

Juan Carlos Chasquero Martínez

DETERMINACIÓN DE LA COBERTURA Y USO DEL SUELO EN LA CUENCA BINACIONAL MAYO CHINCHIPE EMPLEANDO IMÁG...

 Quick Submit Quick Submit Universidad Nacional de Jaen

Detalles del documento

Identificador de la entrega

trn:oid:::1:3645351989

Fecha de entrega

10 sep 2026, 10:53 a.m. GMT-5

Fecha de descarga

10 sep 2026, 10:57 a.m. GMT-5

Nombre del archivo

INFORME_FINAL_JCCM.pdf

Tamaño del archivo

8.7 MB

67 páginas

12.611 palabras

72.939 caracteres



UNIVERSIDAD NACIONAL DE JAÉN
Dr. Alexander Huamán Mera
DIRECTOR(A) DE LA ESCUELA DE POSGRADO

3% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- ▶ Bibliografía
- ▶ Texto citado
- ▶ Coincidencias menores (menos de 15 palabras)

Fuentes principales

- 2%  Fuentes de Internet
- 1%  Publicaciones
- 2%  Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión

No se han detectado manipulaciones de texto sospechosas.

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.

 UNIVERSIDAD NACIONAL DE JAÉN
Dr. Alexander Huaman Mera
DIRECTOR GENERAL DE LA ESCUELA DE POSGRADO

Fuentes principales

- 2% Fuentes de Internet
- 1% Publicaciones
- 2% Trabajos entregados (trabajos del estudiante)

Fuentes principales

Las fuentes con el mayor número de coincidencias dentro de la entrega. Las fuentes superpuestas no se mostrarán.

1	Trabajos del estudiante	Universidad Nacional Agraria la Molina	<1%
2	Internet	www.repositorio.usac.edu.gt	<1%
3	Trabajos del estudiante	Pontificia Universidad Catolica del Peru	<1%
4	Internet	doczz.es	<1%
5	Publicación	Zhewen Zhao, Fakhrul Islam, Liaqat Ali Waseem, Aqil Tariq et al. "Comparison of T...	<1%
6	Trabajos del estudiante	uncedu	<1%
7	Trabajos del estudiante	Submitted on 1687725940988	<1%
8	Trabajos del estudiante	University of Sheffield	<1%
9	Trabajos del estudiante	Universidad Nacional de Moquegua	<1%
10	Internet	core.ac.uk	<1%
11	Internet	repositorio.comillas.edu	<1%

12	Internet	repositorio.upt.edu.pe	<1%
13	Internet	repository.usta.edu.co	<1%
14	Trabajos del estudiante Escola de Enxeñería Forestal		<1%
15	Internet	www.adaptation-fund.org	<1%

UNIVERSIDAD NACIONAL DE JAÉN

ESCUELA DE POSGRADO



**DETERMINACIÓN DE LA COBERTURA Y USO DEL
SUELO EN LA CUENCA BINACIONAL MAYO
CHINCHIPE EMPLEANDO IMÁGENES SENTINEL Y
GOOGLE EARTH ENGINE, 2024**

**PROYECTO DE TESIS PARA OBTENER EL GRADO ACADÉMICO
DE MAESTRO EN CIENCIAS EN “RECURSOS HÍDRICOS CON
MENCIÓN EN GESTIÓN INTEGRAL DE CUENCAS
HIDROGRÁFICAS Y DIPLOMACIA DEL AGUA”**

ESTUDIANTE: Ing. Juan Carlos Chasquero Martinez

ASESOR: Dr. Segundo Sanchez Tello

JAÉN – PERÚ

2026

I. ÍNDICE

Contenido	pág.
II. RESUMEN.....	6
III. INTRODUCCIÓN	7
IV. REVISIÓN LITERARIA	9
4.1. Antecedentes	9
4.2. Marco teórico	12
V. MATERIALES Y MÉTODOS	18
5.1. Materiales	18
5.1.1. Equipos.....	18
5.1.2. Software	18
5.1.3. Materiales de oficina	18
5.1.4. Material cartográfico digital.....	18
5.2. Metodología	19
5.2.1. Ubicación del área de estudio.....	19
5.2.2. Delimitación del área de estudio.....	19
5.2.3. Obtención de datos	19
5.2.4. Preprocesamiento del mosaico	20
5.2.5. Generación de índices espectrales, variables topográficas y Transformación Tasseled Cap (TCT).....	20
5.2.6. Selección de áreas de muestreo y observación en campo	21
5.2.7. Segmentación de datos	22
5.2.8. Clasificación mediante RF.....	22
5.2.9. Corrección post clasificación	22
5.2.10. Cálculo de métricas de precisión	23
5.2.11. Elaboración del mapa de LUC	24
5.2.12. Análisis de implicancias ambientales.....	24

VI.	RESULTADOS Y DISCUSIÓN.....	24
6.1.	Resultados	24
6.1.1.	Determinación y distribución espacial de LUC	24
6.1.2.	Clasificación supervisada.....	29
6.1.3.	Mapeo y cuantificación de LUC	32
6.1.4.	Análisis de implicancias ambientales.....	33
6.2.	Discusión.....	37
VII.	CONCLUSIONES	40
VIII.	RECOMENDACIONES	41
IX.	REFERENCIAS BIBLIOGRÁFICAS.....	42
X.	ANEXOS.....	48

ÍNDICE DE TABLAS

Tabla 1	Especificaciones de las bandas espectrales de Sentinel 2 usadas en este estudio	20
Tabla 2	Índices espectrales usados en la clasificación	21
Tabla 3	Descripción de clases de LUC encontradas en la cuenca	25
Tabla 4	Distribución de LUC en la parte alta, media y baja de la cuenca	28
Tabla 5	Matriz de confusión de la clasificación	30
Tabla 6	Valores de las métricas de precisión	30
Tabla 7	Cuantificación de clases de LUC encontradas en la cuenca	33
Tabla 8	Cuantificación de clases de LUC en pendientes mayores a 75 %	34
Tabla 9	Cuantificación de LUC en espacios de conservación dentro de la cuenca	35

ÍNDICE DE FIGURAS

Figura 1	Cultivos de arroz en el centro poblado Shumba, distrito de Bellavista	49
Figura 2	Cultivos transitorios en el caserío Hawai, distrito de Chirinos	49
Figura 3	Vegetación arbustiva y herbácea en el caserío El Tablón, distrito de Chirinos	50
Figura 4	Mosaico de relictos de bosque junto a vegetación arbustiva y herbácea	50
Figura 5	Vegetación arbustiva y herbácea en el distrito de Huarango	51
Figura 6	Pasturas en zonas con pendientes pronunciadas, caserío La Florida, distrito de Chirinos	51
Figura 7	Bosque natural en Puerto Ciruelo, distrito de Huarango	52
Figura 8	Sistema agroforestal café y Cordia. Parroquia Chito, Cantón Zamora Chinchipe	52
Figura 9	Pasturas con relictos de bosque natural. Parroquia Zumba, Ecuador	53
Figura 10	Compuesto mixto entre cultivo permanente, Suelo desnudo y con escasa vegetación y vegetación arbustiva herbácea. Caserío La Lima, distrito de Chirinos	53
Figura 11	Ecosistema páramo en el Santuario Nacional Tabaconas Namballe, Provincia de San Ignacio	54
Figura 12	Ecosistema páramo en el Distrito Carmen de la Frontera, Provincia de Huancabamba	54
Figura 13	Bosques naturales en el caserío El Porvenir, distrito de San José del Alto	55
Figura 14	Bosques naturales en el caserío San Patricio, distrito de San José del Alto	55

ÍNDICE DE GRÁFICOS

Gráfico 1 Importancia de variables en la clasificación.	31
Gráfico 2 Matriz de separabilidad espectral entre clases de LUC.	32
Gráfico 3 Cuantificación de clases de LUC.	33
Gráfico 4 Distribución de LUC por Área Natural Protegida	36

ÍNDICE DE ANEXOS

Anexo 1 Mapa de ubicación de la cuenca Mayo Chinchipe	48
Anexo 2 Panel fotográfico de las clases de LUC registradas durante la toma de datos en campo	49
Anexo 3 Mapa de LUC del año 2024 de la cuenca Mayo Chinchipe	56
Anexo 4 Mapa de la cuenca con pendientes mayores a 75 %.....	57
Anexo 5 Mapa de LUC en pendientes mayores a 75 %.....	58
Anexo 6 Mapa de LUC resultante del Parque Nacional Podocarpus.....	59
Anexo 7 Mapa de LUC resultante del Parque Nacional Yacuri	60
Anexo 8 Mapa de LUC resultante del Santuario Nacional Tabaconas Namballe.....	61
Anexo 9 Mapa de LUC resultante del ACR Páramos y Bosques Montanos de Jaén y Tabaconas	62
Anexo 10 Mapa de LUC resultante del ACR Bosques del Chaupe, Cunía y Chinchiquilla	63
Anexo 11 Mapa de ubicación de áreas seleccionadas	64
Anexo 12 Clases de LUC identificadas en Google Earth	65
Anexo 13 Interfaz de la plataforma GEE	67

II. RESUMEN

La cuenca binacional Mayo Chinchipe es un espacio natural que forma parte del corredor biológico transfronterizo andino amazónico entre Perú y Ecuador, desempeña un papel fundamental para abordar la crisis actual de la falta de agua y reducción de biodiversidad, dado que son escasas las instituciones gubernamentales en implementar políticas de protección y conservación de estos recursos, resulta necesario realizar un diagnóstico de cobertura y uso del suelo (LUC) con los recursos informáticos que están a disposición de investigadores sin generar mayores costos. En esta investigación se desarrolló un método que combina imágenes multiespectrales de Sentinel 2, la plataforma Google Earth Engine y un estudio de campo para determinar LUC del año 2024. Usando bandas espectrales de Sentinel 2, índices multiespectrales, Transformación Tasseled Cap; además, un Modelo Digital de Elevación de Alos PalSAR para generar índices topográficos. Se aplicó el algoritmo de aprendizaje automático Random Forest (RF), obteniendo como principales coberturas al bosque natural con 4,985.00 km², vegetación herbácea y arbustiva con 1,364 km², pasturas, cultivos permanentes y suelo desnudo y con escasa vegetación con 1,156.97, 1,061.4 y 680.6 km² respectivamente. Con datos registrados en campo se realizó la validación temática, obteniendo 96.5 % de precisión general y un 0.95 de coeficiente Kappa. Se determinaron 506.8 km² de LUC en suelos con pendientes mayor a 75%. El enfoque propuesto demostró que el procesamiento de imágenes satelitales de Sentinel 2 en GEE puede determinar LUC en espacios con ecosistemas heterogéneos y topografías complejas.

Palabras clave: Clasificación supervisada, Índices topográficos, Clases, Random Forest, Implicancia ambiental.

III. INTRODUCCIÓN

La Organización de las Naciones Unidas para la Agricultura y la alimentación (FAO, 2020) indica que la actividad agrícola se ha convertido en una de las principales formas en que la humanidad ha alterado la superficie de la tierra. A nivel global, el 38 % de esta superficie es usada por actividades agrícolas, aproximadamente un tercio de esta se viene destinando a cultivos, y dos tercios para actividades pastoriles. En las últimas décadas, estos cambios han generado reducción de ecosistemas y pérdida de biodiversidad, ocasionando impactos ambientales, sociales y económicos, afectando la calidad de vida de poblaciones locales (De Jong et al., 2021). Si bien algunas intervenciones políticas han conseguido minimizar la pérdida de bosques, cada vez más en la Amazonía y en todo el mundo, las áreas de expansión agrícola se superponen con áreas de prioridad de conservación, incluidas las áreas protegidas (Hänggli et al., 2023).

El mapeo de LUC en ecosistemas boscosos es importante para investigadores y gobiernos (Lu et al., 2013), dado que se trata de puntos críticos de biodiversidad global que sustentan los medios de vida de miles de millones de personas a nivel mundial. La gestión sostenible de estos ecosistemas figura en la Agenda 2030 de las Naciones Unidas para el Desarrollo Sostenible (NUDS, sf) bajo el Objetivo de Desarrollo Sostenible (ODS) 15.4. Por otro lado, el acceso a datos precisos, actualizados y de alta resolución espacial sobre LUC en países en vías de desarrollo es limitado (Medina Medina et al., 2024), dificultando crear políticas ambientales basadas en información real. Esta limitación afecta a muchos gobiernos y les impide tomar decisiones estratégicas para proteger y organizar el territorio de la cuenca.

La cuenca binacional Mayo Chinchipe forma parte de un importante corredor biológico transfronterizo andino amazónico de alta relevancia ecológica entre Perú y Ecuador, tiene una superficie total de 9,771.64 km² (Naturaleza y Cultura Internacional [NCI], 2024). Además, articula ecosistemas de páramo, bosque montano y vegetación xerofítica en elevaciones que van desde los 357 hasta los 3,950 msnm (CUIDAR, 2024). También integra áreas naturales protegidas (ANP) como el Santuario Nacional Tabaconas-Namballe y áreas de conservación regional (ACR) como los Páramos y Bosques Montanos de Jaén y Tabaconas, además del ACR Bosques del Chaupe Cunía y Chinchiquilla.

Esta investigación se justifica por la necesidad de elaborar un diagnóstico territorial mediante insumos satelitales recientes que orienten la toma de decisiones. La investigación integra antecedentes científicamente comprobados, fundamentos teóricos sólidos y una metodología moderna basada en teledetección, con el propósito de generar información actualizada que contribuya a la gestión sostenible de esta cuenca.

En síntesis, esta investigación no solo busca generar conocimiento científico sobre la distribución de LUC en la cuenca, sino también contribuir al desarrollo mediante herramientas prácticas que brinden resultados confiables. Los resultados obtenidos son de gran utilidad para organismos gubernamentales y no gubernamentales dedicados a implementar planes y políticas de conservación, al proporcionar información espacial actualizada que oriente la gestión integral de la cuenca. Se espera que este estudio marque un precedente en la aplicación de la teledetección para el manejo integral de cuencas en contextos similares.

El objetivo general de esta investigación fue determinar la distribución espacial y porcentual de las clases de LUC en la cuenca binacional Mayo Chinchipe, mediante el uso de imágenes Sentinel 2 y GEE durante el año 2024. Los objetivos específicos fueron:

- Realizar una clasificación supervisada de LUC usando imágenes de Sentinel 2, índices de vegetación y topográficos, empleando el algoritmo RF en la plataforma GEE
- Elaborar un mapa de distribución espacial y cuantificación de LUC de la cuenca binacional Mayo Chinchipe del año 2024, empleando SIG
- Analizar las implicancias ecosistémicas de la distribución espacial de la cobertura y uso de suelo presentes en el año 2024 en la cuenca binacional Mayo Chinchipe.

IV. REVISIÓN LITERARIA

4.1. Antecedentes

De Luca et al. (2022) desarrollaron una clasificación supervisada que integró datos de radar de apertura sintética (SAR) de Sentinel 1 y ópticos de Sentinel 2 para el mapeo de LUC en un área forestal mediterránea heterogénea. Las series temporales de SAR y bandas ópticas, tres índices ópticos y dos índices SAR, constituyeron el conjunto de datos. Todo el proceso se realizó utilizando datos de libre acceso y software y bibliotecas de código abierto ejecutados en lenguaje Python-script. También usó el algoritmo RF para entrenar y clasificar el conjunto de datos final. La precisión global alcanzó un 90.33 % y la integración de SAR la mejoró en un 2.53 % en comparación con la obtenida utilizando solo datos ópticos.

Loukika et al. (2021) examinaron el rendimiento de varias técnicas de aprendizaje automático como RF, Classification and Regression Trees (CART) y Support Vector Machine (SVM) en la clasificación de LUC en GEE, utilizando datos de reflectancia superficial Landsat 8 Nivel 1 y Sentinel 2 Nivel 1C. Además, usó el índice de agua de diferencia normalizada (NDWI) y el índice de vegetación de diferencia normalizada (NDVI), que son representativos de las masas de agua y de las características de la vegetación respectivamente. Obteniendo como resultado que el clasificador RF supera a los clasificadores SVM y CART en términos de precisión.

El estudio de Aghababaei et al. (2021) evaluó la clasificación de tipos de vegetación en un paisaje heterogéneo semiárido de Irán utilizando imágenes Landsat 8 en la plataforma GEE. Mediante el análisis de perfiles temporales de NDVI (2018 - 2020) y el clasificador RF, se comparó el uso de una imagen de fecha única (mayo 2018) frente a un conjunto multitemporal de imágenes óptimas. Los resultados demostraron que la clasificación multitemporal mejoró significativamente la precisión, alcanzando una exactitud global del 81 % y un coeficiente kappa del 0.74 frente al 64 % y 51 % de la imagen única. Concluyendo que el uso de series multitemporales, junto con plataformas de cómputo en la nube como GEE, es fundamental para discriminar tipos de

vegetación con respuestas espectrales similares, especialmente en ecosistemas áridos y heterogéneos.

Un estudio realizado por Stoyanov (2022) en el Parque Natural “Piedras Azules” al sureste de Bulgaria, pudo determinar con precisión la distribución espacial y la evaluación cuantitativa de la cobertura forestal integrando la Transformación Tasseled Cap (TCT) de imágenes Sentinel 2. El método de monitoreo forestal propuesto puede integrarse en la gestión forestal, la silvicultura y el inventario de recursos forestales.

En un estudio desarrollado por Arpitha et al. (2023) en el estado de Karnataka, India, evaluaron la eficiencia de tres algoritmos de aprendizaje automático RF, SVM y CART para la clasificación de LUC mediante la plataforma GEE, empleando imágenes multitemporales de Sentinel 2 y Landsat 8. Los resultados evidenciaron que el algoritmo RF alcanzó el mayor rendimiento clasificatorio en todas las temporalidades, con una precisión global (OA) superior al 95 % y un coeficiente Kappa de 0.924 para imágenes Sentinel 2, superando consistentemente a los modelos SVM y CART. En cuanto a la distribución de coberturas, el territorio estudiado estuvo dominado por tierras agrícolas, que representaron aproximadamente el 64 % de la superficie total, seguidas por las áreas forestales con cerca del 20 %.

Aziz et al. (2024) desarrollaron una investigación orientada a mejorar la estimación y monitoreo de la cobertura forestal en el distrito de Abbottabad, Pakistán. Para ello, emplearon imágenes multiespectrales de Sentinel 2, procesadas tanto en modalidad de imagen única como en composiciones temporales apiladas, aplicando dos algoritmos de aprendizaje automático: Red Neuronal Artificial (ANN) y RF. Los resultados evidenciaron que la integración de imágenes temporales de varias fechas mejoró considerablemente el rendimiento clasificatorio respecto al uso de imágenes individuales. El algoritmo ANN alcanzó una OA de validación del 97.75 % y un Kappa de 0.965, mientras que RF logró una OA del 96.98 % y Kappa de 0.954. En cuanto a la estimación de la cobertura forestal, ambos algoritmos coincidieron en el cálculo del 31 % del territorio como superficie boscosa. Los autores concluyeron que la combinación de datos satelitales de libre acceso con algoritmos de aprendizaje

automático constituye una estrategia eficiente y replicable para el monitoreo forestal en territorios de difícil acceso.

Pizarro et al. (2022) desarrollaron un método eficiente para la clasificación de LUC en la Reserva Paisajística Nor Yauyos-Cochas, ubicada en los Andes centrales del Perú, mediante el uso de GEE y algoritmos de aprendizaje automático. Utilizaron imágenes satelitales de Landsat 8 OLI. Metodológicamente, se emplearon 3601 píxeles de entrenamiento obtenidos a partir de bandas espectrales, índices espectrales (vegetación, agua, suelo, nieve y áreas quemadas) y variables topográficas como elevación, pendiente y orientación. Evaluaron seis algoritmos de aprendizaje automático: CART, RF, Gradient Tree Boosting (GTB), Minimum Distance (DM), Naive Bayes (NB) y SVM. Los resultados evidenciaron que la combinación de bandas espectrales e índices topográficos mejora significativamente la discriminación entre coberturas con firmas espectrales similares, alcanzándose el mejor desempeño con RF, con un índice Kappa de 0.81 y OA de 83.05 %, lo que indica una alta precisión en la clasificación.

En un estudio realizado por Barboza et al. (2024) en los bosques secos del Perú, se determinaron los cambios LUC en 2017 y 2021 utilizando la computación en nube y el algoritmo RF. La información generada contribuyó en gran medida a generar mapas LUC para un importante ecosistema obteniendo precisiones OA y Kappa superiores al 89 y 85 % respectivamente. La dinámica del LUC en el periodo de análisis reportó un aumento en las áreas de tierra desnuda y la dinámica de bosque seco abierto y denso, que podría estar condicionada por la temperatura y las precipitaciones.

El estudio de Sánchez et al. (2026) determinó la cantidad de LUC en la microcuenca Tumbillán, ubicada en la provincia de Jaén, región Cajamarca en el año 2024 utilizando la plataforma GEE, el algoritmo RF y la leyenda Corine Land Cover. Los resultados identificaron siete tipos de cobertura, predominando áreas sin o con escasa vegetación (29,8 %), vegetación arbustiva/herbácea (22,2 %) y cultivos permanentes (20,3 %), además de bosque abierto bajo (17,3 %), pastos (5,6 %), cultivos transitorios (3,0 %) y tejido urbano discontinuo (1,8 %). El estudio concluye que la expansión agrícola y ganadera ha fragmentado los

relictos forestales, afectando la captura e infiltración de agua, y resalta la necesidad de implementar sistemas agroforestales y manejo sostenible del territorio.

4.2. Marco teórico

Google Earth Engine: Es una plataforma basada en la nube para el análisis de datos científicos. Ofrece conjuntos de datos listos para usar y alojados en la nube, así como un amplio conjunto de servidores. Una característica que hace que Earth Engine sea especialmente atractivo es la capacidad de ejecutar grandes cálculos muy rápidamente distribuyéndolos entre un gran grupo de servidores. La API de Earth Engine permite utilizar de forma eficiente conjuntos de datos y cálculos alojados en la nube (Gandhi, 2024).

API de Earth Engine: Representa una manera de comunicación con los servidores de la plataforma Earth Engine. Esta API presenta un diseño innovador con la finalidad de evitar que los usuarios deban preocuparse por la forma en que el procesamiento se distribuye en un clúster de máquinas o cómo se integran los resultados obtenidos. En ese sentido, la API permite que los usuarios únicamente definan las tareas que desean ejecutar, mientras el sistema gestiona automáticamente los procesos internos. Esto facilita considerablemente la programación, ya que oculta los aspectos técnicos de implementación y, al mismo tiempo, convierte a GEE en una plataforma accesible incluso para personas con conocimientos limitados en programación.(Cardille et al., 2024).

JavaScript: La API de JavaScript de GEE se caracteriza por ser una de las más consolidadas y sencillas de utilizar para quienes se inician en el uso de la plataforma. GEE incorpora un “Editor de Código” en línea que posibilita trabajar directamente con la API JavaScript sin requerir procesos de instalación previos. Asimismo, este entorno ofrece diversas herramientas complementarias para visualizar resultados en mapas, almacenar scripts, consultar documentación, administrar tareas y realizar otras funciones de manera eficiente. La plataforma también cuenta con una opción de compartición de código mediante un solo clic, favoreciendo tanto la colaboración entre usuarios como la reproducibilidad de los procesos desarrollados. Adicionalmente, la API de JavaScript integra una

biblioteca de interfaz gráfica que facilita la creación de gráficos y aplicaciones web con un esfuerzo mínimo (Gandhi, 2024).

Teledetección: Es una herramienta empleada para obtener datos o imágenes en formato ráster, las cuales representan un registro detallado del espectro vinculado a las características físicas y la composición química de los materiales en la superficie terrestre. No obstante, el proceso de extraer información de estas imágenes depende completamente de la interpretación subjetiva, dependiendo del enfoque o área de aplicación de cada persona, se pueden obtener interpretaciones temáticas muy diversas de una misma imagen (Liu & Mason, 2016).

Las tecnologías de teledetección pueden ser muy útiles para numerosas tareas de conservación y gestión ambiental. Sin embargo, comprender sus limitaciones es tan importante como comprender sus beneficios. Si bien el uso adecuado de los datos de teledetección puede aumentar el conocimiento y ampliar la comprensión, su uso inadecuado puede resultar costoso y generar productos que inducen a error en lugar de informar (Horning et al., 2010).

Sistema de Información Geográfica: Ofrece capacidades de integrar la base de datos multisectorial y multinivel. Es un sistema de base de datos computarizado para captura, almacenamiento, recuperación, análisis y visualización de datos espaciales. Es una tecnología de uso general para manejar datos geográficos en forma digital y satisfacer las siguientes necesidades específicas (Reddy, 2008). Las disciplinas contribuyentes para la evolución de un SIG son la geografía, la cartografía, la teledetección, la topografía y la fotogrametría, la tecnología de la informática, las matemáticas y las estadísticas (Burrough & Masser, 1998).

Modelo de Elevación Digital: Constituye un recurso fundamental para llevar a cabo diversos análisis relacionados con el relieve terrestre, entre ellos los estudios de características geomorfológicas, los cuales resultan cruciales en múltiples tipos de investigaciones (Ibrahim et al., 2020). Un DEM se encuentra entre los recursos más importantes utilizados para cartografiar y extraer procesos hidrológicos, así como para delinear componentes terrestres relacionados con la gestión de recursos naturales (Reddy et al. 2018).

QGIS: Es un software GIS de código abierto conocido que se usa y reconoce ampliamente. Proporciona una interfaz unida a muchos otros programas relevantes de software GIS de código abierto, como SAGA, GDAL, Grass o Lastools (Menke et al. 2016). La última versión de QGIS está disponible en el sitio web de QGIS (www.qgis.org).

Índices de vegetación: Se desarrollaron principalmente para tener en cuenta las condiciones atmosféricas variables y eliminar la contribución del fondo del suelo al estimar las respuestas de la vegetación (Navulur, 2006). Se han utilizado ampliamente para estudios globales para monitorear los cambios en la vegetación y han sido efectivos en el mapeo de sequías, desertificación, fenología y deforestación en todo el mundo (Horning et al., 2010).

Transformación Tasseled Cap: Consiste en convertir los DN en diversas bandas espectrales en valores compuestos. Una de estas sumas ponderadas mide aproximadamente el brillo de cada píxel de la escena. Los demás valores compuestos son combinaciones lineales de los valores de los canales individuales, pero algunos pesos son negativos y otros positivos. Uno de estos valores compuestos representa el grado de verdor de los píxeles, y otro representa el grado de amarilleamiento de la vegetación o, quizás, la humedad del suelo (Navulur, 2006).

Cobertura terrestre: Está referida a las cubiertas biofísicas de la tierra. Las zonas sin una cubierta específica, como las zonas de roca desnuda o suelo desnudo, también se consideran cubiertas terrestres (García-Álvarez et al., 2022). En los últimos años, el término "cobertura del suelo" se ha utilizado comúnmente junto con el término "uso del suelo". Sin embargo, no son sinónimos. El uso del suelo incluye todo aquello para lo que los residentes del país utilizan la tierra, desde granjas hasta campos de golf, viviendas, restaurantes, hospitales y cementerios. La cobertura del suelo se refiere más a la vegetación y las construcciones artificiales que cubren la superficie terrestre (Lindgren, 1985).

Uso del Suelo: Se entiende por uso de suelo a las actividades realizadas por los seres humanos sobre la superficie terrestre o en una capa específica del territorio. Una capa terrestre puede ser destinada a uno o varios usos, o incluso carecer de

ellos (García-Álvarez et al., 2022). Los datos de LUC constituyen una fuente clave de información para una amplia variedad de usuarios provenientes de diferentes campos y disciplinas científicas. Estos datos ofrecen una visión integral de las distintas coberturas del suelo, como la vegetación, áreas agrícolas, rocas, cuerpos de agua y superficies artificiales, así como su evolución a lo largo del tiempo (García-Álvarez et al., 2022).

Los usos actuales del suelo, debido a su fuerte influencia en cómo se utilizará la tierra en el futuro, son un elemento crucial en el desarrollo de un plan de uso o desarrollo del suelo. Los datos sobre el cambio en el uso del suelo son necesarios tanto para desarrollar políticas de uso del suelo como para monitorear su efectividad (Lindgren, 1985).

Cuenca hidrográfica: Son unidades hidrológicas definidas como el área que recoge el agua dentro de una divisoria de aguas (divisoria es la línea que separa las cuencas hidrográficas vecinas). Todas las cuencas de todos los afluentes de un río se agrupan para formar una cuenca hidrográfica (Schmutz & Sendzimir, 2018). Siendo una componente clave del ciclo hidrológico global, desempeña un papel crucial tanto en los ecosistemas naturales como en las actividades humanas. Asimismo, ante los desafíos crecientes del cambio climático y la necesidad de garantizar la seguridad hídrica, la comprensión y gestión eficiente de las cuencas resulta hoy en día más relevante que nunca (J. Wang et al., 2023).

Sentinel: Los satélites Sentinel, desarrollados en el marco del programa Copernicus de la Agencia Espacial Europea (ESA), proporcionan imágenes con alta resolución espacial, espectral y temporal. Entre ellos destaca el Sentinel-2, equipado con un sensor multiespectral de 13 bandas que cubren regiones del espectro visible, el infrarrojo cercano y el infrarrojo de onda corta. Gracias a estas características, este satélite resulta especialmente útil para aplicaciones relacionadas con el seguimiento y análisis de áreas agrícolas, forestales y urbanas (De Fioravante et al., 2021).

Clasificación supervisada: Es una técnica clave en el análisis de datos y teledetección que se basa en entrenar un modelo utilizando datos etiquetados previamente. Este proceso involucra asignar etiquetas conocidas (clases) a un conjunto de datos de entrenamiento y luego aplicar este modelo a datos sin

clasificar para predecir las clases correspondientes. Este enfoque permite una alta precisión al detectar patrones complejos en los datos, siempre que el conjunto de entrenamiento sea representativo y esté correctamente etiquetado (Amancio et al., 2014)

Random Forest: Es un enfoque de aprendizaje supervisado empleado para tareas de clasificación y regresión. Este método se fundamenta en un conjunto de árboles de decisión, donde cada árbol se construye a partir de un subconjunto aleatorio de los datos de entrenamiento y sus características. El resultado final se obtiene al combinar las predicciones de los árboles, generalmente mediante votación (en clasificación) o promediado (en regresión). Este enfoque mejora la precisión y reduce el riesgo de sobreajuste, siendo especialmente útil en problemas de alta dimensionalidad. (Breiman, 2001)

Imagen satelital multiespectral: Las imágenes satelitales obtenidas por teledetección continúan aumentando en resolución espacial y temporal y se están convirtiendo en un insumo bruto cada vez más poderoso a partir del cual se pueden crear mapas de diferentes tipos de usos del suelo (S. Wang et al., 2019). La correcta aplicación de la clasificación de imágenes multiespectrales facilita la obtención de información para una adecuada clasificación de LUC (Amini et al., 2022).

Las propiedades de los datos obtenidos a partir de imágenes digitales que resultan fundamentales para su procesamiento y análisis comprenden el número y la disposición de las mediciones espectrales, conocidas como bandas o canales, así como la resolución espacial, determinada por el tamaño del píxel. Del mismo modo, la resolución radiométrica constituye un aspecto esencial, ya que define el rango y la cantidad de niveles discretos de brillo que pueden diferenciarse en una imagen. Esta propiedad se denomina en ocasiones rango dinámico, se encuentra vinculada con la relación señal-ruido de los detectores empleados. Generalmente, la resolución radiométrica se representa mediante la cantidad de bits necesarios para expresar el rango disponible de valores de brillo (Richards, 2013).

13

Precisión global: La precisión global indica la proporción de datos de referencia que se clasificaron correctamente, se calcula como el número total de puntos identificados correctamente dividido por el número total de píxeles de la muestra (Cardille et al., 2024). Su fórmula es la siguiente:

$$\text{Precisión general} = \frac{(TP + TN)}{\text{Tamaño de muestra}}$$

Donde:

TP: clasificado como positivo, y la clase real es positiva

TN: clasificados como negativos, y la clase real es negativa.

Corine Land Cover (CLC): es una iniciativa desarrollada por la Unión Europea desde 1985, diseñada para proporcionar un inventario armonizado de la cobertura y el uso del suelo en toda Europa. Este sistema utiliza datos satelitales para categorizar el territorio europeo en 44 clases temáticas de cobertura y uso del suelo. Las categorías incluyen bosques, áreas agrícolas, superficies artificiales, y ecosistemas acuáticos, entre otros. La clasificación se basa en unidades mínimas de mapeo de 25 hectáreas para fenómenos areales y 100 metros para fenómenos lineales, lo que garantiza un alto nivel de estandarización en la representación espacial (Stara & Halounova, 2022).

El CLC se actualiza cada seis años (las más recientes en 2012 y 2018) y permite analizar cambios en la cobertura de la tierra con un enfoque en áreas de al menos 5 hectáreas. Es ampliamente utilizado en estudios de planificación territorial, evaluación ambiental, gestión de emergencias y monitoreo del cambio climático debido a su precisión y consistencia temática (Stara & Halounova, 2022).

Coefficiente Kappa: Es un indicador del desempeño del clasificador basado en la matriz de error, diseñado para evitar posibles sesgos derivados de la coincidencia aleatoria entre los resultados del clasificador y los datos de referencia. (Richards, 2013). Este coeficiente evalúa el rendimiento de la clasificación en comparación con el azar. El valor del coeficiente kappa puede oscilar entre -1 y 1, un valor negativo indica que la clasificación es peor de lo que habría sido una asignación aleatoria de categorías; un valor de 0 indica que

3

la clasificación no es mejor o peor que aleatoria; y un valor positivo indica que la clasificación es mejor que aleatoria. (Cardille et al., 2024)

$$K = \frac{(\text{probabilidad de clasificación correcta}) - (\text{probabilidad de coincidencia fortuita})}{1 - (\text{probabilidad de acuerdo fortuito})}$$

9

V. MATERIALES Y MÉTODOS

5.1. Materiales

5.1.1. Equipos

- Sistema de Posicionamiento Global (GPS) Garmin 68S
- Cámara fotográfica Nikon
- Laptop Asus Vivobook 15

5.1.2. Software

- QGIS Versión 3.40
- RStudio 4.3.2
- MapSource

5.1.3. Materiales de oficina

- Lapiceros
- Libreta de apuntes

5.1.4. Material cartográfico digital

- Imágenes satelitales multiespectrales de Sentinel 2
- Modelo Digital de Elevación de ALOS DSM.
- Shapefiles de Caseríos y Centros Poblados del Instituto Nacional de Estadística e Informática (INEI).
- Shapefiles de límites parroquiales, cantonales y provinciales de la Secretaría Técnica del Comité Nacional de Límites Internos (CONALI).
- Shapefiles de límites distritales, provinciales, departamentales y nacionales del Instituto Geográfico Nacional (IGN).
- Mapa Nacional de cobertura vegetal del Ministerio del Ambiente (MINAM).

5.2. Metodología

5.2.1. Ubicación del área de estudio

La cuenca binacional Mayo Chinchipe forma parte de la vertiente del Atlántico, hacia la cual se dirigen sus aguas tras recorrer los ríos Marañón y Amazonas. Con una superficie de 9,771.64 km² (de los cuales el 67 % se localiza en territorio peruano y el 33 % en territorio ecuatoriano), esta cuenca representa una de las principales conexiones del bosque amazónico entre ambos países. Específicamente, abarca 3,148 km² en Ecuador y 6,539 km² en Perú (NCI, 2024). En el lado peruano, la cuenca se extiende por las provincias de Jaén, San Ignacio de la región Cajamarca y una parte de Huancabamba en Piura; mientras que en territorio ecuatoriano abarca gran parte de los cantones Chinchipe y Palanda. (Anexo 1).

5.2.2. Delimitación del área de estudio

La cuenca binacional Mayo Chinchipe se delimitó mediante las herramientas de QGIS 3.40 y se tuvo como punto de desembocadura la unión del río Chinchipe al río Marañón. El archivo shapefile resultante se importó al apartado “Assets” de la plataforma GEE.

5.2.3. Obtención de datos

Se realizó desde el catálogo de datos de Copernicus en la plataforma GEE, este conjunto de datos es de acceso público (Tesfaye et al., 2024). Se usaron imágenes de Sentinel 2 como fuente principal de datos para esta investigación, el instrumento multiespectral (MSI) tiene una resolución espacial de hasta 10 metros y contiene 13 bandas multiespectrales (Zhao et al., 2024). Las bandas usadas para este estudio se detallan en la tabla 1. El Modelo Digital de Elevación se incorporó desde el catálogo de datos de “ALOS DSM: Global 30m v3.2” en la plataforma GEE y fue recortado a través de la función “clip”, el resultado fue un DEM de toda la cuenca.

Tabla 1

Especificaciones de las bandas espectrales de Sentinel 2 usadas en este estudio

Banda	Descripción	Longitud de onda central (*)	Resolución espacial (m)	Anchura de banda
B2	Blue	0.496 μm	10	0.066 μm
B3	Green	0.560 μm	10	0.036 μm
B4	Red	0.664 μm	10	0.031 μm
B5	Red Edge	0.705 μm	20	0.014 μm
B8	NIR	0.843 μm	10	0.106 μm
B11	SWIR 1	1.613 μm	20	0.091 μm
B12	SWIR 2	2.200 μm	20	0.174 μm

Fuente: Elaboración propia

Nota. (*) Longitud de onda central nominal en el ancho completo a la mitad del máximo.

5.2.4. Preprocesamiento del mosaico

Se usó una función Fmask (Zhu et al., 2015) obteniendo un producto con el menor número de píxeles nublados y fue verificado con una prueba visual final, también se aplicó un filtro de rango de fechas desde junio a diciembre del 2024, obteniendo un mosaico limpio de nubes.

Las imágenes compuestas utilizadas se ensamblaron a través de un reductor mediano basado en herramientas GEE, para utilizar el valor de píxel más frecuente de la imagen (Pizarro et al., 2022).

Se realizó una calibración radiométrica, corrección atmosférica y eliminación de ruidos en las imágenes (Zhao et al., 2024). Este preprocesamiento se realizó apoyándose en funciones incorporadas en GEE. El resultado de este procedimiento fue un mosaico de imágenes limpias y corregidas de toda la cuenca de estudio.

5.2.5. Generación de índices espectrales, variables topográficas y Transformación Tasseled Cap (TCT).

Se generó el índice de vegetación de diferencia normalizada (NDVI), índice de suelo desnudo (BSI), índice de diferencia normalizada del agua (NDWI),

índice de vegetación mejorado (EVI), índice de diferencia normalizada de construcciones (NDBI) e índice de vegetación ajustado al suelo (SAVI) a partir de las bandas espectrales del mosaico compuesto. Las variables topográficas pendiente, elevación y aspecto se generaron a partir del DEM y sirvieron para mejorar la clasificación de LUC. Estos índices, que se detallan en la tabla 2, fueron usados como variables de predicción. También se generó el índice TCT que consta de brillo, verdor y humedad.

Tabla 2

Índices espectrales usados en la clasificación

Índice	Formula	Referencia
NDVI	$\frac{(NIR - RED)}{(NIR + RED)}$	(Tucker, s. f.)
NDWI	$\frac{(SWIR - NIR)}{(SWIR + NIR)}$	(McFeeters, 1996)
NDBI	$\frac{(SWIR1 - NIR)}{(SWIR1 + NIR)}$	(Zha et al., 2003)
BSI	$\frac{(RED + SWIR1) - (NIR + BLUE)}{(RED + SWIR1) + (NIR + BLUE)}$	(Rasul et al., 2018)
MSAVI	$\frac{(2 * NIR + 1 - \sqrt{(2 * NIR + 1)^2 - 8 * (NIR - RED)})}{2}$	(Qi et al., 1994)
EVI	$2.5 * \frac{(NIR - RED)}{(NIR + 6 * RED - 7.5 * BLUE + 0.5)}$	(Huete et al., 2002)

Fuente: Elaboración propia

5.2.6. Selección de áreas de muestreo y observación en campo

Se recopilaban datos sobre la composición de la vegetación dentro de las zonas accesibles de la cuenca, esta información fue georreferenciada con un equipo GPS portátil y se usó una cámara fotográfica para tomar imágenes de las coberturas existentes. También se usó el Mapa Nacional de Cobertura Vegetal elaborado por el Ministerio del Ambiente (MINAM, 2015) para identificar clases de LUC. Las clases identificadas y distribuidas en toda la cuenca se detallan en la Tabla 3 de los resultados.

En espacios inaccesibles se usaron imágenes satelitales de Google Earth para delimitar áreas de referencia a través de la fotointerpretación visual. También

se recopilaron fotografías georreferenciadas tomadas por guardabosques de las áreas de protección existentes en el ámbito de la cuenca. La identificación de clases de LUC se hizo en base a la cobertura dominante en cada área. De todas las áreas seleccionadas el 60 % fueron tomadas en campo, mientras que el 40 % a través de Google Earth. Obteniendo en total 666 polígonos. Finalizado este proceso, la información recopilada se incorporó al apartado “Assets” de la plataforma GEE.

5.2.7. Segmentación de datos

Se crearon puntos aleatorios dentro de las 666 áreas de muestreo, mediante la función “randomColumn” en GEE. La división de los puntos fue de 70 % para el entrenamiento del clasificador y 30 % para la validación temática (Cardille et al., 2024), de tal forma, el clasificador pudo predecir los datos que no se le han mostrado antes (datos de validación).

5.2.8. Clasificación mediante RF

La clasificación de LUC se realizó usando los puntos de entrenamiento, la selección de este clasificador se debe a sus altas precisiones en la clasificación (Breiman, 2001), este algoritmo se encuentra integrado en el apartado “clasificadores” de GEE. Las variables predictoras usadas fueron: bandas espectrales, índices espectrales, variables topográficas y TCT, como resultado se obtuvo el nivel de importancia de cada variable. El número de árboles del clasificador afecta la precisión final. Nicolau et al. (2024) demostraron que con 70 árboles se alcanza la mejor precisión final. Por lo que en este estudio se usó la misma cantidad de árboles.

5.2.9. Corrección post clasificación

Los huecos presentes en el mosaico de imágenes producto del filtro de enmascaramiento de nubes, y que generan vacíos de datos, fueron rellenados mediante la función “neighborhood” y “kernel” en la plataforma GEE. Posterior a ello se exportó el resultado en formato vector, y se realizó una representación final en el software QGIS 3.40.

5.2.10. Cálculo de métricas de precisión

Se utilizó una matriz de confusión para examinar el rendimiento del clasificador. La matriz de confusión, también llamada "matriz de error" por Stehman (1997) resumió las métricas clave de precisión que se utilizaron para evaluar los productos derivados de datos obtenidos por teledetección. Este proceso se realizó en GEE a través de la función "ConfusionMatrix". Además, se calcularon la precisión general (OA) (ecuación 1), el coeficiente Kappa (Pontius & Millones, 2011) (ecuación 2), la precisión del usuario (UA) y la precisión del productor (PA) (ecuaciones 3 y 4 respectivamente).

$$OA = \frac{\text{número de muestras clasificadas correctamente}}{\text{número de muestras totales}} \dots \dots (1)$$

$$Kappa = \frac{\text{precisión general} - \text{acuerdo de probabilidad estimada}}{1 - \text{acuerdo de probabilidad estimada}} \dots (2)$$

$$UA = \frac{\text{numero de muestras correctamente clasificadas en cada clase}}{\text{número de muestras clasificadas en cada clase}} \dots (3)$$

$$PA = \frac{\text{numero de muestras correctamente clasificadas en cada clase}}{\text{número de muestras de datos de referencia de cada clase}} \dots (4)$$

Utilizamos estas métricas para evaluar la calidad del mapa de LUC resultante. El OA determina la eficiencia general de un algoritmo y se mide dividiendo el número total de muestras clasificadas correctamente por el número total de muestras de prueba. El Índice Kappa indica el grado de concordancia entre los datos reales del terreno y los valores predichos, mientras que PA mide qué tan bien se ha clasificado un píxel e incluye el error de omisión (la proporción de características observadas en el terreno que se excluyen erróneamente de una clase). La UA mide la confiabilidad del mapa, informando qué tan bien el mapa representa lo que hay en el suelo e incluye el error de comisión que se refiere a píxeles incluidos erróneamente en una clase

5.2.11. Elaboración del mapa de LUC

Se realizó usando las herramientas de edición del programa QGIS 3.4, se realizó la presentación de la información espacial obtenida a partir de GEE, estos datos fueron vectorizados y posteriormente cuantificados usando la calculadora de campos. Se usó el software R Studio 4.3.2 para elaborar los cuadros y gráficos de los resultados.

5.2.12. Análisis de implicancias ambientales

Los resultados de distribución de LUC se analizaron desde un enfoque ambiental, mediante la superposición con shapefiles del Santuario Nacional Tabaconas Namballe (SNTN), Área de conservación Regional Bosques El Chaupe Cunía y Chinchiquilla (BCHCCH), Área de Conservación Regional Páramos y Bosques montanos de Jaén y Tabaconas (PBMJT). Además de los Parques Nacionales de Podocarpus (PNP) y Yacuri (PNY) en Ecuador.

También se hizo un análisis usando un mapa de pendientes de la cuenca clasificado en base al Ministerio de Desarrollo Agrario y Riego (MIDAGRI, 2022), haciendo una superposición de LUC en pendientes con valores mayor al 75 %. Estos análisis permitieron identificar espacios donde el uso del suelo está generando riesgos de degradación, pérdida de biodiversidad y servicios ecosistémicos.

VI. RESULTADOS Y DISCUSIÓN

6.1. Resultados

6.1.1. Determinación y distribución espacial de LUC

Se determinaron nueve clases para el año 2024 (el panel fotográfico de estas clases se muestra en el Anexo 2), estas clases identificadas en la cuenca binacional Mayo Chinchipe se detallan en la Tabla 3:

Tabla 3
Descripción de clases de LUC encontradas en la cuenca.

Cobertura terrestre	Descripción
Cultivos permanentes (CPE)	Áreas compuestas generalmente por monocultivos de café (<i>Coffea arabica</i>) y en algunos casos complementados con sistemas agroforestales (SAF), estos SAF consisten en café asociado a guabas (<i>Inga edulis</i>), eucalipto (<i>Eucalyptus</i> sp), romerillo (<i>Podocarpus rospigliosi</i>). Además de cultivos de cacao (<i>Theobroma cacao</i>) y en menor proporción cultivos de cítricos como limón y naranjas.
Cultivos transitorios (CTR)	Áreas compuestas principalmente por cultivos de arroz (<i>Oryza sativa</i>), maíz (<i>Zea mays</i>), yuca (<i>Manihot esculenta</i>), plátano (<i>Musa paradisiaca</i>) y productos de pan llevar ubicadas casi en su totalidad en la parte baja de la cuenca con pendientes menores a 30 grados.
Páramo (PAR)	Estos espacios son colchones acuíferos ubicados en elevaciones mayores a 3,000 metros y están compuestos por herbazales naturales. El paisaje típico del páramo se distingue por el predominio de gramíneas y especies herbáceas que se desarrollan en ambientes con drenaje deficiente, donde son frecuentes los lodazales y pequeñas acumulaciones temporales de agua. Los suelos presentan elevados niveles de humedad y suelen encontrarse cubiertos por líquenes y musgos; sin embargo, en las zonas de menor altitud permanecen inundados de manera temporal. En las áreas planas del relieve sobresale la presencia de la “chamiza” <i>Neurolepis aristata</i> (Poaceae), especie reconocida por sus extensas hojas basales que otorgan al paisaje el aspecto de pajonal característico de los

páramos. Asimismo, dentro de las Poáceas presentes en este ecosistema también destacan representantes de los géneros Festuca, Calamagrostis y Chusquea.

Bosque natural (BOS)

Es un ecosistema que se encuentra distribuido en gran parte en la cabecera de cuenca. En el bosque montano destacan los géneros Escallonia, Podocarpus y Clusia. De igual manera, los bosques que permanecen aislados o insularizados favorecen la formación de microclimas que contribuyen a su conservación y permanencia. En estas coberturas vegetales sobresalen géneros como Vaccinium, Miconia y Gynoxys, además de una notable abundancia de plantas epífitas, entre las que destacan orquídeas, bromelias, helechos y musgos. Por otro lado, en los bosques secos es frecuente la presencia de especies pertenecientes a los géneros Cordia y Acacia. Dentro de las principales categorías de bosques presentes en estas zonas se identifican el bosque siempre verde montano bajo, el bosque siempre verde montano alto, el bosque montano de neblina, el bosque secundario o intervenido y el bosque montano de Yunga.

Cuerpos de agua (AGU)

Están representados por ríos y quebradas con un ancho de cauce mayor a 10 metros que fácilmente pueden ser detectadas por el sensor. También están incluidas lagunas existentes en el páramo altoandino. Dentro de los que se pueden reconocer mediante RF son los ríos Tabaconas, San José de Lourdes, Canchis y Chinchipe.

Suelo desnudo y con escasa vegetación (SDE)

Es la parte de la cuenca que por distintos factores (deslizamientos o intervención antrópica) no presentan ninguna cobertura, y generalmente están rodeadas por vegetación de tallos cortos de forma muy dispersa.

Vegetación herbácea y arbustiva (VAH)

Esta cobertura vegetal se localiza en los bosques estacionalmente secos del Maraón y se distingue por el predominio de comunidades arbóreas caducifolias, acompañadas en el estrato inferior por especies herbáceas de comportamiento estacional. Asimismo, las cactáceas de porte arbóreo constituyen un componente representativo de estos ecosistemas, debido a su abundancia y alto grado de endemismo.

Hasta la actualidad, estas áreas no han experimentado una intervención antrópica considerable, situación que se atribuye principalmente a la baja productividad de sus suelos y a ciertas limitaciones ambientales, entre ellas la escasa precipitación característica de la zona.

Tejido urbano (URB)

Representado por las edificaciones en ciudades, caseríos y centros poblados, entre los espacios que más resaltan se encuentran la ciudad de San Ignacio, Chirinos, La Coipa y Tabaconas.

Pasturas (PAS)

Estas pasturas están dominadas por especies de gramíneas (*Pennisetum purpureum*) y leguminosas introducidas, utilizados con fines pecuarios. En otros casos también están presentes de manera natural, es decir, es un espacio no intervenido por poblaciones locales.

Los pastos cultivados están distribuidos en toda la cuenca, principalmente en zonas contiguas de los bosques nativos, siendo esta actividad una de las principales causas de la pérdida de los bosques en las últimas décadas.

La distribución espacial de LUC se detalla en la tabla 4:

Tabla 4

Distribución de LUC en la parte alta, media y baja de la cuenca.

Parte	Descripción de LUC
Alta	Se encuentra cubierta por páramos y rodeados por bosques naturales. Comprende elevaciones desde los 2400 a 3950 msnm, del lado peruano estos ecosistemas se encuentran las partes altas de los distritos de Tabaconas, Namballe y gran parte de El Carmen de la Frontera en Huancabamba, mientras que en Ecuador están presentes en las parroquias de Valladolid, Palanda, El Porvenir del Carmen y San Andrés. En los páramos altoandinos se forman lagunas que son reguladoras de agua de ríos como el Tabaconas y Canchis, y en Ecuador los ríos Palanda y Numbala. En estas áreas predominan los bosques montanos que se caracterizan por tener árboles de estratos mayores que superan los 25 metros de altura en algunos casos y por mantenerse constantemente cubiertos por neblina. En esta parte de la cuenca también existen pastos, que refleja una alta actividad ganadera.
Media	Esta parte de la cuenca se encuentra entre los 1,500 a 2,400 msnm, está cubierta por cultivos permanentes, entre los que más destacan son el café, cacao y cítricos en menor cantidad. Además, están cubiertos por pasturas, pequeños tejidos urbanos y vegetación arbustiva y herbácea. En Ecuador comprende las parroquias de La Canela, San Francisco de Vergel y las partes altas de Zumba y Chito. En Perú los distritos de San José de Lourdes y las partes altas de Huarango, San José del Alto y La Coipa presentan una importante presencia de bosques naturales que a su vez están rodeados por pasturas producto de la expansión pecuaria en la zona. En esta parte de la cuenca también están presentes los bosques estacionalmente secos del Marañón.

En esta parte de la cuenca predominan los cultivos transitorios como el arroz, maíz yuca y productos de cortos periodos de cosecha. Además, la parte baja de la cuenca está cubierta por vegetación herbácea y arbustiva y en elevaciones de 357 a 800 msnm existen áreas desnudas y con escasa vegetación, esto por la ausencia de precipitaciones y climas cálidos. Ecosistémicamente estas zonas integran los bosques secos del Marañón.

Baja Los espacios dedicados a los cultivos transitorios, principalmente el arroz, se encuentran en los valles de los distritos de Bellavista, Santa Rosa y Chirinos. En ambas márgenes del río Chinchipe desde la altura del distrito de San Ignacio pasando por San José de Lourdes y Huarango. También existen cultivos transitorios en ambas márgenes del Río Tabaconas desde el Centro Poblado Cochalán hasta Tamborapa. Del lado ecuatoriano están las parroquias de Pucapamba, El Chorro, La Chonta, Chito y parte de Zumba donde las coberturas predominantes son los cultivos permanentes, pasturas y vegetación arbustiva y herbácea. La presencia de bosques es muy escasa en estas parroquias, y en general en toda la parte baja de la cuenca.

Fuente: Elaboración propia

6.1.2. Clasificación supervisada

6.1.2.1. Validación temática

En la matriz de confusión que se muestra en la Tabla 5, los elementos de la diagonal indican el número de muestras para las cuales las predicciones coinciden con los datos de referencia. Los elementos fuera de la diagonal en filas y columnas capturan errores de comisión y omisión respectivamente.

Los resultados mostraron que OA para RF fue de 96.5 %, mientras que el Kc obtuvo 0.95, estos resultados se detallan en la tabla 6.

Tabla 5
Matriz de confusión de la clasificación

	CPE	BOS	VAH	PAR	CTR	PAS	URB	AGU	SDE	Total	PA (%)	UA (%)
CPE	508	26	10	0	9	11	2	0	13	579	87.737	95.489
BOS	18	2,369	45	2	6	6	0	0	6	2,452	96.615	96.852
VAH	2	19	2,524	0	1	16	0	0	21	2,583	97.716	95.897
PAR	0	1	0	831	0	0	5	0	5	842	98.694	99.76
CTR	0	0	11	0	1,601	0	0	0	27	1,639	97.682	96.33
PAS	1	22	3	0	0	995	0	0	4	1,025	97.073	95.95
URB	0	1	2	0	13	5	1,531	0	89	1,641	93.297	97.33
AGU	0	4	5	0	6	0	1	691	22	729	94.787	98.714
SDE	3	4	32	0	26	4	34	9	4,238	4,350	97.425	95.774
Total	532	2,446	2,632	833	1,662	1,037	1,573	700	4,425			

Fuente: Elaboración propia

Tabla 6
Valores de las métricas de precisión

Combinación	Métrica	valor
Bandas espectrales + índices espectrales + variables topográficas + TCT	Precisión General	96.5 %
	Coeficiente Kappa	0.95


Fuente: Elaboración propia

6.1.2.2.Importancia de variables

El gráfico 1 muestra que la elevación, pendiente y aspecto fueron las más importantes, seguidas por las bandas espectrales, entre las que resaltan las bandas 2, 3, 5 y 11 de Sentinel 2. Por parte de TCT, el que más sobresalió fue el verdor. Los índices espectrales más importantes fueron el BSI y EVI. Lo que las convierte en las variables de RF con los efectos más altos.

Gráfico 1

Importancia de variables en la clasificación.




6.1.2.3. Análisis de separabilidad espectral

La cuenca binacional Mayo Chinchipe presenta un paisaje heterogéneo, se ha considerado que la distancia Jefferies Matusita tiene niveles aceptables para la separabilidad en las áreas de entrenamiento. En general, la separabilidad de clases fue adecuada y proporcionó una clasificación bastante precisa.

El gráfico 2 muestra que las coberturas con mejor separabilidad son los cuerpos de agua y el bosque natural, mientras que las clases con menos separabilidad son los suelos desnudos con escasa vegetación frente a vegetación herbácea arbustiva, cascós urbanos, páramo, pasturas y cultivos transitorios. Una solución para mejorar la separabilidad entre coberturas fue aumentar las áreas de entrenamiento de aquellas clases con un bajo índice de separabilidad.

Gráfico 2

Matriz de separabilidad espectral entre clases de LUC.



Nota. La matriz muestra la separabilidad espectral (JM) entre las nueve clases de LUC. Cada celda muestra el grado de separabilidad entre dos clases. La barra lateral indica valores de separabilidad entre 0 y 2, donde el azul oscuro representa una muy baja separabilidad y las clases son prácticamente indistinguibles. El verde muestra una separabilidad media, es decir existe cierta confusión entre clases. El color amarillo claro muestra buena separabilidad donde las clases son diferenciables. El color crema muy claro muestra alta separabilidad, indicando clases claramente diferenciadas.

6.1.3. Mapeo y cuantificación de LUC

El mapa final de LUC se muestra en el Anexo 3 y muestra la distribución espacial de las clases de LUC encontradas en la cuenca. En las clases destacan los cultivos permanentes, bosque natural, vegetación arbustiva y herbácea, páramo, cultivos transitorios, pasturas, urbano, cuerpos de agua y por último suelo desnudo y con escasa vegetación, con una cantidad que se detalla en la tabla 7 y gráfico 3.

Tabla 7


Cuantificación de clases de LUC encontradas en la cuenca.

Número	Código	Cobertura	Área (km ²)	Porcentaje (%)
1	CPE	Cultivo permanente	1,061.44	10.86
2	BOS	Bosque natural	4,985.41	51.02
3	VAH	Vegetación arbustiva y herbácea	1,364.10	13.96
4	PAR	Páramo	365.93	3.74
5	CTR	Cultivo transitorio	113.53	1.16
6	PAS	Pasturas	1,156.97	11.84
7	URB	Urbano	19.35	0.20
8	AGU	Cuerpos de agua	24.27	0.25
9	SDE	Suelo desnudo y con escasa vegetación	680.64	6.97
Total			9,771.64	100

Fuente: Elaboración propia

Gráfico 3

Cuantificación de clases de LUC.



6.1.4. Análisis de implicancias ambientales

La sobreposición del mapa de pendientes (Anexo 4) con el mapa de LUC, indica una importante presencia de cultivos permanentes, suelo desnudo y con escasa vegetación, pasturas y vegetación herbácea y arbustiva en lugares

con pendientes por encima del 75 %, principalmente en los distritos de San José del Alto, La Coipa, Chirinos, San Ignacio, Tabaconas, Carmen de la Frontera, Namballe y Huarango, y en las parroquias de Chito, Zumba, Palanda, Valladolid, El Porvenir del Carmen y San Francisco de Vergel. La cuantificación de las clases de LUC en pendientes mayores al 75 % se detalla en la Tabla 8. El mapa con la distribución de LUC en pendientes superiores al 75 % se muestra en el Anexo 5.

Tabla 8

Cuantificación de clases de LUC en pendientes mayores a 75 %.

Código	Cobertura	Área (km ²)
CPE	Cultivo permanente	95.41
VAH	Vegetación arbustiva y herbácea	171.02
SDE	Suelo desnudo y con escasa vegetación	104.99
PAS	Pasturas	206.43
URB	Urbano	0.06
CTR	Cultivo transitorio	0.15
Total		578.06

Fuente: Elaboración propia

Desde otro enfoque, a partir de los espacios de conservación existentes, la cuantificación del recorte de las clases de LUC en el Parque Nacional de Podocarpus (PNP), Parque Nacional Yacuri (PNY), Santuario Nacional Tabaconas Namballe (SNTN), ACR Páramos y Bosques Montanos de Jaén y Tabaconas (PBMJT) y el ACR Bosques del Chaupe, Cunía y Chinchiquilla (BCHCCH) se detallan en la Tabla 9 y gráfico 4, los mapas resultantes se muestran en los anexos 6, 7, 8, 9 y 10 respectivamente.

Tabla 9

Cuantificación de LUC en espacios de conservación dentro de la cuenca.


Clase de LUC	Extensión (ha)				
	BCHCCH	PBMJT *	PNP *	PNY *	SNTN
CPE	1,391.55	278.29	273.04	123.72	152.74
BOS	17,946.79	10,858.85	35,489.58	21,099.10	25,175.78
VAH	268.82	258.89	175.66	129.03	183.26
PAR	58.17	536.55	2,804.55	15,047.71	5,904.15
CTR	3.74	0.60	1.41	1.42	0.96
PAS	2,116.18	780.20	584.25	153.24	534.82
URB	2.04	0.19	1.11	0.59	0.03
AGU	4.09	2.38	53.47	81.28	82.21
SDE	77.50	110.07	141.33	177.22	83.91
Total	21,868.88	12,826.03	39,524.40	36,813.31	32,117.85

Fuente: Elaboración propia

Nota. (*) Se calculó solo el área que se encuentra dentro del territorio de la cuenca.

Gráfico 4

Distribución de LUC por Área Natural Protegida



Nota. Las gráficas muestran la distribución en hectáreas de las clases de LUC en las ANP Y ACR que se encuentran en el ámbito de la cuenca. Para los casos de PBMJT, PNP, PNY se calculó solo el área que se encuentra dentro de la cuenca.

6.2. Discusión

- Los resultados del presente estudio demuestran que es factible utilizar la plataforma GEE de acceso abierto para mapear las coberturas terrestres en ecosistemas andino-amazónicos complejos, utilizando el clasificador de aprendizaje automático RF, como lo consiguieron también (Pizarro et al., 2022) en la Reserva Paisajística Nor Yauyos Cochas, (Barboza et al., 2024) en los bosques secos del norte del Perú y (Stoyanov, 2022) en el parque natural “Piedras Azules” con métricas de precisión aceptables. Las nueve categorías de LUC encontradas reflejan una marcada heterogeneidad ecológica, condicionada principalmente por la existencia de diversos pisos altitudinales. En elevaciones por encima de los 3,100 msnm predominan los páramos al lado occidental de la cuenca, mientras que el bosque montano se encuentra en ambos márgenes con una importante predominancia en los distritos de Huarango y San José de Lourdes, en estos distritos los bosques se encuentran desde los 1,000 metros de elevación. En Tabaconas y Namballe están a partir de los 1,900 msnm, estos ecosistemas cumplen con funciones hidrológicas esenciales para la regulación de caudales. En altitudes intermedias desde los 1,100 a 2,500 msnm dominan los cultivos permanentes, especialmente café, cuya expansión ha generado fragmentación de bosques nativos. En las partes bajas, principalmente en los valles prevalecen cultivos de ciclo corto y vegetación xerofítica adaptada a condiciones de sequía. En conjunto, la altitud, pendiente y disponibilidad hídrica son los factores determinantes en la configuración del paisaje y la distribución de LUC en la cuenca.
- El algoritmo Random Forest alcanzó una OA de 96.5 % y un coeficiente Kappa de 0.95, resultados descritos como excelentes según (Stehman, 1997), y muy similares a los obtenidos por (Gülci et al., 2025) y Zhao et al. (2024) con una OA de 98 % y Kappa de 0.97 para ambos casos. Este buen desempeño se atribuye a su capacidad para manejar múltiples variables y resistir el sobreajuste, superando a clasificadores como CART y SVM.
- El análisis de importancia de variables mostró que los factores topográficos elevación, pendiente y aspecto fueron los más influyentes en la clasificación, en concordancia con estudios previos en zonas montañosas, como el desarrollado

por Pizarro et al. (2022) que determinó la fuerte dependencia de la elevación en la clasificación de LUC.

- El análisis de separabilidad espectral identificó a los cuerpos de agua y los bosques naturales como las clases más fácilmente diferenciables, debido a sus firmas espectrales contrastantes. En cambio, los suelos desnudos, la vegetación herbácea-arbustiva y algunas coberturas agrícolas presentaron menor separabilidad por compartir respuestas espectrales similares, especialmente según la fase fenológica de los cultivos. La incorporación de mayores muestras de entrenamiento para estas clases mejoró la discriminación, destacando la importancia de contar con datos de entrenamiento representativos y espacialmente bien distribuidos. Las coberturas con firmas espectrales bien definidas, como páramo y bosque natural, fueron clasificadas con mayor exactitud, mientras que las confusiones registradas entre clases espectralmente similares como cultivos permanentes y bosque, o suelo desnudo y vegetación herbácea responden a la heterogeneidad propia de este ecosistema.
- Mediante el uso de QGIS 3.40 se elaboró el mapa de distribución espacial de LUC, los resultados de la cuantificación muestran una predominancia del bosque natural ocupando 4,985.41 km² (51.02 %), concentrándose principalmente en las zonas altas y áreas protegidas, seguido por vegetación arbustiva y herbácea con 1,364.10 km² (13.96 %) distribuidos en ambos márgenes del río Chinchipe y una gran parte de la subcuenca del río Tabaconas, conformando un corredor longitudinal continuo que se extiende desde la zona de confluencia hasta la parroquia de Zumba en Ecuador. Las pasturas ocupan 11,56.97 km² (11.84 %) y representan una transición entre los cultivos permanentes y el bosque natural, esto explica en gran medida los cambios de uso de suelo de bosque natural al establecimiento de pasturas con fines pecuarios. Por su parte, los cultivos permanentes ocupan 1,061.44 km² (10.86 %), están compuestos en gran mayoría por café y se expanden en toda la parte media de la cuenca. Con respecto al suelo desnudo y con escasa vegetación, este se encuentra muy relacionado con la vegetación arbustiva y herbácea, debido a la poca precipitación y climas cálidos, se desarrollan principalmente en elevaciones menores a 1,000 metros. Existen 3,65.93 km² de páramo que se distribuyen en el lado occidental de la cuenca en elevaciones mayores a los 3,100 metros. En menores cantidades se encuentran

cultivos transitorios, cuerpos de agua y áreas urbanas con 113.53, 24.17 y 29.35 km² respectivamente.

- El análisis de implicancias ambientales determinó que existen 506.8 km² de LUC que se encuentran distribuidos en espacios con pendientes mayores a 75 %, consideradas extremadamente empinadas según MIDAGRI (2022). Las clases de LUC que más destacan en esta condición son pasturas y vegetación arbustiva y herbácea con 206.43 y 171.02 km² respectivamente, seguido por suelo desnudo y con escasa vegetación con 104.99 km² y cultivos permanentes con 95.41 km². Las menores cantidades son para cultivos transitorios y urbanos con 0.15 y 0.06 km² respectivamente. Esta presencia representa un potencial riesgo a los servicios ecosistémicos de la cuenca, asociados a procesos de erosión y degradación de suelos. Por otro lado, los espacios naturales protegidos concentran una cantidad significativa de bosques naturales y ecosistemas de páramo, lo que confirma su papel estratégico en la protección de ecosistemas altoandinos y en la conservación de fuentes hídricas.
- La cuenca binacional Mayo Chinchipe presenta una amplia extensión de bosque montano húmedo caracterizados por la elevada cobertura nubosa la mayor parte del año, este es un problema persistente para los sensores ópticos cuando se buscan imágenes satelitales libres de nubes. En esta investigación se demostró que este problema se puede reducir de manera efectiva utilizando el enmascaramiento de nubes y compuesto multitemporal, gracias a la función “Fmask” desarrollada por Zhu et al. (2015).

VII. CONCLUSIONES

- El procesamiento de imágenes multiespectrales de Sentinel 2 en la plataforma GEE y el algoritmo RF permitieron cartografiar de manera precisa nueve clases de LUC distribuidas en la cuenca Mayo Chinchipe durante el 2024. Se concluye que la integración de datos de libre acceso y computación en la nube es una metodología escalable para el mapeo de ecosistemas andinos y amazónicos heterogéneos.
- La aplicación del clasificador RF en GEE, utilizando bandas espectrales, índices de vegetación, variables topográficas y TCT, demostró una alta eficacia para el mapeo de paisajes montañosos complejos con una OA de 96.5 % y Kappa de 0.95. El análisis de importancia de variables indicó que los índices topográficos derivados de un DEM (elevación, pendiente y aspecto) fueron los factores más determinantes en la clasificación de LUC, seguido por las bandas espectrales y los índices espectrales como EVI y BSI. Lo que confirma la fuerte relación entre las condiciones topográficas y la distribución espacial de las coberturas en la cuenca.
- Se concluye que la integración de QGIS 3.40 permitió elaborar de manera efectiva un mapa de la distribución espacial y cuantificación de LUC de la cuenca Mayo Chinchipe. Se determinó la predominancia de bosque natural ocupando 4,985.41 km², concentrado en la parte alta y media de la cuenca. Seguido por vegetación arbustiva y herbácea, pasturas y cultivos permanentes con 1,364.10, 1,156.97 y 1,061.44 km² respectivamente, estos tres últimos formando un corredor longitudinal continuo en la subcuenca del río Tabaconas y todo el río Chinchipe, validando así la hipótesis alterna planteada en el proyecto.
- La distribución espacial de LUC en relación con la pendiente concluye que el 5.92 % del territorio de la cuenca se encuentra sometido a una presión antrópica significativa en zonas de alta susceptibilidad a la erosión y degradación del suelo, situación que representa un riesgo ambiental y requiere atención prioritaria. También se determinó que los espacios naturales protegidos cumplen un papel estratégico e irremplazable en la conservación de estos ecosistemas al concentrar una gran proporción de bosques naturales y páramos.

VIII. RECOMENDACIONES

- Se recomienda a las municipalidades distritales de Tabaconas, Namballe, San José del Alto, Chirinos, La Coipa, Carmen de la Frontera realizar proyectos de forestación y reforestación, así como la integración de sistemas agroforestales y silvopastoriles en espacios que se han determinado como “conflicto de uso” en este estudio.
- Se recomienda a las Agencias Agrarias de Jaén, San Ignacio y Huancabamba enfocar sus estrategias en la recuperación de suelos degradados a través de la reforestación con enfoque de conservación en sitios con pendientes mayores a 75% que se encuentran sin cubiertas vegetales y en otros casos con escasa vegetación.
- Se recomienda al Gobierno Regional de Cajamarca iniciar acciones para el establecimiento de nuevas áreas de conservación regional en los espacios que aún presentan bosques naturales y riqueza biológica sin intervención antrópica, específicamente en los distritos de San José de Lourdes y Huarango. Asimismo, fortalecer la vigilancia y monitoreo de las ACR ya establecidas a través de la Gerencia de Recursos Naturales y Medio Ambiente.
- Se recomienda integrar variables derivadas de DEM para futuros estudios de mapeo de LUC, puesto que brindan mejores resultados en precisión en espacios con relieves complejos.

IX. REFERENCIAS BIBLIOGRÁFICAS

- Aghababaei, M., Ebrahimi, A., Naghipour, A. A., Asadi, E., & Verrelst, J. (2021). Vegetation Types Mapping Using Multi-Temporal Landsat Images in the Google Earth Engine Platform. *Remote Sensing*, 13(22), 4683. <https://doi.org/10.3390/rs13224683>
- Amancio, D. R., Comin, C. H., Casanova, D., Travieso, G., Bruno, O. M., Rodrigues, F. A., & Da Fontoura Costa, L. (2014). A Systematic Comparison of Supervised Classifiers. *PLoS ONE*, 9(4), e94137. <https://doi.org/10.1371/journal.pone.0094137>
- Amini, S., Saber, M., Rabiei-Dastjerdi, H., & Homayouni, S. (2022). Urban Land Use and Land Cover Change Analysis Using Random Forest Classification of Landsat Time Series. *Remote Sensing*, 14(11), 1-23. <https://doi.org/10.3390/rs14112654>
- Arpitha, M., Ahmed, S. A., & N, H. (2023). Land use and land cover classification using machine learning algorithms in google earth engine. *Earth Science Informatics*, 16(4), 3057-3073. <https://doi.org/10.1007/s12145-023-01073-w>
- Aziz, G., Minallah, N., Saeed, A., Frnda, J., & Khan, W. (2024). Remote sensing based forest cover classification using machine learning. *Scientific Reports*, 14(1), 69. <https://doi.org/10.1038/s41598-023-50863-1>
- Barboza, E., Salazar, W., Gálvez-Paucar, D., Valqui-Valqui, L., Valqui, L., Zagaceta, L. H., Gonzales, J., Vásquez, H. V., & Arbizu, C. I. (2024). Cloud Computing Application for the Analysis of Land Use and Land Cover Changes in Dry Forests of Peru. *International Journal of Environmental Impacts*, 7(3). <https://doi.org/10.18280/ije.070312>
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
- Cardille, J. A., Crowley, M. A., Saah, D., & Clinton, N. E. (Eds.). (2024). *Cloud-Based Remote Sensing with Google Earth Engine: Fundamentals and Applications*. Springer International Publishing. <https://doi.org/10.1007/978-3-031-26588-4>
- De Fioravante, P., Luti, T., Cavalli, A., Giuliani, C., Dichicco, P., Marchetti, M., Chirici, G., Congedo, L., & Munafò, M. (2021). Multispectral Sentinel-2 and SAR Sentinel-1 Integration for Automatic Land Cover Classification. *Land*, 10(6), 611. <https://doi.org/10.3390/land10060611>

- De Jong, L., De Bruin, S., Knoop, J., & Van Vliet, J. (2021). Understanding land-use change conflict: A systematic review of case studies. *Journal of Land Use Science*, 16(3), 223-239. <https://doi.org/10.1080/1747423X.2021.1933226>
- De Luca, G., M. N. Silva, J., Di Fazio, S., & Modica, G. (2022). Integrated use of Sentinel-1 and Sentinel-2 data and open-source machine learning algorithms for land cover mapping in a Mediterranean region. *European Journal of Remote Sensing*, 55(1), 52-70. <https://doi.org/10.1080/22797254.2021.2018667>
- Gandhi, U. (2024). JavaScript and the Earth Engine API. En N. E. C. Jeffrey A. Cardille , Morgan A. Crowley , David Saah (Ed.), *Cloud-Based Remote Sensing with Google Earth Engine* (1.^a ed., pp. 3-18). Springer International Publishing. <https://doi.org/10.1007/978-3-031-26588-4>
- García-Álvarez, D., Camacho Olmedo, M. T., Mas, J.-F., & Paegelow, M. (2022). Land Use Cover Mapping, Modelling and Validation. A Background. En D. García-Álvarez, M. T. Camacho Olmedo, M. Paegelow, & J. F. Mas (Eds.), *Land Use Cover Datasets and Validation Tools* (pp. 21-33). Springer International Publishing. https://doi.org/10.1007/978-3-030-90998-7_2
- Gülci, S., Wing, M., & Akay, A. E. (2025). Land Use and Land Cover (LULC) Mapping Accuracy Using Single-Date Sentinel-2 MSI Imagery with Random Forest and Classification and Regression Tree Classifiers. *Geomatics*, 5(3), 29. <https://doi.org/10.3390/geomatics5030029>
- Hänggli, A., Levy, S. A., Armenteras, D., Bovolo, C. I., Brandão, J., Rueda, X., & Garrett, R. D. (2023). A systematic comparison of deforestation drivers and policy effectiveness across the Amazon biome. *Environmental Research Letters*, 18(7), 073001. <https://doi.org/10.1088/1748-9326/acd408>
- Horning, N., Robinson, J. A., Sterling, E. J., Turner, W., & Spector, S. (2010). *Remote sensing for ecology and conservation: A handbook of techniques*. Oxford university press.
- Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83(1-2), 195-213. [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2)

- Ibrahim, M., Al-Mashaqbah, A., Koch, B., & Datta, P. (2020). An evaluation of available digital elevation models (DEMs) for geomorphological feature analysis. *Environmental Earth Sciences*, 79(13), 336. <https://doi.org/10.1007/s12665-020-09075-3>
- Lindgren, D. T. (1985). *Land use planning and remote sensing*. Springer Netherlands. <https://doi.org/10.1007/978-94-017-2035-9>
- Liu, J., & Mason, P. (2016). Image processing and GIS for remote sensing. 2016, 472.
- Loukika, K. N., Keesara, V. R., & Sridhar, V. (2021). Analysis of Land Use and Land Cover Using Machine Learning Algorithms on Google Earth Engine for Munneru River Basin, India. *Sustainability*, 13(24), 13758. <https://doi.org/10.3390/su132413758>
- Lu, D., Li, G., Moran, E., & Hetrick, S. (2013). Spatiotemporal analysis of land-use and land-cover change in the Brazilian Amazon. *International Journal of Remote Sensing*, 34(16), 5953-5978. <https://doi.org/10.1080/01431161.2013.802825>
- Medina Medina, A. J., Salas López, R., Zabaleta Santisteban, J. A., Tuesta Trauco, K. M., Turpo Cayo, E. Y., Huaman Haro, N., Oliva Cruz, M., & Gómez Fernández, D. (2024). An Analysis of the Rice-Cultivation Dynamics in the Lower Utcubamba River Basin Using SAR and Optical Imagery in Google Earth Engine (GEE). *Agronomy*, 14(3), 557. <https://doi.org/10.3390/agronomy14030557>
- Ministerio del Ambiente (MINAM). Mapa Nacional de Cobertura Vegetal—Memoria Descriptiva (2015). Available online: <https://www.gob.pe/institucion/minam/informes-publicaciones/2674-mapa-nacional-de-cobertura-vegetal-memoria-descriptiva> (accessed on 16 January 2025).
- Ministerio de Desarrollo Agrario y Riego (2022). Decreto Supremo N.º 005-2022-MIDAGRI que aprueba el Reglamento de Clasificación de Tierras por su Capacidad de Uso Mayor. Presidencia de la República. Diario Oficial El Peruano. <https://www.gob.pe/institucion/midagri/normas-legales/2979424-0005-2022-midagri>
- McFEETERS, S. K. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, 17(7), 1425-1432. <https://doi.org/10.1080/01431169608948714>
- Naciones Unidas para el Desarrollo Sostenible (NUDS). sf. Goal 15: Life on land. Sustainable Development Goals. Disponible en línea: <https://sdgs.un.org/goals/goal15> (consultado el 20 de mayo de 2026).

- Naturaleza y Cultura Internacional (2024). Cuarta escuela del agua por la cuenca binacional Mayo-Chinchipe. <https://www.natureandculture.org/es/directorio/se-desarrollo-cuarta-escuela-del-agua-por-la-cuenca-binacional-mayo-chinchipe/>
- Navulur, K. (2006). *Multispectral Image Analysis Using the Object-Oriented Paradigm* (0 ed.). CRC Press. <https://doi.org/10.1201/9781420043075>
- Nicolau, A. P., Dyson, K., Saah, D., & Clinton, N. (2024). Accuracy Assessment: Quantifying Classification Quality. En J. A. Cardille, M. A. Crowley, D. Saah, & N. E. Clinton (Eds.), *Cloud-Based Remote Sensing with Google Earth Engine* (pp. 135-145). Springer International Publishing. https://doi.org/10.1007/978-3-031-26588-4_7
- Organización de las Naciones Unidas para la Agricultura y la alimentación (FAO). (15 de Setiembre de 2020). Land use in agriculture by the numbers. Sustain Food Agric. Obtenido de <https://www.fao.org/sustainability/news/detail/en/c/1274219/>
- Pizarro, S. E., Pricope, N. G., Vargas-Machuca, D., Huanca, O., & Ñaupari, J. (2022). Mapping Land Cover Types for Highland Andean Ecosystems in Peru Using Google Earth Engine. *Remote Sensing*, 14(7), 1562. <https://doi.org/10.3390/rs14071562>
- Pontius, R. G., & Millones, M. (2011). Death to Kappa: Birth of quantity disagreement and allocation disagreement for accuracy assessment. *International Journal of Remote Sensing*, 32(15), 4407-4429. <https://doi.org/10.1080/01431161.2011.552923>
- Proyecto CUIDAR (2024). <https://proyecto-cuidar.net/geoportal/>
- Qi, J., Chehbouni, A., Huete, A. R., Kerr, Y. H., & Sorooshian, S. (1994). A modified soil adjusted vegetation index. *Remote Sensing of Environment*, 48(2), 119-126. [https://doi.org/10.1016/0034-4257\(94\)90134-1](https://doi.org/10.1016/0034-4257(94)90134-1)
- Rasul, A., Balzter, H., Ibrahim, G. R. F., Hameed, H. M., Wheeler, J., Adamu, B., Ibrahim, S., & Najmaddin, P. M. (2018). Applying Built-Up and Bare-Soil Indices from Landsat 8 to Cities in Dry Climates. *Land*, 7(3), 81. <https://doi.org/10.3390/land7030081>
- Reddy, A. (2008). Remote Sensing and Geographical Information Systems. 2008, 476.
- Richards, J. A. (2013). *Remote Sensing Digital Image Analysis: An Introduction*. Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-642-30062-2>


- Sánchez Tello, S., Romero Rojas, J., Núñez Figueroa, M., Roncal Briones, W. R., Chasquero Martínez, J. C., & Chávez Santa Cruz, G. A. (2026). *Distribution of land cover and land use in the Tumbillán micro-basin, province of Jaén through the use of Google Earth Engine*. 12(4). <https://doi.org/DOI:%252010.5281/zenodo.12426536>
- Schmutz, S., & Sendzimir, J. (Eds.). (2018). *Riverine Ecosystem Management: Science for Governing Towards a Sustainable Future*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-73250-3>
- Stara, L., & Halounova, L. (2022). CLASSIFICATION OF SELECTED CORINE CLASSES USING SENTINEL-2 DATA. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLIII-B3-2022*, 175-180. <https://doi.org/10.5194/isprs-archives-XLIII-B3-2022-175-2022>
- Stehman, S. V. (1997). Selecting and interpreting measures of thematic classification accuracy. *Remote Sensing of Environment*, 62(1), 77-89. [https://doi.org/10.1016/S0034-4257\(97\)00083-7](https://doi.org/10.1016/S0034-4257(97)00083-7)
- Stoyanov, A. (2022). Application of Tasseled Cap Transformation of Sentinel-2—MSI Data for Forest Monitoring and Change Detection on Territory of Natural Park “BLUE STONES”. *The 3rd International Electronic Conference on Forests—Exploring New Discoveries and New Directions in Forests*, 42. <https://doi.org/10.3390/IECF2022-13073>
- Tesfaye, W., Elias, E., & Tekalign, M. (2024). *Modelado de cambios en el uso y la cobertura del suelo mediante el uso de Google Earth y un enfoque de aprendizaje automático: Implicaciones para la gestión del paisaje*.
- Tucker, C. J. (s. f.). Red and Photographic Infrared Linear Combinations for Monitoring Vegetation. 1979.
- Wang, J., Hu, Z., Wu, Y., & Zhang, J. (Eds.). (2023). *Remote Sensing of Watershed*. MDPI - Multidisciplinary Digital Publishing Institute.
- Wang, S., Azzari, G., & Lobell, D. B. (2019). Crop type mapping without field-level labels: Random forest transfer and unsupervised clustering techniques. *Remote Sensing of Environment*, 222, 303-317. <https://doi.org/10.1016/j.rse.2018.12.026>
- Zha, Y., Gao, J., & Ni, S. (2003). Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *International Journal of Remote Sensing*, 24(3), 583-594. <https://doi.org/10.1080/01431160304987>

- Zhao, Z., Islam, F., Waseem, L. A., Tariq, A., Nawaz, M., Islam, I. U., Bibi, T., Rehman, N. U., Ahmad, W., Aslam, R. W., Raza, D., & Hatamleh, W. A. (2024). Comparison of Three Machine Learning Algorithms Using Google Earth Engine for Land Use Land Cover Classification. *Rangeland Ecology & Management*, 92, 129-137. <https://doi.org/10.1016/j.rama.2023.10.007>
- Zhu, Z., Wang, S., & Woodcock, C. E. (2015). Improvement and expansion of the Fmask algorithm: Cloud, cloud shadow, and snow detection for Landsats 4–7, 8, and Sentinel 2 images. *Remote Sensing of Environment*, 159, 269-277. <https://doi.org/10.1016/j.rse.2014.12.014>

X. ANEXOS

Anexo 1

Mapa de ubicación de la cuenca Mayo Chinchipe



Anexo 2

Panel fotográfico de las clases de LUC registradas durante la toma de datos en campo

Figura 1

Cultivos de arroz en el centro poblado Shumba, distrito de Bellavista



Figura 2

Cultivos transitorios en el caserío Hawai, distrito de Chirinos



Figura 3

Vegetación arbustiva y herbácea en el caserío El Tablón, distrito de Chirinos



Figura 4

Mosaico de relictos de bosque junto a vegetación arbustiva y herbácea



Figura 5

Vegetación arbustiva y herbácea en el distrito de Huarango



Figura 6

Pasturas en zonas con pendientes pronunciadas, caserío La Florida, distrito de Chirinos




Figura 7

Bosque natural en Puerto Ciruelo, distrito de Huarango




Figura 8

Sistema agroforestal café y Cordia. Parroquia Chito, Cantón Zamora Chinchipe




Figura 9

Pasturas con relictos de bosque natural. Parroquia Zumba, Ecuador



Figura 10

Compuesto mixto entre cultivo permanente, Suelo desnudo y con escasa vegetación y vegetación arbustiva herbácea. Caserío La Lima, distrito de Chirinos.



Figura 11

Ecosistema páramo en el Santuario Nacional Tabaconas Namballe, Provincia de San Ignacio



Figura 12

Ecosistema páramo en el Distrito Carmen de la Frontera, Provincia de Huancabamba



Figura 13

Bosques naturales en el caserío El Porvenir, distrito de San José del Alto




Figura 14

Bosques naturales en el caserío San Patricio, distrito de San José del Alto.




Mapa de LUC del año 2024 de la cuenca Mayo Chinchipe




Anexo 4

Mapa de la cuenca con pendientes mayores a 75 %




Anexo 5

Mapa de LUC en pendientes mayores a 75 %




Anexo 6

Mapa de LUC resultante del Parque Nacional Podocarpus




Anexo 7

Mapa de LUC resultante del Parque Nacional Yacuri




Anexo 8

Mapa de LUC resultante del Santuario Nacional Tabaconas Namballe




Anexo 9

Mapa de LUC resultante del ACR Páramos y Bosques Montanos de Jaén y Tabaconas




Anexo 10

Mapa de LUC resultante del ACR Bosques del Chaupe, Cunía y Chinchiquilla



Anexo 11

Mapa de ubicación de áreas seleccionadas



Anexo 12

Clases de LUC identificadas en Google Earth

LUC	Imagen		
CPE			
CTR			
URB			
AGU			


SDE



VAH




PAR



PAS



BOS



Anexo 13

Interfaz de la plataforma GEE

