

UNIVERSIDAD NACIONAL INTERCULTURAL DE LA SELVA CENTRAL JUAN SANTOS ATAHUALPA



FACULTAD DE INGENIERÍA ESCUELA PROFESIONAL DE INGENIERÍA AMBIENTAL

Análisis de la deforestación a partir de los cambios de cobertura y usos del suelo con teledetección en el distrito de Pichanaqui (2016 – 2023)

TESIS

Para optar el título profesional de Ingeniero Ambiental

AUTORAS

Sheyli Diana Gomez Rodriguez

Betzabeth Levy Leandro Roncal

ASESOR

Dr. Alex Rubén Huamán De La Cruz

Chanchamayo, Perú

2024

AGRADECIMIENTOS

Estamos profundamente agradecidas con Dios por otorgarnos la sabiduría y fortaleza necesaria para culminar esta importante investigación. También, nuestro más sincero agradecimiento a nuestros padres y hermanos, cuyo apoyo incondicional fue fundamental en esta etapa crucial de nuestras vidas. Asimismo, queremos destacar el valioso respaldo de los ingenieros de nuestra universidad, quienes, con su conocimiento y orientación, nos guiaron a lo largo de este camino, brindándonos herramientas y consejos claves para superar los desafíos encontrados.

DEDICATORIA

Este trabajo lo dedicamos a nuestros padres por su apoyo incondicional y por ser la base fundamental de nuestro desarrollo como personas. También a nuestras familias por su compañía y ánimos en cada etapa de nuestras vidas. Finalmente, a aquellas personas que nos han venido apoyando en cada paso que damos, ellos son el asesor, docentes, amigos y conocidos.

RESUMEN

Esta investigación surge ante la gran problemática de deforestación, para identificar sus causas y contribuir con información clave para su mitigación. Por ello, el objetivo del estudio fue analizar los cambios de cobertura y usos del suelo ocasionados por la deforestación en el distrito de Pichanaqui desde el 2016 al 2024. El enfoque metodológico se realizó en base al sistema de clasificación Corine Land Cover, utilizando el algoritmo Random Forest para la clasificación supervisada de imágenes satelitales (Landsat-8 y Sentinel-2). La validación de los datos se realizó mediante el trabajo de campo para el 2024. Adicionalmente, se empleó el modelo de la exponencial negativa para proyectar las tendencias de deforestación al 2030. Los resultados indican que en el distrito de Pichanaqui se identificaron 10 tipos de cobertura y uso de suelo, las cuales presentaron cambios en relación al área, destacando la cobertura de bosques que presentó pérdidas de 21972 hectáreas, a comparación de las áreas agrícolas, vegetación herbácea y áreas sin vegetación que incrementaron su extensión. A partir de estos datos históricos se proyectó que al 2030 solo habrá 62805.09 hectáreas de bosques, equivalente al 50% de bosques en el territorio. Se concluye que los cambios de cobertura y usos del suelo fueron ocasionados por la expansión agrícola, el incremento de áreas sin vegetación a causa de los incendios forestales y el incremento de vegetación herbácea como resultado de la fragmentación de bosques. Por lo cual se recomienda, el uso de herramientas de teledetección y sistemas de información geográfica para enfrentar los desafíos del futuro.

Palabras clave: Clasificación supervisada, deforestación, proyección y teledetección.

ABSTRACT

This research arises in response to the major problem of deforestation, to identify its causes and contribute with key information for its mitigation. Therefore, the objective of the study was to analyze the changes in land cover and use caused by deforestation in the district of Pichanaqui from 2016 to 2023. The methodological approach was based on the Corine Land Cover classification system, using the Random Forest algorithm for the supervised classification of satellite images (Landsat-8 and Sentinel-2). Data validation was carried out through field work for 2024. Additionally, the negative exponential model was used to project deforestation trends to 2030. The results indicate that in the district of Pichanaqui, 10 types of land cover and use were identified, which presented changes in relation to the area, highlighting the forest cover that presented losses of 21,972 hectares, compared to agricultural areas, herbaceous vegetation and areas without vegetation that increased their extension. From this historical data, it was projected that by 2030 there will only be 62,805.09 hectares of forests. It is concluded that the changes in land cover and use were caused by agricultural expansion, the increase in areas without vegetation due to forest fires and the increase in herbaceous vegetation as a result of forest fragmentation and livestock farming. Therefore, the use of remote sensing tools and geographic information systems is recommended to face the challenges of the future.

Keywords: Supervised classification, deforestation, projection and remote sensing.

ÍNDICE

AGRADECIMIENTOS.....	ii
DEDICATORIA.....	iii
RESUMEN.....	iv
ABSTRACT.....	v
INTRODUCCIÓN.....	xii
CAPÍTULO I.....	13
PLANTEAMIENTO DEL PROBLEMA.....	13
1.1. Fundamentación del problema.....	13
1.2. Formulación del problema.....	14
1.2.1. Problema general.....	14
1.2.2. Problemas específicos.....	14
1.3. Objetivos.....	14
1.3.1. Objetivo general.....	14
1.3.2. Objetivos específicos.....	14
1.4. Definición y operacionalización de variables.....	15
1.5. Hipótesis.....	15
1.6. Justificación.....	15
1.6.1. Ambiental.....	15
1.6.2. Social.....	16
1.6.3. Económica.....	16
1.6.4. Teórica.....	16
1.6.5. Práctica.....	17
CAPÍTULO II.....	18
MARCO TEÓRICO.....	18
2.1. Antecedentes.....	18
2.1.1. A nivel internacional.....	18
2.1.2. A nivel nacional.....	18

2.1.3. A nivel local.....	19
2.2. Bases teóricas	20
2.2.1. Deforestación.....	20
2.2.2. Cobertura vegetal.....	21
2.2.3. Usos del suelo	21
2.2.4. Teledetección.....	21
2.2.5. Análisis multitemporal	21
2.2.6. Sistemas de Información Geográfica (SIG).....	22
2.2.7. Sensores remotos y plataformas	23
2.2.8. Software para SIG	25
2.2.9. Resoluciones de imágenes satelitales	26
2.2.10. Preprocesamiento de Imágenes Satelitales	27
2.2.11. Técnicas de clasificación de imágenes satelitales	28
2.2.12. Metodología Corine Land Cover	29
2.2.13. Modelos de Aprendizaje supervisado	30
2.2.14. Matriz de confusión	31
2.2.15. Proyección con el modelo de la regresión exponencial.....	32
2.2.16. Mapa Nacional de ecosistemas del Perú.....	32
CAPÍTULO III	33
METODOLOGÍA Y TÉCNICAS DE INVESTIGACIÓN	33
3.1. Ámbito de estudio	33
3.2. Tipo, nivel y diseño de investigación.....	34
3.2.1. Tipo de investigación.....	34
3.2.2. Nivel de investigación	34
3.2.3. Diseño de investigación.....	34
3.3. Población y muestra	34
3.3.1. Población	34
3.3.2. Muestra	34

3.4.	Procedimientos, técnicas e instrumentos de recolección de datos	36
3.4.1.	Procedimientos de recolección de datos	37
3.4.2.	Técnicas e instrumentos de recolección de datos	42
3.5.	Análisis de datos.....	42
3.5.1.	Estadística descriptiva	42
3.5.2.	Tendencias de proyecciones futuras sobre la deforestación	42
3.6.	Consideraciones éticas	43
CAPÍTULO IV		44
RESULTADOS Y DISCUSIONES		44
4.1.	Presentación de resultados y discusiones	44
4.1.1.	Identificación del modelo de aprendizaje	44
4.1.2.	Clasificación de las coberturas y usos del suelo.....	45
4.1.3.	Cuantificación de los cambios de cobertura y usos del suelo.....	49
4.1.4.	Estimación de la pérdida de cobertura boscosa	54
4.1.5.	Clasificación de los tipos de bosques	56
4.1.6.	Estimación de la pérdida de bosques al 2030	61
4.2.	Prueba de hipótesis.....	66
CONCLUSIONES.....		67
RECOMENDACIONES		68
REFERENCIAS BIBLIOGRÁFICAS		69

ÍNDICE DE FIGURAS

Figura 1 Delimitación geográfica de la zona de estudio	33
Figura 2 Flujograma del procedimiento metodológico	36
Figura 3 Evaluación de algoritmos de Machine Learning para la clasificación supervisada ...	44
Figura 4 Distribución geoespacial de los puntos de validación en campo	45
Figura 5 Matriz de confusión en la clasificación supervisada.....	46
Figura 6 Serie multitemporal de la clasificación de coberturas y usos del suelo	48
Figura 7 Diagrama de barras de los cambios de cobertura y usos de suelo	49
Figura 8 Diagrama de Sankey de los cambios de cobertura y usos de suelo	50
Figura 9 Diagrama de cuerdas de los cambios de cobertura y usos de suelo	51
Figura 10 Diagrama de ganancias y pérdidas de los cambios de cobertura y usos de suelo ...	52
Figura 11 Superficie total deforestada y tasa anual de deforestación.....	55
Figura 12 Porcentaje de reducción de cobertura forestal por año	56
Figura 13 Clasificación de los tipos de bosques en el distrito de Pichanaqui	57
Figura 14 Verificación in situ de los tipos de bosques	58
Figura 15 Serie temporal de los tipos de bosques identificados en el distrito de Pichanaqui ..	59
Figura 16 Serie temporal de las áreas de bosque desde el 2016 al 2024.....	62
Figura 17 Análisis de autocorrelación de la serie temporal de las áreas boscosas	63
Figura 18 Pronóstico de áreas boscosas con el modelo de la regresión exponencial negativa	64
Figura 19 Diagnósticos residuales del método de la exponencial negativa	66
Figura 20 Identificación de la cobertura de áreas urbanizadas en zona rural.....	89
Figura 21 Identificación de la cobertura de áreas urbanizadas en zona urbana	89
Figura 22 Identificación de la cobertura de áreas agrícolas en cultivo de piña.....	90
Figura 23 Identificación de la cobertura de áreas agrícolas en cultivo de plátano	90
Figura 24 Identificación de la cobertura del bosque estacional seco	91
Figura 25 Identificación de la cobertura del bosque basimontano de yunga.....	91
Figura 26 Identificación de la cobertura de vegetación herbácea en zona de pastizal	92
Figura 27 Identificación de la cobertura de vegetación herbácea en vegetación secundaria ...	92
Figura 28 Identificación de la cobertura de áreas sin vegetación en un rozo	93
Figura 29 Identificación de la cobertura de áreas sin vegetación para cultivos de kion	93
Figura 30 Identificación de la cobertura del río Perené.....	94
Figura 31 Identificación de la cobertura del río Ipoki	94
Figura 32 Identificación de la cobertura de áreas arenosas con pedregal	95
Figura 33 Identificación de la cobertura de áreas arenosas	95
Figura 34 Mapa nacional de ecosistemas del Perú	96

Figura 35 Mapa vial del distrito de Pichanaqui97

ÍNDICE DE TABLAS

Tabla 1 Operacionalización de variables.....	15
Tabla 2 Características de Landsat 8	23
Tabla 3 Combinación de bandas para Landsat 8	24
Tabla 4 Bandas del Satélite Sentinel-2.....	25
Tabla 5 Valoración del Índice de Kappa	31
Tabla 6 Clases de cobertura y uso del suelo identificadas en el área de estudio.....	35
Tabla 7 Distribución de los puntos de muestreo.....	39
Tabla 8 Evolución de la superficie por tipo de cobertura y usos del suelo	54
Tabla 9 Estimación de áreas según la clasificación de tipos de bosques	61
Tabla 10 Evolución proyectada de las áreas forestales con la exponencial negativa.....	65

INTRODUCCIÓN

Los bosques son uno de los recursos naturales más valiosos del planeta, que albergan gran biodiversidad de plantas, animales y hongos esenciales para mantener el equilibrio ecológico (John et al., 2021). Además, brindan servicios ecosistémicos para regular el clima, purificar el agua y el aire, proteger el suelo de la erosión y proporcionar alimentos y recursos económicos para las personas (Cisterna, 2020).

Entre los principales problemas que aquejan a los bosques es la deforestación, que es impulsado por factores como el crecimiento de la población, el desarrollo industrial, la agricultura intensiva (Dammert, 2016), la tala ilegal (Fernandez & Muñante, 2021), la expansión urbana (Moschella, 2023) y otras actividades humanas (Rojas et al., 2019), que amenazan la salud y calidad de vida de las generaciones futura (Rescia et al., 2023). Asimismo, cambian la cobertura del suelo y transforman vastas áreas naturales que provocan extinción de especies, alteraciones en la biodiversidad, cambio climático, y modificación de ecosistemas (Álava & Guerrero, 2021)

En los últimos años, frente a esta problemática de deforestación se aplicaron tecnologías de teledetección y sistemas de información geográfica para cuantificar la pérdida de bosques y analizar los cambios en la cobertura y uso del suelo a nivel mundial (Álvarez et al., 2021; Sahu et al., 2022; Saucedo, 2023; Shah & Shah, 2023; Tariq & Mumtaz, 2023; Tsegaye et al., 2023; Zerouali et al., 2023; Barbosa et al., 2023; Kaselimi et al., 2023; Khan et al., 2024). Las imágenes satelitales proporcionan datos de diversos aspectos como la topografía, uso del suelo, condiciones meteorológicas, vegetación, etc. que son útiles para monitorear, detectar cambios y hacer evaluaciones multitemporales de la cobertura terrestre. Así mismo, las técnicas de teledetección permiten obtener resultados rápidos y precisos gracias a diversos programas SIG donde se puede procesar los datos y generar mapas temáticos (Quispe & Cáceres, 2020).

En el Perú, estas tecnologías también fueron aplicadas, por ejemplo, Rojas et al. (2019) utilizó métodos de clasificación supervisada con imágenes Landsat. Tarazona & Miyasiro-López (2020) combinó análisis espacial y técnicas de clasificación. Alarcón et al. (2021) emplea técnicas de sensoramiento remoto con imágenes Landsat con una clasificación supervisada. Kinnebrew et al. (2022) genera mapas de cobertura del suelo utilizando imágenes Landsat y clasificación supervisada.

En la región de Junín, estudios que abordan el análisis de la deforestación mediante teledetección fueron realizados en Satipo (Torre & Rivas, 2019), Tarma (Hinostroza, 2021) y Pangoa (Janampa & Ponce, 2022), siendo estos escasos. Sin embargo, ningún reporte científico utilizó técnicas de teledetección en Pichanaqui.

CAPÍTULO I

PLANTEAMIENTO DEL PROBLEMA

1.1. Fundamentación del problema

Desde la década de 1900, la humanidad fue testigo de la disminución de cobertura forestal, impulsado por el crecimiento demográfico, la industrialización y la expansión urbana, que ejercieron presión sobre la cobertura terrestre y transformaciones del paisaje (Marquet et al., 2019), generando la extinción de especies (Acosta, 2020).

Esta transformación está vinculada tanto a cambios en la diversidad biológica (Calderon-ptaron & Moreno, 2019), como al cambio climático (Morote & Olcina, 2021), lo que resulta en una alteración de los ecosistemas. Además, la deforestación intensiva conlleva un aumento en las emisiones de CO₂ y afecta la calidad del agua (González-Vergel et al., 2022), asociado con una mayor pérdida de carbono debido a incendios forestales (Peacock et al., 2021). Sumado a esto, la expansión agrícola, la tala ilegal y el desarrollo urbano también afectan la capacidad del planeta para regular el clima y conservar la biodiversidad, lo que ha ocasionado el incremento de la deforestación en la Amazonía peruana, afectando áreas protegidas y territorios indígenas en Madre de Dios (Nicolau et al., 2019).

Sin embargo, el uso de teledetección y análisis de datos permite monitorear la cobertura terrestre y comprender los factores de la deforestación, desarrollando estrategias de conservación adaptadas a cada región (Cortes, 2020; Von et al., 2020; Álvarez et al., 2021). Usando imágenes satelitales se puede analizar la cobertura boscosa y así identificar patrones de pérdida de bosque para cada año (Carpio & Fath, 2019; Habib & Connolly, 2023), analizando los factores antropogénicos y generando datos históricos que rastrean los cambios del bosque hacia otros usos. Además, este enfoque de monitoreo ejerce un papel crucial en la gestión ambiental del territorio, proporcionando información para la formulación de estrategias que aborden los desafíos actuales y anticipen escenarios futuros (Alarcón et al., 2021).

La investigación se centra en el distrito de Pichanaqui, que cuenta con alrededor de 70 mil habitantes y abarca una extensión de 124 mil hectáreas. De esta área, el 20.1% tiene suelos aptos para plantaciones forestales y el 61.4% para cultivos permanentes, lo cual hace que la agricultura ocupe unas 33 mil hectáreas, donde el 74 % es dedicado a la caficultura (Buendía, 2018). Ante esto, vemos que uno de los principales problemas en la disminución de la cobertura forestal es el cambio de uso del suelo, debido a actividades agrícolas, pecuarias y extracción forestal. Por ello, resaltamos la necesidad de contar con información geográfica a nivel local para la adecuada gestión del territorio y sus recursos.

1.2. Formulación del problema

1.2.1. Problema general

¿Cuáles son los cambios de cobertura y usos del suelo ocasionados por la deforestación en el distrito de Pichanaqui a partir del 2016 al 2024?

1.2.2. Problemas específicos

- ¿Cuál es el modelo de aprendizaje automático adecuado para la clasificación supervisada de coberturas y usos del suelo en Pichanaqui?
- ¿Cuál es la clasificación de coberturas y usos del suelo en Pichanaqui entre el 2016 y 2024 utilizando el modelo óptimo de aprendizaje?
- ¿Cuáles son los cambios de coberturas y usos del suelo en Pichanaqui desde 2016 hasta 2024?
- ¿Cuánto es la pérdida de cobertura boscosa en el distrito de Pichanaqui entre el 2016 al 2024?
- ¿Cuáles son los tipos de bosques identificados en el distrito de Pichanaqui según el mapa nacional de ecosistemas del Perú entre el 2016 y 2024?
- ¿Cuál es la estimación de la pérdida de bosques en el distrito de Pichanaqui para el 2030?

1.3. Objetivos

1.3.1. Objetivo general

Analizar los cambios de cobertura y usos del suelo ocasionados por la deforestación en el distrito de Pichanaqui desde el 2016 al 2024

1.3.2. Objetivos específicos

- Identificar el modelo de aprendizaje automático adecuado para la clasificación supervisada de coberturas y usos del suelo en el distrito de Pichanaqui.
- Clasificar las coberturas y usos del suelo en el distrito entre 2016 y 2024 utilizando el modelo de aprendizaje automático óptimo.
- Cuantificar los cambios en las coberturas y usos del suelo en el distrito de Pichanaqui entre el 2016 y 2024.
- Cuantificar la pérdida de cobertura boscosa en el distrito de Pichanaqui entre el 2016 al 2024.
- Clasificar los tipos de bosques en el distrito de Pichanaqui según el mapa nacional de ecosistemas del Perú entre 2016 y 2024.
- Estimar la pérdida de bosques en el distrito de Pichanaqui al 2030.

1.4. Definición y operacionalización de variables

Tabla 1

Operacionalización de variables

Variab	Definición conceptual	Dimensiones	Indicadores	Unidad de medida
Deforestación	La deforestación es el desarrollo de actividades en áreas boscosas que resultan en la eliminación de la cobertura forestal (Sánchez & Sánchez, 2022)	Extensión y magnitud de deforestación	Superficie total deforestada	ha
			Tasa anual de deforestación	ha/año
Cambios de coberturas y usos del suelo	Los cambios de coberturas se refieren a las clases biológicas o físicas presentes sobre la superficie de la tierra (López, 2021) y los usos del suelo son las actividades que la sociedad realiza sobre la superficie terrestre (Abad-Auquilla, 2020).	Tipos de coberturas y usos del suelo	Porcentaje de reducción de cobertura forestal	%
			Modelos de clasificación supervisada	Precisión global
			Superficie de número de clases identificadas	ha

1.5. Hipótesis

La deforestación en el distrito de Pichanaqui entre 2016 y 2024 ha generado cambios significativos en la cobertura y usos del suelo.

1.6. Justificación

1.6.1. Ambiental

Nuestra investigación es fundamental para monitorear y comprender los procesos de deforestación a lo largo del tiempo, proporcionándoles datos actualizados sobre la pérdida de cobertura boscosa y las alteraciones en el uso del suelo. Estos hallazgos nos permitirán identificar áreas críticas donde se requieren acciones urgentes de conservación y restauración, ayudando a frenar la deforestación, proteger la biodiversidad y los servicios ecosistémicos esenciales que sustentan a las comunidades locales. Ya que, el alarmante aumento de la deforestación causado principalmente por actividades antrópicas, representa una amenaza significativa para la integridad de los ecosistemas en el distrito.

1.6.2. Social

La deforestación impacta directamente a las comunidades locales que dependen de los recursos naturales para su subsistencia. Los resultados de esta investigación proporcionarán una base científica sólida para apoyar la implementación de políticas y regulaciones que promuevan la conservación y el manejo sostenible de los bosques, abordando los impactos socioeconómicos que la deforestación genera, como la pérdida de medios de vida y la inseguridad alimentaria. Además, esta investigación contribuirá a concienciar a las comunidades, involucrándose activamente en la toma de decisiones sobre el uso sostenible del suelo y la conservación de los bosques, promoviendo su participación y empoderamiento en la protección de su entorno.

1.6.3. Económica

La deforestación causa un impacto directo en la economía local al degradar los recursos de suelo y agua, lo que lleva a costos elevados para la recuperación de tierras y pérdidas de productividad agrícola a largo plazo. Esto podría derivar en un menor rendimiento de los cultivos y en costos adicionales para los agricultores, que necesitan fertilizantes y otras intervenciones para mantener la productividad en suelos degradados. No obstante, con la creciente valorización del carbono, proteger los bosques de Pichanaqui representa un valor monetario adicional en mercados de compensación de carbono. Inversores podrían aprovechar los beneficios financieros de mantener la cobertura forestal como sumideros de carbono, lo que permitiría a la región ingresar a programas de financiamiento verde y compensación de emisiones.

1.6.4. Teórica

Esta investigación establece una base científica sólida para el entendimiento teórico de los patrones de deforestación en regiones tropicales, proporcionando un enfoque metodológico innovador mediante el uso de teledetección y aprendizaje automático. Estas técnicas, combinadas con software avanzado y códigos replicables,

permiten desarrollar un modelo metodológico adaptable que maximiza la replicabilidad, facilitando su aplicación en otros contextos geográficos o con objetivos de investigación afines. Así, el estudio no solo contribuye al conocimiento de la dinámica de la deforestación en el distrito de Pichanaqui, sino que también aporta un marco teórico y metodológico valioso para la investigación en ciencias ambientales, fomentando el desarrollo de estrategias de conservación basadas en evidencia científica.

1.6.5. Práctica

Los resultados de esta investigación proporcionan una base sólida para la implementación y la información de políticas ambientales y regulaciones locales, ayudando a crear estrategias de conservación que beneficien a la población. También, la práctica de conservar la cobertura forestal contribuye a la seguridad alimentaria, mejora la calidad de vida de las comunidades y genera un impacto económico positivo en sectores como el turismo y la agricultura sostenible.

CAPÍTULO II

MARCO TEÓRICO

2.1. Antecedentes

2.1.1. A nivel internacional

Quezada et al. (2022) nos mencionan que sus investigaciones se centraron en el análisis multitemporal de imágenes satelitales para determinar el estado de la deforestación en las Provincias de Pastaza y Orellana de la región amazónica del Ecuador, durante un periodo de 20 años desde el 2000 al 2020, dicho análisis se realizó utilizando imágenes satelitales mediante el proceso de clasificación de uso del suelo y cobertura vegetal, obteniendo una composición de mapas a través de los softwares de ENVI y ArcMap. En sus resultados, evidenciaron el desgaste de la cobertura vegetal y el cambio de uso del suelo, debido a la expansión de las fronteras agrícolas y urbanas. Álvarez et al. (2021) nos refieren que sus investigaciones fueron monitoreos de deforestación debido al cambio de uso en la zona centro de Hopelchén, Campeche - México, mediante el análisis multitemporal de imágenes satelitales. De acuerdo a sus resultados, se identificó un aumento del suelo desnudo en un 49.46%, lo cual se traduce en un aumento de la deforestación en la zona de estudio, principalmente a zonas de cultivos, las cuales a lo largo del tiempo dañan el suelo convirtiéndolos en suelo desnudo e infértil. También, nos mencionan que el haber utilizado recepción remota cumplió sus expectativas a gran escala.

Farfán et al. (2015) nos mencionan que el análisis jerárquico de intensidad de cambio de cobertura y uso de suelo es un marco cuantitativo de análisis espacial, que permite estimar los cambios en tres niveles de orden, intervalo de tiempo, categoría y transición, a partir de una matriz de cambio. El análisis de su estudio le permitió conocer en qué intervalo de tiempo la tasa anual general de cambio es más rápida, cuáles son las categorías más activas y cuáles son latentes. De acuerdo a sus resultados nos mencionan que se observó una mayor tasa anual de cambio entre 2000 y 2004 en comparación con el periodo 2004 y 2008. Esto se debe a la actividad ganadera como un factor promotor del proceso de deforestación.

2.1.2. A nivel nacional

Fuentes & Velasquez (2022) nos mencionan que el objetivo de su investigación sobre la pérdida de cobertura vegetal en el Distrito de Morales en San Martín, fue analizar la pérdida de cobertura vegetal. Por ello, el método que emplearon consistió en el análisis multitemporal de imágenes satelitales, mediante la técnica de clasificación

supervisada con el Software ArcGIS y los periodos estudiados fueron del 1987 al 1997, 1997 al 2007 y 2007 al 2017. En sus resultados se observaron cambios en la cobertura vegetal en el periodo de 1987 al 1997, con una pérdida de 948.42 ha; también, en el periodo de 1997 al 2007 hubo una reducción de 81.83 ha y finalmente en el periodo de 2007 al 2017 la pérdida fue de 59.26 ha. Ante esto, concluyeron que la cobertura vegetal del Distrito de Morales está experimentando pérdidas de la cobertura vegetal, siendo el principal factor el crecimiento demográfico.

Sánchez & Sánchez (2022), en su estudio indican que el tramo III del Corredor Vial Interoceánica-Sur (Puerto Maldonado – Inambari), es una de las áreas más impactadas de Madre de Dios, donde el paisaje ha sufrido una conversión abrupta por la intervención de la minería y la agricultura. En su investigación realizaron el análisis y modelado de los procesos de deforestación, para los periodos de 1999, 2013, 2019 y 2030. Además, sus imágenes fueron descargadas y procesadas mediante la plataforma Google Earth Engine, ENVI y ArcMap, mediante el algoritmo Random Forest. En sus resultados, mencionan que los cambios de cobertura y uso del suelo reportan una conversión de los bosques a causa de deforestación en un promedio del 81.54%.

Rojas et al. (2019) en su artículo de investigación nos mencionan que los bosques de la Amazonía peruana han experimentado importantes transformaciones desde mediados del siglo pasado. Por ende, este trabajo evaluó los cambios de cobertura y uso del suelo en la Provincia de Rodríguez de Mendoza, mediante los métodos de clasificación supervisada de máxima probabilidad e interpretación visual interdependiente de imágenes del satélite Landsat. Además, se evidenció que las altas concentraciones de pérdida de cobertura boscosa están próximas a la red vial e hídrica. Por ello, las principales causas de la pérdida de bosques fueron la actividad ganadera y la expansión agrícola migratoria a pequeña explotación, favorecidas por la accesibilidad de infraestructuras de transporte.

2.1.3. A nivel local

Bashi (2023), nos menciona que en el reporte del portal GEOBOSQUE desde el 2001 al 2021, se evidencia una pérdida de 17191 ha de bosques y que se mantiene 60943 ha de cobertura forestal. Además, destaca que la agricultura constituye la principal causa de deforestación, ya que esta actividad desempeña un papel crucial en la economía del distrito, siendo los cultivos de café, cítricos y piña fundamentales en la región; también, el cultivo de jengibre ha tomado relevancia durante los últimos años, teniendo un incremento de producción en el 2020. Por ello, en las encuestas realizadas a los jóvenes indican que hacen uso de los bosques para la producción agrícola como

uno de sus intereses, lo que sugiere que la deforestación con fines agrícolas se percibe como una necesidad actual. Por otro lado, la investigación enfoca el tema de restauración, adaptando la dinámica agrícola del territorio para efectos de sostenibilidad, el cual permite la coexistencia con el componente forestal mediante la promoción de sistemas agroforestales.

Atalaya (2023), señala en su investigación que los productores de café tienen un sistema intensivo convencional que están fuertemente asociados con la deforestación; esto hace que se amplíe sus áreas agrícolas y se intensifique la quema de los bosques. Además, en su resultado muestra que un 10% de las emisiones provienen del sector agrícola; sin embargo, el 55% de los productores han escogido el manejo orgánico para sus fincas y el 90% han adoptado el sistema agroforestal usando árboles maderables como sombra, con el fin de mitigar la deforestación. También, menciona que los caficultores aumentan sus áreas agrícolas a costa de la deforestación de los bosques, esta tendencia se asociada a otras actividades agropecuarias como el cultivo de cacao, palma aceitera, coca y la ganadería.

Bashi (2021) en su tesis nos menciona que los productores de café contrarrestaron la baja productividad de sus cultivos aumentando sus áreas agrícolas a través de la pérdida de bosques; según, las entrevistas realizadas a los caficultores, señalan que a partir del 2013 se vio fuertemente afectada sus cultivos por la Roya amarilla (*Hemilia vastatrix*), lo que causó una crisis ambiental, económica y social en el distrito. También, indican que hubo una expansión de las áreas de cultivo a zonas boscosas, es decir que hubo un incremento de deforestación para ampliar sus cultivos. Finalmente, se destaca que la falta de estudios específicos, propicia que haya un aumento significativo en la pérdida de biodiversidad debido a la intensificación de la agricultura, combinada con la deforestación y la degradación de sus ecosistemas.

2.2. Bases teóricas

2.2.1. Deforestación

La deforestación es un fenómeno que se ha ido manifestando de manera progresiva en los últimos años, teniendo como resultado una marcada disminución de la extensión global de la superficie terrestre. Esta problemática, alimentada por actividades como la tala indiscriminada y la expansión agrícola, ha alcanzado dimensiones alarmantes. Además de su impacto devastador en la pérdida de biodiversidad en los bosques naturales, este problema también conlleva consecuencias significativas para el cambio climático, contribuyendo a la emisión de gases de efecto invernadero y al desequilibrio ambiental a escala global. Asimismo, genera desafíos

específicos en los ecosistemas circundantes, teniendo un impacto negativo en su funcionalidad y salud (Sánchez & Sánchez, 2022).

2.2.2. Cobertura vegetal

Es la capa de vegetación que incluye una amplia gama de biomasa natural con diferentes características físicas y ambientales, que proveen al hombre servicios ambientales y satisfacen sus necesidades tales como despensa de alimentos, agua dulce, medicinas, materias primas, calidad de aire, regulación del clima, entre otras (Arellano Sánchez, 2020). Dichos elementos que cubren la superficie terrestre de origen natural o cultural son susceptibles de ser observados y medidos mediante fotografías aéreas, imágenes de satélite u otros sensores remotos (López, 2021).

2.2.3. Usos del suelo

Contribuyen a las acciones, actividades e intervenciones llevadas a cabo por individuos sobre un tipo específico de superficie (Fuentes & Velasquez, 2022). El cambio de uso del suelo es uno de los componentes principales en el deterioro a escala global, regional y local del territorio. Además, está documentado como el segundo problema ambiental a nivel global. Durante la última década, las actividades humanas y la demanda por bienes y servicios han generado presión sobre los recursos naturales con grandes impactos, la mayoría de ellos negativos, los cuales son difíciles de revertir (Abad-Auquilla, 2020).

2.2.4. Teledetección

La teledetección es una herramienta que nos ayuda a obtener datos de la superficie terrestre desde sensores instalados en plataformas espaciales. Para realizar distintos estudios como es el análisis del cambio de los ecosistemas, el cual representa un aspecto clave para evaluar los impactos producidos por la desertificación. Esta actividad antrópica afecta a suelos con gran inestabilidad y produce respuestas de cambio abruptas e irreversibles (Hernández-Clemente & Hornero, 2021).

2.2.5. Análisis multitemporal

Son análisis de tipo espacial realizados mediante la comparación de las coberturas interpretadas de dos o más imágenes satelitales, fotografías aéreas o mapas de un mismo lugar en diferentes periodos de tiempo (años, meses, días). Este análisis va a permitir evaluar los cambios en la situación de las coberturas que han sido clasificadas, notando así su evolución ya sea por causas antropogénicas o naturales (Gonzales, 2019).

Las técnicas empleadas en el análisis multitemporal difieren según si la imagen que se utiliza es continua o categorizada. En el caso de imágenes continuas, se requiere

el uso de enfoques cuantitativos, que incluyen métodos como la detección de diferencias, análisis de regresión, componentes principales, entre otros. En contraste, si la imagen es categorizada, lo que significa que ya ha sido clasificada previamente, la técnica utilizada se basa en la construcción y el análisis de tablas de contingencia (Saucedo, 2023).

2.2.6. Sistemas de Información Geográfica (SIG)

Es la agrupación de datos, procedimientos, hardware, software y recursos humanos que se utilizan para trabajar con datos geográficos, que generalmente se aplican a sistemas informáticos, los cuales son utilizados entre otras cosas para la investigación en ciencias de la tierra. Además, su aplicación se da para resolver problemas de gestión territorial y de recursos naturales, asuntos relacionados con el medio ambiente, ciencias de la tierra, navegación, arquitectura, entre otros estudios más (Radicelli et al., 2019).

2.2.6.1. Componentes de un SIG

- **Datos:** Se refiere a la información geográfica que se utiliza en el SIG, como mapas, imágenes satelitales, datos de sensores remotos, información de campo, entre otros.
- **Procedimientos:** Son los métodos y técnicas utilizados para capturar, almacenar, analizar y visualizar datos geográficos dentro del SIG. Esto puede incluir la manipulación de datos, análisis espacial, modelado y generación de informes.
- **Hardware:** Son los componentes físicos del sistema, como computadoras, dispositivos de entrada y salida, unidades de almacenamiento y dispositivos de visualización, necesarios para ejecutar el software del SIG y procesar los datos.
- **Software:** Consiste en las aplicaciones informáticas diseñadas específicamente para la manipulación de datos geográficos. Este software proporciona herramientas para la captura, almacenamiento, análisis, modelado y visualización de datos espaciales.
- **Recursos humanos:** Son las personas involucradas en el uso y mantenimiento del SIG, incluidos los técnicos, analistas, científicos de datos y gestores de información geográfica que trabajan con el sistema.

2.2.7. Sensores remotos y plataformas

Los dispositivos conocidos como sensores remotos tienen la capacidad de obtener datos de la superficie de la tierra sin estar en contacto directo con ella. Se montan sobre distintas plataformas que pueden operar desde el aire, como aviones y drones, o desde el espacio, como es el caso de los satélites. En esta última tenemos a los satélites Landsat o Sentinel, que ofrecen una cobertura global y una mayor repetitividad temporal, lo que permite monitorear cambios en la superficie terrestre a lo largo del tiempo, sin embargo, su resolución espacial suele ser menor que la de las plataformas aéreas (Caita & Castañeda, 2021).

2.2.7.1. Landsat 8

Landsat 8, forma parte del programa Landsat, una serie de satélites de observación terrestre que inició en 1972, manejado por la NASA y el Servicio Geológico de Estados Unidos (USGS), su lanzamiento se dio el 11 de febrero de 2013 (Requelme, 2019). Este programa ha sido fundamental para el monitoreo continuo de la superficie terrestre (Quispe & Cáceres, 2020). Además, son utilizados en diversos estudios debido a que son datos de acceso libre (Saucedo, 2023). Este satélite, está conformado por dos sensores que captan las imágenes satelitales a través de 11 bandas espectrales, de las cuales las bandas del sensor OLI (Operational Land Imager), están conformadas del 1 al 9, teniendo una resolución espacial de 30 metros, excepto la banda 8 que tiene una resolución de 15 metros, mientras que las bandas del sensor TIRS (Thermal Infrared Sensor) son el 10 y 11, teniendo una resolución espacial de 100 metros (Bueno, 2019).

Tabla 2

Características de Landsat 8

Bandas	Sensor	Longitud de onda (μm)	Resolución Espacial (m)	Resolución Radiométrica
1.Ultra azul (costero/aerosol)	OLI	0.43 – 0.45	30	16 bits
2.Azul	OLI	0.45 – 0.51	30	16 bits
3.Verde	OLI	0.53 – 0.59	30	16 bits
4.Rojo	OLI	0.64 – 0.67	30	16 bits
5.Infrarrojo Cercano (NIR)	OLI	0.85 – 0.88	30	16 bits

6.Onda Corta				
Infrarroja (SWIR)	OLI	1.57 – 1.65	30	16 bits
1				
7.Onda Corta				
Infrarroja (SWIR)	OLI	2.11 – 2.29	30	16 bits
2				
8.Pancromática	OLI	0.52 – 0.90	15	16 bits
9.Cirrus	OLI	1.36 – 1.38	30	16 bits
10.Infrarrojo térmico 1	TIRS	10.60 – 11.19	100 * (30)	16 bits
11.Infrarrojo térmico 2	TIRS	11.50 – 12.51	100 * (30)	16 bits

Fuente: Janampa & Ponce (2022).

Tabla 3

Combinación de bandas para Landsat 8

Descripción	Combinación (RGB)
Color natural	4, 3, 2
Falso color (urbano)	7, 6, 4
Color infrarrojo (vegetación)	5, 4, 3
Agricultura	6, 5, 2
Penetración atmosférica	7, 6, 5
Vegetación saludable	5, 6, 2
Tierra / agua	5, 6, 4
Natural con remoción atmosférica	7, 5, 3
Infrarrojo de onda corta	7, 5, 4
Análisis de vegetación	6, 5, 4

Fuente: Janampa & Ponce (2022).

2.2.7.2. Sentinel-2

El satélite Sentinel-2, forma parte del programa Copernicus de la Agencia Espacial Europea (ESA), está conformado por dos satélites: Sentinel-2A y Sentinel-2B con una resolución de 10 metros en el visible y disponibles para descarga de manera gratuita. El lanzamiento del Sentinel 2A se realizó el 23 de junio del 2015 y el del Sentinel-2B el 7 de marzo del 2017 (Requelme, 2019).

Estos satélites están equipados con un instrumento óptico multiespectral llamado MSI (Multispectral Instrument), que puede capturar imágenes en 13 bandas espectrales diferentes, desde el visible y el infrarrojo cercano hasta el infrarrojo de onda corta. Las imágenes tienen una resolución espacial de 10 metros para las bandas del espectro visible e infrarrojo cercano, 20 metros para algunas bandas del infrarrojo de onda corta y 60 metros para otras bandas especializadas (Verdugo, 2022).

Tabla 4

Bandas del Satélite Sentinel-2

Sentinel-2	Longitud de onda (μm)	Resolución (m)
Banda 1 - Aerosol	0.43 – 0.45	60
Banda 2 - Blue	0.45 – 0.52	10
Banda 3 - Green	0.54 – 0.57	10
Banda 4 - Red	0.65 – 0.68	10
Banda 5 - Red edge 1	0.69 – 0.71	20
Banda 6 - Red edge 2	0.73 – 0.74	20
Banda 7 - Red edge 3	0.77 – 0.79	20
Banda 8 - Near Infrared (NIR) 1	0.78 – 0.90	10
Banda 8A - Near Infrared (NIR) 2	0.85 – 0.87	20
Banda 9 - Water vapour	0.93 – 0.95	60
Banda 10 - Cirrus	1.36 – 1.39	60
Banda 11 - SWIR 1	1.56 – 1.65	20
Banda 12 - SWIR 2	2.10 – 2.28	20

Fuente: Alonso (2020).

2.2.8. Software para SIG

2.2.8.1. Arcmap

Arcmap es el programa central que forma parte de ArcGIS Desktop junto con ArcCatalog y ArcToolbox que fueron desarrollados por Esri (Environmental Systems Research Institute). Constituyen uno de los mejores sistemas SIG para el análisis y procesamiento de datos espaciales. Entre las principales funciones de esta aplicación están: creación y edición de mapas, análisis espacial, gestión de datos geográficos y cartografía temática (Environmental Systems Research Institute (ESRI, 2021).

2.2.8.2. Plataforma de R y RStudio

R es una plataforma que funciona como un lenguaje de programación especializado para análisis de datos, es de fuente abierta (Open Source) y de uso gratuito. Fue creado en 1991 por Ross Ihaka y Robert Gentleman en la Universidad de Auckland. En la actualidad R ha alcanzado un gran éxito debido a que las herramientas esenciales para su funcionamiento están disponibles para diversos sistemas operativos: Linux, Windows y Mac; además de eso cuenta con una comunidad de usuarios activos que con el tiempo han ido contribuyendo con la interfaz de R. Por otro lado, RStudio es un entorno de desarrollo integrado (IDE) que maneja R haciéndolo más cómodo de usar, ofreciendo un entorno más organizado que permite ver el código, la consola, gráficos, datos y otros recursos en una sola ventana, para así poder escribir y ejecutar códigos fácilmente (Verdugo, 2022).

2.2.9. Resoluciones de imágenes satelitales

La resolución va a depender de la plataforma espacial y del sensor de donde se obtienen las imágenes satelitales, el uso de estas resoluciones también va a variar de acuerdo a las necesidades del estudio. Por ello es necesario determinar el tipo de resolución que se necesita para elegir el sensor más adecuado (Verdugo, 2022).

2.2.9.1. Resolución Espacial

La resolución espacial describe el nivel de detalle con el que se observan los objetos dentro de una imagen satelital. Para medir esto se utiliza el pixel, que es la unidad mínima representada por un cuadradito que contiene información de la imagen, de esta manera un conjunto de píxeles ordenados en filas y columnas conforman una imagen completa. Se clasifican de acuerdo:

- **Alta:** con un tamaño de píxel de 0.5 – 4.0 m.
- **Media:** con un tamaño de píxel de 10 – 60 m.
- **Gruesa:** con un tamaño de píxel de 100 – 1000 m.
- **Muy gruesa:** con un tamaño de píxel de 10 – 50 km.

2.2.9.2. Resolución Espectral

La resolución espectral hace referencia al número de bandas del espectro electromagnético que han sido detectadas por el sensor, y los anchos de estas bandas deberían ser lo suficientemente estrechos para identificar mejor características específicas de la imagen. La clasificación de los sensores remotos espaciales será de acuerdo a la cantidad de bandas que capturen, siendo estos:

- **Pancromáticas:** una banda (estas tienen mayor resolución espacial).

- **Multiespectral:** capturan pocas bandas, entre 4 – 7.
- **Hiperespectrales:** decenas o centenas de bandas.
- **Ultraespectrales:** con miles de bandas.

2.2.9.3. Resolución Radiométrica

La resolución radiométrica describe la capacidad de un sensor para diferenciar pequeñas variaciones en la radiación espectral que registró, en concreto se refiere a cuántos tonos registra un sensor en una imagen. Esta resolución se mide en bits, ya que cada imagen se guarda en bytes digitalmente, un byte equivale a 8 bits, lo que significa que se combinen «0» y «1» en 8 espacios lo que equivale a 256 posibilidades. A mayor número de bits mejor será la resolución radiométrica donde se tendrán más variaciones en la imagen, viendo esto se pueden clasificar en:

- Resolución radiométrica de **8 bits** puede distinguir 256 niveles (2^8).
- Resolución radiométrica de **11 bits** puede distinguir 2048 niveles (2^{11}).
- Resolución radiométrica de **16 bits** puede distinguir 65536 niveles (2^{16}).

2.2.9.4. Resolución Temporal

La resolución temporal indica la frecuencia con la que el sensor captura datos o información de una misma área, esto va a depender de factores que influyen en la órbita del satélite como su altura, velocidad y declinación. Una mejor resolución será la que puede tomar imágenes de la misma área varias veces al día, ya que el mundo está siempre en constantes cambios como el movimiento de nubes, el crecimiento de cultivos, la propagación de incendios forestales, o las mareas. Generalmente los sensores que tienen mejor resolución espacial tienen menor resolución temporal, como por ejemplo la serie Landsat que ofrece imágenes cada 16 días. Sin embargo, existen excepciones como el satélite Sentinel-2 de la Agencia Espacial Europea (ESA) que toma imágenes cada 2 a 5 días con una resolución espacial entre 10 y 60 m.

2.2.10. Preprocesamiento de Imágenes Satelitales

2.2.10.1. Correcciones geométricas

Es un proceso donde se aplican transformaciones matemáticas a la imagen para ubicar correctamente los píxeles con sus ubicaciones reales, mediante una proyección cartográfica específica y un sistema de coordenadas asociado. Esto es necesario para poder utilizar las imágenes de manera confiable en diversos estudios que requieran una alta precisión espacial, ya que pueden

verse afectados por factores como la curvatura de la tierra, la inclinación del satélite, el movimiento del sensor y las distorsiones causadas por la topografía (Bueno, 2019).

2.2.10.2. Correcciones radiométricas

Esta corrección se aplica para ajustar las diferencias en la radiancia registrada por los sensores debido a anomalías causadas por el sistema del sensor, la calibración, efectos de la iluminación, la atmósfera, el ángulo del sol, etc. Esto implica por una parte la restauración de líneas o píxeles perdidos y por otra la corrección del bandeo de la imagen, de esta manera se garantiza que los valores en la imagen representen con exactitud las propiedades de la superficie terrestre. Esta corrección es necesaria en estudios cuantitativos como la estimación de la concentración de clorofila en cuerpos de agua, la detección de incendios forestales, y el monitoreo de la vegetación (Universidad de Murcia, 2019).

2.2.10.3. Correcciones atmosféricas

Este tipo de corrección se utiliza para eliminar o minimizar las distorsiones introducidas por la atmósfera al momento de que el sensor capture los valores de radiancia de la superficie, esto sucede porque la luz es reflejada por la superficie terrestre y pasa a través de la atmósfera para ser capturada por los sensores del satélite, es ahí cuando pueden interferir partículas y gases que puedan alterar los colores y la intensidad de la imagen capturada. Para corregir esto se utilizan algoritmos y modelos que tienen en cuenta variables como la densidad del aire, la cantidad de vapor de agua, aerosoles y la geometría del sol-satélite; de esta manera los datos se ajustan para que representen lo más real posible a las características de la superficie de la Tierra (Bueno, 2019).

2.2.11. Técnicas de clasificación de imágenes satelitales

2.2.11.1. Clasificación supervisada

Es un proceso que requiere el conocimiento de la zona de estudio, adquirido por experiencia previa o por la realización de un trabajo de campo para poder interpretar y delimitar sobre la imagen, áreas suficientemente representativas, denominadas áreas o regiones de interés que compondrán la leyenda (Saucedo, 2023). En esta misma temática, Torre & Rivas (2019) mencionan que los pasos básicos para realizar una clasificación supervisada, son los siguientes:

- **Etapa de entrenamiento:** Durante esta fase, el analista selecciona zonas de entrenamiento que sean representativas y crea una representación numérica de las características espectrales de cada tipo de cobertura del suelo en una escena específica.
- **Etapa de clasificación:** Se asigna una categoría específica de acuerdo a su mayor similitud a cada píxel, siguiendo la leyenda. Si un píxel no es lo suficientemente parecido, se clasificará como "desconocido".
- **Etapa de análisis de precisión y verificación de resultados:** La evaluación de la precisión de una clasificación se refiere al nivel de acuerdo entre las categorías asignadas por el clasificador y los datos recolectados en el terreno. Esta evaluación proporciona una estimación más precisa de los errores, siempre y cuando la muestra de píxeles sea adecuada.

2.2.11.2. Clasificación no supervisada

Este clasificador emplea algoritmos para agrupar píxeles con características espectrales similares en clústeres naturales presentes en la imagen. En este procedimiento, no hay intervención directa por parte del analista, y no se utilizan áreas de entrenamiento. Aunque los resultados no son altamente precisos, este paso es necesario ya que permite al intérprete vincular tipos de cobertura a los clusters generados, utilizando información adicional (Torre & Rivas, 2019). Cabe mencionar, que la clasificación no supervisada en ArcGIS no asigna prioridades a las clases; en su lugar, se basa en probabilidades. Como resultado, se obtiene una imagen de píxeles reasignados, creando un archivo que contenga la descripción de las firmas de las clases. Para llevar a cabo este proceso, se emplea la herramienta de clasificación no supervisada llamada "Iso Cluster Unsupervised Classification" (Torre & Rivas, 2019).

2.2.12. Metodología Corine Land Cover

La metodología CORINE (Coordination of information of the Environment) LAND COVER (CLC) es el sistema de clasificación de coberturas de la tierra más común a nivel global. Fue desarrollado por la Unión Europea en 1985, donde surgió a partir de la recolección de datos de imágenes satelitales Landsat. La Agencia Europea de Medioambiente (EEA) establece el objetivo de esta metodología, el cual es proporcionar datos cualitativos y cuantitativos sobre los cambios en el uso y la cobertura del suelo (Vargas, 2020).

El sistema CLC contiene 44 clases de cobertura que se encuentran clasificados en 3 niveles, donde las cinco categorías del nivel uno son superficies artificiales, áreas

agrícolas, bosques y áreas seminaturales, humedales y cuerpos de agua. Asimismo, esta metodología es aplicada en muchos países debido a su estandarización, ya que tiene una jerarquización y leyenda que son fácilmente adaptables para cada región además de ser un sistema fácil de entender y manejar para los diferentes usuarios (Bueno, 2019).

2.2.13. Modelos de Aprendizaje supervisado

El aprendizaje supervisado es una subcategoría del machine learning, en el cual se usan algoritmos que son entrenados iterativamente por un conjunto de datos etiquetados, con el objetivo de que estos algoritmos que conforman un modelo puedan realizar clasificaciones de datos o predicciones de resultados (Coaquira, 2023).

2.2.13.1. Random Forest (RF)

El modelo Random Forest o también llamado Bosques Aleatorios, es un algoritmo de aprendizaje que maneja problemas de clasificación y regresión. Este modelo está conformado por múltiples árboles de decisión que se combinan para llegar a un resultado final, cada uno de los árboles es entrenado con una muestra aleatoria que proviene de los datos de entrenamiento originales, los cuales después emiten una predicción. El resultado final se obtendrá del promedio o la mayoría de estas predicciones (Saucedo, 2023).

2.2.13.2. Support Vector Machine (SVM)

El modelo Support Vector Machine o también llamado Máquina de Vectores de Soporte, es un algoritmo de aprendizaje relacionado mayormente a problemas de clasificación y regresión. Este modelo utiliza algoritmos que clasifican los datos al encontrar un hiperplano óptimo donde se maximiza la distancia entre clases, con el objetivo de encontrar la mejor frontera de decisión. Su aplicación es ideal en espacios de alta dimensión y tiene la capacidad para clasificar datos que no han sido vistos en el entrenamiento (Valladares, 2023).

2.2.13.3. Naive Bayes (B)

Naive Bayes o Clasificador Bayesiano Ingenuo es un modelo constituido por algoritmos clasificadores probabilísticos que están basados en el Teorema de Bayes, el cual utiliza principios de probabilidad para realizar tareas de clasificación. Este modelo clasifica asumiendo que todas las variables de un objeto son independientes entre sí, lo cual lo hace altamente eficaz en la categorización de textos. Sin embargo, no es recomendable usarlo en datos donde las características están altamente relacionadas (Coaquira, 2023).

2.2.13.4. Decision Tree (D)

Decision Tree o árbol de decisión es un modelo usado en tareas de clasificación o regresión, el cual está conformado por algoritmos de aprendizaje supervisado no paramétrico. Este modelo presenta la estructura jerárquica de un árbol, donde los datos se van dividiendo en conjuntos más pequeños en cada rama, con el fin de maximizar la separación entre clases. Este tipo de clasificación identifica puntos de división óptimos y los repite hasta que todos los datos tengan clases específicas, de esta manera se forma una representación fácil de entender, permitiendo ver la manera en cómo se tomó una decisión (Fajardo, 2023).

2.2.14. Matriz de confusión

Es una herramienta que evalúa el desempeño de un modelo de aprendizaje supervisado en relación a la clasificación. Está diseñada en forma de tabla, donde las columnas representan las clases reales que se verificaron en campo y las filas son las clases obtenidas en gabinete. Asimismo, la diagonal que atraviesa la tabla contiene los datos que fueron clasificados correctamente, mientras que los que están afuera presentaron diferencias leves o significativas, esto representa cuán bien está clasificando el modelo, permitiéndonos ver los errores y aciertos que están teniendo los algoritmos (Bueno, 2019).

2.2.14.1. Índice de Kappa

El índice de Kappa está relacionado con la matriz de confusión, debido a que este se utiliza para evaluar la precisión de la clasificación comparando los diferentes modelos de aprendizaje. Dentro de la tabla se encuentran valores entre 0 y 1, si el valor es más cercano a 1 el grado de correlación es mayor y si es más próximo a 0, será menor (Janampa & Ponce, 2022).

Tabla 5

Valoración del Índice de Kappa

Índice de Kappa	Fuerza de concordancia
0.00	Pobre
0.01 – 0.20	Leve
0.21 – 0.40	Aceptable
0.41 – 0.60	Moderado
0.61 – 0.80	Considerable
0.81 – 1.00	Casi perfecto

Fuente: Janampa & Ponce (2022).

2.2.15. Proyección con el modelo de la regresión exponencial

La regresión exponencial es un método estadístico que se utiliza para determinar la ecuación de una función exponencial que se adapte de manera óptima a un conjunto de datos, lo que permite realizar estimaciones de valores futuros, para esto el ajuste de datos se realiza mediante el método de mínimos cuadrados. En el caso de la regresión exponencial negativa es un modelo no lineal que permite ajustar datos que siguen una tendencia de decaimiento exponencial (Abramson, 2022). Su fórmula general es:

$$Y = a * e^{-b*x} \dots\dots\dots(3)$$

Donde:

Y: es la variable dependiente (el área de bosque en hectáreas).

x: es la variable independiente (el tiempo expresado en términos relativos al año inicial).

a: es el parámetro que representa el valor inicial de Y (el área de bosque en el 2016).

b: es la tasa de decaimiento exponencial.

e: es la base de los logaritmos naturales (aproximadamente ≈ 2.718).

2.2.16. Mapa Nacional de ecosistemas del Perú

Los ecosistemas son conjuntos de seres vivos, tales como plantas, animales y microorganismos que interactúan entre sí y con el entorno que los rodea como el suelo, el agua y el clima. Esta diversidad de ecosistemas forma parte del patrimonio natural de la nación, pero con el paso del tiempo se han ido degradando debido al cambio climático y a la actividad humana, disminuyendo así los servicios y bienes que nos brindan estos ecosistemas que influyen en nuestra calidad de vida (Aranda & Vilca, 2022).

Ante esta situación en el año 2015 el Ministerio del Ambiente formó un equipo para la elaboración del Mapa Nacional de Ecosistemas, el cual se culminó en luego de tres años. En este mapa se logró identificar y mapear 36 ecosistemas continentales del territorio nacional: 11 para la región de selva baja o tropical, 3 para la selva alta o región yunga, 11 para la región andina, 9 para la región costa y dos 2 ecosistemas acuáticos. Esta herramienta contribuye a la adecuada gestión del territorio, manejo de los recursos naturales y elaboración de instrumentos, planes, proyectos de gestión ambiental (MINAM, 2019).

CAPÍTULO III

METODOLOGÍA Y TÉCNICAS DE INVESTIGACIÓN

3.1. **Ámbito de estudio**

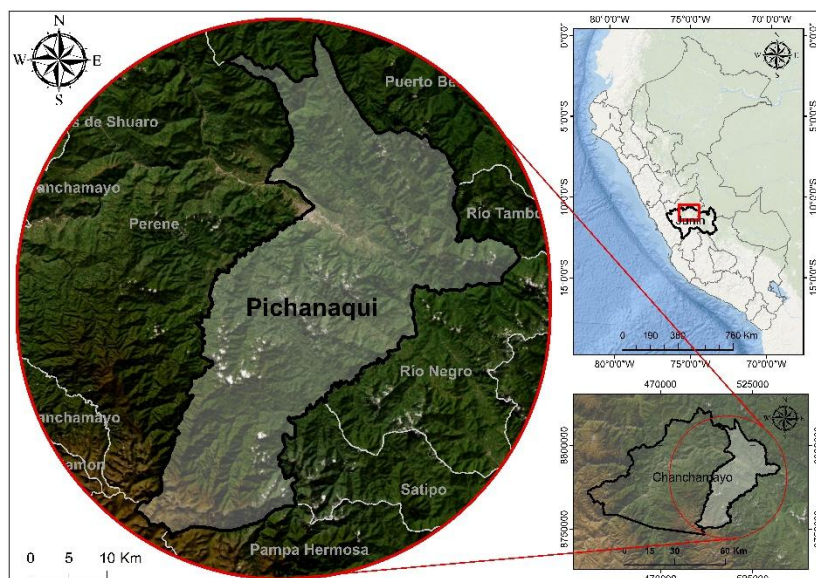
El ámbito de estudio se sitúa en el distrito de Pichanaqui (UTM 514650.30 m Este y 8789591.90 m Norte), provincia de Chanchamayo, región Junín. Tiene una extensión territorial de 124 mil hectáreas y una población de 67929 habitantes, limita por el Norte con el distrito de Puerto Bermúdez, por el Sur con el distrito de Vítoc y Pampa Hermosa, por el Este con el distrito de Río Tambo, Río Negro y Satipo y por el Oeste con el distrito de Perene (Municipalidad de Pichanaqui, 2018).

Este distrito cuenta con carreteras troncales que conectan las microcuencas, ramales primarios y secundarios. Tiene grandes recursos hídricos, como el río Perené y el río Pichanaqui, también existen quebradas formadas por aguas superficiales de arroyos y riachuelos. El territorio se encuentra entre los 422 m.s.n.m. hasta los 4276 m.s.n.m, lo cual genera diversos microclimas que están asociados a tipos de bosque y a determinadas especies de flora y fauna (Municipalidad de Pichanaqui, 2018).

Asimismo, Pichanaqui presenta un clima tropical húmedo y cálido, su temperatura está entre los 25 a 30 °C en la parte baja y a partir de los 1200 msnm varía entre los 15 y 25 °C, las precipitaciones se concentran más entre diciembre a marzo, superando los 200 mm por mes, este exceso ocasiona problemas de erosión de los suelos y crecidas de los ríos. La topografía presenta terrenos accidentados con pendientes pronunciadas y en varias partes se tiene terrenos bajos donde los suelos son fértiles (Municipalidad de Pichanaqui, 2018).

Figura 1

Delimitación geográfica de la zona de estudio



3.2. Tipo, nivel y diseño de investigación

3.2.1. Tipo de investigación

El tipo de investigación es básico (Hernández-Sampieri, R. & Mendoza, 2018), porque genera conocimientos sobre la dinámica de la deforestación a través de los cambios de cobertura y uso del suelo mediante el análisis de las imágenes satelitales analizadas en el distrito de Pichanaqui en un periodo de nueve años y realizar una proyección al 2030.

3.2.2. Nivel de investigación

La investigación es de nivel descriptiva (Janampa & Ponce, 2022), ya que aborda la presentación de datos en relación con la evolución de un fenómeno en un determinado periodo, proporcionando una visión detallada de la situación que se viene analizando. Además, se cuantificó el área deforestada desde el 2016 hasta el 2024 a partir de los cambios de cobertura y usos del suelo en el distrito de Pichanaqui. Este enfoque resulta esencial para identificar las causas de deforestación y facilitar la proyección a futuro sobre la pérdida de bosques al 2030.

3.2.3. Diseño de investigación

El diseño de la investigación es no experimental (Janampa & Ponce, 2022), ya que implica la observación sistemática de los cambios anuales a lo largo de un periodo. Este enfoque incluye la recopilación de datos mediante el procesamiento de imágenes satelitales a través del software ArcGIS y RStudio, permitiendo así un análisis detallado de la deforestación que se genera a partir de los cambios de cobertura y usos del suelo evaluados en el distrito de Pichanaqui.

3.3. Población y muestra

3.3.1. Población

En la evaluación de la deforestación mediante teledetección, se tomó como población a toda la cobertura terrestre del distrito de Pichanaqui, que comprende una extensión territorial de 124 mil hectáreas.

3.3.2. Muestra

En esta investigación, se aplicó un muestreo no probabilístico por conveniencia, adecuado para abarcar la extensa área de estudio. Para ello, se realizaron 23478 puntos de muestreo en gabinete, distribuidos entre las siete clases de coberturas identificadas según la metodología Corine Land Cover adaptada para Perú (MINAM, 2015). De estos puntos, solo se empleó el 10% para la prueba en los diferentes modelos de clasificación, con el fin de identificar el modelo más óptimo; además, el 2024 se utilizó como referencia para la validación en campo de las coberturas identificadas.

Tabla 6*Clases de cobertura y uso del suelo identificadas en el área de estudio*

Nivel I	Nivel II	Nivel III	Cobertura y Uso del Suelo
1. Áreas artificializadas	1.1. Áreas urbanizadas	1.1.1. Tejido urbano continuo	Áreas urbanizadas
		1.1.2. Tejido urbano discontinuo	
2. Áreas agrícolas	2.2. Cultivos permanentes	2.2.1. Cultivos permanentes herbáceos	Áreas agrícolas
		2.2.2. Cultivos permanentes arbustivas	
3. Bosques y áreas mayormente naturales	3.1. Bosques	2.2.3. Cultivos permanentes arbóreos	Bosque
		3.1.1. Bosque denso bajo	
3. Bosques y áreas mayormente naturales	3.1. Bosques	3.1.3. Bosque denso alto	Bosque
		3.1.4. Bosque abierto alto	
3. Bosques y áreas mayormente naturales	3.1. Bosques	3.1.5. Bosque fragmentado	Bosque
		3.2. Bosques plantados	
3. Bosques y áreas mayormente naturales	3.2. Bosques plantados	3.2.1. Plantación Forestal	Vegetación
		3.3. Áreas con vegetación herbácea y/o arbustivo	
3. Bosques y áreas mayormente naturales	3.3. Áreas con vegetación herbácea y/o arbustivo	3.3.3. Vegetación secundaria o en transición	Vegetación
		3.3.4. Vegetación arbustiva / herbácea	
5. Superficies de agua	5.1. Aguas continentales	2.3. Pastos	Áreas arenosas
		3.4. Áreas sin o con poca vegetación	
5. Superficies de agua	5.1. Aguas continentales	3.4.1. Áreas arenosas naturales	Áreas arenosas
		3.4.3. Tierras desnudas	
5. Superficies de agua	5.1. Aguas continentales	3.4.4. Áreas quemadas	Suelo desnudo
		5.1.1. Ríos (50 m)	Aguas continentales
5.1.2. Lagunas, lagos y ciénagas naturales permanentes			

Fuente: Elaborado a partir del Mapa Nacional de Cobertura Vegetal (MINAM, 2015).

Posteriormente, se llevaron a cabo los puntos de validación *in situ* de las clases identificadas según el modelo Random Forest (RF), que resultó ser el más óptimo en nuestro estudio, en conjunto con el Mapa Nacional de Ecosistemas del Perú (MINAM,

2019). La selección del número de muestras para el trabajo de campo se realizó utilizando la (Ecuación 1) (MINAM, 2014; Leiva-Godínez, 2023):

$$n = \frac{z^2 * p * (1 - p)}{E^2} \dots\dots\dots(1)$$

Donde:

n: es el tamaño de la muestra.

z: es el nivel de confianza deseado de 1.96 para un 95% de confianza.

p: es la proporción estimada de 0.8 para un 80% de precisión esperada.

E: es el margen de error de 0.05 o 5%.

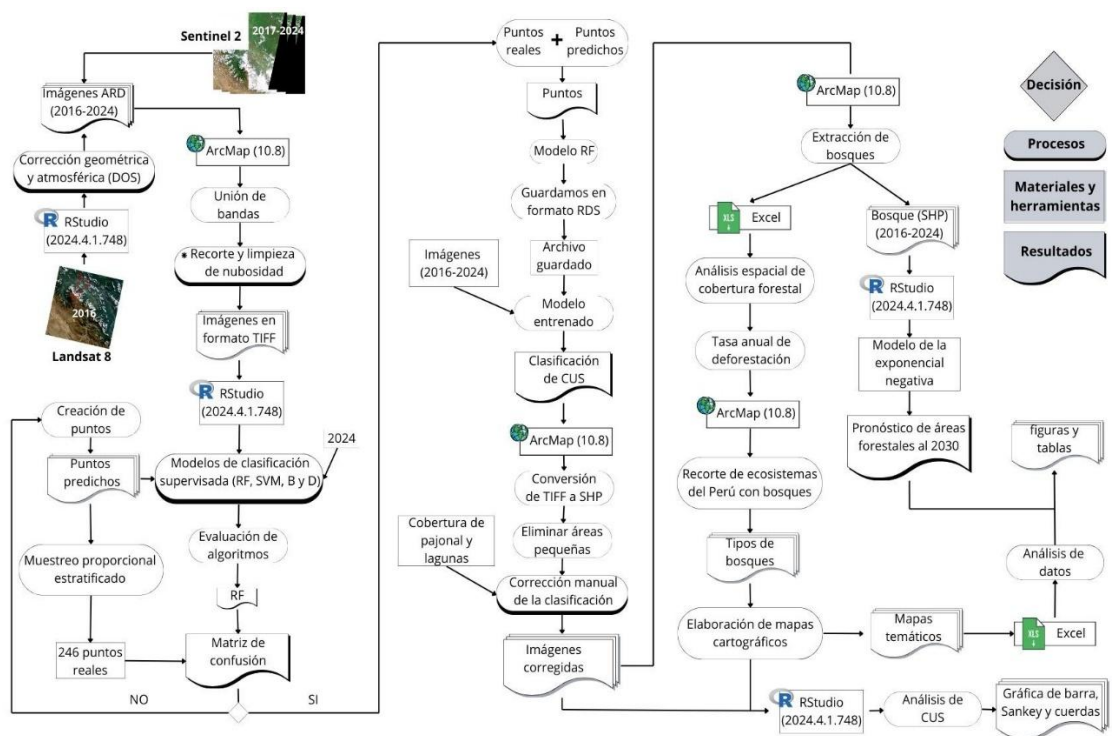
$$n = \frac{1.96^2 * 0.8 * (1 - 0.8)}{0.05^2} = 246$$

El total de los puntos de muestreo es de 23725, resultado de la suma de los 23478 puntos generados en gabinete y los 246 puntos reales recolectados en campo más la adición de un punto en la cobertura de nubes, con el fin de tener todas las clases de cobertura y usos del suelo en las categorías. Este conjunto de puntos fue utilizado en la clasificación supervisada, desde el 2016 al 2024.

3.4. Procedimientos, técnicas e instrumentos de recolección de datos

Figura 2

Flujograma del procedimiento metodológico



3.4.1. Procedimientos de recolección de datos

a. Recopilación de imágenes satelitales

La recopilación de imágenes satelitales se realizó a partir de los satélites Landsat 8 y Sentinel-2, ambos gestionados por programas de observación de la Tierra. Para las imágenes satelitales de Landsat 8 se utilizó la plataforma de la agencia de investigación del Servicio Geológico de los Estados Unidos (USGS), la cual es de acceso libre y descarga gratuita. Asimismo, se seleccionaron 4 imágenes satelitales del 2016 de la Colección 2, Nivel 1 debido a su mayor precisión y fiabilidad. En cada imagen, se aplicó criterios específicos como el porcentaje de nubosidad y la estacionalidad.

Por otro lado, desde el 2017 hasta 2024 se descargaron 48 imágenes satelitales de Sentinel-2, las cuales fueron obtenidas de manera gratuita a través de la plataforma Copernicus Browser, desarrollada por la Agencia Espacial Europea (ESA). Estas imágenes provienen del instrumento multiespectral MSI (MultiSpectral Instrument), procesadas al nivel L2A, donde han sido corregidas atmosféricamente, lo que incluye la corrección por la dispersión de moléculas de aire y los efectos de absorción y dispersión de gases atmosféricos, como el ozono, el oxígeno y el vapor de agua. En estas imágenes, se han corregido los efectos causados por las partículas de aerosol. Por esta razón, se consideran productos ARD (Analysis Ready Data), es decir, datos satelitales pre-procesados que están listos para su análisis inmediato, sin necesidad de realizar correcciones adicionales (ESA, 2024).

b. Criterios de selección de imágenes

Las imágenes satelitales se descargaron anualmente de abril a octubre, durante los meses más secos, cuando la irradiación solar es más intensa y la duración de la luz solar es mayor (Solargis, 2024). Esto asegura una mejor visualización de las características de las imágenes y la coherencia de los datos recopilados (Cotoa Hernández, 2020). Además, la presencia de nubes en las imágenes satelitales no excedió el 20% del área total de cada imagen.

c. Corrección atmosférica y geométrica de Landsat 8

En R, se utilizaron las librerías `terra` y `RStoolbox` para cargar los metadatos de la imagen satelital y apilar sus bandas con la función `stack Meta()`, seleccionando específicamente las bandas 4 a 7. Posteriormente, se aplicó la corrección atmosférica con el método Dark Object Subtraction (DOS) para

ajustar los valores de reflectancia. Por último, se realizó la corrección geométrica en ArcGIS, ajustando la proyección a WGS 1984 UTM Zona 18S.

d. Unión de bandas de las imágenes satelitales

En ArcGis, se combinaron las bandas a través de la herramienta Composite Bands. Dado que el área de estudio abarca tres imágenes satelitales con respecto a Sentinel-2, se unieron con la herramienta To New Raster.

e. Extracción del área de estudio

En ArcGis, cargamos el shape del distrito de Pichanaqui y con el raster unido recortamos el área de estudio con la herramienta Raster Processing.

f. Reducción de nubosidad

En ArcGIS, creamos un shapefile en formato polígono para las nubes. Luego, con la herramienta Erase para eliminar el polígono de nubes del área de estudio. Posteriormente, utilizamos la herramienta Clip para recortar el ráster que contiene las nubes utilizando el polígono de eliminación creado. Repetimos el proceso de recorte para el ráster limpio, usando el polígono de nubes como referencia. Finalmente, para unir los rústeres modificados y corregir cualquier desfase o valores faltantes creamos un nuevo raster dataset usando Create Raster Dataset y unimos los rústers usando la herramienta Mosaic, para guardar el resultado en el dataset creado previamente.

g. Creación de puntos de muestreo

En ArcGis, creamos un shapefile, en formato de punto.

h. Ampliación de modelos de clasificación supervisada

En R, se emplearon cuatro algoritmos de machine learning, estos modelos fueron Random Forest (RF), Support Vector Machine (SVM), Naive Bayes (NB) y Decision Tree (DT). Para su evaluación, se utilizó un conjunto de datos de entrenamiento (90%) y prueba (10%) del total de puntos. Cada modelo fue evaluado mediante una matriz de confusión y el índice de Kappa, permitiendo comparar su precisión y desempeño en la clasificación. Las librerías utilizadas fueron randomForest, e1071, rpart, raster, y mapview.

i. Evaluación de algoritmos

En R, se valida el rendimiento de los cuatro modelos de clasificación supervisada a partir de los valores del índice de Kappa de cada modelo y se generó un gráfico de dispersión.

j. Muestreo proporcional estratificado

El número de puntos de verificación en campo fue de 246 realizados en el 2024 y distribuidos mediante un muestreo proporcional estratificado. A partir de los 23478 puntos generados en gabinete, se excluyeron 94 ubicados en áreas cubiertas por nubes, obteniéndose así 23384 puntos efectivos. La proporción de puntos por clase se calculó dividiendo los puntos en gabinete (por clase) entre 23384 y multiplicando por 246. Los resultados se presentan en la Tabla 7. Además, para la verificación en campo se consideró la accesibilidad de las zonas, empleando como referencia el mapa de vías del distrito de Pichanaqui (Figura 35) y archivos shapefile de centros poblados y ríos.

Tabla 7

Distribución de los puntos de muestreo

N°	Tipo de cobertura	Código	Puntos predichos	Puntos reales
1	Áreas urbanizadas	Au	3137	33
2	Áreas agrícolas	Aa	5798	61
3	Bosques	B	3327	35
4	Vegetación herbácea	Vh	5323	56
5	Áreas sin vegetación	Asv	2092	22
6	Aguas continentales	Ac	1806	19
7	Nubes	N	94	1*
8	Áreas arenosas	Ar	1901	20
Total			23478	247

Nota. (*) representa la cobertura de nubes que se agregó en los puntos reales, con la finalidad de tener todas las clases presentes, para realizar la matriz de confusión posteriormente.

k. Unión de puntos reales más puntos predichos

El tamaño total de los puntos de muestreo es de 23725, resultado de la suma de los 23478 puntos generados en gabinete y los 247 puntos adicionales recolectados en campo en la verificación de los tipos de cobertura y usos de suelo.

l. Aplicación del modelo Random Forest

En R, se cargaron el total de puntos de muestreo para obtener las firmas espectrales, que se organizan en un data frame. Luego, se divide el conjunto de datos en una muestra de entrenamiento y otra de prueba, mediante una selección

aleatoria. Luego, se entrena el modelo Random Forest con la muestra de entrenamiento y se realiza una predicción en la muestra de prueba, generando una matriz de confusión para evaluar su precisión a través del índice Kappa. En esta etapa se utilizaron las librerías `rgdal`, `raster`, y `randomForest`.

m. Guardado del modelo Random Forest en formato RDS

En R, se guardó el modelo entrenado de Random Forest en un archivo RDS. Esto permitió almacenar el modelo entrenado en un formato compacto, que incluye toda la configuración y los parámetros del modelo.

n. Aplicación del modelo entrenado para cada año

En R, se cargó las imágenes satelitales anuales desde el 2016 al 2024 en formato TIFF. Luego, se convirtió cada imagen en una matriz de datos para aplicar el modelo de clasificación Random Forest previamente entrenado. Finalmente, cada clasificación anual se guarda en formato GeoTIFF, lo que permite su almacenamiento y posterior análisis geoespacial. Las librerías utilizadas en este procedimiento fueron `raster`, `rgdal`, `randomForest` y `ggplot2`.

o. Conversión de formato TIFF a SHP

En ArcGis, convertimos el mapa clasificado de formato tiff a shp a través de la herramienta `Reclassify`. El raster creado se convierte a polígono con la herramienta `Raster to Polygon`.

p. Eliminación de áreas pequeñas

En ArcGis, creamos un campo del área en hectáreas del shapefile de la clasificación, seguidamente realizamos una selección por atributos para poner que las áreas sean menor o igual a 0.1 hectáreas. Luego, con la herramienta `Eliminate`, ingresamos la selección de entrada y escogemos los polígonos de la clasificación. Repetimos este proceso varias veces hasta que no queden áreas menores o iguales a 0.1 hectáreas.

q. Corrección manual de la clasificación

En ArcGis, corregimos los polígonos de algunos errores presentados por la clasificación supervisada, cambiando sus valores de sus códigos con edición.

r. Análisis de cobertura y uso del suelo

En R, mediante archivos TIFF de la clasificación, se generó gráficos de barras, diagramas de Sankey y diagramas de cuerdas para ilustrar las transformaciones en la cobertura de suelo y las métricas de cambio, así como los cambios, ganancias y pérdidas netas en cada categoría desde 2016 al 2024. Las librerías utilizadas fueron `raster` y `openland`.

s. Extracción de bosques

En ArcGis, se eliminaron las distintas coberturas de la clasificación a excepción de bosques y con la herramienta Dissolve unimos sus polígonos en una sola área.

t. Análisis espacial de cobertura forestal

En esta etapa se calcula la superficie total deforestada y el porcentaje de reducción a partir de las áreas boscosas de todos los años evaluados mediante Excel.

u. Tasa anual de deforestación

La tasa promedio anual de deforestación se calculó tomando como referencia el área boscosa del primer año (2016) y del último año de los datos históricos (2024), con respecto a su diferencia (Ecuación 2).

$$TPAD = \frac{(St1 - St2)}{N} \dots\dots\dots(2)$$

Donde:

TPAD: es la tasa promedio anual de deforestación.

St1: es la superficie cubierta por bosque, año 2016.

St2: es la superficie cubierta por bosque, año 2024.

N: es la diferencia entre el primer y último año.

v. Recorte de ecosistemas del Perú con bosques

El Mapa Nacional de Ecosistemas del Perú lo recortamos con el Shapefile de bosques, para esto primero descargaremos el Mapa Nacional desde el GEO GPS PERÚ (<https://www.geogpsperu.com/2019/04/mapa-de-ecosistemas-del-peru-descargar.html>) en formato shp y en ArcGis se recorta utilizando la herramienta Clip en Geoprocessing.

w. Estimación de deforestación al 2030

En R, se cargó los archivos de tipo SHP de cada año de las coberturas de bosque y se calculó el área en hectáreas, asignando esta información a una columna. Luego, agrega una columna de clasificación por año. A partir de este conjunto combinado se crea una serie temporal unitaria, para ser ajustada al modelo de la exponencial negativa. Asimismo, se presenta una predicción a seis años hacia el futuro desde el 2025 al 2030. La visualización incluye una figura de la serie temporal y las predicciones, mostrando los intervalos de confianza. Al final, se crea una tabla con las predicciones, incluyendo el valor medio de

área predicha y los límites de confianza al 80% y 95% para cada año pronosticado. Las librerías utilizadas son sf, rgdal, dplyr, forecast, y ggplot2.

x. Proceso de análisis de datos

El análisis de los datos obtenidos de la clasificación supervisada se realizó en RStudio y Excel, generando gráficos y tablas que describen la clasificación de coberturas y usos del suelo, así como las áreas boscosas y proyecciones futuras. Esto permitió una interpretación más precisa de los resultados.

y. Elaboración de mapas cartográficos

Se elaboraron mapas detallados de la clasificación de coberturas y usos del suelo, así como de los distintos tipos de bosques identificados, utilizando el software ArcGIS. Estos mapas temáticos, fueron generados para el periodo 2016 al 2024, facilitaron una interpretación exacta de los datos geoespaciales.

3.4.2. Técnicas e instrumentos de recolección de datos

- **Análisis de campo.** Se elaboraron fichas para registrar las coordenadas de los distintos tipos de cobertura y usos del suelo identificados, con el propósito de validar el modelo de clasificación supervisada.

3.5. Análisis de datos

3.5.1. Estadística descriptiva

Las imágenes satelitales fueron procesadas en los softwares ArcGIS (10.8) y RStudio (2024.4.1.748) con los paquetes raster, RStoolbox, terra, sf, e1071, snow, rpart, randomForest, dplyr, sp, ggplot2, factoextra, RColorBrewer, ggspatial, rgdal, caret, mapview, OpenLand, tmap y forecast para realizar la clasificación supervisada, basada en la leyenda Corine Land Cover de nivel III; donde, se puede detallar el procedimiento en ArcGIS en el Anexo 2 y la programación en R en el Anexo 6. Los datos obtenidos tras el procesamiento fueron analizados en RStudio y Excel, organizándose en tablas y figuras que cuantificaron las áreas de cobertura y usos del suelo, así como las áreas boscosas correspondientes a cada año de estudio.

3.5.2. Tendencias de proyecciones futuras sobre la deforestación

El análisis de datos se utilizó la cobertura de bosques desde 2016 al 2024, para proyectar la deforestación al 2030, mediante el modelo de regresión exponencial negativa en RStudio, empleando paquetes sf, rgdal, dplyr, forecast, ggplot2 y scales. Además, se generó una tabla en Excel basada en las tendencias temporales y los posibles patrones estacionarios identificados, lo que facilitó la interpretación de las tendencias futuras en la investigación.

3.6. Consideraciones éticas

Plantear los fundamentos básicos para el respeto a la dignidad humana, la investigación científica y los derechos de autor y la ética profesional.

- No haremos falsificación o modificación en los resultados que obtengamos del trabajo de investigación.
- Daremos el consentimiento para brindar la información a la Universidad Nacional Intercultural de la Selva Central Juan Santos Atahualpa, para la divulgación de la investigación, previa consulta de nuestra persona.
- Evitar cualquier daño que pueda afectar a la universidad, ello con fines de mantener la integridad de la institución y de nuestra persona, esto es cuando hay documentos por medio.
- Nos regimos en el cumplimiento normativo de nuestra universidad y cualquier otra entidad que apoye en nuestro proyecto de investigación.
- Mantendremos siempre la integridad personal, profesional y científica, siendo honestas en todas las etapas del proceso de la investigación, desde la recopilación de datos hasta la presentación de los resultados.

CAPÍTULO IV

RESULTADOS Y DISCUSIONES

4.1. Presentación de resultados y discusiones

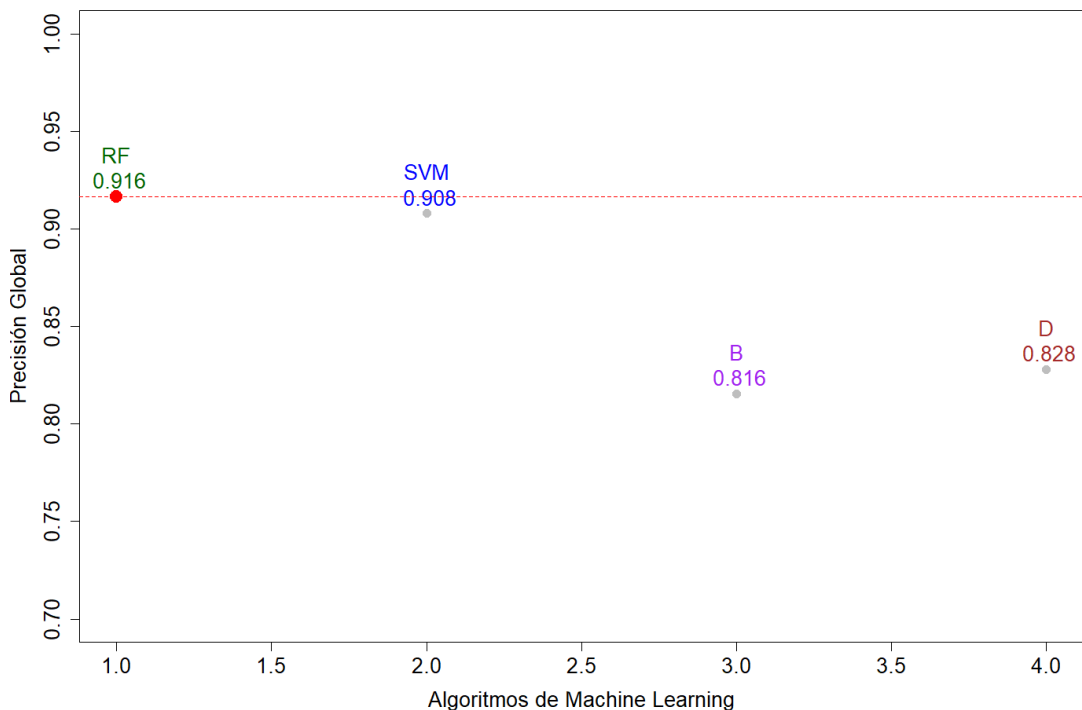
4.1.1. Identificación del modelo de aprendizaje

En la Figura 3, se presentan los resultados de cuatro algoritmos (Random Forest, Support Vector Machine, Naive Bayes y Decision Tree) de Machine Learning empleados en la clasificación supervisada para el 2024, en función de su precisión global. El modelo Random Forest mostró mejor desempeño con una precisión global de 0.916 en su índice de Kappa en comparación con los otros modelos. Resultados similares como el de Khan et al. (2024), reportó que Random Forest supera a Support Vector Machine y a Naive Bayes (Elmahdy et al. 2020). Con gran similitud, Fajardo (2019) también evaluó el desempeño de tres algoritmos, obteniendo que Random Forest es superior en comparación con los otros algoritmos. De acuerdo al desempeño de los algoritmos Tariq et al. (2023), reportó que Support Vector Machine mostró mejores resultados que Naive Bayes, concordando con nuestros resultados.

Cabe destacar que los cuatro modelos están dentro de un rango aceptable en la valoración de su índice de Kappa, con una fuerza de concordancia casi perfecta que va en el rango de 0.81 a 1.00 (Torre & Rivas, 2019). Por tanto, se determina que Random Forest es el modelo más adecuado en este estudio.

Figura 3

Evaluación de algoritmos de Machine Learning para la clasificación supervisada



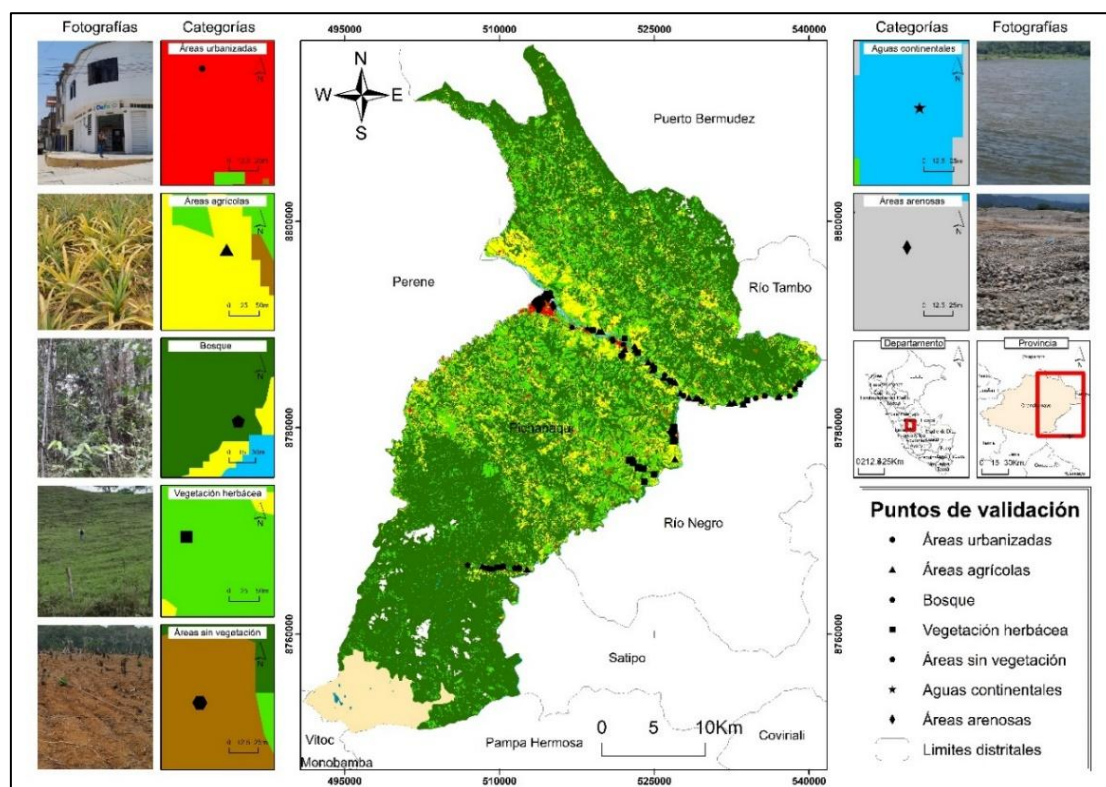
4.1.2. Clasificación de las coberturas y usos del suelo

En la Figura 4, se muestra la distribución geoespacial de los puntos de validación en campo dentro del distrito de Pichanaqui. Recolectados en total 246 puntos distribuidos en 7 tipos de coberturas. Para su obtención, se realizaron visitas a las áreas de mayor accesibilidad con ayuda del mapa vial del distrito (Anexo 5), donde se tomaron coordenadas con GPS, fotografías georreferenciadas visualizadas en el Anexo 4, y fichas de recolección de datos para documentar el trabajo en campo (Anexo 3).

La fase de campo garantiza que la clasificación sea precisa y confiable, ya que permite realizar ajustes necesarios para mejorar la calidad de los resultados. Esta metodología se alinea con otros estudios previos, como el de Requelme (2019) el cual realizó la verificación in situ para la corrección de posibles errores. De igual manera, (Saucedo Banda, 2023) realizó una fase de campo, resaltando la importancia de la corroboración directa para la precisión de los estudios ambientales. Por otro lado, en un estudio de De Celis (2019) se utilizó fotografías aéreas, que fueron orto rectificadas para la validación de mapas. Incluir las visitas a campo también permite analizar los factores que ocasionaron la pérdida de cobertura boscosa mediante las observaciones reales en terreno, mejorando así la interpretación y utilidad de los resultados en la toma de decisiones para la gestión ambiental y la planificación territorial (Torre & Rivas, 2019).

Figura 4

Distribución geoespacial de los puntos de validación en campo




En la Figura 5, se muestra la matriz de confusión de doble entrada, entre las clases predichas y las reales. Los elementos en la diagonal corresponden a las predicciones correctas y los que están fuera corresponden a predicciones incorrectas (González et al., 2022). También, la intensidad de los tonos indica la frecuencia en la clasificación. Las categorías representadas son áreas urbanizadas (1), áreas agrícolas (2), bosque (3), vegetación herbácea (4), áreas sin vegetación (5), aguas continentales (6), nubes (7) y áreas arenosas (8).

El modelo Random Forest muestra un excelente desempeño en las categorías de áreas urbanizadas, áreas agrícolas, bosque, aguas continentales y nubes, esto indica que el modelo clasifica bien estas categorías. En cambio, se observa confusión en la categoría de vegetación herbácea, con respecto a áreas agrícolas y bosque, lo cual concuerda con estudios reportados por Tapia & Ulloa, (2020) y Castillo et al. (2023), donde la clase de herbazal, suelen ser clasificadas erróneamente con otro tipo de cobertura. De igual modo, las áreas arenosas se confunden con áreas urbanizadas, áreas sin vegetación y áreas agrícolas; esto se debe a que los píxeles en estas categorías son similares en algunas zonas. Este patrón, se debe a la confusión entre clases (González et al., 2022). A pesar de los errores en algunas categorías, el número total es aceptable, por lo que no se considera necesario ajustar el modelo.

Figura 5

Matriz de confusión en la clasificación supervisada

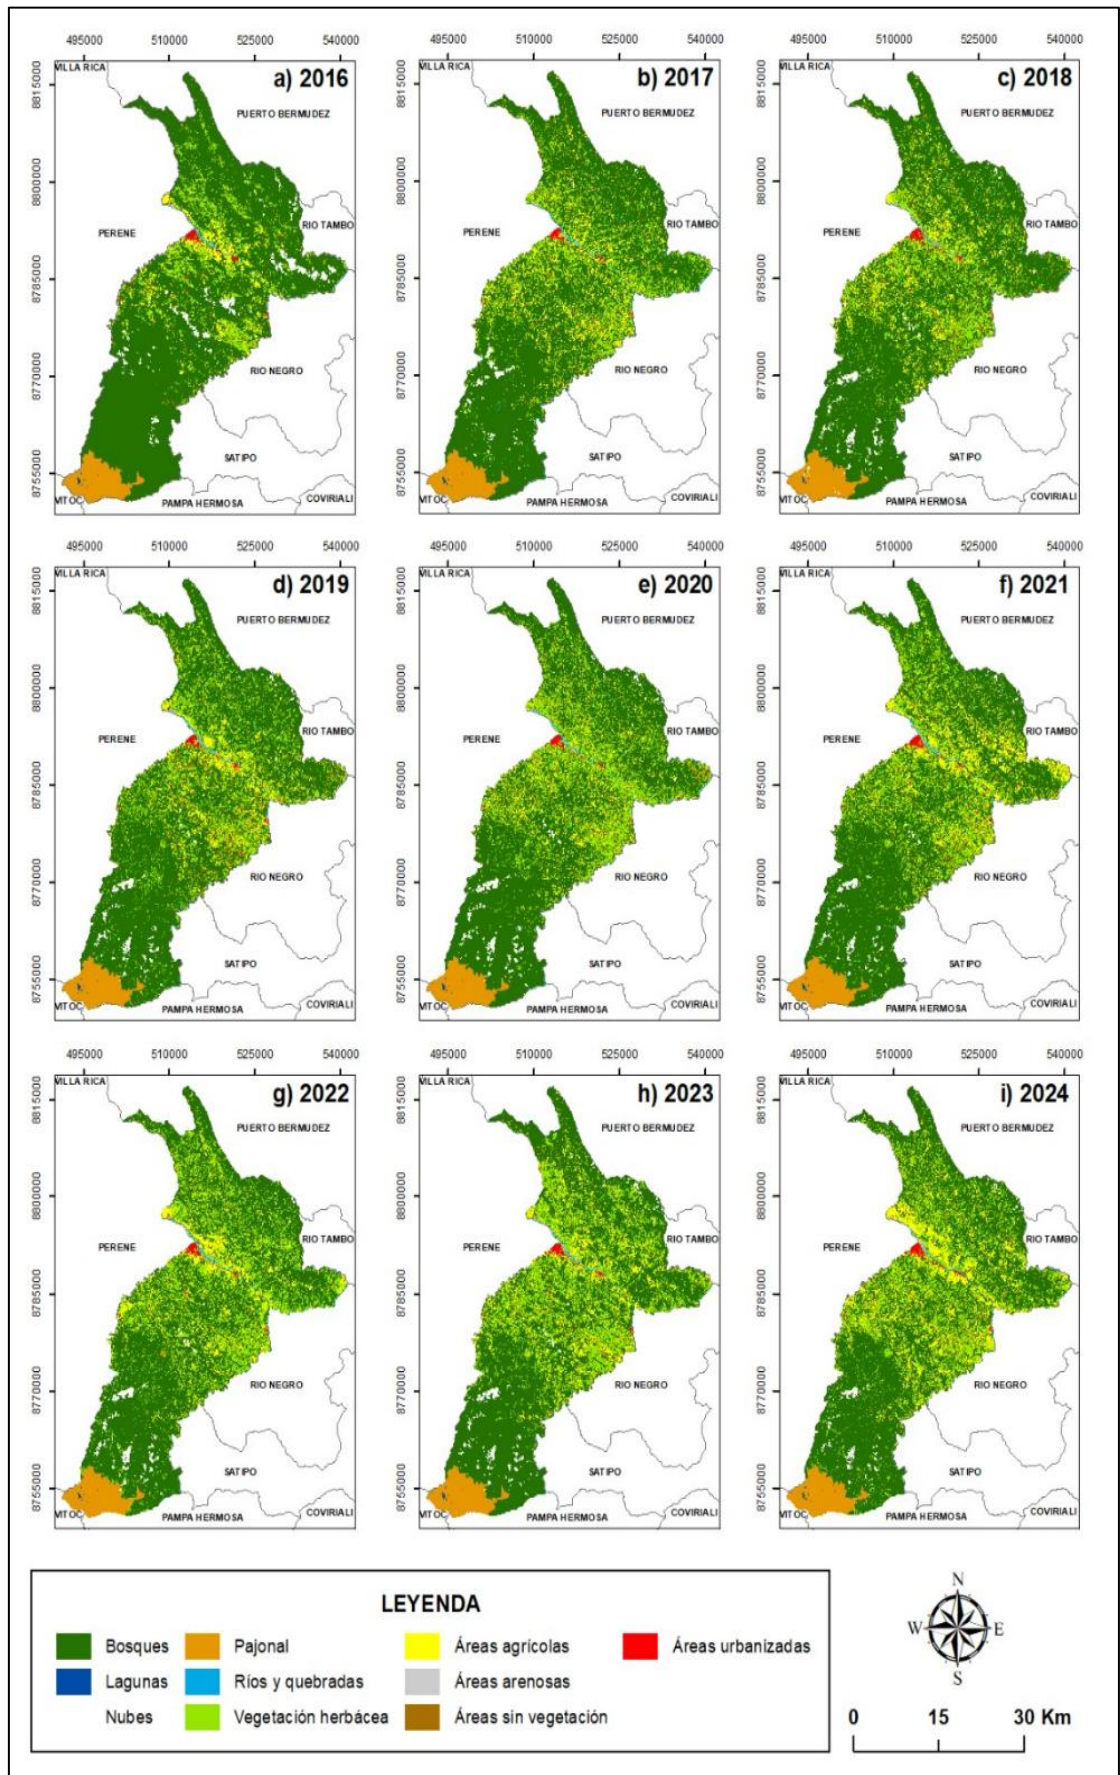


En la Figura 6, se muestra la clasificación de los tipos de cobertura en el distrito de Pichanaqui desde el año 2016 al 2024. Realizado mediante la metodología Corine Land Cover, donde se identificó 10 tipos de coberturas: bosques, lagunas, nubes, pajonal, ríos y quebradas, áreas agrícolas, áreas arenosas, áreas sin vegetación y áreas urbanizadas.

La metodología Corine Land Cover utiliza una leyenda organizada en niveles. (Lumba, 2023). Diversos estudios en el Perú también se basaron en esta metodología, tal es el caso de Villalobos (2020), que realizó el análisis de la cobertura boscosa y uso de la tierra en el distrito de Pomahuaca. De la misma manera Requelme (2019) trabajó con esta metodología en el distrito de Chadín. Además, presenta una estructura jerárquica lo que permite hacer análisis detallados (Bueno, 2019).

Figura 6

Serie multitemporal de la clasificación de coberturas y usos del suelo




4.1.3. Cuantificación de los cambios de cobertura y usos del suelo

En la Figura 7, se muestran las variaciones de los tipos de coberturas durante el periodo 2016 al 2024, observándose que la cobertura de bosques (B) se ha ido reduciendo notablemente. A diferencia de la cobertura de vegetación herbácea (Vh) y de áreas agrícolas (Aa) que fueron aumentando. Otros estudios también obtuvieron resultados similares, tal es el caso de Janampa & Ponce (2022) cuya investigación realizada en el distrito de Pangoa, identificó que las coberturas que más se habían incrementado fueron de infraestructura urbana y áreas agrícolas; por su parte Requielme (2019) concluyó que la cobertura de pastos se incrementó debido a la ganadería ya que era la principal actividad productiva en otro sitio de estudio.

Dentro del periodo de estudio también se observó que la cobertura de suelos desnudos (Asv) llegó a un considerable aumento para el 2024, debido a la quema de bosques y pastizales ocasionados con fines agrícolas, los cuales se ven reflejados en el registro de 415 incendios que afectaron al menos 17867 ha con cobertura vegetal para este año (Defensoría del Pueblo, 2024). Esta dinámica de coberturas sucede a causa de actividades antrópicas como la agricultura, expansión urbana y la ganadería, que ocasionan la pérdida de ecosistemas y de la biodiversidad afectando la calidad de los suelos (Leija et al., 2020).

Figura 7

Diagrama de barras de los cambios de cobertura y usos de suelo




La Figura 8, representada mediante el diagrama de Sankey, donde enfatiza el tamaño y dirección de los flujos (Cuba, 2015), evidenciándose los patrones clave en los cambios de cobertura y uso del suelo en el distrito de Pichanaqui desde 2016 al 2024. Asimismo, concordamos con Cuba (2015) donde menciona que este tipo de figura transmite de manera eficiente el cambio en la cobertura terrestre a lo largo de múltiples años. Además, el grosor de cada categoría se ve refleja en la persistencia de la cobertura (Tapia & Ulloa, 2020), lo cual indica que el ancho de las líneas representa el área ocupada (Arenas, 2024).

Las categorías de lagunas (L), pajonal (P), áreas arenosas (Ar), nubes (N), ríos y quebradas (Ryq) y áreas urbanizadas (Au) demuestran una mayor estabilidad, siendo las más persistentes a lo largo del tiempo. Por otro lado, las áreas agrícolas (Aa), bosques (B), vegetación herbácea (Vh) y áreas sin vegetación (Asv) presentan una alta susceptibilidad a transiciones, lo que indica un dinamismo en su ocupación y mayor exposición a cambios en el uso del suelo. En otra zona de estudio Von et al. (2020) resaltar que los principales cambios en las transiciones de bosques a otro tipo de cobertura se da por la actividad económica del lugar, impulsado por las áreas agrícolas y formaciones rurales (Vasconcelos et al., 2024)

Figura 8

Diagrama de Sankey de los cambios de cobertura y usos de suelo



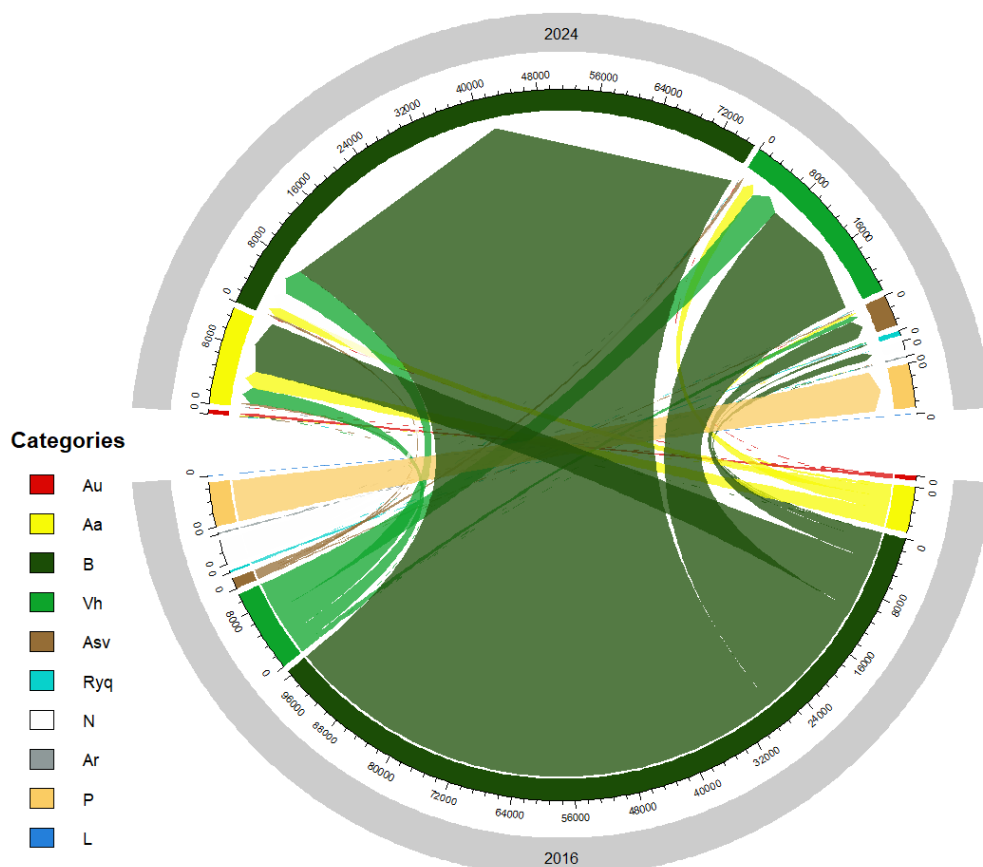
En la Figura 9, se observa el cambio de los tipos de cobertura a través de un diagrama de cuerdas. Las áreas boscosas (B) se redujo, debido a su transición de vegetación herbácea (Vh), áreas agrícolas (Aa) y suelos desnudos (Asv), concordando con el estudio de Requelme (2019) donde registró una pérdida de cobertura boscosa, causado por la tala y la conversión del bosque a zonas agrícolas y ganaderas.

Respecto a las áreas agrícolas (Aa) estas han ido aumentando a causa de la conversión de vegetación herbácea (Vh) y bosques (B), ya que en el distrito es común ampliar los cultivos en zonas boscosas, debido a la calidad de estos suelos (Bashi, 2021). De igual manera la vegetación herbácea (Vh) también aumentó para el 2024 por la conversión de bosques (B) y áreas agrícolas (Aa), contrastando con el estudio de Lumba (2023) donde una de las dinámicas más importantes fueron los cambios de cultivos a pastos en 665.3 ha, a razón del incremento de la actividad ganadera.

Por último, se observa la conversión de bosques (B), vegetación herbácea (Vh) y áreas agrícolas (Aa) a suelos desnudos. Esto ocurre debido a la falta de aptitud de ciertas zonas para actividades productivas, lo cual, si se le da un uso inadecuado, puede degradar el suelo, aumentando la escorrentía y reduciendo su fertilidad, lo que resulta en suelos sin vegetación. (Requelme, 2019).

Figura 9

Diagrama de cuerdas de los cambios de cobertura y usos de suelo




En la Figura 10, se muestran los cambios brutos, ganancias y pérdidas netas en (Rengifo, 2024). Expresado en las distintas categorías de cobertura y usos del suelo en el distrito de Pichanaqui entre 2016 y 2024. Las categorías de áreas urbanizadas (Au), ríos y quebradas (Ryq) y áreas arenosas (Ar) experimentaron cambios brutos mínimos, sin registrar pérdidas ni ganancias netas. Este patrón está asociado a la distribución del terreno que se compensan entre sí (Tapia & Ulloa, 2020).

Por otro lado, la categoría de bosque (B) presentó una mayor pérdida neta y cambio bruto, seguido de la cobertura de nubes (N). En contraste, la categoría de vegetación herbácea (Vh) registró la mayor ganancia neta, seguida por áreas agrícolas (Aa) y áreas sin vegetación (Asv). En otro estudio similar Pérez et al. (2024) nos mencionan que la mayor vulnerabilidad de cambio, se debe al uso de suelo, ocasionado por la conversión de bosques a áreas agrícolas y pastizales. Finalmente, en las categorías de pajonal (P) y lagunas (L) no se observan cambios brutos, ni ganancias o pérdidas netas significativas. Esto se debe a una relativa estabilidad de estas categorías a lo largo del tiempo analizado, ya que la cobertura de pajonal se tomó del Mapa Nacional de Ecosistemas del Perú (MINAM, 2019) y de lagunas identificadas dentro del Bosque de Protección Pui-Pui, como base para todos años analizados.

Figura 10

Diagrama de ganancias y pérdidas de los cambios de cobertura y usos de suelo



En la Tabla 8, se observa las variaciones que han experimentado los tipos de cobertura desde el 2016 hasta el 2024. Respecto a esto se determina que las áreas urbanizadas (Au) han ido expandiéndose ligeramente llegando a aumentar 14.392 ha, las causas se deben mayormente a la construcción de infraestructuras grandes y la expansión urbana debido al crecimiento poblacional (Saucedo, 2023).

De la misma manera, la cobertura vegetal herbácea (Vh) también incrementó su superficie en 13215.6 ha, la razón de esto se le atribuye a la expansión de ganadería en la zona y al abandono de áreas agrícolas, lo que ha facilitado el crecimiento de vegetación en estas superficies (Bueno, 2019). En otras investigaciones se hallaron resultados similares como el de Saucedo (2023) donde las áreas con vegetación herbácea y/o arbustivo habían aumentado a 12.46% del área total en 15 años.

Por su parte, las áreas sin vegetación (Asv), también aumentaron en 2839.36 ha, lo cual sucede por la quema de bosques y pastizales destinados al uso agrícola (Bueno, 2019). Otra causa son los factores climáticos como deslizamientos, erosión y sequías prolongadas que provocan escasez de vegetación y dejan áreas desnudas. (Requelme, 2019). Nuestros resultados concuerdan con otro estudio realizado por Álvarez et al., (2021) donde se identificó un aumento del suelo desnudo en un 49.46% principalmente para ser convertidos a zonas de cultivos.

Respecto a las áreas agrícolas (Aa) han llegado a incrementar notablemente su superficie en 7571.98 ha, la razón de esto es porque en el distrito de Pichanaqui la agricultura constituye la economía principal de muchas familias que cultivan: café, cacao, cítricos, piña, plátanos y jengibre (Bashi, 2023). En el distrito de Pangoa, el cual también es una zona de la selva, se realizó un estudio por parte de (Janampa & Ponce, 2022), donde se destaca que hubo un incremento de 2779.46 ha de áreas agrícolas debido mayormente a la adaptabilidad de la tierra para diferentes tipos de cultivo.

Por último, los bosques (B) fueron los que más redujeron su área en 21971.65 ha desde el 2016, esto debido a la tala y quema de bosques para la intensificación de la actividad agropecuaria, en un estudio de Atalaya (2023) realizado en Pichanaqui se menciona que los productores de café emplean un sistema intensivo convencional que está relacionado con la deforestación; lo cual provoca la expansión de sus áreas de cultivo, esto se contrasta con el reporte del portal GEOBOSQUE que informa una pérdida de 17191 ha de bosques desde el 2001 al 2021 (Bashi, 2023). Otro factor que influye en la pérdida de bosques es el desarrollo de pistas y carreteras, que permiten el acceso a zonas boscosas para extraer los recursos que este provee (Rojas et al., 2019)

esto se evidencia en los mapas de cobertura donde las zonas cercanas a la red vial sufrieron una mayor fragmentación de bosques y aumento de áreas agrícolas.

Tabla 8

Evolución de la superficie por tipo de cobertura y usos del suelo

Tipos de Cobertura	Cód.	Superficie (ha) / año								
		2016	2017	2018	2019	2020	2021	2022	2023	2024
Áreas urbanizadas	Au	600	594	537	493	549	557	615	600	614
Áreas agrícolas	Aa	5791	10414	8643	7772	7648	11747	9593	10651	13363
Bosques	B	96606	88003	86396	83361	81564	80398	79224	77614	74634
Vegetación herbácea	Vh	10588	15233	16388	19797	22439	19984	24793	24708	23804
Áreas sin vegetación	Asv	1320	2308	3701	4609	3425	3654	1568	2365	4159
Ríos y quebradas	Ryq	353	915	709	627	599	483	683	490	650
Nubes	N	3138	1166	2122	1747	2197	1554	2020	1979	1180
Áreas arenosas	Ar	201	94	165	205	196	226	192	203	199
Pajonal	P	5572	5571	5518	5562	5566	5567	5568	5567	5573
Lagunas	L	59	59	55	63	58	64	52	54	58

4.1.4. Estimación de la pérdida de cobertura boscosa

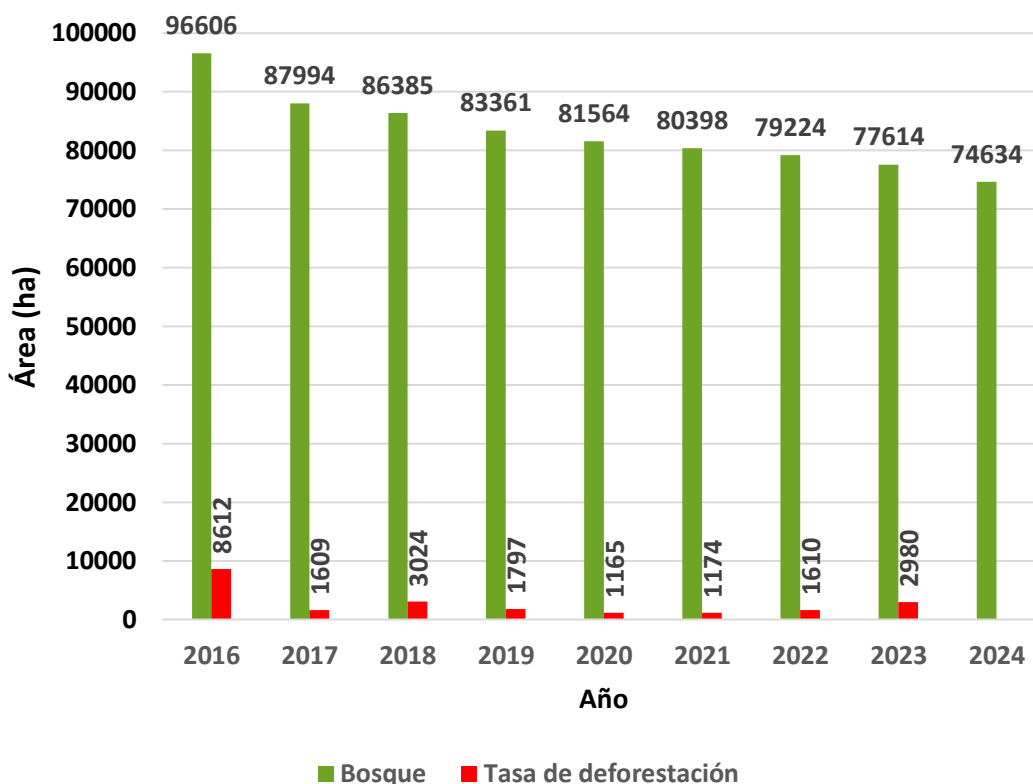
En la Figura 11, se observa la superficie total de cobertura forestal en el distrito de Pichanaqui. En el 2016, la superficie total de bosque era de 96606 hectáreas, mientras que para 2024 esta se redujo a 74634 hectáreas, lo que implica una pérdida de 21972 hectáreas a lo largo de los nueve años analizados; esto representa una tasa de deforestación anual promedio del 1.97%, lo que equivale a 2441 hectáreas de bosque perdido por cada año. De acuerdo con estos datos, se evidencia una alarmante pérdida de cobertura forestal, un tipo de cobertura fundamental para la conservación de la biodiversidad (Von et al., 2020) y el suministro de bienes y servicios ecosistémicos (Huchin et al., 2022 y Pérez et al., 2021).

Los períodos con mayor pérdida de bosque fueron entre el 2016 al 2017, seguido del 2018 al 2019 y del 2023 al 2024, con tasas de 8612, 3024 y 2980 hectáreas respectivamente. En contraste, los periodos con menor tasa de deforestación fueron

entre el 2020 al 2021, seguido del 2021 al 2022 y del 2017 al 2018, con tasas de deforestación de 1165, 1174 y 1609 hectáreas perdidas, estos datos sugieren que en esos años los cambios en la cobertura boscosa fueron menos significativos. Sin embargo, Von et al. (2020) señala que el aumento o disminución de la tasa de deforestación en ciertas zonas está influenciado por factores de accesibilidad y actividades agropecuarias, así como la ubicación dentro de áreas actualmente restringidas o protegidas.

Figura 11

Superficie total deforestada y tasa anual de deforestación



En la Figura 12, muestra el porcentaje de cobertura forestal en el distrito de Pichanaqui desde 2016 al 2024. Observándose que, en el 2016 el porcentaje de bosque cubría aproximadamente el 77.8% del área evaluada. A lo largo de los años, se observa una disminución constante de la cobertura forestal, con una reducción notable del 60.1% para el 2024. Esto representa una pérdida significativa del 18% de reducción. Asimismo, coincidimos con Laulli (2022), quien señala que la sostenibilidad ambiental en Pichanaqui es baja, reflejando un manejo inadecuado de los recursos forestales, lo cual ha contribuido a esta marcada reducción de bosques.


Además, este cambio muestra que la pérdida de bosque no ha sido uniforme a lo largo de los años. Destacando que, entre el 2016 y 2018 el porcentaje de bosque disminuyó de 77.8% a 70.8%, una diferencia de casi 7% en solo dos años, siendo este periodo uno de los de mayor pérdida relativa. Seguidamente, entre el 2019 y 2021, la

tasa de disminución se redujo ligeramente del 67.1% al 64.7%, aunque la deforestación continuó, fue menos intensa en estos años.

A partir del 2022, la cobertura forestal sigue reduciéndose, hasta llegar a solo el 60.1% en el 2024, esto indica que en los últimos años la deforestación ha continuado de manera significativa, lo cual es preocupante, ya que podría reducir las áreas de bosque a niveles críticos. Alarcón et al. (2021) menciona que, a nivel nacional el patrón de pérdida forestal está mayormente asociado a actividades como la expansión agrícola y la explotación forestal. De igual modo, Bashi Pizarro et al. (2024) pone de manifiesto que la respuesta más inmediata para abordar la baja rentabilidad en la agricultura se da mediante la conversión de los bosques.

Figura 12

Porcentaje de reducción de cobertura forestal por año



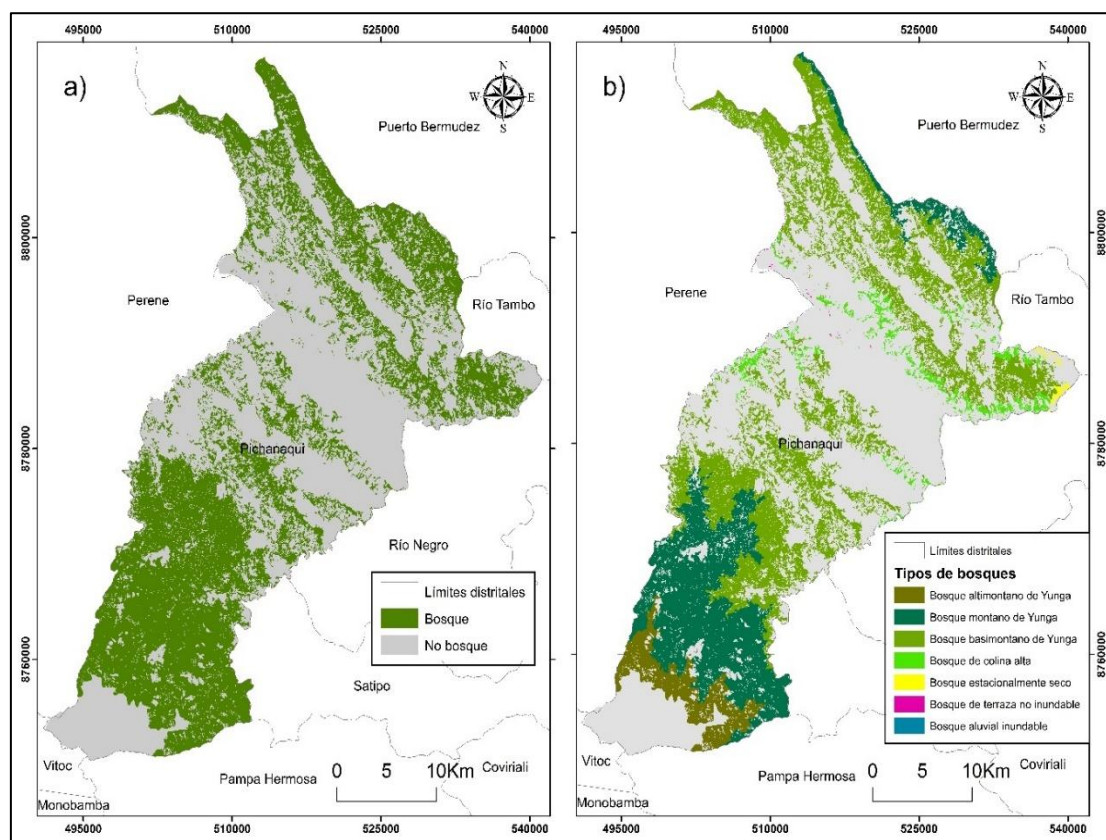
4.1.5. Clasificación de los tipos de bosques

La Figura 13, presenta la clasificación de los bosques identificados en el área de estudio, en la subfigura (a) se muestra las áreas de bosque y no bosque, mientras que la subfigura (b) detalla los distintos tipos de bosque. Esta clasificación fue realizada tomando como referencia el Mapa Nacional de Ecosistemas del Perú, el cual detalla los 36 ecosistemas continentales del territorio peruano (MINAM, 2019). Según este mapa el distrito de Pichanaki se caracteriza principalmente por el Bosque basimontano de Yunga (B-bY), el Bosque montano de Yunga (B-mY), y en menor medida por el pajonal de puna húmeda (Pjph) (Bashi, 2023).

Conocer la clasificación de las coberturas forestales en una zona determinada es importante para elaborar planes de manejo forestal que permitan la gestión adecuada y el aprovechamiento ordenado de los recursos que ofrecen estos bosques (Román, 2013). Otros estudios que se realizaron antes de que se elaborara el Mapa de Nacional de Ecosistemas del Perú (2019) se basaron en las características fisiográficas utilizando imágenes satelitales, tal es el caso de Reátegui (2017) que identificó 12 tipos de cobertura arbórea en la provincia de Alto Amazonas usando imágenes Landsat, tomando como base los criterios fisionómicos y florísticos.

Figura 13

Clasificación de los tipos de bosques en el distrito de Pichanaqui



En la Figura 14, se muestra la verificación en campo de los tipos de bosques, para ello se eligieron puntos representativos, según la clasificación inicial realizada. De acuerdo al mapa se muestra una alta correspondencia entre la clasificación y las observaciones de campo, lo que confirma la precisión de la metodología. Sin embargo, durante la visita a los puntos de muestreo se observó que varios tipos de bosque ya estaban siendo invadidos por zonas de cultivo y áreas urbanas.

Empezando con el Bosque Basimontano de Yunga, este constituye un ecosistema con altas pendientes, donde los árboles crecen entre 25 - 35 m (Loayza,

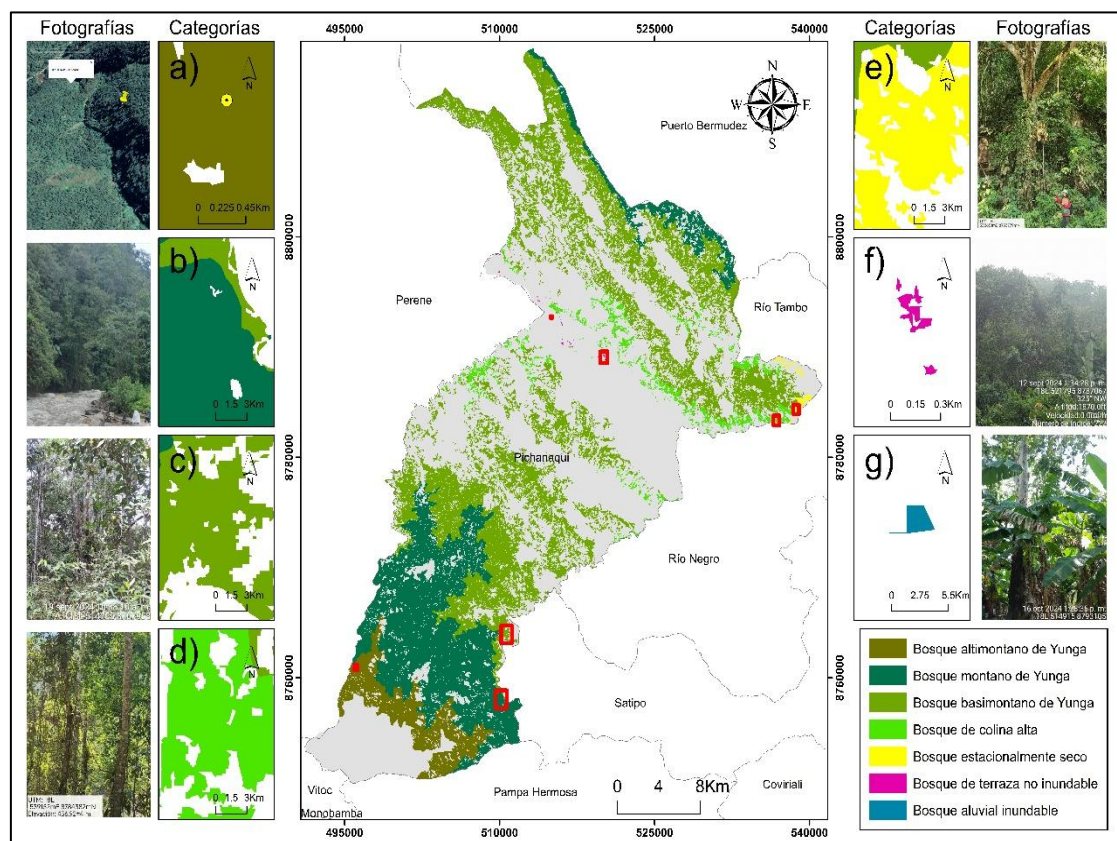
2020), este tipo de bosque cubre la mayor parte del distrito, pero en campo se pudo observar que la mayor parte de sus áreas ya estaban en transición a usos agrícolas.

Otro tipo de bosque que también estaba siendo afectado por las actividades humanas fue el Bosque de Colina Alta. Este bosque se desarrolla en colinas altas, con pendientes empinadas que son susceptibles a la erosión hídrica, presentan un sotobosque denso y los árboles llegan hasta los 25 metros de altura (SERFOR, 2020). Por otra parte, está el Bosque aluvial inundable, el cual es un ecosistema que está presente en las llanuras amazónicas con susceptibilidad a inundaciones durante épocas de lluvia (MINAM, 2019). A pesar de esto, igualmente fue afectado, ya que durante la visita en campo se observó muchas plantaciones de plátano y naranja en esta área.

La transición de áreas boscosas a otros usos representa un riesgo significativo, ya que estos bosques cumplen un papel importante en el equilibrio de los ecosistemas, generando servicios ambientales como la protección del suelo, la regulación del ciclo hidrológico, suministro de agua y almacenamiento de carbono (MINAM, 2015)

Figura 14

Verificación in situ de los tipos de bosques




En la Figura 15, se compara el área de los 7 tipos de bosques identificados durante el periodo 2016 al 2024. Donde se observa que el Bosque Basimontano de Yunga (BBY) es el más extenso y el que más redujo su área en 7.3%. El segundo más

grande es el Bosque montano de Yunga (BMY) cuya área se redujo ligeramente en 1.2%. Por otra parte, el Bosque Altimontano de Yunga (BAY) se mantuvo casi igual para todos los años, a diferencia del Bosque de colina alta (BCA) que redujo su extensión hasta cubrir el 2.2% del territorio. Los otros tipos de bosques cubren un área muy pequeña y no presentaron diferencias significativas.

La reducción de estos bosques están relacionadas con las actividades agrícolas, pecuarias y de extracción forestal, que van dejando ecosistemas degradados y poco productivos (Buendía, 2018). Estas consecuencias se evidencian en estudios como el de Quispe & Cáceres (2020) donde se evaluó la distribución de bosques alto andinos y se obtuvo una tasa de deforestación de 4.16 ha por año. Otro factor que influye es la falta de una buena planificación por parte de las autoridades en temas de recursos forestales (Buendía, 2018). En este contexto, urge la necesidad de tomar medidas que permitan evaluar de una manera más detallada la situación de los diferentes tipos de bosque y conocer las causas específicas por las que están siendo afectados (Loayza, 2020).

Figura 15

Serie temporal de los tipos de bosques identificados en el distrito de Pichanaqui



La Tabla 9, presenta la evolución de la superficie de diferentes tipos de bosques entre 2016 y 2024. Los bosques altimontanos de yunga (BAY) muestran una tendencia a la disminución, pasando de 5266 hectáreas en 2016 a 4715 hectáreas en 2024, aunque con cierta variabilidad interanual. Asimismo, los bosques montanos de yunga (BMY)

también registran una reducción, de 20246 hectáreas a 18717 hectáreas en el mismo período, aunque de forma más gradual. Por otro lado, John et al. (2021) nos menciona que las mayores pérdidas de bosques se dan fuera de áreas protegidas; corroborando esta información en nuestra investigación, ya que ambos tipos de bosques colindan con el bosque de protección Pui-Pui y se evidencia una disminución leve a comparación con los otros tipos de bosques.

En cambio, los bosques basimontanos de yunga (BBY), presenta una reducción notable en su superficie, pasando de 40113 hectáreas en 2016 a 31038 hectáreas en 2024, esta disminución es considerable, especialmente en los primeros años. De igual modo, los bosques de colina alta (BCA), también sufren una reducción significativa en su superficie, particularmente del 2016 a 2020, pasando de 4479 hectáreas en 2016 a 2672 hectáreas en 2024. Por último, los bosques estacionales secos (BES), también, tienen una disminución notable, desde 312 hectáreas en 2016 hasta 205 hectáreas en 2024.

De manera particular, los bosques de terraza no inundable (BTNI), muestran una disminución casi constante en su superficie, desde 73 hectáreas en 2016 hasta 26 hectáreas en 2024, estos valores son pequeños en comparación con otros tipos de bosque, pero el descenso es evidente, sugiriendo una alta vulnerabilidad de este tipo de bosque a la pérdida. Asimismo, los bosques aluviales inundables (BAI) han experimentado una drástica reducción de su superficie, pasando de 1.75 hectáreas en 2016 a solo 0.10 hectáreas para el 2024. Esta tendencia decreciente y constante, con valores cercanos a cero, sugiere una inminente extinción de este tipo de bosque. Además, su carácter abierto, intercalado con cultivos como naranja, plátano y cacao. Estudios como los de John et al. (2021) confirman que estas tendencias, señalan que la mayoría de los cambios forestales ocurren en bosques abiertos debido a las prácticas migratorias.

La tendencia de pérdida de superficie en todos los tipos de bosques revela una reducción más pronunciada en los bosques basimontanos de yunga y en los bosques de colina alta. Sin embargo, otros bosques de menor extensión, como el bosque de terraza no inundable y el bosque aluvial inundable, también muestran disminuciones significativas, lo que refleja una alarmante vulnerabilidad. Esta situación es preocupante, así como comunicar a los tomadores de decisiones en Pichanaqui para que tomen medidas inmediatas, ya que los datos reflejan una disminución de las áreas boscosas entre 2016 y 2024, impulsada por procesos de deforestación (Salizzi, 2020),

explotación forestal, incremento de la frontera agrícola (Loayza, 2020) y cambios en el uso del suelo (Escobar & Castillo, 2021).

Tabla 9

Estimación de áreas según la clasificación de tipos de bosques

Tipos de Bosques	Cód.	Superficie (ha) / año								
		2016	2017	2018	2019	2020	2021	2022	2023	2024
Bosque altimontano de Yunga	BAY	5267	5143	4931	4789	4931	4871	4479	5006	4716
Bosque montano de Yunga	BMY	20246	19331	19065	18650	18927	19094	18596	18843	18718
Bosque basimontano de Yunga	BBY	40114	36389	36302	34942	34457	34100	32995	32569	31038
Bosque de colina alta	BCA	4479	3183	3376	3126	2636	3014	2820	3085	2672
Bosque estacionalmente seco	BES	312	242	274	246	219	161	200	237	205
Bosque de terraza no inundable	BTNI	73	69	52	42	52	43	25	19	26
Bosque aluvial inundable	BAI	1.75	0.69	0.88	0.93	1.47	0.04	0.06	0.26	0.10

4.1.6. Estimación de la pérdida de bosques al 2030

En la Figura 16, se muestra el comportamiento histórico de las áreas boscosas del distrito de Pichanaqui durante el periodo 2016 al 2024. Se observa una tendencia decreciente con una ligera curvatura hacia abajo. Para confirmar esta tendencia, se aplicó la prueba de Mann-Kendall, que evalúa la presencia de tendencias significativas en series temporales; según esta prueba, un p-valor menor a 0.05 indica una tendencia significativa, mientras que un p-valor mayor o igual a 0.05 señala que no hay evidencia de una tendencia significativa (Alencar da Silva & Silva, 2017). En este caso, el p-valor obtenido fue de 0.0002633, lo que proporciona una fuerte evidencia estadística de una tendencia significativa. El estadístico estándar fue de -3.649, lo que confirma que la tendencia es decreciente debido al valor negativo y su magnitud refleja una tendencia pronunciada, ya que valores más alejados de 0 indican mayor significancia.


A simple vista, la serie parece ser no estacionaria. Para validar esta hipótesis, se utilizó la prueba de Dickey-Fuller Aumentada (ADF), que determina si una serie temporal es estacionaria o no. Según esta prueba, indica que un p-valor mayor a 0.05

implica que la serie es no estacionaria, mientras que un p-valor menor o igual a 0.05 señala estacionariedad (Montero, 2013). En este caso, el p-valor obtenido fue de 0.5129, confirmando que los datos no son estacionarios en su forma original.

Adicionalmente, para evaluar la normalidad de los datos, se empleó la prueba de Shapiro-Wilk. Según esta prueba, un p-valor mayor a 0.05 indica que los datos siguen una distribución normal, mientras que un p-valor menor o igual a 0.05 sugiere que no lo son (Dietrichson, 2019). El p-valor obtenido fue de 0.6122, lo que indica que los datos presentan una distribución normal. Este análisis conjunto proporciona una visión integral sobre las propiedades estadísticas de los datos, confirmando la tendencia decreciente, la no estacionariedad de la serie y la normalidad de los valores observados.

Figura 16

Serie temporal de las áreas de bosque desde el 2016 al 2024

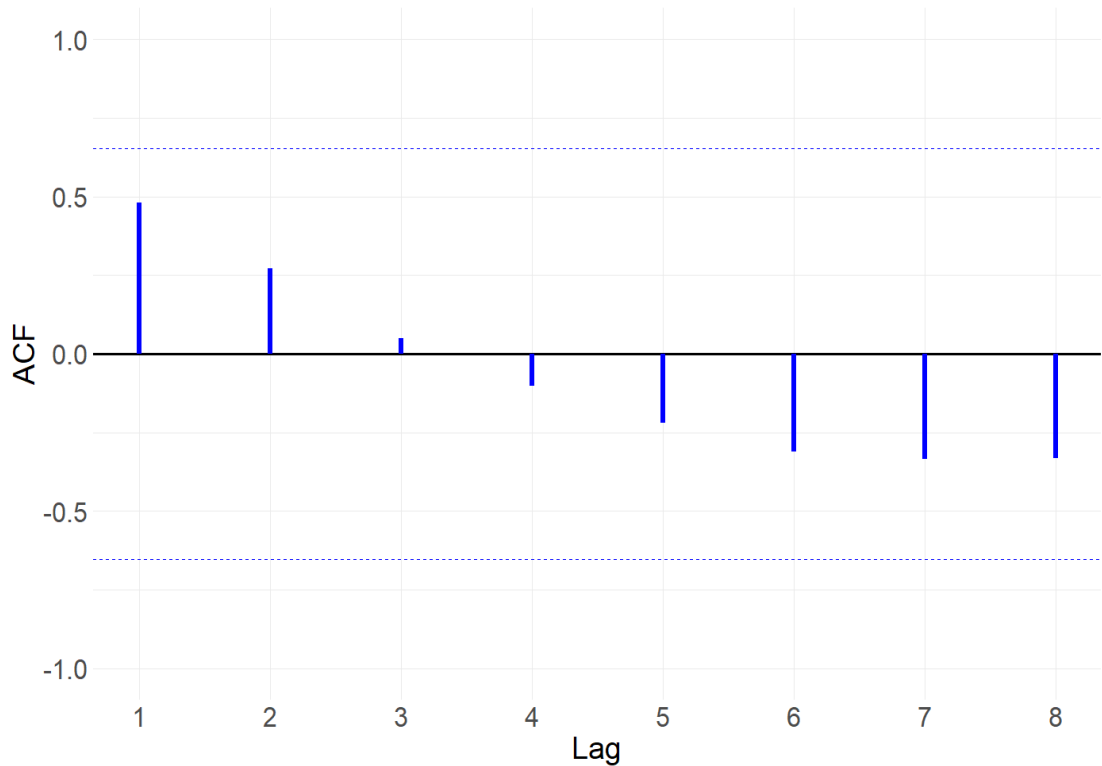


En la Figura 17, se muestra el análisis de autocorrelación diseñado para evaluar si nuestros datos contienen ruido. Este análisis revela que las series temporales no presentan autocorrelación, esto quiere decir que los datos se clasifican como ruido blanco; para estas series, se espera que las autocorrelaciones sean cercanas a cero, aunque no idénticas, debido a la variabilidad aleatoria inherente (Hyndman & Athanasopoulos, 2021). Los resultados demuestran que nuestros datos son completamente aleatorios y carecen de un patrón discernible. Por lo tanto, no es adecuado utilizar modelos complejos para pronosticar las áreas boscosas al 2030, ya que ello comprometería la validez de las proyecciones. Debido a la naturaleza de

nuestros datos y a su tendencia observada, se optó por emplear el modelo de la regresión exponencial negativa para llevar a cabo el pronóstico, con el fin de ser más realistas según nuestros datos.

Figura 17

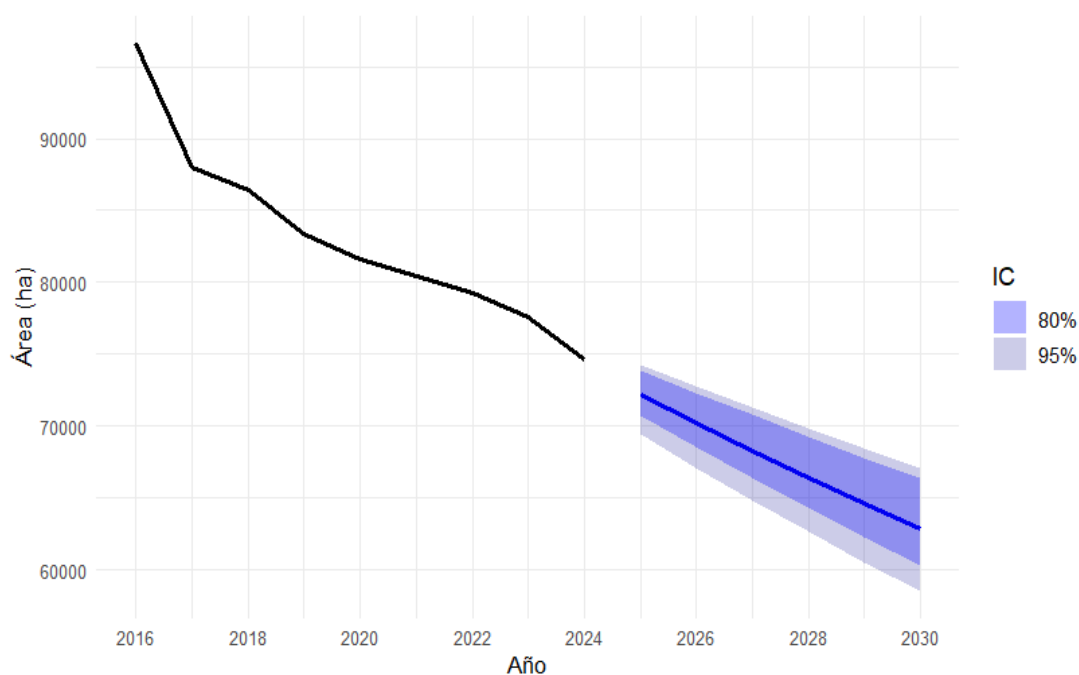
Análisis de autocorrelación de la serie temporal de las áreas boscosas



En la Figura 18, se muestra el pronóstico de las áreas boscosas obtenido mediante el modelo de la exponencial negativa, según lo observado se espera que el área de bosque continúe disminuyendo en los próximos años. Las áreas sombreadas de color azul oscuro y azul representan intervalos de Confianza del 80% y 95%, respectivamente. Estos intervalos indican la confianza que tenemos en que el verdadero valor del área de bosque se encuentre dentro de ese rango. Un intervalo de confianza del 95% significa que estamos 95% seguros de que el valor real estará dentro de ese rango; también, cuanto más a futuro se pronostica, mayor será la incertidumbre asociada con el pronóstico; por lo tanto, más amplios serán los intervalos de predicción (Hyndman & Athanasopoulos, 2021).

Figura 18

Pronóstico de áreas boscosas con el modelo de la regresión exponencial negativa



Nota. IC, son los intervalos de confianza al 80% y 95%.

En la Tabla 10, se presentan los valores proyectados de las áreas boscosas, mostrando una disminución significativa a medida que avanzan los años. Las proyecciones indican una reducción de aproximadamente 72143.98 hectáreas en el 2025 y 62805.09 hectáreas para el 2030, lo que equivale al 58.1% y 50.5% del área total, respectivamente. Los intervalos de confianza se calcularon al 80% y 95%, ya que estos niveles son ampliamente reconocido y es comúnmente utilizarlos (Hyndman & Athanasopoulos, 2021).

Por otro lado, estos niveles de tendencias se evidencian en un aumento de la incertidumbre conforme las predicciones se distancian de los datos históricos. Por ejemplo, en los intervalos de confianza al 80% para 2030 se extiende desde aproximadamente 60324.86 hectáreas en el límite inferior hasta 66350.29 hectáreas en el límite superior, equivalente al 48.5% y 53.4%, respectivamente. A comparación con un intervalo de confianza al 95% para 2030 se extiende desde aproximadamente 58491.59 hectáreas en el límite inferior hasta 67041.35 hectáreas en el límite superior, equivalente al 47.1% y 53.9%, respectivamente. Al analizar estos dos intervalos se muestra una alta variabilidad, ya que la incertidumbre juega un papel importante en el pronóstico.

Por ende, estas bandas reflejan la complejidad de los factores que influyen en la dinámica de los bosques, estas dinámicas están influenciadas por eventos inesperados

como incendios forestales (Franco, 2022) y cambios en las políticas de uso del suelo (Romero, 2021). Sin embargo, Saikia et al. (2024) resalta que estas predicciones son útiles para que los responsables de las políticas y los planificadores adopten enfoques holísticos para la protección y conservación de ecosistemas únicos como los bosques.

Tabla 10

Evolución proyectada de las áreas forestales con la exponencial negativa

Años	Áreas (ha)				
	Límite inferior IC 95%	Límite inferior IC 80%	Área predicha	Límite superior IC 80%	Límite superior IC 95%
2025	69416.33	70691.74	72143.98	73868.91	74280.39
2026	67066.37	68500.18	70171.22	72300.18	72759.06
2027	64814.18	66397.53	68252.41	70764.29	71285.50
2028	62641.30	64306.72	66386.07	69263.43	69854.03
2029	60530.99	62281.42	64570.76	67792.88	68441.05
2030	58491.59	60324.86	62805.09	66350.29	67041.35

En la Figura 19, se presentan tres gráficos que analizan los residuos del modelo de exponencial negativa aplicado. El primer gráfico, correspondiente a la serie histórica de residuos, muestra un patrón alternado de valores positivos y negativos. Los residuos positivos indican que el modelo sobreestima la deforestación en ciertos años, mientras que los valores negativos reflejan una subestimación. Sin embargo, dado que la mayoría de los residuos están cercanos a cero, se puede inferir que el modelo proporciona un buen pronóstico, capturando adecuadamente la información disponible.

En el segundo gráfico, la Función de Autocorrelación (ACF) revela que casi todos los valores se encuentran dentro de las bandas de confianza (líneas punteadas). Esto indica la ausencia de autocorrelación significativa en los residuos, lo que refuerza la idea de que las predicciones del modelo son fiables.

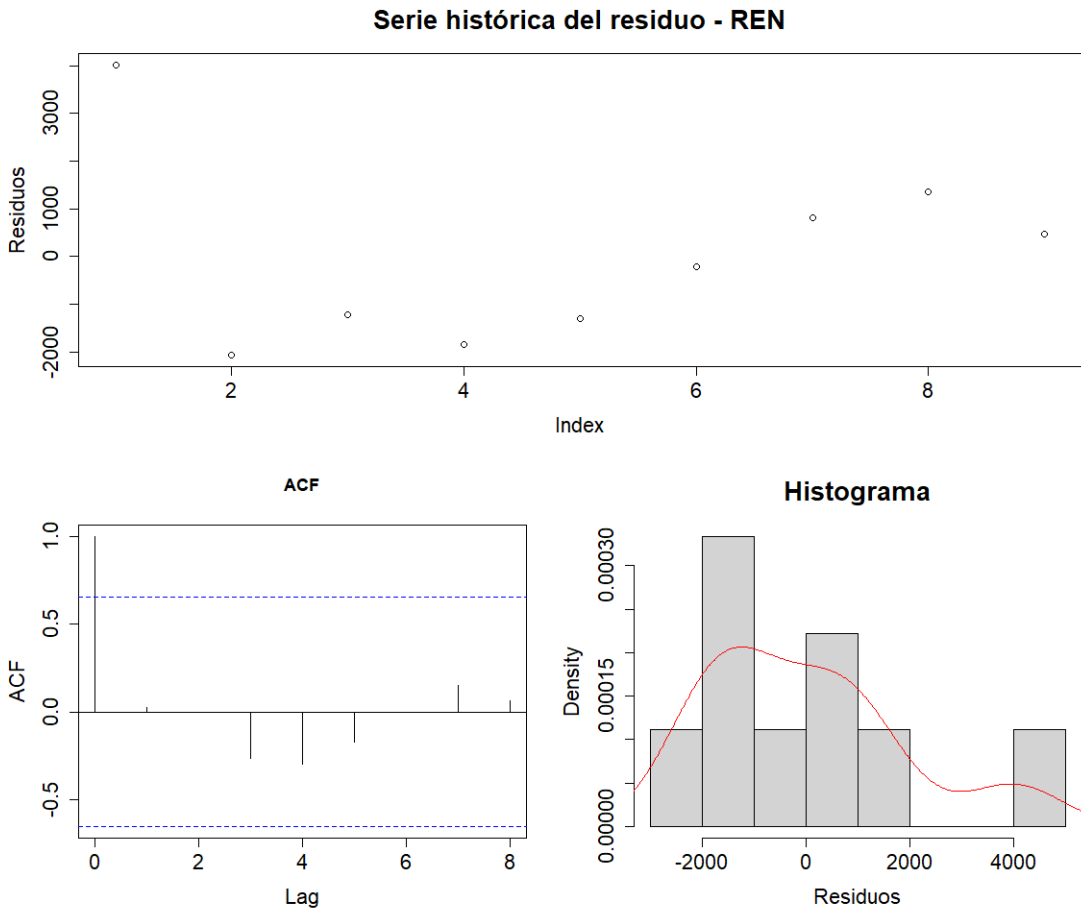
El tercer gráfico, un histograma de los residuos, muestra una distribución asimétrica con mayor densidad en valores negativos y una cola más larga hacia los positivos. Esto sugiere que los residuos no cumplen completamente con el supuesto de normalidad, ya que lo ideal sería una distribución aproximadamente normal, simétrica alrededor de cero.

Para evaluar con mayor precisión la normalidad de los residuos, se aplicó la prueba de Shapiro-Wilk, obteniéndose un p-valor de 0.3073. Este resultado, al ser mayor a 0.05, confirma que los residuos del modelo tienen una distribución normal, lo cual

respalda la validez del modelo utilizado para representar la serie temporal de deforestación.

Figura 19

Diagnósticos residuales del método de la exponencial negativa



Nota. REN es la abreviatura del modelo de la Regresión Exponencial Negativa.

4.2. Prueba de hipótesis

Se ha evidenciado una pérdida de cobertura forestal debido a la deforestación, con una reducción de 21972 hectáreas de bosques durante los nueve años analizados. Esta disminución se atribuye principalmente a la expansión agrícola, el aumento de áreas sin vegetación provocadas por incendios, y el predominio de vegetación herbácea como consecuencia de la fragmentación de bosques y la intensificación de actividades ganaderas.

CONCLUSIONES

- Los cambios de cobertura y usos del suelo ocasionados por la deforestación en el distrito de Pichanaqui desde el 2016 al 2024 a través de la clasificación supervisada, se mostró una pérdida significativa de cobertura boscosa, ocasionados por la expansión agrícola, el incremento de áreas sin vegetación a causa de los incendios forestales y el incremento de vegetación herbácea como resultado de la fragmentación de bosques y la ganadería.
- El modelo que mostró mejor desempeño de los cuatro modelos de Machine Learning evaluados, fue Random Forest con una precisión global de 0.916 en su índice de Kappa en comparación con los otros modelos.
- La clasificación de las coberturas y usos del suelo en el distrito de Pichanaqui, para el periodo 2016 al 2024, basados en la metodología Corine Land Cover, se identificaron 10 categorías las cuales fueron: Áreas urbanizadas (Au), Áreas agrícolas (Aa), Bosques (B), Vegetación herbácea (Vh), Áreas sin vegetación (Asv), Ríos y quebradas (Ryq), Nubes (N), Áreas arenosas (Ar), Pajonal (P) y Lagunas (L).
- Durante el período 2016 al 2024, el distrito de Pichanaqui ha pasado por un notable proceso de transición en cuanto a las coberturas y usos del suelo, de los cuales los cambios más significativos fueron: Áreas urbanizadas (Au) incrementaron su extensión en 14.392 ha, Áreas agrícolas (Aa) aumentaron notablemente su área en 7571.98 ha, Bosques (B) han reducido significativamente su superficie en 21971.65 ha, Vegetación herbácea (Vh) incrementó su área en 13215.6 ha y las Áreas sin vegetación (Asv) ampliaron su extensión en 2839.36 ha.
- La pérdida de cobertura boscosa del distrito de Pichanaqui para el periodo 2016 al 2024 fue de 21972 hectáreas, con una tasa de deforestación anual promedio del 1.97%, lo que equivale a 2441 hectáreas de bosque perdido por cada año.
- Se identificó 7 tipos de bosques en el distrito de Pichanaqui, durante el periodo 2016-2024, tomando como referencia el Mapa Nacional de Ecosistemas del Perú (2019), de acuerdo a la clasificación estos son: el Bosque Basimontano de Yunga (BBY), el Bosque Altimontano de Yunga (BAY), el Bosque de colina alta (BCA), el Bosque estacionalmente seco (BES), el Bosque de terraza no inundable (BTNI) y el Bosque aluvial inundable (BAI).
- Se estimó que la cobertura boscosa para el 2030 a través del modelo de la regresión exponencial negativa, se perdió 11829 hectáreas desde el 2024 al 2030 y para el 2030, quedará solo el 51.5% de cobertura boscosa respecto al área total. Con intervalos de confianza al 80% de 48.5% y 53.4% y al 95% de 47.1% y 53.9%.

RECOMENDACIONES

- Utilizar imágenes satelitales de un mismo sensor y que tengan una mejor resolución espacial y temporal, esto para tener datos mucho más precisos y confiables al realizar los estudios. Así mismo, tener en cuenta al momento de adquirir las imágenes que sean en una etapa menos lluviosa y con la menor cantidad de nubes posibles, ya que se podría perder áreas relevantes para el estudio.
- Complementar los estudios que usen imágenes satelitales con datos socioeconómicos, demográficos y climáticos para comprender mejor las causas y los patrones de deforestación y así proponer alternativas de solución.
- Difundir los resultados de esta investigación a las diferentes entidades y organizaciones para proponer políticas que ayuden en la conservación de los bosques y fomenten prácticas sostenibles para reducir la deforestación.
- Todas las instituciones educativas, especialmente las universidades, promuevan el desarrollo de investigaciones que incorporen el uso de herramientas de teledetección y sistemas de información geográfica, ya que estas tecnologías son fundamentales para enfrentar los desafíos del futuro y ofrecen un gran potencial en el análisis y comprensión de diversos fenómenos ambientales, sociales y económicos.
- No abarcar grandes áreas de estudios al realizar este tipo de estudio debido a que requiere un procesamiento de datos extensos lo que incrementa costos computacionales y el tiempo necesario para el análisis. Así como, la dificultad para obtener datos de campo representativos y suficientes para entrenar los distintos modelos de clasificación.

REFERENCIAS BIBLIOGRÁFICAS

- Abad-Auquilla, A. (2020). El cambio de uso de suelo y la utilidad del paisaje periurbano de la cuenca del río Guayllabamba en Ecuador. *Revista de Ciencias Ambientales*, 54(2), 68–91. <https://doi.org/10.15359/rca.54-2.4>
- Abramson, J. (2022). *Precálculo* (Segunda ed). Universidad Estatal de Arizona. <https://openstax.org/details/books/precálculo-2ed>
- Acosta Martínez, L. A. (2020). Caracterización de los procesos históricos de degradación y restauración de servicios ecosistémicos en el territorio de incidencia del Bosque Modelo Colinas Bajas, República Dominicana. *CATIE: Solution for Environment and Development*, 44(8), 1–74. <https://doi.org/10.1088/1751-8113/44/8/085201>
- Alarcón Aguirre, G., Canahuire Robles, R. R., Guevara Duarez, F. M., Rodríguez Achata, L., Gallegos Chacón, L. E., & Garate-Quispe, J. (2021). Dynamics of forest loss in the southeast of the Peruvian Amazon: A case study in Madre de Dios. *Ecosistemas*, 30(2), 1–11. <https://doi.org/10.7818/ECOS.2175>
- Álava Santana, K. E., & Guerrero Vélez, J. S. (2021). *Estrategias de adaptación basada en ecosistemas enfocadas a la influencia de actividades agroproductivas sobre la deforestación de la comunidad Mocochoal, Bolívar* [Tesis de pregrado, Escuela Superior Politécnica Agropecuaria de Manabí Manuel Félix López]. <https://repositorio.espam.edu.ec/handle/42000/1658>
- Alencar da Silva Alves, K. M., & Silva Nóbrega, R. (2017). Tendencia Pluviométrica Y Concentración Estacional De Precipitación En La Cuenca Hidrográfica Del Río Moxotó – Pernamcuco – Brasil. *Revista Geográfica de América Central*, 1(58), 295. <https://doi.org/10.15359/rgac.58-1.12>
- Alonso, D. (2020). *Combinación de bandas en imágenes de satélite Landsat y Sentinel*. MappingGIS. <https://mappinggis.com/2019/05/combinaciones-de-bandas-en-imagenes-de-satelite-landsat-y-sentinel/>
- Álvarez Vélez, S., Hernández Flores, A., Mayorga Arellano, E. A., & Méndez Montero, E. E. (2021). *Monitoreo de la deforestación debido al cambio de uso de suelo en la zona centro de Hopelchén, Campeche, mediante análisis multitemporal de imágenes satelitales* [Tesis de pregrado, Instituto Politécnico Nacional]. <https://tesis.ipn.mx/handle/123456789/31770>
- Aranda Javes, A. N., & Vilca Chipana, R. E. (2022). *Evaluación de la Alteración del Ecosistema en las Lomas de Amancaes mediante la teledetección desde 2016 hasta el 2021* [Tesis de pregrado, Universidad César Vallejo]. <https://repositorio.ucv.edu.pe/handle/20.500.12692/100466>

- Arenas González, B. A. (2024). *Efecto de los cambios de la cobertura de la tierra en la recarga potencial directa en el Acuífero Libre del Valle de Aburrá*. [Universidad Nacional de Colombia]. <https://repositorio.unal.edu.co/handle/unal/86269>
- Atalaya Rojas, G. A. (2023). Percepción de cambio climático de los productores de café en el distrito de Pichanaqui, Chanchamayo- Junín. in *UNALM*.
- Barbosa, V. A., Nabout, J. C., & Cunha, H. F. da. (2023). Spatial and temporal deforestation in the Brazilian Savanna: The discrepancy between observed and licensed deforestation in the state of Goiás. *Land Use Policy*, 131. <https://doi.org/10.1016/j.landusepol.2023.106730>
- Bashi Pizarro*, M. S. (2021). Carterizacion tecnico-economico de sistemas agroforestales de café (*Coffea arabica* L) en fundos cafetaleros de dos microcuencas de Pichanaki, Junin, Perú [Tesis de pregrado, Universidad Nacional Agraria La Molina]. In *Universidad Nacional Agraria La Molina-facultad de ciencias forestales*. https://repositorio.concytec.gob.pe/bitstream/20.500.12390/187/3/2017_Puicon_Evaluacion-resistencia-natural.pdf
- Bashi Pizarro, M. S. (2023). Participación de las juventudes en la restauración del paisaje forestal: perspectivas y desafíos en Pichanaki, Perú. In *CATIE: Solution for environment and development*. <https://repositorio.catie.ac.cr/handle/11554/12335>
- Bashi Pizarro, M. S., Imbach Hermida, A., Ruiz Guevara, N., Diaz Briones, A., & Carrera Gambetta, F. (2024). *Juventudes en forestal en el Bosque restauración del paisaje las iniciativas de Modelo Pichanaki, Perú*. <https://repositorio.catie.ac.cr/handle/11554/12689>
- Buendía Martínez, O. (2018). Bosque modelo Pichanaki, una herramienta para el manejo sustentable de los recursos naturales en la Selva Central del Perú [Tesis de posgrado, Universidad Nacional Agraria La Molina]. In *LA MOLINA*. <https://repositorio.lamolina.edu.pe/handle/20.500.12996/3638>
- Bueno Quiliche, E. L. (2019). *Cambios de cobertura y uso del suelo con imágenes satelitales del distrito El Prado - Cajamarca, periodo 2003-2018* [Tesis de pregrado, Universidad Nacional de Cajamarca]. <https://repositorio.unc.edu.pe/handle/20.500.14074/3307>
- Caita Tautiva, J. R., & Castañeda Palacios, W. A. (2021). *Determinación de la mejor clasificación de coberturas obtenidas con imágenes satelitales de radar, ópticas y su sinergia 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 Ama* [Tesis de pregrado, Universidad Distrital Francisco José de Caldas]. <https://repository.udistrital.edu.co/items/771249fd-4889-48fa-a6e4-41fb1af87eeb>
- Calderon-ptaron, J. M., & Moreno, C. E. (2019). Diversidad beta como disimilitud: su partición

- en componentes de recambio y diferencias en riqueza. *La Biodiversidad En Un Mundo Cambiante: Fundamentos Teóricos y Metodológicos Para Su Estudio*, February, 203–202.
- https://www.researchgate.net/publication/339209649_Diversidad_beta_como_disimilitud_su_particion_en_componentes_de_recambio_y_diferencias_en_riqueza
- Carpio, O. V., & Fath, B. D. (2019). Assessing the environmental impacts of urban growth using land use/land cover, water quality and health indicators: A case study of Arequipa, Peru. *American Journal of Environmental Sciences*, 7(2), 90–101. <https://doi.org/10.3844/ajessp.2011.90.101>
- Castillo, C. A., Veramendi, B. N., & Revollo Sarmiento, G. N. (2023). La Caracterización Espacial de Coberturas del Suelo a partir de Información Satelital , Caso de Estudio : Zona Agroproductiva de Santa Fe , Argentina Spatial Characterization of Land Cover from Satellite Information , Case Study : *Revista Difusiones*, 2(2), 116–132. <https://doi.org/https://doi.org/10.5281/zenodo.10729463>
- Cisterna Aguilar, L. F. (2020). *La dimensión ambiental de la política exterior del Perú respecto de los bosques en el ámbito multilateral* (Vol. 2507, Issue February) [Tesis de maestría, Academia Diplomática del Perú Javier Pérez de Cuéllar]. <http://repositorio.adp.edu.pe/handle/ADP/156>
- Coaquira, E. E. (2023). *Modelo De Aprendizaje Automático Basado En El Clasificador Naive De Bayes Para La Detección Del Nivel De Depresión En Estudiantes De La Una-Puno 2022* [Tesis de pregrado, Universidad Nacional del Altiplano]. <https://repositorio.unap.edu.pe/handle/20.500.14082/20902>
- Cortes 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 pregrado, Universidad de los Andes]. <https://repositorio.uniandes.edu.co/bitstream/handle/1992/48761/u833357.pdf?sequence=1&isAllowed=y>
- Cotoa Hernández, G. J. (2020). Análisis multitemporal de la deforestación en la ciénaga de Ayapel mediante el procesamiento de imágenes de satelitales en el periodo 2010 – 2020. *Programa de Geografía - Universidad de Córdoba*, 10(1), 54–75. <https://repositorio.unicordoba.edu.co/entities/publication/9862abd5-520a-4e06-b403-17ccb2597f00>
- Cuba, N. (2015). Research note: Sankey diagrams for visualizing land cover dynamics. *Landscape and Urban Planning*, 139, 163–167. <https://doi.org/10.1016/j.landurbplan.2015.03.010>

- Dammert, J. L. (2016). *Tráfico de tierras: Deforestación, agricultura de gran escala y titulación en la Amazonía*. 1–18. <http://dlc.dlib.indiana.edu/dlc/handle/10535/10671>
- De Celis Llanos, E. R. (2019). *Modelos de clasificación para detección del cambio de uso de la tierra en la Amazonia Peruana* [Universidade Federal Do Paraná]. <https://acervodigital.ufpr.br/handle/1884/69168>
- Defensoría del Pueblo. (2024). *Informe de supervisión en el marco de los incendios forestales 2024: impacto, responsabilidad y vulneración de derechos fundamentales*. <https://www.defensoria.gob.pe/wp-content/uploads/2024/09/Informe-Defensorial-n.-225-Incendios-forestales.pdf>
- Dietrichson, A. (2019). *Métodos Cuantitativos*. <https://bookdown.org/dietrichson/metodos-cuantitativos/#prefacio>
- Elmahdy, S. I., Ali, T. A., Mohamed, M. M., Howari, F. M., Abouleish, M., & Simonet, D. (2020). Spatiotemporal Mapping and Monitoring of Mangrove Forests Changes From 1990 to 2019 in the Northern Emirates, UAE Using Random Forest, Kernel Logistic Regression and Naive Bayes Tree Models. *Frontiers in Environmental Science*, 8(July), 1–23. <https://doi.org/10.3389/fenvs.2020.00102>
- ESA, A. E. E. (2024). *Copernicus Data Space Ecosystem*. <https://dataspace.copernicus.eu/>
- Escobar Flores, R. E., & Castillo Santiago, M. Á. (2021). Cambios en la cobertura y uso del suelo en la región del Soconusco, Chiapas. *Revista Mexicana de Ciencias Forestales*, 12(66), 1–22. <https://doi.org/https://doi.org/10.29298/rmcf.v12i66.755>
- ESRI. (2021). *Qué es ArcMap*. <https://desktop.arcgis.com/es/arcmap/latest/map/main/what-is-arcmap-.htm>
- Fajardo Gamarra, R. (2023). *Análisis de la deforestación de los años 2016 y 2022 en el distrito Castillo Grande, Huánuco, Perú* [Tesis de pregrado, Universidad Nacional Agraria de la Selva]. <https://repositorio.unas.edu.pe/items/58b7f432-1d07-483c-9eae-544ec52c1a00>
- Farfán Gutiérrez, M., Rodríguez-Tapia, G., & Mas, J. F. (2015). Análisis jerárquico de la intensidad de cambio de cobertura/uso de suelo y deforestación (2000-2008) en la Reserva de la Biosfera Sierra de Manantlán, México. *Investigaciones Geográficas*, 2016(90), 89–104. <https://doi.org/10.14350/rig.48600>
- Fernandez, K., & Muñante, R. (2021). *La tala ilegal y su efecto en la deforestación en Latinoamérica - revisión bibliográfica* [Tesis de pregrado, Universidad César Vallejo]. http://repositorio.ucv.edu.pe/bitstream/handle/20.500.12692/47102/Gutierrez_RS-SD.pdf?sequence=1&isAllowed=y
- Fuentes Rivera, C. P., & Velasquez Enrique, N. P. (2022). *Análisis Multitemporal de la Intervención de Actividades Antropogénicas en la Cobertura Vegetal, Mediante*

- Teledetección, Curimaná - Ucayali, 2011 – 2022* [Tesis de pregrado, Universidad César Vallejo]. <https://repositorio.ucv.edu.pe/handle/20.500.12692/111595>
- Gonzales, L. (2019). *Evaluación de la deforestación de tolares a partir de análisis multitemporal con el uso de técnicas telemétricas en Comunidades del Altiplano Central, del departamento de La Paz*. 1–115. <https://repositorio.umsa.bo/handle/123456789/23732>
- González-Vergel, M. S., Carvajal Rodríguez, J. C., & Núñez-Rodríguez, J. de J. (2022). Factores determinantes en las emisiones de CO₂ en Colombia originados por la explotación del carbón. *Rev. Iberoam. Bioecon. Cambio Clim.*, 9(17). <https://doi.org/10.5377/ribcc.v9i17.15496>
- González, R. M., González, M. A. B., Cruz, A. M., González, A. R., & Pérez, A. L. (2022). Classification of land use and vegetation with convolutional neural networks. *Revista Mexicana de Ciencias Forestales*, 13(74), 97–119. <https://doi.org/10.29298/rmcf.v13i74.1269>
- Habib, W., & Connolly, J. (2023). A national-scale assessment of land use change in peatlands between 1989 and 2020 using Landsat data and Google Earth Engine—a case study of Ireland. *Regional Environmental Change*, 23(4). <https://doi.org/10.1007/s10113-023-02116-0>
- Hernández-Clemente, R., & Hornero, A. (2021). Monitoring and assessment of desertification using remote sensing. *Ecosistemas*, 30(3), 1–7. <https://doi.org/10.7818/ECOS.2240>
- Hernández-Sampieri, R. & Mendoza, C. (2018). *Metodología de la investigación. Las rutas cuantitativa, cualitativa y mixta* (Editorial). <https://doi.org/https://doi.org/10.22201/fesc.20072236e.2019.10.18.6>
- Hinostroza Medina, L. F. (2021). *Análisis del grado de fragmentación del paisaje mediante herramientas de información geográfica y teledetección en el distrito de Huaricolca (Tarma - Junín)* [Tesis de pregrado, Universidad Católica Sedes Sapientiae]. <https://repositorio.ucss.edu.pe/handle/20.500.14095/1021>
- Huchin Ochoa, S. A., Navarro-Martínez, A., Alan Ellis, E., & Hernández Gómez, I. U. (2022). Deforestation in the municipality of Bacalar, Quintana Roo, Mexico during the period 1993-2017. *Madera y Bosques*, 28(3), 1–13. <https://doi.org/10.21829/myb.2022.2832396>
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Pronóstico: principios y práctica* (Universidad de Monash (ed.); 3.^a edición). <https://otexts.com/fpp3/index.html>
- Janampa Torres, S. &, & Ponce Cristobal, J. (2022). *Análisis multitemporal de la deforestación por imágenes satelitales en el distrito de Pangoa, Junín desde el año 2000 al 2020* [Tesis de pregrado, Universidad Continental]. https://repositorio.continental.edu.pe/bitstream/20.500.12394/12239/4/IV_FIN_107_TE_

- John, E., Bunting, P., Hardy, A., Silayo, D. S., & Masunga, E. (2021). A forest monitoring system for tanzania. *Remote Sensing*, *13*(16), 1–29. <https://doi.org/10.3390/rs13163081>
- Kaselimi, M., Voulodimos, A., Daskalopoulos, I., Doulamis, N., & Doulamis, A. (2023). A Vision Transformer Model for Convolution-Free Multilabel Classification of Satellite Imagery in Deforestation Monitoring. *IEEE Transactions on Neural Networks and Learning Systems*, *34*(7), 3299–3307. <https://doi.org/10.1109/TNNLS.2022.3144791>
- Khan, K., Khan, J. A., Khokhar, M. F., Khan, S. N., & Iqbal, J. (2024). Estimating afforestation related forest cover change using data fusion and machine learning Estimating afforestation related forest cover change using data fusion and machine learning. *Environmental Research Communications*, 1–19. <https://doi.org/doi.org/10.1088/2515-7620/ad88e0>
- Kinnebrew, E., Ochoa-Brito, J. I., French, M., Mills-Novoa, M., Shoffner, E., & Siegel, K. (2022). Biases and limitations of Global Forest Change and author-generated land cover maps in detecting deforestation in the Amazon. *PLoS ONE*, *17*(7). <https://doi.org/10.1371/journal.pone.0268970>
- Laulli Romero, F. (2022). *Sostenibilidad de la Política Nacional Agraria en el distrito de Pichanaqui, 2020* [Tesis de maestría, Universidad Nacional del Centro del Perú]. <https://repositorio.uncp.edu.pe/handle/20.500.12894/8345>
- Leiva-Godínez, I. (2023). *Validación de la Cobertura Forestal Clasificada en el Mapa de Tipos de Bosque y Otras Tierras 2021 del SINAC para el Área Conservación Tempisque, Guanacaste, Costa Rica* [Tesis de pregrado, Instituto Tecnológico de Costa Rica]. <https://hdl.handle.net/2238/15060>
- Loayza Basan, K. J. L. (2020). *Análisis Multitemporal de los Cambios de la Cobertura Boscosa y su Proyección para el 2025 en la Estación Biológica Villa Carmen, cusco* [Tesis de pregrado, Universidad Católica Sedes Sapientiae]. https://alicia.concytec.gob.pe/vufind/Record/UCSS_f26e541bcb402582b75271792a066a42/Description#tabnav
- López Álvarez, D. V. (2021). *Relación entre los cambios de la cobertura vegetal ocurridos en la región del Valle de San Nicolás y los casos de dengue en sus 9 municipios durante el periodo 2007-2019*. <https://bibliotecadigital.udea.edu.co/handle/10495/18847>
- Lumba Huamán, E. (2023). *Análisis de la cobertura y usos de la tierra en el periodo 2000-2020 del distrito de Chalamarca-Chota-Perú*. [Tesis de pregrado, Universidad Nacional Autónoma de Chota]. <http://www.repositorio.unach.edu.pe/handle/20.500.14142/443>
- Marquet, P. A., Altamirano, A., Arroyo, M. T. K., Fernández, M., Gelcich, S., Górski, K., Habit,

- E., Lara, A., Maass, A., Pauchard, A., Pliscoff, P., Samaniego, H., & Smith-Ramírez, C. (2019). Biodiversidad y cambio climático en Chile: Evidencia científica para la toma de decisiones. *Comité Científico COP25; Ministerio de Ciencia, Tecnología, Conocimiento e Innovación*. 2019., 1–318. <https://bibliotecadigital.ciren.cl/handle/20.500.13082/32249>
- MINAM. (2014). Protocolo: Evaluación de la Exactitud Temática del Mapa de Deforestación. In *Ministerio del Ambiente*. <http://www.minam.gob.pe/ordenamientoterritorial/wp-content/uploads/sites/18/2013/10/Protocolo-Validacion-Mapa-Deforestacion.pdf>
- MINAM. (2015). Mapa Nacional de Cobertura Vegetal. *Memoria Descriptiva*, 108. <https://www.gob.pe/minam>
- MINAM. (2019). Mapa Nacional de Ecosistemas del Perú - Memoria Descriptiva. *Ministerio Del Ambiente*, 1–124. <https://repositoriodigital.minam.gob.pe/handle/123456789/925>
- Montero, R. (2013). Variables no estacionarias y cointegración. *Documentos de Trabajo En Economía Aplicada. Universidad de Granada, España*, 1–8. <https://www.ugr.es/~montero/matematicas/cointegracion.pdf>
- Morote, Á. F., & Olcina, J. (2021). Cambio climático y sostenibilidad en la Educación Primaria. Problemática y soluciones que proponen los manuales escolares de Ciencias Sociales. *Sostenibilidad Económica, Social y Ambiental*, 3(3), 25. <https://doi.org/10.14198/sostenibilidad2021.3.02>
- Moschella, P. (2023). Loss of Amazonian forests due to urban expansion in Peru. *Revista Kawsaypacha: Sociedad y Medio Ambiente*, 12, 1–17. <https://doi.org/10.18800/kawsaypacha.202302.A007>
- Municipalidad de Pichanaqui. (2018). *Plan de Desarrollo Concertado del distrito de Pichanaqui*.
- Nicolau, A. P., Herndon, K., Flores-Anderson, A., & Griffin, R. (2019). A spatial pattern analysis of forest loss in the Madre de Dios region, Peru. *Environmental Research Letters*, 14(12). <https://doi.org/10.1088/1748-9326/ab57c3>
- Peacock, M., Audet, J., Bastviken, D., Futter, M. N., Gauci, V., Grinham, A., Harrison, J. A., Kent, M. S., Kosten, S., Lovelock, C. E., Veraart, A. J., & Evans, C. D. (2021). Global importance of methane emissions from drainage ditches and canals. *Environmental Research Letters*, 16(4). <https://doi.org/10.1088/1748-9326/abeb36>
- Pérez, M. G. H., Sandoval, O. A. A., Vázquez, G. M., & Pulido, B. V. (2024). Uso y manejo del suelo. Vulnerabilidad de cambio de uso de suelo en una microcuenca del río Pantepec, Hidalgo, México. *Uso y manejo del suelo*, 299-304. https://www.researchgate.net/profile/David-Palma-7/publication/378823774_Hacia_un_conocimiento_global_y_multidisciplinario_del_rec

urso_suelo_Division_III_Uso_y_manejo_del_suelo/links/65eb3e099ab2af0ef897f9ae/Hacia-un-conocimiento-global-y-multidisciplinar

- Pérez Hernández, M. J., Hernández Acosta, E., Sánchez Jiménez, R., González Gervacio, C., & Madrigal Reyes, S. (2021). Dynamics of changes in land use and vegetation due to anthropogenic activities in Zaachila, Oaxaca. *Revista Mexicana de Ciencias Forestales*, 12(66). <https://doi.org/10.29298/rmcf.v12i66.894>
- Quezada, A. S., Sevilla Tapia, J. D., & Avilés Sacoto, E. C. (2022). Estimación de la tasa de deforestación en Pastaza y Orellana- Ecuador mediante el análisis multitemporal de imágenes satelitales durante el período 2000-2020. *Revista Alfa*, 6(17), 282–299. <https://doi.org/10.33996/revistaalfa.v6i17.168>
- Quispe Quispe, J. C., & Cáceres Fuentes, R. M. (2020). *Análisis espacial y modelado predictivo en la distribución de bosques altoandinos, en los distritos de Lares y Ollantaytambo - Cusco* [Tesis de pregrado, Universidad Nacional de San Antonio Abad del Cusco]. http://repositorio.unsaac.edu.pe/bitstream/handle/UNSAAC/2874/253T20171097.pdf?sequence=1&isAllowed=y%0Ahttps://repositorio.unsaac.edu.pe/bitstream/handle/20.500.12918/6651/253T20211152_TC.pdf?sequence=1&isAllowed=y
- Radicelli García, C., Pomboza Floril, M., Villacrés Cevallos, P., & Boderó Poveda, E. (2019). Sistemas De Información Geográfica Y Su Aplicación En Las Ciencias Sociales: Una Revisión Bibliográfica. *Chakiñan, Revista De Ciencias Sociales Y Humanidades*, 8, 24–35. <https://doi.org/10.37135/chk.002.08.02>
- Reátegui Olortegui, P. N. (2017). Clasificación de bosques utilizando imágenes de satélite Landsat, con criterio fisiográfico, en la provincia de Alto Amazonas, departamento de Loreto - Perú - 2015 [Tesis de pregrado, Universidad Nacional de la Amazonia Peruana]. <https://repositorio.unapiquitos.edu.pe/handle/20.500.12737/4698>
- Rengifo Candia, H. R. (2024). *Análisis espacio temporal del cambio de cobertura y uso de la tierra entre los años 2000 – 2020, mediante la teledetección, distrito José Crespo y Castillo – Aucayacu, Tingo María* [Tesis de pregrado, Universidad Nacional Agraria de la Selva]. <https://repositorio.unas.edu.pe/items/bf1160c5-7677-451f-825a-a30966d3f394>
- Requelme, J. (2019). *Análisis de la pérdida de cobertura boscosa y cambio de uso del suelo, mediante el análisis de imágenes satelitales, periodo 2000 al 2018; en el distrito de Chadín, Chota*. [Tesis de pregrado, Universidad Nacional de Cajamarca]. http://repositorio.unc.edu.pe/bitstream/handle/UNC/2987/Tesis_completa_Ronald_Romero.pdf?sequence=1&isAllowed=y
- Rescia, A. J., Raffin, D., Jatar, L., Giselle Sales, R., Astrada, E., Quintana, R. D., & Rodríguez Sousa, A. A. (2023). Influence of the socio-spatial context on the perception of

- environmental problems in cities in Spain and Argentina. *Journal of Cleaner Production*, 425. <https://doi.org/10.1016/j.jclepro.2023.138882>
- Rojas Briceño, N. B., Barboza Castillo, E., Maicelo Quintana, J. L., Oliva Cruz, S. M., & Salas López, R. S. (2019). Deforestation in the peruvian Amazon: Indexes of Land Cover/Land Use (LC/LU) changes based on GIS. *Boletín de La Asociación de Geógrafos Españoles*, 81, 1–34. <https://doi.org/10.21138/bage.2538a>
- Román Ruíz, T. M. (2013). *Clasificación De Bosque Utilizando Imágenes. De Satélite Landsat, Con Criterio Fisiográfico, En La Provincia De Maynas* [Tesis de pregrado, Universidad Nacional de la Amazonia Peruana]. <https://repositorio.unapiquitos.edu.pe/handle/20.500.12737/2483>
- Sahu, S. R., Rawat, K. S., Singh, S. K., & Bahuguna, A. (2022). Land Use Land Cover (LU/LC) Change Analysis Using Earth Observation Data Sets over Jharsuguda Districts of Odisha. *AIP Conference Proceedings*, 2481. <https://doi.org/10.1063/5.0117977>
- Salizzi, E. (2020). Agronegocio, deforestación y disputas en torno al Ordenamiento Territorial de Bosques Nativos de la provincia de Córdoba (Argentina). *Territorios*, 43, 1–28. <https://doi.org/10.12804/revistas.urosario.edu.co/territorios/a.7982>
- Sánchez Alvarado, K. G., & Sánchez Orbegozo, C. L. (2022). *Análisis y modelación de los procesos de deforestación en el Eje Vial Interoceánico Sur (Puerto Maldonado – Inambari) Madre de Dios, periodo 1999 – 2030* [Tesis de pregrado, Universidad Nacional Amazónica de Madre de Dios]. <https://repositorio.unamad.edu.pe/handle/20.500.14070/964>
- Saucedo Banda, L. A. (2023). *Análisis de la deforestación del Distrito Huabal – Región Cajamarca durante el periodo 2005 – 2020 y su proyección al año 2050 con teledetección* [Tesis de pregrado, Universidad Nacional de Cajamarca]. <https://repositorio.unc.edu.pe/handle/20.500.14074/5608>
- SERFOR. (2020). *Ficha Técnica de Estado de Conservación Departamento de Madre de Dios- Bosque de Colina de Alta-Kotsimba*. https://cdn.www.gob.pe/uploads/document/file/1502706/FT-MDD-01_Bosque_de_Colina_Alta_-_KotsimbaFFFF.pdf
- Shah, R. K., & Shah, R. K. (2023). Forest Cover Change Detection Using Remote Sensing and GIS in Dibru-Saikhowa National Park, Assam: A Spatio-Temporal Study. *Proceedings of the National Academy of Sciences India Section B - Biological Sciences*, 93(3), 559–564. <https://doi.org/10.1007/s40011-023-01449-4>
- Solargis, G. del B. M. y E. (2024). *Atlas solar mundial*. <https://globalsolaratlas.info/map?c=11.523088,8.173828,3>

- Tapia Salazar, L. P., & Ulloa Trujillo, A. E. (2020). *Transiciones en los cambios de uso y cobertura de suelo en la Reserva de Producción Faunística Chimborazo* [Tesis de pregrado, Universidad Nacional de Chimborazo]. <http://dspace.unach.edu.ec/handle/51000/7288>
- Tarazona, Y., & Miyasiro-López, M. (2020). Monitoring tropical forest degradation using remote sensing. Challenges and opportunities in the Madre de Dios region, Peru. *Remote Sensing Applications: Society and Environment*, 19. <https://doi.org/10.1016/j.rsase.2020.100337>
- Tariq, A., Jiango, Y., Li, Q., Gao, J., Lu, L., Soufan, W., Almutairi, K. F., & Habib-ur-Rahman, M. (2023). Modelling, mapping and monitoring of forest cover changes, using support vector machine, kernel logistic regression and naive bayes tree models with optical remote sensing data. *Heliyon*, 9(2), e13212. <https://doi.org/10.1016/j.heliyon.2023.e13212>
- Tariq, A., & Mumtaz, F. (2023). A series of spatio-temporal analyses and predicting modeling of land use and land cover changes using an integrated Markov chain and cellular automata models. *Environmental Science and Pollution Research*, 30(16), 47470–47484. <https://doi.org/10.1007/s11356-023-25722-1>
- Torre, M., & Rivas, P. (2019). *Análisis temporal de la pérdida de cobertura vegetal mediante teledetección en el distrito de Satipo-Satipo-Junín, durante los años 2015 – 2018* [Tesis de pregrado, Universidad César Vallejo]. <https://repositorio.ucv.edu.pe/handle/20.500.12692/39901>
- Tsegaye, N. T., Dibaba, W. T., & Gemed, D. O. (2023). Spatiotemporal forest cover change and its implication for environmental sustainability in Dedo district of Jimma zone, southwest Ethiopia. *Environmental and Sustainability Indicators*, 19. <https://doi.org/10.1016/j.indic.2023.100262>
- Universidad de Murcia. (2019). Correcciones a las imágenes de satélites. *Apuntes de La Asignatura Teledetección En Geografía*, 79–88. <https://www.um.es/geograf/sigmur/teledet/tema07.pdf>
- Valladares Herrera, J. P. (2023). *Monitoreo Y Proyección Del Cambio De Cobertura Forestal Por Impacto Antrópico, Aplicando Teledetección En Inambari - Madre De Dios Años 2000 Al 2030* [Tesis de pregrado, Universidad Nacional Federico Villareal]. <https://repositorio.unfv.edu.pe/handle/20.500.13084/7234>
- Vargas Tobón, Y. (2020). *Revisión de metodologías para la clasificación de las coberturas de la Tierra*. <https://bibliotecadigital.udea.edu.co/handle/10495/15420>
- Vasconcelos, B. R. de, Vieira Lima, M. T., & Conceição Paranhos Filho, A. (2024). Detecção De Mudanças No Uso E Ocupação Do Solo No Estado Do Amazonas Baseada Nas

- Classificações Do Projeto Mapbiomas. *Geofronter*, 10, 1–21.
<https://doi.org/10.61389/geofronter.v10.7773>
- Verdugo Chaura, D. A. (2022). Ráster con Terra. Esto va de Filas, Columnas, Cotas y Píxeles. In *Revista Cartográfica*. <https://doi.org/10.35424/rcarto.i106.3367>
- Villalobos, L. E. (2020). *Análisis Multitemporal de la Cobertura Boscosa y Uso de la Tierra en el Distrito de Pomahuaca, Provincia de Jaén, Periodo 2000-2019* [Tesis de pregrado, Universidad Nacional de Jaén]. <https://repositorio.unj.edu.pe/handle/UNJ/165?locale=en>
- Von Thaden, J., Laborde, J., Guevara, S., & Mokondoko-Delgadillo, P. (2020). Dinámica de los cambios en el uso del suelo y cobertura vegetal en la Reserva de la Biosfera Los Tuxtlas (2006-2016). *Revista Mexicana de Biodiversidad*, 91, 1–14.
<https://doi.org/10.22201/IB.20078706E.2020.91.3190>
- Zerouali, B., Santos, C. A. G., do Nascimento, T. V. M., & Silva, R. M. da. (2023). A cloud-integrated GIS for forest cover loss and land use change monitoring using statistical methods and geospatial technology over northern Algeria. *Journal of Environmental Management*, 341. <https://doi.org/10.1016/j.jenvman.2023.118029>

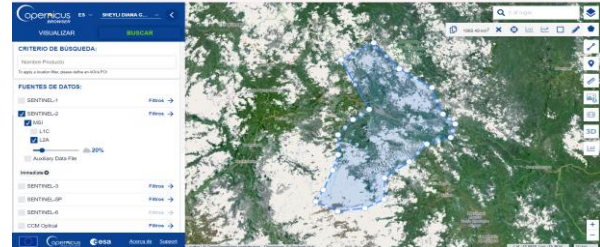
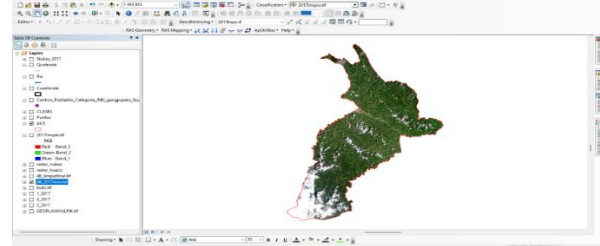
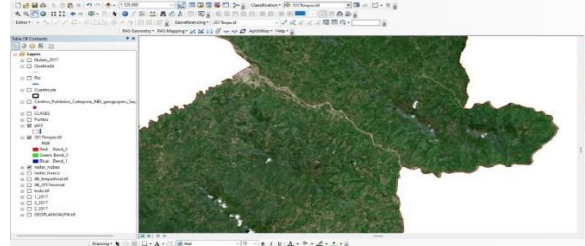
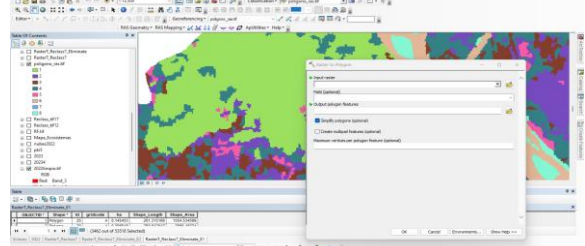
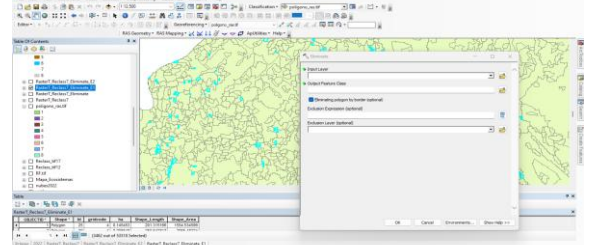
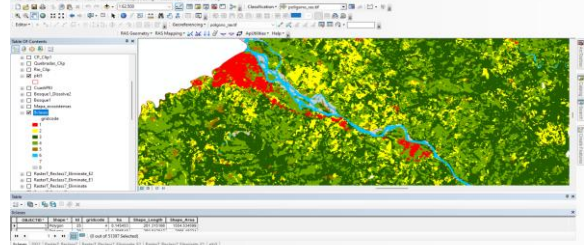
ANEXOS

Anexo 1. Matriz de consistencia

FORMULACIÓN DEL PROBLEMA	OBJETIVOS	HIPÓTESIS	VARIABLES, DIMENSIONES E INDICADORES	METODOLOGÍA DE LA INVESTIGACIÓN
Problema general	Objetivo general	Hipótesis general	<p>a) Variable Deforestación</p> <ul style="list-style-type: none"> • Dimensión Extensión y magnitud de deforestación • Indicadores <ul style="list-style-type: none"> - Superficie total deforestada - Tasa anual de deforestación - Porcentaje de reducción de cobertura forestal <p>b) Variable Cambios de coberturas y usos del suelo</p> <ul style="list-style-type: none"> • Dimensión Tipos de coberturas y usos del suelo • Indicadores 	<p>a) Nivel, tipo y diseño de la investigación</p> <ul style="list-style-type: none"> • Nivel Descriptivo. • Tipo Básico. • Diseño No experimental. <p>b) Población y muestra</p> <ul style="list-style-type: none"> • Población Cobertura terrestre del Distrito de Pichanaqui. • Muestra Se aplicó un muestreo de 23478 puntos en gabinete, distribuidos entre las siete clases de coberturas identificadas
¿Cuáles son los cambios de cobertura y usos del suelo ocasionados por la deforestación en el distrito de Pichanaqui a partir del 2016 al 2024?	Analizar los cambios de cobertura y usos del suelo ocasionados por la deforestación en el distrito de Pichanaqui desde el 2016 al 2024.	La deforestación en el distrito de Pichanaqui entre 2016 y 2024 ha generado cambios significativos en la cobertura y usos del suelo, con una notable reducción de la superficie forestal, impulsado principalmente por la expansión agrícola, que representa una de las principales causas de pérdidas de bosques.		
Problemas específicos	Objetivos específicos			
¿Cuál es el modelo de aprendizaje automático más adecuado para la clasificación supervisada de coberturas y usos del suelo en Pichanaqui?	Identificar el modelo de aprendizaje automático más adecuado para la clasificación supervisada de coberturas y usos del suelo en el distrito de Pichanaqui.			

¿Cuál es la clasificación de coberturas y usos del suelo en Pichanaqui entre el 2016 y 2024 utilizando el modelo óptimo de aprendizaje?	Clasificar las coberturas y usos del suelo en el distrito entre 2016 y 2024 empleando el modelo de aprendizaje automático óptimo.			<p>c) Técnicas e instrumentos de recolección de datos</p> <ul style="list-style-type: none"> • Análisis de campo Se elaboraron fichas para registrar las coordenadas de los distintos tipos de cobertura y usos del suelo.
¿Cuáles son los cambios de coberturas y usos del suelo en Pichanaqui desde 2016 hasta 2024?	Cuantificar los cambios en las coberturas y usos del suelo en el distrito de Pichanaqui entre el 2016 y 2024.		<ul style="list-style-type: none"> • Dimensión Proyección del cambio de cobertura forestal al 2030 • Indicadores Superficie forestal al 2030 	
¿Cuánto es la pérdida de cobertura boscosa en el distrito de Pichanaqui entre el 2016 y 2024?	Cuantificar la pérdida de cobertura boscosa en el distrito de Pichanaqui entre el 2016 y 2024.			
¿Cuáles son los tipos de bosques identificados en el distrito de Pichanaqui según el mapa nacional de ecosistemas del Perú entre el 2016 y 2024?	Clasificar los tipos de bosques en el distrito de Pichanaqui según el mapa nacional de ecosistemas del Perú entre 2016 y 2024.			
¿Cuál es la probabilidad de la pérdida de bosques en el distrito de Pichanaqui para el 2030?	Estimar la pérdida de bosques en el distrito de Pichanaqui al 2030.			

Anexo 2. Procedimientos de recolección de datos

Recopilación de imágenes satelitales	Criterios de selección de imágenes																										
	<p>Promedios mensuales Irradiación normal directa</p>  <table border="1"> <caption>Monthly Direct Normal Irradiation (kWh/m²)</caption> <thead> <tr> <th>Mes</th> <th>Irradiación (kWh/m²)</th> </tr> </thead> <tbody> <tr><td>Jan</td><td>70</td></tr> <tr><td>Feb</td><td>50</td></tr> <tr><td>Mar</td><td>70</td></tr> <tr><td>Apr</td><td>85</td></tr> <tr><td>May</td><td>95</td></tr> <tr><td>Jun</td><td>105</td></tr> <tr><td>Jul</td><td>110</td></tr> <tr><td>Aug</td><td>105</td></tr> <tr><td>Sep</td><td>90</td></tr> <tr><td>Oct</td><td>85</td></tr> <tr><td>Nov</td><td>80</td></tr> <tr><td>Dec</td><td>70</td></tr> </tbody> </table>	Mes	Irradiación (kWh/m²)	Jan	70	Feb	50	Mar	70	Apr	85	May	95	Jun	105	Jul	110	Aug	105	Sep	90	Oct	85	Nov	80	Dec	70
Mes	Irradiación (kWh/m²)																										
Jan	70																										
Feb	50																										
Mar	70																										
Apr	85																										
May	95																										
Jun	105																										
Jul	110																										
Aug	105																										
Sep	90																										
Oct	85																										
Nov	80																										
Dec	70																										
Corrección atmosférica de Landsat 8	Unión de bandas de las imágenes satelitales																										
																											
Extracción del área de estudio	Reducción de nubosidad																										
																											
Creación de puntos de muestreo	Conversión de formato TIFF a SHP																										
																											
Eliminación de áreas pequeñas	Corrección manual de la clasificación																										
																											
Extracción de bosques	Recorte de ecosistemas con bosques																										
																											

Anexo 3. Tabla de los 246 puntos de validación en campo

N°	Clases de CUS	Longitud	Latitud	Altitud
1	Áreas urbanizadas	514119	8792050	521
2	Áreas urbanizadas	513980	8792131	518
3	Áreas urbanizadas	513806	8792282	530
4	Áreas urbanizadas	514195	8792004	522
5	Áreas urbanizadas	514111	8792483	524
6	Áreas urbanizadas	514039	8792540	523
7	Áreas urbanizadas	513854	8792532	531
8	Áreas urbanizadas	513964	8792439	531
9	Áreas urbanizadas	514031	8792375	533
10	Áreas urbanizadas	514121	8792083	523
11	Áreas urbanizadas	513979	8792233	527
12	Áreas urbanizadas	513822	8792363	530
13	Áreas urbanizadas	513580	8792366	541
14	Áreas urbanizadas	513730	8792234	542
15	Áreas urbanizadas	513911	8792077	529
16	Áreas urbanizadas	514085	8791921	532
17	Áreas urbanizadas	513957	8791779	532
18	Áreas urbanizadas	513645	8792060	542
19	Áreas urbanizadas	513467	8792222	546
20	Áreas urbanizadas	513344	8792078	536
21	Áreas urbanizadas	513416	8791978	547
22	Áreas urbanizadas	513572	8791822	553
23	Áreas urbanizadas	513689	8791726	542
24	Áreas urbanizadas	513900	8791532	544
25	Áreas urbanizadas	513810	8791401	555
26	Áreas urbanizadas	535792	8783136	468
27	Áreas urbanizadas	529584	8782562	512
28	Áreas urbanizadas	529240	8782783	499
29	Áreas urbanizadas	527798	8783095	505
30	Áreas urbanizadas	526457	8784597	500
31	Áreas urbanizadas	526880	8779564	505
32	Áreas urbanizadas	515374	8768578	524
33	Áreas urbanizadas	525795	8783143	542
34	Áreas agrícolas	522156	8787593	503
35	Áreas agrícolas	521887	8787346	530
36	Áreas agrícolas	521827	8787182	548
37	Áreas agrícolas	524769	8785552	504
38	Áreas agrícolas	526683	8784512	515
39	Áreas agrícolas	526991	8784408	503
40	Áreas agrícolas	512683	8766295	1119
41	Áreas agrícolas	510393	8766593	1200
42	Áreas agrícolas	508335	8766596	1297
43	Áreas agrícolas	527000	8777008	1125
44	Áreas agrícolas	523814	8774437	1137
45	Áreas agrícolas	523816	8774432	1163
46	Áreas agrícolas	523828	8774501	1112

47	Áreas agrícolas	522081	8772982	1107
48	Áreas agrícolas	518179	8770790	1122
49	Áreas agrícolas	518187	8770806	1120
50	Áreas agrícolas	517293	8770462	1135
51	Áreas agrícolas	516566	8769415	1131
52	Áreas agrícolas	516422	8769221	1147
53	Áreas agrícolas	515756	8768836	1161
54	Áreas agrícolas	515469	8768234	1127
55	Áreas agrícolas	515369	8768233	1139
56	Áreas agrícolas	515120	8768209	1165
57	Áreas agrícolas	529017	8782901	422
58	Áreas agrícolas	529019	8782888	488
59	Áreas agrícolas	538992	8784259	460
60	Áreas agrícolas	537041	8783041	471
61	Áreas agrícolas	533587	8782305	485
62	Áreas agrícolas	532318	8782437	500
63	Áreas agrícolas	532665	8782385	478
64	Áreas agrícolas	531710	8762286	486
65	Áreas agrícolas	528379	8782877	496
66	Áreas agrícolas	527569	8783412	495
67	Áreas agrícolas	525916	8784877	503
68	Áreas agrícolas	524870	8786126	505
69	Áreas agrícolas	524415	8786365	497
70	Áreas agrícolas	523180	8787604	531
71	Áreas agrícolas	523088	8787933	501
72	Áreas agrícolas	519884	8789389	506
73	Áreas agrícolas	519634	8789343	506
74	Áreas agrícolas	514570	8792885	511
75	Áreas agrícolas	514601	8792869	509
76	Áreas agrícolas	514560	8793020	513
77	Áreas agrícolas	514859	8793018	509
78	Áreas agrícolas	514842	8793009	509
79	Áreas agrícolas	514921	8793026	510
80	Áreas agrícolas	515003	8792887	506
81	Áreas agrícolas	514974	8792936	504
82	Áreas agrícolas	514910	8793058	501
83	Áreas agrícolas	526684	8779822	500
84	Áreas agrícolas	526658	8779807	499
85	Áreas agrícolas	526642	8779810	499
86	Áreas agrícolas	526673	8779788	500
87	Áreas agrícolas	526648	8779732	499
88	Áreas agrícolas	526795	8778734	544
89	Áreas agrícolas	526825	8778762	541
90	Áreas agrícolas	526848	8778812	547
91	Áreas agrícolas	526983	8778877	548
92	Áreas agrícolas	526976	8778887	546
93	Áreas agrícolas	539008	8784257	568
94	Áreas agrícolas	529015	8782886	579

95	Bosque	521791	8787058	556
96	Bosque	521880	8786955	599
97	Bosque	511952	8766387	1162
98	Bosque	511905	8766487	1174
99	Bosque	511471	8766457	1165
100	Bosque	510309	8766593	1194
101	Bosque	509322	8766358	1205
102	Bosque	506930	8766716	1385
103	Bosque	510345	8766627	1187
104	Bosque	511859	8766489	1164
105	Bosque	520196	8771642	1178
106	Bosque	517562	8770824	1147
107	Bosque	516963	8770312	1181
108	Bosque	516710	8770032	1176
109	Bosque	516541	8769645	1155
110	Bosque	515462	8768239	1198
111	Bosque	514755	8767953	1172
112	Bosque	513770	8767320	1183
113	Bosque	513768	8767322	1171
114	Bosque	513770	8767323	1192
115	Bosque	539172	8784381	518
116	Bosque	538649	8783783	456
117	Bosque	538126	8783074	463
118	Bosque	533585	8782306	489
119	Bosque	514916	8793101	508
120	Bosque	514892	8793127	511
121	Bosque	514906	8793096	511
122	Bosque	526638	8779718	504
123	Bosque	526767	8779444	513
124	Bosque	526849	8778849	560
125	Bosque	526920	8778812	544
126	Bosque	526979	8778909	544
127	Bosque	526989	8778915	544
128	Bosque	538651	8783779	534
129	Bosque	539152	8784382	555
130	Vegetación herbácea	509819	8766468	1201
131	Vegetación herbácea	524006	8774762	725
132	Vegetación herbácea	525207	8775505	895
133	Vegetación herbácea	524440	8775062	547
134	Vegetación herbácea	521104	8772438	687
135	Vegetación herbácea	520721	8772206	798
136	Vegetación herbácea	519008	8770519	534
137	Vegetación herbácea	518988	8770473	789
138	Vegetación herbácea	515376	8768585	625
139	Vegetación herbácea	533986	8782688	485
140	Vegetación herbácea	525011	8785706	519
141	Vegetación herbácea	523378	8787262	551
142	Vegetación herbácea	522097	8788678	527

143	Vegetación herbácea	519023	8789416	505
144	Vegetación herbácea	523845	8776108	612
145	Vegetación herbácea	523870	8776089	612
146	Vegetación herbácea	523850	8776073	618
147	Vegetación herbácea	523872	8776071	621
148	Vegetación herbácea	523835	8776077	618
149	Vegetación herbácea	523810	8776103	612
150	Vegetación herbácea	523841	8776102	606
151	Vegetación herbácea	523834	8776116	600
152	Vegetación herbácea	523517	8776139	603
153	Vegetación herbácea	523484	8776112	603
154	Vegetación herbácea	523471	8776120	602
155	Vegetación herbácea	523464	8776100	604
156	Vegetación herbácea	523479	8776094	606
157	Vegetación herbácea	523478	8776076	607
158	Vegetación herbácea	523486	8776149	600
159	Vegetación herbácea	523471	8776152	600
160	Vegetación herbácea	523456	8776137	602
161	Vegetación herbácea	523440	8776143	602
162	Vegetación herbácea	522974	8776623	611
163	Vegetación herbácea	522956	8776634	614
164	Vegetación herbácea	522935	8776636	616
165	Vegetación herbácea	522820	8776775	613
166	Vegetación herbácea	522807	8776779	612
167	Vegetación herbácea	522841	8776772	612
168	Vegetación herbácea	522833	8776787	611
169	Vegetación herbácea	522593	8776846	620
170	Vegetación herbácea	522625	8776854	617
171	Vegetación herbácea	522652	8776857	616
172	Vegetación herbácea	522641	8776877	615
173	Vegetación herbácea	524973	8775444	577
174	Vegetación herbácea	526912	8779882	497
175	Vegetación herbácea	526923	8779867	495
176	Vegetación herbácea	526921	8779913	496
177	Vegetación herbácea	526891	8780007	502
178	Vegetación herbácea	526892	8780015	498
179	Vegetación herbácea	526874	8780033	496
180	Vegetación herbácea	526876	8780040	495
181	Vegetación herbácea	526859	8780068	490
182	Vegetación herbácea	526855	8780066	489
183	Vegetación herbácea	526844	8780099	485
184	Vegetación herbácea	526861	8778809	536
185	Vegetación herbácea	526840	8778841	550
186	Áreas sin vegetación	517111	8789783	514
187	Áreas sin vegetación	520941	8788587	511
188	Áreas sin vegetación	520994	8788429	512
189	Áreas sin vegetación	521893	8787958	505
190	Áreas sin vegetación	509165	8766351	1194

191	Áreas sin vegetación	508922	8766377	1230
192	Áreas sin vegetación	508624	8766424	1257
193	Áreas sin vegetación	526649	8784538	1751
194	Áreas sin vegetación	520640	8772183	1187
195	Áreas sin vegetación	519000	8770492	1121
196	Áreas sin vegetación	518628	8770705	1251
197	Áreas sin vegetación	516556	8769430	1236
198	Áreas sin vegetación	516570	8769427	1189
199	Áreas sin vegetación	515657	8768764	1193
200	Áreas sin vegetación	515152	8768221	1259
201	Áreas sin vegetación	514305	8767589	1167
202	Áreas sin vegetación	513013	8766674	1178
203	Áreas sin vegetación	538151	8783083	467
204	Áreas sin vegetación	534911	8782909	490
205	Áreas sin vegetación	525811	8785075	517
206	Áreas sin vegetación	526637	8779715	504
207	Áreas sin vegetación	526783	8779437	506
208	Aguas continentales	526654	8784521	503
209	Aguas continentales	514370	8792833	500
210	Aguas continentales	514384	8792827	497
211	Aguas continentales	514458	8792798	499
212	Aguas continentales	514471	8792791	501
213	Aguas continentales	514488	8792777	502
214	Aguas continentales	514521	8792753	500
215	Aguas continentales	514563	8792706	504
216	Aguas continentales	514641	8792698	504
217	Aguas continentales	514641	8792692	506
218	Aguas continentales	514657	8792672	505
219	Aguas continentales	514705	8792677	506
220	Aguas continentales	514709	8792679	504
221	Aguas continentales	514834	8792281	504
222	Aguas continentales	514544	8792844	504
223	Aguas continentales	514515	8792838	507
224	Aguas continentales	538123	8783045	461
225	Aguas continentales	518568	8789640	500
226	Aguas continentales	538119	8783051	503
227	Áreas arenosas	514361	8792824	502
228	Áreas arenosas	514391	8792819	498
229	Áreas arenosas	514613	8792637	505
230	Áreas arenosas	514635	8792676	505
231	Áreas arenosas	514638	8792637	507
232	Áreas arenosas	514727	8792647	503
233	Áreas arenosas	514729	8792646	507
234	Áreas arenosas	514758	8792653	504
235	Áreas arenosas	514759	8792656	506
236	Áreas arenosas	514773	8792634	504
237	Áreas arenosas	514802	8792629	503
238	Áreas arenosas	514798	8792638	503

239	Áreas arenosas	515124	8791877	497
240	Áreas arenosas	515137	8791860	499
241	Áreas arenosas	515163	8791819	501
242	Áreas arenosas	515187	8791828	499
243	Áreas arenosas	515248	8791840	500
244	Áreas arenosas	515246	8791813	501
245	Áreas arenosas	515208	8791771	499
246	Áreas arenosas	514510	8792867	506

Anexo 4. Panel fotográfico

Figura 20

Identificación de la cobertura de áreas urbanizadas en zona rural



Figura 21

Identificación de la cobertura de áreas urbanizadas en zona urbana



Figura 22

Identificación de la cobertura de áreas agrícolas en cultivo de piña



Figura 23

Identificación de la cobertura de áreas agrícolas en cultivo de plátano



Figura 24

Identificación de la cobertura del bosque estacional seco




Figura 25

Identificación de la cobertura del bosque basimontano de yunga



Figura 26

Identificación de la cobertura de vegetación herbácea en zona de pastizal



Figura 27

Identificación de la cobertura de vegetación herbácea en vegetación secundaria



Figura 28

Identificación de la cobertura de áreas sin vegetación en un rozo



Figura 29

Identificación de la cobertura de áreas sin vegetación para cultivos de kion



Figura 30

Identificación de la cobertura del río Perené



Figura 31

Identificación de la cobertura del río Ipoki



Figura 32

Identificación de la cobertura de áreas arenosas con pedregal



Figura 33

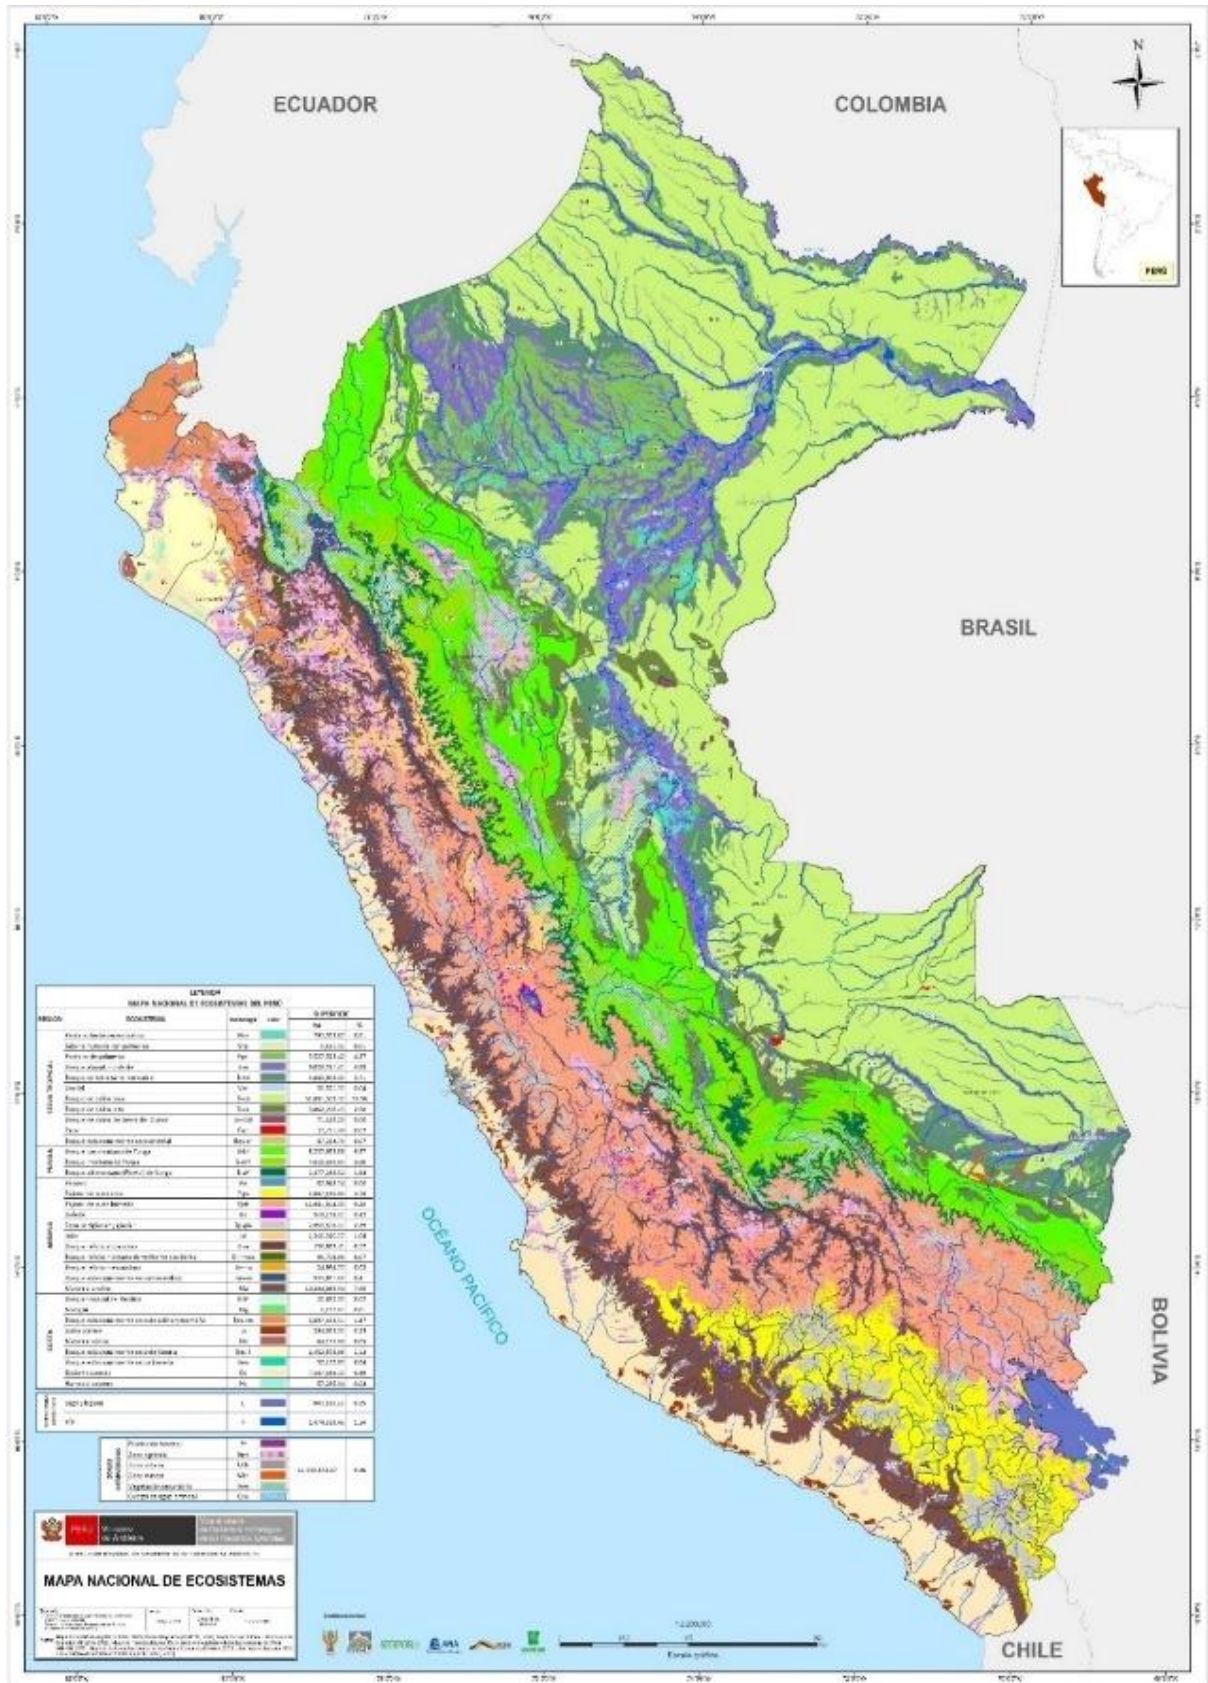
Identificación de la cobertura de áreas arenosas



Anexo 5. Mapas adicionales de referencia en el estudio

Figura 34

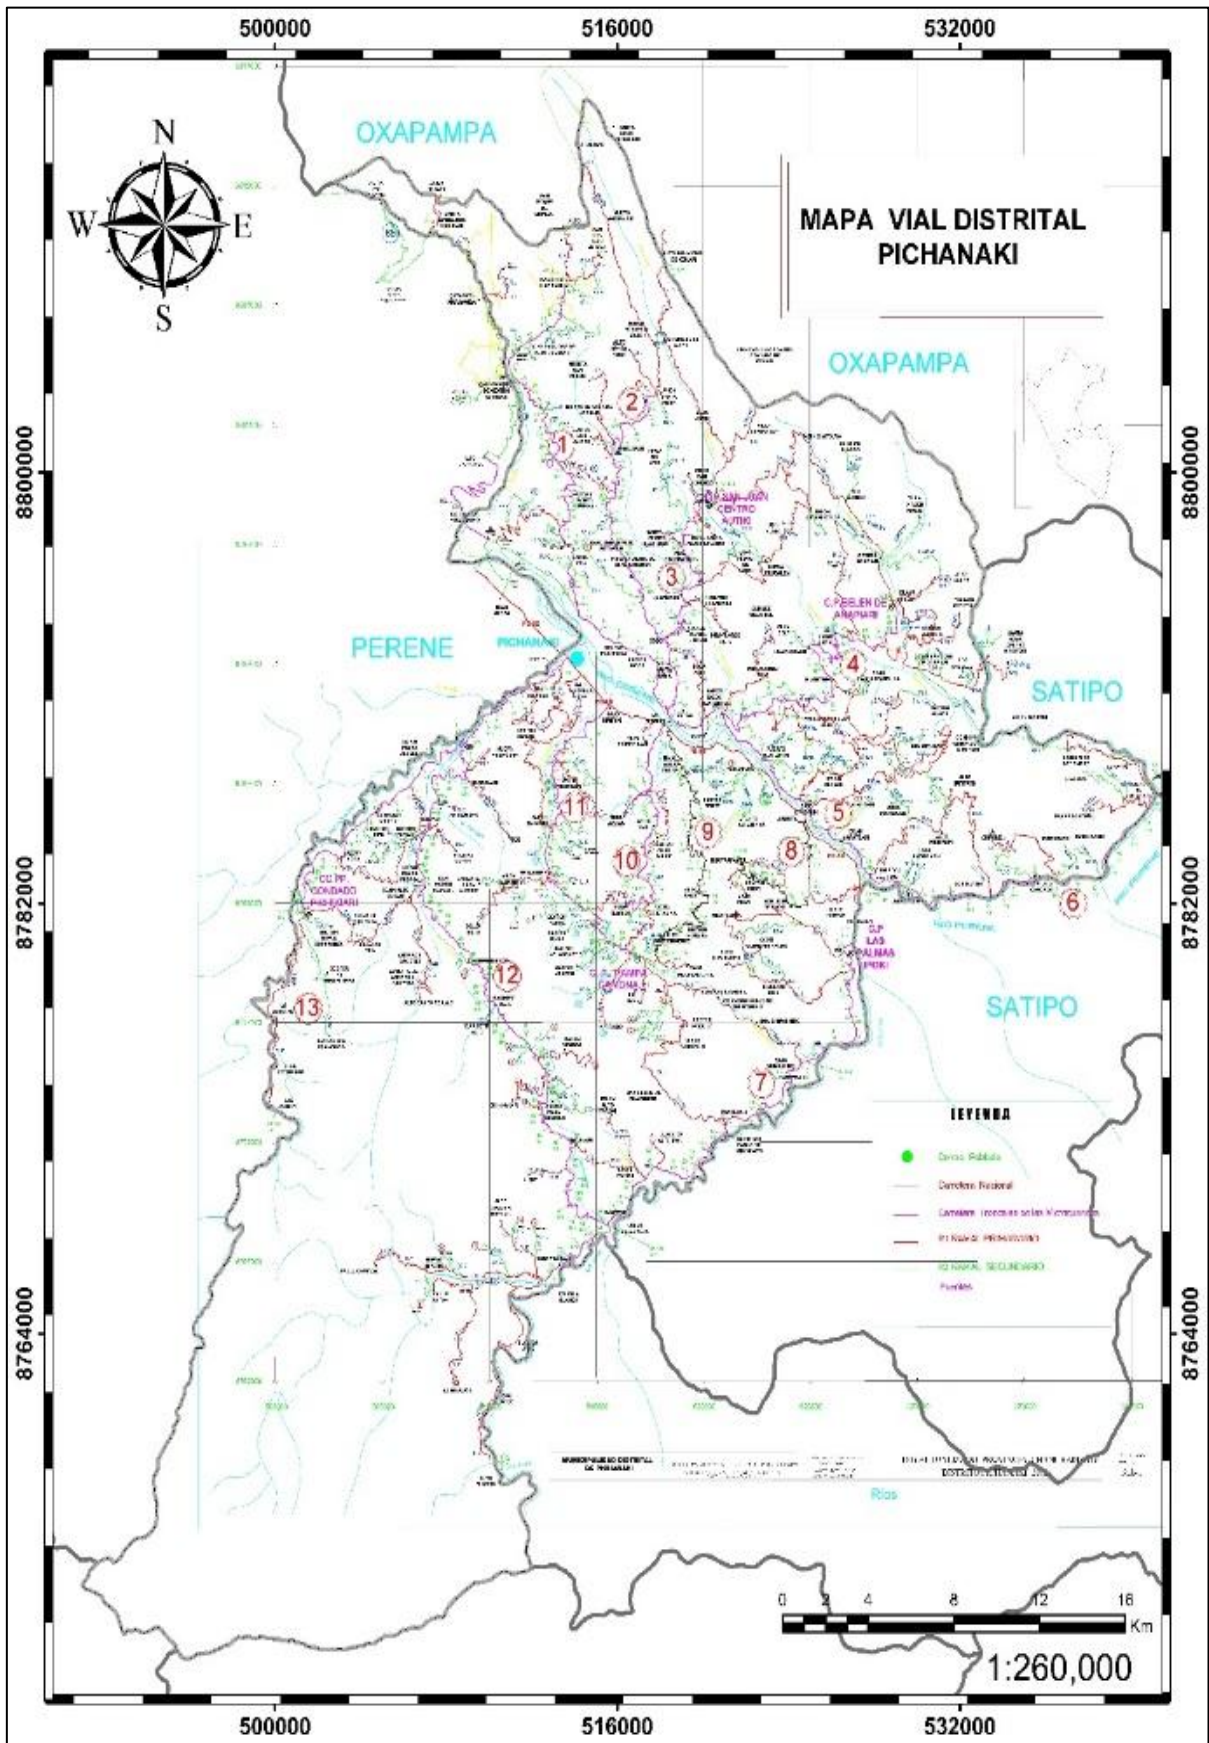
Mapa nacional de ecosistemas del Perú



Fuente: MINAM (2019).

Figura 35

Mapa vial del distrito de Pichanaqui



Fuente: Municipalidad de Pichanaqui (2018).

Anexo 6. Programación desarrollada en R

```
#Paquetes utilizados
suppressMessages(library(raster)) # Manejo de imágenes satelitales
suppressMessages(library(RStoolbox)) #Trabaja con datos raster
suppressMessages(library(terra)) # Alternativa para manejar datos espaciales
suppressMessages(library(sf)) #Manejo de datos vectoriales
suppressMessages(library(e1071)) #Bayes y svm
suppressMessages(library(snow)) #Computación paralela y distribuida de datos
suppressMessages(library(rpart)) #Decision tree
suppressMessages(library(randomForest)) # Random forest
suppressMessages(library(dplyr)) #Datos tabulares
suppressMessages(library(sp)) #Manipulación y análisis vectoriales
suppressMessages(library(ggplot2)) #Visualización gráfica
suppressMessages(library(factorextra)) #Simplificar la visualización de datos
suppressMessages(library(RColorBrewer)) #Gama de paletas de colores diseñadas
suppressMessages(library(ggspatial)) #Creación de mapas y la visualización
suppressMessages(library(rgdal)) # Manejo de coordenadas geoespaciales
suppressMessages(library(caret)) # Modelos de clasificación
suppressMessages(library(mapview)) #Visualizacion de datos geoespaciales
suppressMessages(library(OpenLand)) # Analisis LUCC
suppressMessages(library(tmap)) #Mapas tematicos
suppressMessages(library(brms)) #Mapas tematicos
suppressMessages(library(minpack.lm))
suppressMessages(library(gridExtra)) #Datos estacionarios
suppressMessages(library(tseries)) #residuos

# PARTE [1]

# Imagen Landsat 8 - 2016
mtlfile <-"LC08_L1TP_006068_20160617_20200906_02_T1_MTL.txt"
metadata <- readMeta(mtlfile)
lsat <- stackMeta(mtlfile)
plotRGB (lsat, 6,5,4 ,stretch="lin")
```

```

landsat <- subset(lsat, 4:7)
plot(landsat)
#corrección atmosférica landsat8 - preprocesamiento
last_dos<- radCor(landsat, metaData = metaData, method = "dos")
# Asigna nombres genéricos a las capas
names(last_dos) <- c("BLUE","GREEN","RED","NIR")
names(last_dos)
plot(last_dos)
#Guardar
writeRaster(last_dos, "2016.tif", overwrite=TRUE)
#Imagen Sentinel 2 - año [2024]
imgs2 <- brick("2024.tif")
dim(imgs2)
plotRGB(imgs2, 3,2,1, stretch="lin")
names(imgs2) <- c("BLUE","GREEN","RED","NIR")
n_pixeles <- ncell(imgs2)
print(n_pixeles)
#CLASIFICACION SUPERVISADA
#Firmas espectrales
muestras <- readOGR("Puntos_predichos1.shp")
# Convertir los puntos a un data frame espacial (sf) para ggview
muestras_sf <- as(muestras, "sf")
# Definir los colores personalizados
mycolor <- c("#DA0603", "#F7FA07", "#1B4D06", "#0DA42B", "#956D36", "#08D1CB",
"#fefefe", "#8e9999")
# Crear un mapa interactivo con mapview
mapview(muestras_sf, zcol = "Id", col.regions = mycolor)
# Extraemos las firmas espectrales
vegt <- extract(imgs2,muestras)
df <- data.frame(vegt,class=data.frame(class = muestras@data))
str(df)

```

```

# sample, separa aleatoriamente los datos
Muestra<-sample(1:23478 , 2347)
testeo <- df[Muestra,]
entrenamiento<-df[-Muestra,]
#MODELOS DE CLASIFICACION CON SUPERVISION
# [1] RandomForest
entrenamiento_clean <- na.omit(entrenamiento)
model <- randomForest(as.factor(Id)~., data=entrenamiento_clean, importance=TRUE)
prediccion <- predict(model, testeo[,-5])
Matriz<-table(testeo[,5],prediccion)
Matriz
kappa_RF <- sum(diag(Matriz))/sum(Matriz)
kappa_RF
class(kappa_RF)
beginCluster()
rf_class<- clusterR(imgs2, raster::predict, args = list(model = model))
endCluster()
mycolor <- c("#DA0603", "#F7FA07", "#1B4D06", "#0DA42B", "#956D36", "#08D1CB",
"#fefefe", "#8e9999")
plot(rf_class, col = mycolor, cex.lab = 0.7, cex.axis = 0.6,
     main=paste("Kappa = ", format(kappa_RF, digits=2), sep = "Random Forest "), cex.main =
0.8)
# [2] SVM
model<-svm(as.factor(Id)~.,data=entrenamiento_clean, importance=TRUE)
prediccion <- predict(model, testeo[,-5])
length(prediccion)
MC<-table(testeo[,5],prediccion)
MC
kappa_SVM<-sum(diag(MC))/sum(MC)
kappa_SVM
beginCluster()
svm_class<- clusterR(imgs2, raster::predict, args = list(model = model))

```

```

endCluster()

mycolor <- c("#DA0603", "#F7FA07", "#1B4D06", "#0DA42B", "#956D36", "#08D1CB",
"#E1FAF7")

plot(svm_class, main=paste("kappa = ",format(kappa_SVM, digits=2), sep = "Support Vector
Machine"), col = mycolor, cex.lab=0.6,
      cex.axis=0.6, cex.main=0.7)

# [3] Bayesiano

model<-naiveBayes(as.factor(ld)~.,data=entrenamiento, importance=TRUE)

prediccion<- predict(model, testeo[,-5])

length(prediccion)

MC<-table(testeo[,5],prediccion)

MC

kappa_B<-sum(diag(MC))/sum(MC)

kappa_B

beginCluster()

bayesiano_class<- clusterR(imgs2, raster::predict, args = list(model = model))

endCluster()

mycolor <- c("#DA0603", "#F7FA07", "#1B4D06", "#0DA42B", "#956D36", "#08D1CB",
"#E1FAF7")

plot(bayesiano_class, main=paste("kappa=",format(kappa_B, digits=2), sep = "Bayesiano"), col
= mycolor, cex.lab=0.6,cex.axis=0.6, cex.main=0.7)

# [4] Decision Tree

model<-rpart(as.factor(ld)~.,data=entrenamiento)

prediccion<- predict(model, testeo[,-5], type="class")

length(prediccion)

MC<-table(testeo[,5],prediccion)

MC

kappa_DT<-sum(diag(MC))/sum(MC)

kappa_DT

beginCluster()

beginCluster(n = 7)

DT_class<- clusterR(imgs2, raster::predict, args = list(model = model, type="class"))

```

```

endCluster()

mycolor <- c("#DA0603", "#F7FA07", "#1B4D06", "#0DA42B", "#956D36", "#08D1CB",
"#E1FAF7")

plot(DT_class, main=paste("kappa=", format(kappa_DT, digits=2), sep = "Decision Tree"), col =
mycolor, cex.lab=0.6, cex.axis=0.6, cex.main=0.7)

#Guardar

#writeRaster(rf_class, "2024RF.tif", overwrite=TRUE) #Para la verificación en campo

#VALIDACION DE CLASSIFICATION SUPERVISADA

#Graficando los aciertos globales

vect_kappa<-c(kappa_RF, kappa_SVM, kappa_B, kappa_DT)
x<-c("RF", "SVM", "B", "DT")

plot(vect_kappa, pch=20, col="grey", ylim=c(0.7,1.0), ylab="Precisión Global",
      xlab="Algoritmos de Machine Learning", cex=2.0, cex.lab=1.5, cex.axis=1.5, cex.main=1.5,
      main="2024")

# Añadir el valor de Kappa y el nombre del algoritmo juntos
text(x=1, y=vect_kappa[1], labels=paste("RF\n", round(vect_kappa[1], 3)),
      pos=3, cex=1.5, col="darkgreen")

text(x=2, y=vect_kappa[2], labels=paste("SVM\n", round(vect_kappa[2], 3)),
      pos=3, cex=1.5, col="blue")

text(x=3, y=vect_kappa[3], labels=paste("B\n", round(vect_kappa[3], 3)),
      pos=3, cex=1.5, col="purple")

text(x=4, y=vect_kappa[4], labels=paste("D\n", round(vect_kappa[4], 3)),
      pos=3, cex=1.5, col="brown")

# índice del valor máximo
max_index <- which.max(vect_kappa)

# Resaltar el valor máximo con un círculo rojo
points(max_index, vect_kappa[max_index], pch=19, col="red", cex=2) # cex aumenta el
tamaño del círculo

# Agregar una línea horizontal en el valor máximo de kappa
abline(h=max(vect_kappa), lty=2, lwd=1, col="red")

# PARTE [2]

# Cargar los puntos de verificación de campo

```



```

#Firmas espectrales

muestras <- readOGR("Puntos_finales.shp")

# Extraemos las firmas espectrales

vegt <- extract(imgs2,muestras)

df <- data.frame(vegt,class=data.frame(class = muestras@data))

str(df)

# sample, separa aleatoriamente los datos

Muestra<-sample(1:23725 , 2372)

testeo <- df[Muestra,]

entrenamiento<-df[-Muestra,]

# [1] RandomForest

entrenamiento_clean <- na.omit(entrenamiento)

model <- randomForest(as.factor(Id)~., data=entrenamiento_clean, importance=TRUE)

prediccion <- predict(model, testeo[,-5])

Matriz<-table(testeo[,5],prediccion)

Matriz

kappa_RF <- sum(diag(Matriz))/sum(Matriz)

kappa_RF

class(kappa_RF)

beginCluster()

rf_class<- clusterR(imgs2, raster::predict, args = list(model = model))

endCluster()

mycolor <- c("#DA0603", "#F7FA07", "#1B4D06", "#0DA42B", "#956D36", "#08D1CB",
"#fefefe", "#8e9999")

#Visualizar

plot(rf_class, col = mycolor, cex.lab = 0.7, cex.axis = 0.6,

      main=paste("Kappa = ", format(kappa_RF, digits=2), sep = "Random Forest "), cex.main =
0.8)

# Guardar el modelo Random Forest 2024 realizado

saveRDS(model_final, file = "modelo_clasificacion_2024.rds")

# Cargar el modelo para usarlo en otros años

modelo_rf <- readRDS("modelo_clasificacion_2024.rds")

```

```
# Cargar las imágenes satelitales de otros años
img_2017 <- brick("2017.tif")
names(img_2017) <- c("BLUE", "GREEN", "RED", "NIR")
n_pixeles <- ncell(img_2017)
print(n_pixeles)
img_2018 <- brick("2018.tif")
names(img_2018) <- c("BLUE", "GREEN", "RED", "NIR")
n_pixeles <- ncell(img_2018)
print(n_pixeles)
img_2019 <- brick("2019.tif")
names(img_2019) <- c("BLUE", "GREEN", "RED", "NIR")
n_pixeles <- ncell(img_2019)
print(n_pixeles)
img_2020 <- brick("2020.tif")
names(img_2020) <- c("BLUE", "GREEN", "RED", "NIR")
n_pixeles <- ncell(img_2017)
print(n_pixeles)
img_2021 <- brick("2021.tif")
names(img_2021) <- c("BLUE", "GREEN", "RED", "NIR")
n_pixeles <- ncell(img_2017)
print(n_pixeles)
img_2022 <- brick("2022.tif")
names(img_2022) <- c("BLUE", "GREEN", "RED", "NIR")
n_pixeles <- ncell(img_2017)
print(n_pixeles)
img_2023 <- brick("2023.tif")
names(img_2023) <- c("BLUE", "GREEN", "RED", "NIR")
n_pixeles <- ncell(img_2017)
print(n_pixeles)
# Crear una función para clasificar
clasificar_imagen <- function(imagen, modelo) {
```

```

# Convertir la imagen en una matriz
datos_img <- as.data.frame(values(imagen))

# Predecir usando el modelo de clasificación
predicciones <- predict(modelo, newdata = datos_img)

# Convertir la predicción a raster para mapearlo
raster_pred <- setValues(imagen[[1]], predicciones) # Utiliza una capa de referencia
return(raster_pred)
}

# Aplicar la clasificación para los años
#clasificacion_2016 <- clasificar_imagen(img_2016, modelo_rf)
clasificacion_2017 <- clasificar_imagen(img_2017, modelo_rf)
clasificacion_2018 <- clasificar_imagen(img_2018, modelo_rf)
clasificacion_2019 <- clasificar_imagen(img_2019, modelo_rf)
clasificacion_2020 <- clasificar_imagen(img_2020, modelo_rf)
clasificacion_2021 <- clasificar_imagen(img_2021, modelo_rf)
clasificacion_2022 <- clasificar_imagen(img_2022, modelo_rf)
clasificacion_2023 <- clasificar_imagen(img_2023, modelo_rf)

#VISUALIZAR LOS MAPAS CON ggplot2

# Convertir el raster en un data.frame
rf_class_df <- as.data.frame(rasterToPoints(rf_class))

# Nombrar las columnas del data.frame
colnames(rf_class_df) <- c("x", "y", "class")

# Crear el mapa
ggplot() +
  geom_raster(data = rf_class_df, aes(x = x, y = y, fill = as.factor(class))) +
  scale_fill_manual(values = mycolor,
                    name = "Clases",
                    labels = c("Áreas urbanizadas", "Áreas agrícolas", "Bosques", "Vegetación
herbacea", "Áreas sin vegetación", "Aguas continentales", "Nubes", "Áreas arenosas")) +
  labs(title = paste("Mapa de Clasificación - Random Forest", "\n2024"),
       x = "X",

```

```

y = "Y") +
theme_minimal() +
theme(plot.title = element_text(hjust = 0.5),
      legend.position = "right",
      axis.text = element_text(size = 10),
      axis.title = element_text(size = 12))
plot(clasificacion_2020, col = mycolor, cex.lab = 0.7, cex.axis = 0.6,
      main=paste("Kappa = ", format(kappa_RF, digits=2), sep = "Random Forest "), cex.main =
0.8)
# Guardar la clasificación
writeRaster(clasificacion_2016, "clasificacion_2016.tif", format = "GTiff", overwrite=TRUE)
writeRaster(clasificacion_2017, "clasificacion_2017.tif", format = "GTiff", overwrite=TRUE)
writeRaster(clasificacion_2018, "clasificacion_2018.tif", format = "GTiff", overwrite=TRUE)
writeRaster(clasificacion_2019, "clasificacion_2019.tif", format = "GTiff", overwrite=TRUE)
writeRaster(clasificacion_2020, "clasificacion_2020.tif", format = "GTiff", overwrite=TRUE)
writeRaster(clasificacion_2021, "clasificacion_2021.tif", format = "GTiff", overwrite=TRUE)
writeRaster(clasificacion_2022, "clasificacion_2022.tif", format = "GTiff", overwrite=TRUE)
writeRaster(clasificacion_2023, "clasificacion_2023.tif", format = "GTiff", overwrite=TRUE)
#PARTE [3]
#GRAFICAS LUCC
# Lista de archivos TIFF
archivos <- c("2016.tif", "2017.tif", "2018.tif", "2019.tif",
             "2020.tif", "2021.tif", "2022.tif", "2023.tif", "2024.tif")
# Cargar los r sters en una lista de objetos RasterBrick
poligonos <- lapply(archivos, brick)
# Ajustar las extensiones para que coincidan con la del primer pol gono
ref_extent <- extent(poligonos[[1]]) # Usamos el pol gono 1 como referencia
# Reamostrar todos los dem s pol gonos si no coinciden en extensi n
poligonos_resampled <- lapply(poligonos, function(pol) {
  if (!identical(extent(pol), ref_extent)) {
    # Reamostrar si las extensiones no coinciden

```

```

resample(pol, poligonos[[1]], method = "bilinear")
} else {
  return(pol) # No reamostrar si la extensión ya coincide
}
})

# Apilar todos los polígonos resampleados en un solo stack
cober <- stack(poligonos_resampled)

# Imprimir las extensiones para verificar que todas coincidan
lapply(poligonos_resampled, extent)

# Comprobar el número de capas
num_layers <- nlayers(cober)
print(num_layers)

# Asignar nombres de capas asegurando que coincidan
names(cober)<-c("2016", "2017", "2018", "2019", "2020", "2021", "2022", "2023", "2024")
crs(cober)

mycolor <- c("#DA0603", "#F7FA07", "#1B4D06", "#0DA42B", "#956D36", "#08D1CB",
"#fefefe", "#8e9999", "#facc63", "#247fda")

#MAPA MULTITEMPORAL
plot(cober, col = mycolor)

# Que proporcion ocupa cada clase en cada año? Vamos a conocer la frecuencia de cada uno
frecuencias<-freq(cober)

# El resultado será una lista con 6 elementos, 1 por año
coberturas<-c("Áreas urbanizadas", "Áreas agrícolas", "Bosque", "Vegetación herbácea",
"Áreas sin vegetación", "Ríos y quebradas", "Nubes", "Áreas arenosas", "Pajonal", "Lagunas")

frec.2016<-frecuencias[[1]] %>% as.data.frame() %>% na.omit() %>% mutate(Freq=
count/sum(count), Cober=coberturas)

frec.2017<-frecuencias[[2]] %>% as.data.frame() %>% na.omit() %>% mutate(Freq=
count/sum(count), Cober=coberturas)

frec.2018<-frecuencias[[3]] %>% as.data.frame() %>% na.omit() %>% mutate(Freq=
count/sum(count), Cober=coberturas)

frec.2019<-frecuencias[[4]] %>% as.data.frame() %>% na.omit() %>% mutate(Freq=
count/sum(count), Cober=coberturas)

frec.2020<-frecuencias[[5]] %>% as.data.frame() %>% na.omit() %>% mutate(Freq=
count/sum(count), Cober=coberturas)

```

```

frec.2021<-frecuencias[[6]] %>% as.data.frame() %>% na.omit() %>% mutate(Freq=
count/sum(count), Cober=coberturas)

frec.2022<-frecuencias[[7]] %>% as.data.frame() %>% na.omit() %>% mutate(Freq=
count/sum(count), Cober=coberturas)

frec.2023<-frecuencias[[8]] %>% as.data.frame() %>% na.omit() %>% mutate(Freq=
count/sum(count), Cober=coberturas)

frec.2024<-frecuencias[[9]] %>% as.data.frame() %>% na.omit() %>% mutate(Freq=
count/sum(count), Cober=coberturas)

lista.c<- list(cober[[1]], cober[[2]], cober[[3]], cober[[4]], cober[[5]], cober[[6]], cober[[7]],
cober[[8]], cober[[9]]) #EN FUNCION DE LOS A;OS [aqui cambie cober 100]

names(lista.c)<-
c("Landscape_2016","Landscape_2017","Landscape_2018","Landscape_2019","Landscape_20
20","Landscape_2021","Landscape_2022","Landscape_2023","Landscape_2024") #EN
FUNCION DE LOS A;OS

#tabla.cont<-contingencyTable(lista.c, pixelresolution = 10)

tabla.cont <- contingencyTable(lista.c, pixelresolution = 10 * 10) # 10 metros, ajustado para
hectáreas

print(tabla.cont)

tabla<-as.data.frame(tabla.cont$lulc_Multistep)

unique(tabla$To)

## Editamos los nombres de las categorias

tabla<-as.data.frame(tabla.cont$lulc_Multistep)

unique(tabla$To) # Aquí podemos comprobar que categorias tenemos

tabla.cont$tb_legend$categoryName<- factor(c("Au", "Aa", "B", "Vh", "Asv", "Ryq", "N", "Ar",
"P", "L"), levels=c("Au", "Aa", "B", "Vh", "Asv", "Ryq", "N", "Ar", "P", "L"))

## Seleccionamos los colores para el grafico

tabla.cont$tb_legend$color <- c("#DA0603","#F7FA07","#1B4D06",
"#0DA42B","#956D36","#08D1CB", "#fefefe","#8e9999","#facc63","#247fda")

## Comprobamos la tabla

tabla.cont$tb_legend

# Grafica de barras

barras <- barplotLand(
  dataset = tabla.cont$lulc_Multistep,
  legendtable = tabla.cont$tb_legend,
  xlab = "Año", # Etiqueta para el eje X

```

```

ylab = bquote("Área (" ~ ha~ ")"), # Etiqueta para el eje Y
area_ha = TRUE
)
# Añadiendo tema, ajustando leyendas y tamaños de etiquetas y ticks
barras <- barras +
  theme_bw() + # Tema blanco y negro
  labs(
    x = "Año", # Etiqueta del eje X
    y = bquote("Área (" ~ ha~ ")") # Etiqueta del eje Y
  ) +
  theme(
    axis.title.x = element_text(size = 20), # Tamaño de la etiqueta del eje X
    axis.title.y = element_text(size = 20), # Tamaño de la etiqueta del eje Y
    axis.text.x = element_text(size = 15), # Tamaño de los valores del eje X
    axis.text.y = element_text(size = 15), # Tamaño de los valores del eje Y
    legend.text = element_text(size = 15), # Tamaño del texto de la leyenda
    legend.title = element_text(size = 15) # Tamaño del título de la leyenda
  )
# Imprime el gráfico final
print(barras)
#Visualización de cambios con Sankey [Paso multiple]
sankeyLand(dataset = tabla.cont$lulc_Multistep,
  legendtable = tabla.cont$tb_legend)
# Diagramas de cuerdas (cambios acumulados)
chordDiagramLand(dataset = tabla.cont$lulc_Onestep, legendtable = tabla.cont$tb_legend)
png(filename="Cuerdas.png", units="cm", width = 50, height = 100, res=1000)
dev.off()
netgrossplot(
  dataset = tabla.cont$lulc_Multistep,
  legendtable = tabla.cont$tb_legend,
  xlab = "Categorías", # Etiqueta para el eje X

```

```

ylab = bquote("Área (" ~ ha ~ ")"), # Etiqueta para el eje Y
changesLabel = c(GC = "Cambios Brutos", NG = "Ganancia Neta", NL = "Pérdida Neta"),
color = c(GC = "gray70", NG = "#006400", NL = "#EE2C2C")
) +
scale_y_continuous(labels = scales::comma) + # Muestra los números en formato estándar
theme_bw() + # Tema blanco y negro
theme(
  axis.title.x = element_text(size = 20), # Tamaño de la etiqueta del eje X
  axis.title.y = element_text(size = 20), # Tamaño de la etiqueta del eje Y
  axis.text.x = element_text(size = 15), # Tamaño de los valores del eje X
  axis.text.y = element_text(size = 15), # Tamaño de los valores del eje Y
  legend.text = element_text(size = 15), # Tamaño del texto de la leyenda
  legend.title = element_text(size = 15) # Tamaño del título de la leyenda
)
# PARTE [4]
#PREOYECCION PARA Bosque
bosque_2016 <- st_as_sf (readOGR("2016.shp"))
bosque_2016$ha <- as.numeric(st_area(bosque_2016))/10000
bosque_2017 <- st_as_sf (readOGR("2017.shp"))
bosque_2017$ha <- as.numeric(st_area(bosque_2017))/10000
bosque_2018 <- st_as_sf (readOGR("2018.shp"))
bosque_2018$ha <- as.numeric(st_area(bosque_2018))/10000
bosque_2019 <- st_as_sf (readOGR("2019.shp"))
bosque_2019$ha <- as.numeric(st_area(bosque_2019))/10000
bosque_2020 <- st_as_sf (readOGR("2020.shp"))
bosque_2020$ha <- as.numeric(st_area(bosque_2020))/10000
bosque_2021 <- st_as_sf (readOGR("2021.shp"))
bosque_2021$ha <- as.numeric(st_area(bosque_2021))/10000
bosque_2022 <- st_as_sf (readOGR("2022.shp"))
bosque_2022$ha <- as.numeric(st_area(bosque_2022))/10000
bosque_2023 <- st_as_sf (readOGR("2023.shp"))

```

```

bosque_2023$ha <- as.numeric(st_area(bosque_2023))/10000
bosque_2024 <- st_as_sf (readOGR("2024.shp"))
bosque_2024$ha <- as.numeric(st_area(bosque_2024))/10000
#suponiendo que tienes una columna que clasifica el tipo de bosque
data_combined <- bind_rows(
  mutate(st_as_sf(bosque_2016), year = 2016),
  mutate(st_as_sf(bosque_2017), year = 2017),
  mutate(st_as_sf(bosque_2018), year = 2018),
  mutate(st_as_sf(bosque_2019), year = 2019),
  mutate(st_as_sf(bosque_2020), year = 2020),
  mutate(st_as_sf(bosque_2021), year = 2021),
  mutate(st_as_sf(bosque_2022), year = 2022),
  mutate(st_as_sf(bosque_2023), year = 2023),
  mutate(st_as_sf(bosque_2024), year = 2024)
)
#suponiendo que ha es tu columna de clasificacion
unit_time_series <- data_combined %>%
  arrange(year) %>%
  pull(ha) %>% # Asegúrate de que `ha` es el área del bosque para cada año
  ts(start = 2016, frequency = 1)
#Gráfica de la Serie Temporal
plot(unit_time_series, main = "Serie Temporal de Área de Bosque (2016-2024)",
  xlab = "Año", ylab = "Área (ha)")
#ANÁLISIS DE MIS DATOS
# [1] Prueba de Mann-Kendall
years <- 2016:2024 # Rango de años
area <- as.numeric(unit_time_series) # Conversión de tu serie de datos a formato numérico
# Prueba de Mann-Kendall
mk_test <- mk.test(area)
# Mostrar los resultados
print(mk_test)

```

```

# p < 0.05: Hay una tendencia significativa.
# p ≥ 0.05: No hay evidencia de una tendencia significativa.
#[2] Prueba de Dickey-Fuller Aumentada (ADF)
tseries::adf.test(unit_time_series)
#Si el p-valor es mayor que 0.05, los datos son no estacionarios.
#Si el p-valor es menor o igual a 0.05, los datos son estacionarios.
#[3] Prueba de Shapiro-Wilk
shapiro_result <- shapiro.test(unit_time_series)
# Ver el resultado de la prueba
print(shapiro_result)
#Si el p-valor es mayor que 0.05, los datos tienen una distribución normal.
#Si el p-valor es menor o igual a 0.05, los datos NO tienen una distribución normal.
# # Graficar ACF
acf_plot <- forecast::ggAcf(unit_time_series) +
  ggtitle("") +
  theme_minimal() +
  theme(
    axis.title = element_text(size = 25),
    axis.text = element_text(size = 22),
    plot.title = element_text(size = 25) # Ajustar el tamaño del título aquí
  ) +
  scale_y_continuous(
    breaks = seq(-1, 1, 0.5), # Escala más detallada del eje Y
    limits = c(-1, 1)
  ) +
  geom_hline(yintercept = 0, color = "black", size = 1) + # Línea central más gruesa
  geom_segment(color = "blue", size = 2) # Color naranja para las barras
print(acf_plot)
#PREDICCION CON EL MEDELO DE LA EXPONENCIAL NEGATIVA
# Crear los datos históricos
years <- 2016:2024

```

```

data <- data.frame(year = years, area = as.numeric(unit_time_series))

# Modelo exponencial negativo
model_exp <- nlsLM(area ~ a * exp(-b * (year - 2016)),
  data = data,
  start = list(a = max(data$area), b = 1.2))

# Predicciones históricas
historical_predictions <- data %>%
  mutate(predicted_area = predict(model_exp, newdata = .))

# Años futuros y predicciones
future_years <- data.frame(year = 2025:2030)
future_predictions <- future_years %>%
  mutate(predicted_area = predict(model_exp, newdata = .))

# Bootstrap para intervalos de confianza
set.seed(123)
n_boot <- 2000 # Más iteraciones
boot_samples <- replicate(n_boot, {
  boot_data <- data %>% sample_n(nrow(data), replace = TRUE)
  boot_model <- nlsLM(area ~ a * exp(-b * (year - 2016)),
    data = boot_data,
    start = list(a = max(boot_data$area), b = 0.1))
  predict(boot_model, newdata = future_years)
}, simplify = "array")

# Intervalos de confianza del 80% y 95%
ci_lower_80 <- apply(boot_samples, 1, quantile, 0.1)
ci_upper_80 <- apply(boot_samples, 1, quantile, 0.9)
ci_lower_95 <- apply(boot_samples, 1, quantile, 0.025)
ci_upper_95 <- apply(boot_samples, 1, quantile, 0.975)
future_predictions <- future_predictions %>%
  mutate(lower_ci_80 = ci_lower_80, upper_ci_80 = ci_upper_80,
    lower_ci_95 = ci_lower_95, upper_ci_95 = ci_upper_95)

```

```

# Gráfico con la leyenda en el lado izquierdo
ggplot() +
  # Datos históricos
  geom_line(data = data, aes(x = year, y = area), color = "black", size = 1, linetype = "solid") +
  # Predicciones futuras
  geom_line(data = future_predictions, aes(x = year, y = predicted_area), color = "blue", size =
1) +
  # Intervalo de confianza 95%
  geom_ribbon(data = future_predictions, aes(x = year, ymin = lower_ci_95, ymax =
upper_ci_95, fill = "95%"),
            alpha = 0.2) +
  # Intervalo de confianza 80%
  geom_ribbon(data = future_predictions, aes(x = year, ymin = lower_ci_80, ymax =
upper_ci_80, fill = "80%"),
            alpha = 0.3) +
  # Configuración de colores para la leyenda
  scale_fill_manual(values = c("80%" = "blue", "95%" = "darkblue"),
                  name = "IC") +
  # Configuración del gráfico
  scale_x_continuous(breaks = seq(2016, 2030, by = 2)) +
  labs(
    title = "Predicción del Área de Bosque (2016-2030)",
    x = "Año",
    y = "Área (ha)"
  ) +
  theme_minimal() +
  theme(
    legend.position = "right", # Leyenda a la izquierda
    legend.title = element_text(size = 12), # Tamaño del título de la leyenda
    legend.text = element_text(size = 10) # Tamaño del texto de la leyenda
  )
# Mostrar predicciones futuras con intervalos de confianza

```

```

future_predictions

# evaluar la calidad del ajuste y generar gráficos de diagnóstico con los siguientes pasos:

# [1]

original_values <- data$area # Cambia 'valor' al nombre de tu columna de datos originales

predicted_values <- future_predictions$predicted_area # Cambia 'prediccion' al nombre
correcto

# OBTENER RESIDUOS

residuals <- residuals(model_exp)

# Función para crear un gráfico con los residuos y sus análisis

plot_residuals <- function(residuals, model_name) {
  # Definir el layout: 2 filas y 2 columnas
  layout(matrix(c(1, 1, 2, 3), nrow = 2, byrow = TRUE))

  # Gráfico de residuos
  plot(residuals, main = paste("Serie histórica del residuo", model_name), ylab = "Residuos",
       cex.axis = 1.5, cex.lab = 1.5, cex.main = 1.8)

  # Gráfico de ACF
  acf(residuals, main = "ACF", cex.axis = 1.5, cex.lab = 1.5, cex.main = 2)

  # Histograma de residuos
  hist(residuals, main = "Histograma", probability = TRUE, xlab = "Residuos",
       cex.axis = 1.5, cex.lab = 1.5, cex.main = 1.8)

  lines(density(residuals), col = "red")

  # Restablecer el layout a la configuración predeterminada
  layout(1)
}

# Graficar los residuos del modelo
plot_residuals(residuals, "- REN")

# Realiza el test de Shapiro-Wilk
shapiro.test(residuals(model_exp))

#Si el p-valor > 0.05, no se rechaza la hipótesis nula (los residuos siguen una distribución
normal).

#Si el p-valor ≤ 0.05, los residuos no siguen una distribución normal.

```