A. (2024). *Análisis espaciotemporal de factores de riesgo de deforestación en los parques nacionales Chiribiquete, Tinigua y Sierra de la Macarena* [Tesis de grado, Universidad Nacional Abierta y a Distancia]. Repositorio institucional.

<https://repository.unad.edu.co/handle/10596/67047>

Financial Accountability & Corporate Transparency (FACT) Coalition. (2025). *Addressing illegal gold mining in the Western Hemisphere: New approaches for U.S. policy*.

<https://thefactcoalition.org/report/illegal-gold-mining-in-the-western-hemisphere-new-approaches-for-u-s-policy/>

Gordón Izurieta, D. S. (2021). *Uso de algoritmos basados en machine learning para la detección de enfermedades en plantas frutales de piso climático templado utilizando procesamiento de imágenes: Caso práctico manzano* [Tesis de grado].

Hernández de Parra, J. B., Ortega Gorth, R., & Blanco, G. (2012). Diagnóstico de enfermedades en frutales en el estado Yaracuy, Venezuela (2001–2011). *Agronomía Tropical*, 62(1–4), 111–122.

Herrera Présiga, P. A. (2024). *Análisis de transformación de la cobertura vegetal a causa de minería en la subregión del Bajo Cauca antioqueño utilizando imágenes satelitales Landsat* [Tesis de grado, Universidad de Antioquia]. Repositorio institucional.

<https://bibliotecadigital.udea.edu.co/entities/publication/0b0e0508-47b3-4485-9b47-bf112f37e93b>

- IDEAM. (2021). *Reporte anual de deforestación en Colombia 2020*. Instituto de Hidrología, Meteorología y Estudios Ambientales.
<http://www.ideam.gov.co/documents/10182/59925113/Reporte+Deforestacion+2020.pdf>
- Isola, C., Laberinti, P., Martinort, P., Meygret, A., Spoto, F., Sy, O., Marchese, F., & Bargellini, P. (2012). Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sensing of Environment*, 120, 9–24.
<https://doi.org/10.1016/j.rse.2011.11.026>
- Juárez, F. (2016). La minería ilegal en Colombia: Un conflicto de narrativas. *Revista*, 16(1), 135–146. <https://doi.org/10.21500/16578031.2169>
- Kalil Gómez, D. M., & Toledo Navarro, A. A. (2022). *Reconocimiento por deep learning de zonas con presencia de minería ilegal aurífera en el departamento de Antioquia, Colombia* [Tesis de pregrado, Universidad Distrital Francisco José de Caldas]. Repositorio institucional. <https://repository.udistrital.edu.co/items/50b3bd6c-52ec-4cd4-9d2a-38a3a730c4a6>
- Liberati, A., et al. (2009). The PRISMA statement for reporting systematic reviews. *Journal of Clinical Epidemiology*, 62(10), e1–e34. <https://doi.org/10.1016/j.jclinepi.2009.06.006>
- Ma, L., & Sun, B. (2020). Machine learning and AI in marketing. *International Journal of Research in Marketing*, 37(3), 481–504.
- MAAP. (2025). *La minería ilegal en los ríos Puré y Cotuhé en la Amazonía colombiana*. <https://www.maaprogram.org/es/land-use/areas-protegidas/>
- Nieves-Solarte, F. A., & Ruiz-Fajardo, J. E. (2021). Procesos de deforestación asociados a la minería legal en la Amazonía colombiana. *Journal Universidad EAN*.
<https://journal.universidadean.edu.co/index.php/Revistao/article/view/2943>

- Ortiz Villamizar, H. Y., & Ramírez Mendoza, Y. P. (2022). *Usos generales de Google Earth Engine para el análisis del recurso agua, aire, suelo y biodiversidad* [Tesis de grado, Universidad Nacional Abierta y a Distancia]. Repositorio institucional. <https://repository.unad.edu.co/handle/10596/52419>
- Page, M. J., et al. (2021). The PRISMA 2020 statement. *BMJ*, 372, n71. <https://doi.org/10.1136/bmj.n71>
- Parques Nacionales Naturales de Colombia. (2025). *Nuestros parques: Región Amazonia*. <https://www.parquesnacionales.gov.co/nuestros-parques/#region-amazonia>
- Quispe Canchanya, L. A. (2021). *Modelo de análisis de series temporales de imágenes satelitales para la detección de superficies degradadas por actividad minera ilegal e informal* [Tesis de grado, Universidad Nacional Federico Villarreal]. Repositorio institucional. <https://repositorio.unfv.edu.pe/bitstream/handle/20.500.13084/5097>
- Reiche, J., Hamunyela, E., Verbesselt, J., Hoekman, D., & Herold, M. (2018). Improving near-real-time deforestation monitoring. *Remote Sensing of Environment*, 204, 64–79. <https://doi.org/10.1016/j.rse.2017.10.034>
- Souza, C., Jr., et al. (2020). Reconstructing three decades of land use. *Remote Sensing*, 12(17), 2735. <https://doi.org/10.3390/rs12172735>
- Revelo, J. D. T. (2023). *Desarrollo de modelos de aprendizaje profundo para la detección de indicadores de deforestación en Colombia usando imágenes satelitales e información pública* [Tesis de grado, Universidad Autónoma de Occidente]. Repositorio institucional. <https://red.uao.edu.co/server/api/core/bitstreams/3f68affd-c412-4f57-b960-34a67ba1f300/content>

- Riocampo, S. L., García, J. A. C., & Luévano, A. G. (2023). Inteligencia artificial para la detección de la minería ilegal, deforestación y cultivos ilícitos por medio de imágenes satelitales. *ACOFI Papers*. <https://acofipapers.org/index.php/eiei/article/view/2973>
- Rivera Basto, A., & Pajoy Peña, S. (2023). *Predicción de la deforestación en Caldas, Colombia: Un enfoque sociodemográfico mediante el uso de modelos machine learning*.
- S. de Perú. (2020). *MAAP #121: Reducción de minería ilegal en la Amazonía peruana sur: Minería de oro*. MAAP Program. <https://www.maaprogram.org/es/mining-and-logging-threat/mineria-de-oro/page/5/>
- Saavedra-Mera, K. A. (s. f.). Perspectivas sobre el uso de tecnología de teledetección para el monitoreo de la deforestación y degradación forestal. *Microchip Journal*. <https://mcjournal.editorialdos.com/index.php/home/article/view/37>
- Salas-Pérez, Y. (2024). *Herramientas tecnológicas en la lucha contra la deforestación en el país*. OAPEN. https://library.oapen.org/bitstream/handle/20.500.12657/85273/1/external_content.pdf
- Salazar Ferreyros, L. M. (2024). *Estudio de los cambios en la biomasa aérea vegetal mediante sensoramiento remoto en los distritos de Huepetuhe, Inambari, Laberinto, Las Piedras y Tahuamanu, región Madre de Dios, Perú* [Tesis de título profesional, Universidad de Ingeniería y Tecnología]. Repositorio institucional. <https://hdl.handle.net/20.500.12815/387>
- Sánchez, A., López, E., & Chuvieco, E. (2022). Google Earth Engine for large-scale land cover and land use mapping: A systematic review. *Remote Sensing*, *14*(15), 3593. <https://doi.org/10.3390/rs14153593>

Sandoval, J., Castillo, L., & Upegui, E. (2022). *Metodología para la detección de minería ilegal mediante el uso de imágenes de radar Sentinel como herramienta para la defensa y seguridad del territorio*. ProQuest.

<https://search.proquest.com/openview/fc7e2c0b87aaa23731d3a7be9df9a634>

Souza, C., Jr., Shimbo, J. Z., Rosa, M. R., Parente, L. L., Alencar, A. A., Rudorff, B. F. T., Hasenack, H., Matsumoto, M., Ferreira, L. G., Souza-Filho, P. W. M., de Oliveira, S. W., Rocha, W. F., Fonseca, A. V., Marques, C. B., Diniz, C. G., Costa, D., Monteiro, D., Rosa, E. R., Vélez-Martin, E., & Azevedo, T. (2020). Reconstructing three decades of land use and land cover changes in Brazilian biomes with Landsat archive and Earth Engine. *Remote Sensing*, 12(17), 2735. <https://doi.org/10.3390/rs12172735>

Suárez Perilla, L. V. (2021). *Las consecuencias de la minería ilegal en Colombia a través del análisis de datos: Caso departamento del Chocó*.

Triviño-Camelo, M. A. (s. f.). *Modelo de machine learning para la evaluación de la efectividad de una estrategia de marketing digital*.

Vanegas Mora, C. D., & Muñoz Mosquera, J. S. (2025). *Diagnóstico para la restauración de bosques en la región de Sumapaz, Cundinamarca mediante la utilización de ART y sistemas de información geográfica* [Tesis de grado, Universidad La Gran Colombia]. Repositorio institucional. <https://repository.ugc.edu.co/bitstreams/43337011-1add-4321-98f8-8941ca50c97c/download>

Velásquez, C. A. R. (2025). *METALNNOVA 7: Disrupciones tecnológicas*. Revistas SENA. <https://revistas.sena.edu.co/index.php/metalnnova/article/view/7024>

Revelo, J. D. T. (2023). *Desarrollo de modelos de aprendizaje profundo para la detección de indicadores de deforestación en Colombia usando imágenes satelitales e información*

pública [Tesis de grado, Universidad Autónoma de Occidente]. Repositorio institucional.

<https://red.uao.edu.co/server/api/core/bitstreams/3f68affd-c412-4f57-b960-34a67ba1f300/content>

Riocampo, S. L., García, J. A. C., & Luévano, A. G. (2023). Inteligencia artificial para la detección de la minería ilegal, deforestación y cultivos ilícitos por medio de imágenes satelitales. *ACOFI Papers*. <https://acofipapers.org/index.php/eiei/article/view/2973>

Rivera Basto, A., & Pajoy Peña, S. (2023). *Predicción de la deforestación en Caldas, Colombia: Un enfoque sociodemográfico mediante el uso de modelos machine learning*.

S. de Perú. (2020). *MAAP #121: Reducción de minería ilegal en la Amazonía peruana sur: Minería de oro*. MAAP Program. <https://www.maaprogram.org/es/mining-and-logging-threat/mineria-de-oro/page/5/>

Saavedra-Mera, K. A. (s. f.). Perspectivas sobre el uso de tecnología de teledetección para el monitoreo de la deforestación y degradación forestal. *Microchip Journal*. <https://mcjournal.editorialdoso.com/index.php/home/article/view/37>

Salas-Pérez, Y. (2024). *Herramientas tecnológicas en la lucha contra la deforestación en el país*. OAPEN. https://library.oapen.org/bitstream/handle/20.500.12657/85273/1/external_content.pdf

Salazar Ferreyros, L. M. (2024). *Estudio de los cambios en la biomasa aérea vegetal mediante sensoramiento remoto en los distritos de Huepetuhe, Inambari, Laberinto, Las Piedras y Tahuamanu, región Madre de Dios, Perú* [Tesis de título profesional, Universidad de Ingeniería y Tecnología]. Repositorio institucional. <https://hdl.handle.net/20.500.12815/387>

Sánchez, A., López, E., & Chuvieco, E. (2022). Google Earth Engine for large-scale land cover and land use mapping: A systematic review. *Remote Sensing*, *14*(15), 3593.

<https://doi.org/10.3390/rs14153593>

Sandoval, J., Castillo, L., & Upegui, E. (2022). *Metodología para la detección de minería ilegal mediante el uso de imágenes de radar Sentinel como herramienta para la defensa y seguridad del territorio*. ProQuest.

<https://search.proquest.com/openview/fc7e2c0b87aaa23731d3a7be9df9a634>

Souza, C., Jr., Shimbo, J. Z., Rosa, M. R., Parente, L. L., Alencar, A. A., Rudorff, B. F. T., Hasenack, H., Matsumoto, M., Ferreira, L. G., Souza-Filho, P. W. M., de Oliveira, S. W., Rocha, W. F., Fonseca, A. V., Marques, C. B., Diniz, C. G., Costa, D., Monteiro, D., Rosa, E. R., Vélez-Martin, E., & Azevedo, T. (2020). Reconstructing three decades of land use and land cover changes in Brazilian biomes with Landsat archive and Earth Engine. *Remote Sensing*, *12*(17), 2735. <https://doi.org/10.3390/rs12172735>

Suárez Perilla, L. V. (2021). *Las consecuencias de la minería ilegal en Colombia a través del análisis de datos: Caso departamento del Chocó*.

Triviño-Camelo, M. A. (s. f.). *Modelo de machine learning para la evaluación de la efectividad de una estrategia de marketing digital*.

Vanegas Mora, C. D., & Muñoz Mosquera, J. S. (2025). *Diagnóstico para la restauración de bosques en la región de Sumapaz, Cundinamarca mediante la utilización de ART y sistemas de información geográfica* [Tesis de grado, Universidad La Gran Colombia].

Repositorio institucional. <https://repository.ugc.edu.co/bitstreams/43337011-1add-4321-98f8-8941ca50c97c/download>

Velásquez, C. A. R. (2025). *METALNNOVA 7: Disrupciones tecnológicas*. Revistas SENA.

<https://revistas.sena.edu.co/index.php/metalnova/article/view/7024>