



Esta obra está bajo una
[Licencia Creative Commons
Atribución - 4.0 Internacional \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/)

Vea una copia de esta licencia en
<https://creativecommons.org/licenses/by/4.0/deed.es>





FACULTAD DE INGENIERÍA DE SISTEMAS E INFORMÁTICA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS E INFORMÁTICA

Tesis

Detección de la tala ilegal mediante reconocimiento acústico en el área de conservación regional cordillera escalera

Para optar el título profesional de Ingeniero de Sistemas e Informática

Autor:

Wilmer Roman Cordova

<https://orcid.org/0000-0001-7563-8824>

Asesor:

Ing. Mg. Richard Enrique Injante Oré

<https://orcid.org/0000-0002-2449-8937>

Tarapoto, Perú

2025



FACULTAD DE INGENIERÍA DE SISTEMAS E INFORMÁTICA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS E INFORMÁTICA

Tesis

Detección de la tala ilegal mediante reconocimiento acústico en el área de conservación regional cordillera escalera

Para optar el grado académico de Ingeniero de Sistemas e Informática

Presentado por

Wilmer Roman Cordova

Sustentado y aprobado el 10 de junio del 2025, por los siguientes jurados:

Presidente de Jurado
Lic. Dr. Carlos Rodríguez Grández

Secretario de Jurado
Ing. Dr. Alberto Alva Arévalo

Vocal de Jurado
Ing. Mg. Carlos Armando Ríos
López

Asesor
Ing. Mg. Richard Enrique Injante Ore

Tarapoto, Perú

2025



Universidad Nacional de San Martín
Facultad de Ingeniería de Sistema e Informática
Ciudad Universitaria - Jr. Amorarca # 315 - Morales



ACTA DE SUSTENTACIÓN PARA OPTAR EL TÍTULO DE INGENIERO DE SISTEMAS E INFORMÁTICA

Resolución N° 025-2025-UNSM/FISI-D (06.06.2025)

FACULTAD DE INGENIERÍA DE SISTEMAS E INFORMÁTICA – ESCUELA PROFESIONAL DE
INGENIERÍA DE SISTEMAS E INFORMÁTICA

A las 11:30 horas del día martes, 10 de junio del año 2025, se inició el acto público de sustentación de la tesis titulada: DETECCIÓN DE LA TALA ILEGAL MEDIANTE RECONOCIMIENTO ACÚSTICO EN EL ÁREA DE CONSERVACIÓN REGIONAL CORDILLERA ESCALER; presentado por WILMER ROMAN CORDOVA, con el Asesor: Ing. Mg. Richard Enrique Injante Oré.

Instalado los miembros de jurado calificador conformado por:

Presidente : Lic. Dr. Carlos Rodriguez Grández
Secretario : Ing. Dr. Alberto Alva Arévalo
Vocal : Ing. Mg. Carlos Armando Rios López

El presidente del jurado dirigió brevemente unas palabras y a continuación el secretario dio lectura a la Resolución N° 025-2025-UNSM/FISI-D.

Seguidamente el autor expuso el trabajo de investigación y el jurado realizó las preguntas pertinentes, respondidas por el sustentante y eventualmente por el asesor, con la venia del jurado.

Una vez terminada la ronda de preguntas el jurado procedió a deliberar para determinar la calificación final, para lo cual dispuso un receso de quince (15) minutos, con participación del asesor con voz, pero sin voto y sin la presencia del sustentante y otros participantes del acto público.

Luego de aplicar los criterios de calificación con estricta observancia del principio de objetividad y de acuerdo con los puntajes en escala vigesimal (de 0 a 20), según el Anexo 4.2. del RG-CTI, la nota de sustentación otorgada resultante del promedio aritmético de los calificativos emitidos por cada uno de los miembros del jurado fue ...DIECIOCHO... (18).

De acuerdo con el Artículo 40° del RG – CTI, la nota obtenida es ...APROBADO... y correspondiente a la calificación de ...MUY BUENO...; leído este resultado en presencia de todos los participantes del acto de sustentación, el secretario dio lectura a las observaciones subsanables al informe final que el autor deberá corregir y alcanzar al jurado en un plazo máximo de treinta (30) días calendario.



Universidad Nacional de San Martín

Facultad de Ingeniería de Sistemas e Informática

Ciudad Universitaria - Jr. Américo # 35 - Huancayo



Firman los integrantes del jurado calificador, asesor y el autor de la tesis en señal de conformidad, dando por concluido el acto a las 12:30 horas, el mismo día 10 de junio del 2025.

Lic. Dr. CARLOS RODRÍGUEZ GRÁNDEZ
Presidente

Ing. Dr. ALBERTO ALVA ARÉVALO
Secretario

Ing. Mg. CARLOS ARMANDO RÍOS
LÓPEZ
Vocal

Ing. Mg. RICHARD ENRIQUE INJANTE
ORE
Asesor

WILMER ROMAN CORDOVA
Autor

Declaratoria de autenticidad

Wilmer Roman Cordova, con DNI N° **76956749**, egresado de la Escuela Profesional de Ingeniería de Sistemas e Informática, Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de San Martín, autor de la tesis titulada: **Detección de la tala ilegal mediante reconocimiento acústico en el área de conservación regional cordillera escalera**

Declarajo bajo juramento que:

1. La tesis presentada es de nuestra autoría.
2. La redacción fue realizada respetando las citas y referencia de las fuentes bibliográficas consultadas
3. Toda información que contiene la tesis no ha sido plagiada;
4. Los datos presentados en los resultados son reales, no han sido alterados ni copiados, por tanto, la información de esta investigación debe considerarse como aporte a la realidad investigada.

Por lo antes mencionado, asumimos bajo responsabilidad las consecuencias que deriven de mi accionar, someténdome a las leyes de nuestro país y normas vigentes de la Universidad Nacional de San Martín.

Tarapoto, 10 de junio del 2025



Wilmer Roman Cordova
DNI N° 76956749

Ficha de identificación

<p>Título: Detección de la tala ilegal mediante reconocimiento acústico en el área de conservación regional cordillera escalera</p>	<p>Área de investigación: Ciencias Naturales Línea de investigación: Ciencias de la Computación. Sublínea de investigación: Inteligencia Artificial y Recuperación de Información Grupo de investigación: Grupo de Investigación IA, N° 134–2021–UNSM/FISI/CFT Tipo de investigación: Básica <input type="checkbox"/>, Aplicada <input checked="" type="checkbox"/>, Desarrollo experimental <input type="checkbox"/></p>
---	--

<p>Autor: Wilmer Roman Cordova</p>	<p>Facultad de Ingeniería de Sistemas e Informática Escuela Profesional de Ingeniería de Sistemas e Informática https://orcid.org/0000000175638824</p>
--	---

<p>Asesor: Ing. Mg. Richard Enrique Injante Oré</p>	<p>Dependencia local de soporte: Facultad de Ingeniería de Sistemas e Informática Escuela Profesional de Ingeniería de Sistemas e Informática Unidad o Laboratorio Ingeniería de Sistemas e Informática https://orcid.org/0000-0002-2449-8937</p>
--	--

Dedicatoria

A Dios, quien ha sido la fuerza inspiradora en mi vida y ha guiado cada paso que he dado. A través de su infinita misericordia, he sido bendecido con unos padres maravillosos que han sido mi sostén, mi ejemplo y mi mayor bendición en este viaje llamado vida.

A mi padre Amalio Roman Cordova y a mi madrecita Pascualita Cordova Ruiz por el esfuerzo, consejos, y sabias palabras las cuales fueron la columna vertebral para haber llegado hasta aquí. les dedico mi más profundo agradecimiento, Su amor inquebrantable ha dado forma a mi carácter y me ha dado la confianza para perseguir mis sueños.

Que esta dedicatoria sea un recordatorio constante de mi amor y gratitud hacia ustedes, mis amados padres, y hacia Dios, quien ha sido nuestro faro en esta travesía. Que podamos seguir caminando juntos, confiando en que Dios nos guiará en cada paso del camino.

Agradecimientos

Deseo expresar mi más sincero agradecimiento a mi familia por su amor incondicional y constante apoyo, a mi asesor, académico (Ing. Richard Enrique Injante Oré) por su guía experta, a mis amigos y seres queridos por su aliento y comprensión, a los profesores y profesionales que compartieron su conocimiento conmigo, y a todas las fuentes de información y bibliotecas que brindaron recursos para mi investigación. Sin su apoyo, esta tesis no habría sido posible. Mi gratitud hacia todos ellos es eterna.

Índice general

Ficha de identificación	6
Dedicatoria	7
Agradecimientos.....	8
Índice general.....	9
Índice de tablas	11
Índice de figuras	12
RESUMEN	13
ABSTRACT	14
CAPÍTULO I INTRODUCCIÓN A LA INVESTIGACIÓN.....	15
CAPÍTULO II MARCO TEÓRICO	17
2.1. Antecedentes de la investigación	17
2.2. Fundamentos teóricos	21
CAPÍTULO III MATERIALES Y MÉTODOS.....	28
3.1. Ámbito y condiciones de la investigación.....	28
3.1.1. Contexto de la investigación.....	28
3.1.2. Periodo de ejecución.....	29
3.1.3. Autorizaciones y permisos	29
3.1.4. Control ambiental y protocolos de bioseguridad.....	29
3.1.5. Aplicación de principios éticos internacionales.....	30
3.2. Sistema de variables	30
3.3. Procedimientos de la investigación.....	31
3.3.1. Actividades del objetivo específico 1	31
3.3.2. Actividades del objetivo específico 2.....	32
3.3.3. Actividades del objetivo específico 3.....	33
CAPÍTULO IV RESULTADOS Y DISCUSIÓN	35
4.1. Resultados del Objetivo específico 1	35
4.2. Resultados del Objetivo específico 2.....	38

4.3. Resultados del Objetivo específico 3.....	46
CONCLUSIONES.....	55
RECOMENDACIONES.....	56
REFERENCIAS BIBLIOGRÁFICAS.....	57
Anexos	62

Índice de tablas

Tabla 1 Variables.....	30
Tabla 2 Especificaciones técnicas de la grabadora H1n-Zoom.....	36
Tabla 3 Especificaciones técnicas de la motosierra Stihl 660	36
Tabla 4 Variables registradas en el sistema de hojas de cálculo	37
Tabla 5 Algoritmos utilizados en cada etapa del proceso	38
Tabla 6 Configuración y resultados del entrenamiento del modelo	46
Tabla 7 Métricas De Rendimiento (F1 – Score, Recall, Precisión)	51
Tabla 8 Investigaciones Anteriores y mi Investigación	53

Índice de figuras

Figura 1 Grabadora de audio H1n-Zoom	35
Figura 2 Motosierra utilizada: Stihl 660	36
Figura 3 Registro de Datos en el Sistema de Hojas de cálculo.....	37
Figura 4 Diagrama de procedimiento del modelo.....	40
Figura 5: Instalación de las librerías de Python.....	41
Figura 6 Arquitectura del modelo.....	44
Figura 7 Precisión del Modelo	47
Figura 8 Función entrenamiento y validación del modelo	47
Figura 9 Porcentaje de validación del modelo.....	48
Figura 10 Matriz de confusión del modelo	49
Figura 11 Grafica de la Curva Roc (AUC).....	50

RESUMEN

Detección de la tala ilegal mediante reconocimiento acústico en el área de conservación regional cordillera escalera

La investigación propuso un sistema de detección de tala ilegal en el Área de Conservación Regional Cordillera Escalera (ACR-CE), utilizando técnicas de reconocimiento acústico basadas en inteligencia artificial. El objetivo principal fue evaluar la eficacia de un modelo de red neuronal convolucional (CNN) para identificar sonidos de motosierras, característicos de actividades de tala ilegal, en entornos naturales. Para ello, se recopilaron 1,200 grabaciones de audio con sonidos ambientales y de motosierras mediante grabadoras profesionales distribuidas en puntos estratégicos del ACR-CE. Los audios fueron procesados con técnicas de reducción de ruido y transformados en espectrogramas Mel para su análisis. El modelo fue entrenado con 5,400 audios organizados en 18 carpetas, alcanzando una precisión del 98.01%, una sensibilidad del 97.5% y una especificidad del 98.2%, lo que demostró su alta capacidad de clasificación incluso en entornos acústicamente complejos. Se concluyó que la inteligencia artificial aplicada al monitoreo acústico constituyó una solución eficaz, no invasiva y de bajo costo para la vigilancia ambiental en tiempo real, con potencial de ser replicada en otras áreas protegidas de la Amazonía peruana y del mundo.

Palabras clave: Tala ilegal, Reconocimiento acústico, Inteligencia artificial, Red neuronal convolucional (CNN), Espectrogramas Mel.

ABSTRACT

Detection of illegal logging through acoustic reconnaissance in the Cordillera Escalera regional conservation area

The research proposed a system for detecting illegal logging in the Cordillera Escalera Regional Conservation Area (ACR-CE), using acoustic recognition techniques based on artificial intelligence. The main objective was to evaluate the effectiveness of a convolutional neural network (CNN) model to identify chainsaw sounds, characteristic of illegal logging activities, in natural environments. For this purpose, 1,200 audio recordings of environmental and chainsaw sounds were collected using professional recorders distributed at strategic points in the ACR-CE. The audios were processed with noise reduction techniques and transformed into Mel spectrograms for analysis. The model was trained with 5,400 audios organized in 18 folders, achieving an accuracy of 98.01%, a sensitivity of 97.5% and a specificity of 98.2%, which demonstrated its high classification capability even in acoustically complex environments. It was concluded that artificial intelligence applied to acoustic monitoring constituted an effective, non-invasive and low-cost solution for real-time environmental surveillance, with the potential to be replicated in other protected areas of the Peruvian Amazon and around the world.

Keywords: Illegal Logging, Acoustic Recognition, Artificial Intelligence, Convolutional Neural Network (CNN), Mel Spectrograms.



CAPÍTULO I

INTRODUCCIÓN A LA INVESTIGACIÓN

La tala ilegal es una de las principales causas de deforestación y degradación ambiental a nivel mundial, afectando gravemente los ecosistemas y la biodiversidad, particularmente en regiones como Sudamérica. Desde el surgimiento de las primeras civilizaciones, se estima que el planeta ha perdido alrededor del 46% de sus bosques naturales, siendo la tala ilegal un factor clave en esta reducción (Gabrielli et al. 2020). En la actualidad, se talan aproximadamente 15 mil millones de árboles cada año, contribuyendo a la pérdida acelerada de cobertura forestal (Crowther et al. 2015). La tala ilegal no solo representa una amenaza ambiental, sino también económica y social, ya que debilita la economía, afecta la calidad de vida de las comunidades locales, en especial de los pueblos indígenas, y compromete la estabilidad política de las naciones afectadas (Soto 2003).

En Sudamérica, se estima que el 80% de la tala de bosques es ilegal en algunos países, lo que contribuye significativamente a la deforestación y al cambio climático (Louman & Villalobos 2001). Los bosques desempeñan un rol fundamental en la regulación climática, la purificación del aire y el agua, y la protección frente a desastres naturales (Horton et al. 2021; Burrell et al. 2022). No obstante, la tala ilegal ha reducido millones de hectáreas de bosques en países como Brasil, Colombia y Perú, lo que ha generado un impacto devastador en términos de biodiversidad, emisión de gases de efecto invernadero y erosión del suelo (Arambaru 1995; Van Eynde & Blomley 2015).

El Perú, siendo uno de los países con mayor densidad forestal a nivel mundial, no ha sido ajeno a esta problemática. A pesar de contar con una vasta extensión de bosques amazónicos, aproximadamente el 50% de las actividades madereras en la Cuenca Amazónica son ilegales (Ozinga & Mowat 2012). La corrupción, la falta de control efectivo y las limitaciones en la gestión de los recursos forestales han permitido que la tala ilegal continúe avanzando en territorios clave, como el Área de Conservación Regional Cordillera Escalera (Finer et al. 2014). Esta área de conservación, establecida en 2005, abarca 149,870 hectáreas y es un refugio para especies animales vulnerables y comunidades indígenas. Sin embargo, la creciente presión de las actividades humanas, incluyendo la tala ilegal, ha puesto en peligro su biodiversidad y su potencial como destino ecoturístico (Cancino 2013).

Ante esta problemática, el uso de tecnologías innovadoras, como el reconocimiento acústico, ha surgido como una herramienta prometedora para la detección y monitoreo de la tala ilegal en áreas remotas y de difícil acceso. El reconocimiento acústico se basa en la captura y análisis de sonidos ambientales, permitiendo identificar la actividad humana y el uso de maquinaria pesada en el proceso de tala (Sotomayor 2016). Esta tecnología no solo tiene el potencial de detectar actividades ilícitas en tiempo real, sino que también contribuye a una vigilancia más eficiente y menos invasiva del entorno forestal.

La presente investigación tuvo como objetivo principal evaluar la eficacia del reconocimiento acústico para la detección de la tala ilegal en el Área de Conservación Regional Cordillera Escalera, en el distrito de Tarapoto, región de San Martín. Se espera que los resultados de este estudio promuevan el uso de tecnologías avanzadas en la gestión forestal y aporten soluciones efectivas para la conservación de los recursos naturales en la región amazónica.

Este estudio es relevante debido a la falta de investigaciones previas que aborden el uso del reconocimiento acústico en la detección de la tala ilegal en esta área específica. Asimismo, se busca validar la metodología propuesta, con el fin de implementar una solución tecnológica sostenible que pueda replicarse en otras áreas protegidas de la región.

CAPÍTULO II

MARCO TEÓRICO

2.1. Antecedentes de la investigación

Jaiswal & Patel (2018), describieron un modelo de clasificación de sonidos mediante redes neuronales convolucionales (CNN) para aplicaciones como la detección de tala ilegal en bosques. Los antecedentes del problema resaltan el impacto de la deforestación y la dificultad para detectar actividades ilegales en tiempo real. La propuesta plantea un sistema de monitoreo que distingue entre el sonido de motosierras y el ruido ambiental del bosque usando espectrogramas de sonido. Los objetivos incluyen mejorar la precisión de identificación de eventos de deforestación y probar el sistema en diversos entornos. Durante la implementación, el modelo fue entrenado con un conjunto de datos de sonidos recopilados y procesados en espectrogramas. Los resultados muestran que el modelo logra una precisión del 85% en pruebas, superando métodos previos en un 7%. Las conclusiones indican que esta tecnología podría ser adaptada para aplicaciones adicionales, como la detección de disparos y sonidos inusuales en áreas urbanas, facilitando una respuesta rápida ante emergencias ambientales y de seguridad.

Georgian, Gaiă, Rădoi, & Burileanu (2018), se abordó el problema del desmonte ilegal, que provoca graves consecuencias ambientales como la pérdida de biodiversidad y el cambio climático. Para enfrentar esta problemática, se propone un sistema de detección en tiempo real del sonido de motosierras, herramienta comúnmente utilizada en la deforestación. El objetivo principal es desarrollar una técnica basada en la extracción de características de Haar a partir del espectrograma de sonidos ambientales, logrando una tasa de detección del 97%. Se construyó un conjunto de datos con muestras de sonidos de motosierras y otros ruidos del entorno forestal, lo que permitió entrenar un clasificador que discrimina entre sonidos de motosierras y otros ruidos. Los resultados demostraron que el método propuesto es eficaz para la detección de motosierras, superando en precisión a otros enfoques existentes a pesar de una mayor complejidad computacional. En conclusión, esta investigación presenta una herramienta prometedora para la vigilancia de áreas forestales, contribuyendo a la lucha contra la tala ilegal y sugiriendo la combinación de múltiples características para mejorar el rendimiento del sistema.

Salazar (2019), en el estudio se abordó la problemática de la detección de sonidos de motosierras en entornos naturales, una tarea desafiante debido a la variabilidad acústica

y a la interferencia de ruidos ambientales. Utilizando el modelo de red neuronal LeNet, la investigación implementa un método de transferencia de aprendizaje con variaciones en la longitud del audio (1, 3 y 5 segundos) para mejorar la precisión en el reconocimiento de estos sonidos. El objetivo principal es analizar cómo influye la duración del audio en la capacidad del modelo para generalizar y detectar correctamente el sonido de motosierras en distintos entornos. Los resultados muestran que el modelo logra una precisión de entre 74% y 83% con audio de duraciones específicas, alcanzando hasta un 91.8% de precisión mediante transferencia de aprendizaje, especialmente cuando se entrena con audios de corta a larga duración. La conclusión destaca que entrenar con audios de menor a mayor longitud mejora significativamente la precisión y la robustez del modelo, sugiriendo que esta técnica es eficaz para aplicaciones en dispositivos de monitoreo ambiental en zonas boscosas.

Salazar (2019), El documento aborda la implementación de un microprocesador específico para ejecutar el algoritmo de Modelos Ocultos de Markov (HMM) en la detección de patrones acústicos, específicamente disparos y motosierras en áreas protegidas. Este desarrollo responde a la necesidad de mejorar la vigilancia ambiental en regiones de difícil acceso, donde los recursos humanos son limitados y el control de la tala ilegal es un desafío. La propuesta integra hardware y software en una FPGA para desarrollar un sistema de bajo consumo energético y alta precisión, adaptado a la clasificación acústica. Los objetivos incluyen diseñar un sistema eficiente y flexible en el reconocimiento de patrones, manteniendo un consumo y tamaño reducido del microprocesador. Los resultados muestran una tasa de precisión de 90.33% en la detección de motosierras y 85.43% para disparos, validando la eficacia del enfoque HMM en este contexto. La conclusión destaca que el diseño del microprocesador es una solución viable y escalable para aplicaciones de vigilancia ambiental, ofreciendo una respuesta oportuna y precisa ante eventos de interés.

Sethi, et al. (2020), Los cambios acelerados en los ecosistemas debido a la actividad humana requieren monitoreo constante, pero las metodologías tradicionales son lentas y costosas. Este estudio propone una solución automatizada basada en la acústica ecológica, utilizando una red neuronal convolucional (CNN) para procesar los datos sonoros de diferentes ecosistemas y detectar cambios en la biodiversidad y calidad del hábitat. El objetivo principal es desarrollar un método de monitoreo autónomo que sea capaz de identificar sonidos anómalos, como los producidos por actividades ilegales (p. ej., tala y caza furtiva). Los resultados muestran que el modelo tiene alta precisión al predecir métricas ecológicas y permite la detección en tiempo real de eventos anómalos. Como conclusión, la propuesta es prometedora para una aplicación global de monitoreo

ambiental, ofreciendo una alternativa escalable y efectiva a los métodos manuales y posibilitando la recolección continua de datos ecológicos en diferentes tipos de ecosistemas.

Arevalo et al. (2020), Los autores abordaron el problema del desmonte ilegal, que amenaza la biodiversidad y los ecosistemas forestales, especialmente en países en desarrollo como Filipinas. La propuesta consiste en un sistema de detección en tiempo real de sonidos de motosierras mediante un algoritmo de aprendizaje automático, específicamente K-Nearest Neighbors (k-NN), que permite alertar sobre actividades sospechosas de tala ilegal. Los objetivos del estudio incluyen el desarrollo de un prototipo portátil capaz de analizar audio en tiempo real y la creación de una interfaz gráfica para visualizar alertas y datos relevantes. Los resultados experimentales muestran que el sistema alcanzó una precisión del 96% y un F1-score del 94.34%, lo que indica una alta efectividad en la detección de sonidos de motosierras en entornos naturales. En conclusión, este sistema representa una solución innovadora y eficiente para la vigilancia y prevención de la tala ilegal, ofreciendo una herramienta valiosa para la conservación ambiental y la protección de los recursos forestales.

Jubjainai et al. (2020), los autores abordaron el problema crítico de la deforestación, que contribuye al aumento de CO₂ y al cambio climático. La investigación se centra en la detección de actividades de tala ilegal mediante el análisis de las ondas sonoras generadas por motosierras, utilizando micrófonos y geófonos para captar el sonido en el aire y en el suelo. El objetivo principal es desarrollar un sistema de localización de motosierras que sea de bajo costo, de fácil implementación y que ofrezca alta precisión. Los resultados experimentales mostraron una precisión del 95% en la localización de la fuente de sonido, lo que indica que el sistema es efectivo para identificar actividades de deforestación en tiempo real. Las conclusiones sugieren que este método no solo es menos costoso que las tecnologías actuales, sino que también es más accesible y eficiente para la detección de la tala ilegal, lo que podría ser crucial para la conservación de los recursos forestales y la gestión ambiental.

Gupta & Kumar (2020), presentaron un modelo de monitoreo acústico para detectar actividades de tala ilegal en bosques mediante sensores de audio, configurado a través de redes de sensores inalámbricos (WSN). La metodología implementa algoritmos de clasificación como SVM, MLP, y árboles de decisión (J48) para identificar sonidos de motosierras, logrando un rendimiento óptimo en entornos ruidosos. Los experimentos mostraron que el algoritmo SVM tuvo la mejor precisión, alcanzando hasta un 94.42% en condiciones con una relación señal-ruido de 20 dB. Además, la fusión de resultados

de varios clasificadores y el posprocesamiento mejoraron la precisión en un 2% adicional. La investigación concluye que esta solución acústica es eficaz y económica, siendo ideal para la protección forestal y reducción de la deforestación ilegal, contribuyendo significativamente a la conservación de la biodiversidad

Andreadis et al. (2021), los autores abordaron el problema de la tala ilegal mediante un sistema de monitoreo acústico con dispositivos IoT de ultrabajo consumo conectados a la red LoRaWAN. La propuesta se centra en identificar sonidos asociados con la tala, como el de motosierras, en entornos de bosque remoto. Para ello, el sistema utiliza una red neuronal convolucional (CNN) integrada en los nodos de los dispositivos IoT, lo que permite analizar los sonidos localmente y enviar alertas solo cuando se detecta actividad sospechosa, optimizando así el uso de energía y prolongando la vida útil de los dispositivos. El objetivo es ofrecer una solución de bajo costo y alta eficiencia para la conservación forestal mediante vigilancia continua. Los resultados experimentales mostraron una precisión de detección del 85%, lo que demuestra la efectividad de esta tecnología en condiciones de operación de baja energía. En conclusión, la investigación confirma la viabilidad del sistema para la detección de actividades ilegales en áreas forestales y su potencial como herramienta en programas de conservación ambiental sostenible

Mporas, et al. (2022), en el artículo propusieron un sistema de detección automática de tala de árboles en entornos forestales mediante el uso de propiedades acústicas. La investigación parte de la necesidad de detectar la tala ilegal en tiempo real para ayudar a reducir la deforestación en áreas con recursos limitados de vigilancia. Para abordar este problema, los autores desarrollaron un algoritmo que utiliza la distancia entre parámetros acústicos y se apoya en técnicas de agrupamiento como el modelo de mezcla gaussiana (GMM), el agrupamiento de K-medias y el análisis de componentes principales (PCA). Los objetivos incluyen evaluar la efectividad del sistema en la identificación de sonidos de tala y minimizar falsos positivos en la clasificación. Los experimentos lograron una eficiencia de detección del 92%, superando a otros algoritmos comparados y mostrando que el enfoque es viable para aplicaciones de vigilancia ambiental. La conclusión destaca que el sistema puede ser una herramienta confiable y de bajo costo para monitorear y proteger los bosques en tiempo real mediante la identificación precisa de actividades de tala ilegal.

Ogando et al. (2022), Los autores abordaron la necesidad de optimizar la preservación, monitoreo y protección de áreas protegidas en la República Dominicana, con enfoque en el Parque Nacional Valle Nuevo. La investigación identifica amenazas principales

como incendios forestales, tala ilegal y agricultura no controlada, las cuales degradan estos ecosistemas esenciales. Los antecedentes del problema reflejan una gestión ambiental tradicional que carece de tecnologías modernas para monitorear amenazas en tiempo real. La propuesta integra inteligencia artificial y tecnología IoT, específicamente mediante sensores y modelos de redes neuronales, para la detección y prevención de riesgos ambientales. Los objetivos incluyen desarrollar un sistema de monitoreo automatizado que permita responder oportunamente a actividades perjudiciales, así como reducir la intervención humana y mejorar la precisión en la detección de incidentes ambientales. Los resultados demostraron que el modelo de IA logró una precisión del 85% en la identificación de riesgos, superando métodos tradicionales de monitoreo. En conclusión, el proyecto proporciona una solución tecnológica que, además de reducir costos y mejorar la eficiencia, fortalece la protección del medio ambiente en zonas vulnerables y sirve como base para futuros desarrollos en la gestión de recursos naturales en el país.

2.2. Fundamentos teóricos

2.2.1. Conservación Ambiental y Tala Ilegal

El desarrollo de la detección y monitoreo de la tala ilegal mediante tecnologías avanzadas se basa en una serie de campos teóricos y científicos y puede proporcionarse por un marco sólido para la introducción de las nuevas soluciones que se basan en el reconocimiento acústico. Los fundamentos teóricos de este estudio son la conservación del medio ambiente, el monitoreo acústico, el proceso de inteligencia artificial y los sistemas de alerta temprana.

Estas disciplinas no solo otorgan la oportunidad de conocer más a fondo el tema relacionado con la tala ilegal; sino que, además, ofrecen las herramientas que se requieren para detectar la tala ilegal y llevar a cabo un control sobre ella en las zonas remotas o conocido por ser difícilmente accesibles. Las grandes extensiones que presentan los bosques en las regiones distantes o de difícil acceso suponen un evidente reto para las organizaciones de lucha contra las actividades delictivas, y la detección temprana de actividades ilegales relacionadas con la tala se vuelve imprescindible como factor de mitigación de sus efectos negativos.

este proyecto aspira a contribuir a la conservación de los bosques y la protección de la biodiversidad al reducir la incidencia de la tala ilegal. Al proporcionar herramientas tecnológicas innovadoras para abordar este problema, se espera fortalecer los

esfuerzos globales para preservar los ecosistemas forestales y promover la sostenibilidad ambiental a largo.

2.2.2. Conservación Ambiental Y Tala Ilegal

conservación ambiental se refiere al conjunto de prácticas y políticas destinadas a proteger los recursos naturales, con el objetivo de garantizar su sostenibilidad para las generaciones futuras. Los bosques desempeñan un papel fundamental en este ámbito, ya que actúan como sumideros de carbono, regulan los ciclos hidrológicos, preservan la biodiversidad y previenen la erosión del suelo (Burrell et al. 2022; Horton et al. 2021), Sin embargo, la deforestación causada por la tala ilegal amenaza gravemente estos servicios ecosistémicos. En este contexto, la tala ilegal se define como la extracción no autorizada de madera en áreas donde está prohibida, o más allá de los límites legales permitidos (MINAM 2017).

Los estudios sobre la tala ilegal destacan su impacto en la degradación ambiental, ya que esta actividad no solo reduce la superficie forestal, sino que también contribuye al cambio climático al liberar grandes cantidades de dióxido de carbono (CO₂) a la atmósfera. Además, la tala ilegal suele ir acompañada de prácticas de explotación no sostenible, que generan pérdida de biodiversidad, erosión del suelo y alteración de los ciclos naturales de los ecosistemas (Gabrielli et al., 2020; Y. Li et al., 2022), La tala ilegal también está estrechamente vinculada a problemas sociales, como la corrupción, el debilitamiento de la economía local y los conflictos con las comunidades indígenas, quienes dependen de los recursos forestales para su subsistencia (Arambaru 1995; Soto, 2003).

La **tala ilegal** constituye una de las principales amenazas para la conservación ambiental, ya que esta actividad no solo elimina grandes áreas de bosques, sino que también altera las funciones ecológicas que estos ecosistemas desempeñan. La pérdida de vegetación forestal impacta negativamente en la capacidad de los bosques para regular el clima local y global, lo que se traduce en un incremento de la temperatura y variabilidad climática que afecta directamente a la biodiversidad y la estabilidad del suelo (FAO, 2020). Además, la deforestación intensiva en áreas como la Amazonía tiene consecuencias a nivel mundial, pues se estima que aproximadamente el 10% de las emisiones de gases de efecto invernadero son atribuibles a la tala ilegal y otros tipos de deforestación (Greenpeace, 2018). En este contexto, el establecimiento de estrategias

eficaces para prevenir y detectar la tala ilegal es esencial para preservar el equilibrio ecológico y mitigar los efectos del cambio climático (Armenteras et al., 2017).

Asimismo, la tala ilegal afecta considerablemente a las **comunidades locales e indígenas** que dependen de los bosques para su sustento y cultura. La extracción ilícita de recursos forestales no solo reduce la disponibilidad de madera y otros productos del bosque, sino que también fomenta prácticas de explotación laboral y desplazamiento de comunidades (García-López & Antinori, 2018), Estas actividades ilícitas contribuyen a una economía informal y a la corrupción, debilitando los sistemas de gobernanza y las políticas de conservación (Kaimowitz, 2003), La relación entre la tala ilegal y el deterioro social es particularmente evidente en áreas de alta biodiversidad y riqueza natural, donde la explotación descontrolada da lugar a conflictos y problemas de seguridad para las comunidades que intentan proteger sus territorios (Burgess et al., 2020).

2.2.3. Monitoreo acústico ambiental

El monitoreo acústico es una técnica que se ha desarrollado en las últimas décadas como una herramienta eficaz para el estudio y la protección de los ecosistemas. Consiste en la captura y análisis de sonidos ambientales a través de dispositivos de grabación, lo que permite detectar y caracterizar eventos acústicos asociados a la actividad humana o a fenómenos naturales (Sotomayor, 2016). El monitoreo acústico se ha aplicado con éxito en diversos campos, como la detección de especies animales, el estudio de los patrones de biodiversidad y, más recientemente, en la identificación de actividades ilícitas como la tala ilegal.

En el contexto de la tala ilegal, el reconocimiento acústico permite identificar sonidos característicos generados por maquinaria, como sierras eléctricas y vehículos, que son indicadores claros de actividades madereras no autorizadas (Diario-Voces, 2016). Esta tecnología resulta especialmente útil en áreas protegidas o de difícil acceso, donde el monitoreo visual o la presencia física de guardaparques puede ser limitada o peligrosa. Además, el monitoreo acústico es una herramienta no invasiva que puede operar de manera continua, lo que facilita la vigilancia a largo plazo y la recolección de datos valiosos para el análisis y la toma de decisiones (Sotomayor, 2016).

El uso de tecnología acústica en la detección de actividades ilícitas como la tala ilegal se ha consolidado como un método confiable para identificar señales acústicas específicas de equipos como motosierras y vehículos, permitiendo una respuesta casi en tiempo real. Estos sistemas pueden programarse para detectar sonidos característicos y emitir alertas automáticas que se envían a las autoridades, quienes

pueden evaluar la situación de manera remota antes de realizar una intervención (Finer et al., 2014), La capacidad de distinguir sonidos relacionados con actividades ilegales de otros ruidos ambientales mejora la eficacia del monitoreo y reduce la posibilidad de errores, optimizando así los recursos en áreas donde el acceso y la presencia física son limitados (Aide et al., 2013).

2.2.4. Inteligencia Artificial Y Procesamiento De Señales Acústicas

El uso de inteligencia artificial (IA) y algoritmos de aprendizaje automático ha revolucionado el campo del procesamiento de señales acústicas, permitiendo el desarrollo de sistemas más precisos y eficientes para la detección de eventos acústicos específicos. En este contexto, la Inteligencia artificial permite entrenar modelos para identificar patrones de sonido asociados a la tala ilegal, diferenciándolos de otros ruidos ambientales, como el viento, la lluvia o los sonidos de animales. Estos modelos se basan en el uso de redes neuronales y técnicas de clasificación de audio, que analizan las características espectrales y temporales de las señales acústicas (Widodo et al., 2021).

El procesamiento de señales acústicas implica la transformación de las señales de sonido capturadas en datos que puedan ser analizados por los algoritmos de inteligencia artificial. Este proceso incluye la extracción de características relevantes de las señales, como la frecuencia, la amplitud y la duración, para luego clasificarlas y determinar si corresponden a actividades de tala ilegal (Widodo et al., 2021). Uno de los principales retos en este campo es la capacidad de los modelos para distinguir entre diferentes tipos de sonidos de manera precisa, evitando falsos positivos que puedan derivar en acciones incorrectas o ineficientes.

Un aspecto destacado de la implementación de la inteligencia artificial en el monitoreo acústico es su capacidad para **aprender y adaptarse a nuevas condiciones ambientales**. Los algoritmos de aprendizaje automático pueden ser actualizados regularmente con datos recientes, lo que permite mejorar su precisión al enfrentar variaciones estacionales o cambios en los patrones de ruido ambiental (Herbrüggen, 2003). Además, el uso de tecnologías como redes neuronales convolucionales ha demostrado ser eficaz para analizar grandes volúmenes de datos acústicos de manera eficiente, reduciendo el tiempo necesario para detectar actividades ilícitas. Este enfoque no solo incrementa la capacidad de respuesta de las autoridades, sino que también permite identificar tendencias a largo plazo en las actividades de tala ilegal, lo que puede ser clave para desarrollar políticas de conservación más efectivas (Widodo et al., 2021).

Un desafío crucial en el procesamiento de señales acústicas es la gestión de grandes volúmenes de datos en tiempo real, especialmente en regiones extensas como la Cordillera Escalera. Para abordar esto, se han implementado enfoques híbridos que combinan procesamiento local con análisis en la nube, permitiendo que los dispositivos desplegados en el campo transmitan datos relevantes para un análisis centralizado (Herbrüggen, 2003). Esta arquitectura tecnológica optimiza el uso de recursos, facilita la integración con sistemas de alerta temprana y genera reportes detallados que fortalecen las estrategias de conservación en zonas protegidas.

2.2.5. Sistemas De Alerta Temprana

El modelo de reconocimiento acústico que nosotros planteamos tiene como objetivo principal ser implementado en un **entorno real** o servir como base para facilitar a **futuros investigadores** su aplicación práctica.

Los sistemas de alerta temprana son un componente crucial en el monitoreo y prevención de la tala ilegal. Estos sistemas se basan en la recopilación de datos en tiempo real y el uso de algoritmos de detección que pueden enviar alertas inmediatas a las autoridades locales o a los equipos de vigilancia cuando se detecta una actividad sospechosa. El reconocimiento acústico, combinado con tecnologías de comunicación como los dispositivos GPS y las redes de sensores, permite la creación de redes de monitoreo que pueden cubrir grandes extensiones de terreno y ofrecer una respuesta rápida ante la detección de actividades ilícitas (Cancino, 2013).

Además de detectar actividades sospechosas, los sistemas de alerta temprana ofrecen una herramienta estratégica para la **gestión de recursos y la planificación de vigilancia**. En contextos como la Cordillera Escalera, donde las áreas protegidas abarcan territorios extensos y de difícil acceso, estos sistemas permiten priorizar zonas críticas y asignar patrullajes con mayor eficiencia. La capacidad de generar mapas de calor basados en datos de incidentes acústicos registrados fortalece las decisiones operativas, optimizando el despliegue de recursos humanos y tecnológicos. Estos mapas no solo ayudan a responder a eventos en tiempo real, sino que también identifican patrones recurrentes que pueden estar relacionados con redes organizadas de tala ilegal (Finer et al., 2014).

Por otro lado, los sistemas de alerta temprana se integran cada vez más con tecnologías emergentes, como los drones y las redes de comunicación 5G, para ampliar su cobertura y mejorar la transmisión de datos en tiempo real. Por ejemplo, los drones

pueden actuar como extensores de señal para sensores acústicos ubicados en zonas remotas, permitiendo un monitoreo continuo incluso en áreas donde las condiciones climáticas dificultan la instalación de infraestructura fija. Esta integración tecnológica no solo aumenta la precisión de las detecciones, sino que también reduce los riesgos asociados a la intervención humana en áreas peligrosas, haciendo que la vigilancia sea más segura y efectiva (Herbrüggen, 2003).

La eficacia de un sistema de alerta temprana depende de su capacidad para procesar grandes volúmenes de datos de manera eficiente y en tiempo real. En este sentido, los avances en el procesamiento de señales y en el uso de redes de sensores inalámbricos han permitido que los sistemas de monitoreo acústico sean cada vez más precisos y accesibles, reduciendo los costos operativos y aumentando la cobertura geográfica de las áreas vigiladas (Herbrüggen, 2003). Además, la integración de estos sistemas con plataformas de análisis de datos permite generar informes detallados que pueden ser utilizados por las autoridades para tomar decisiones informadas sobre las acciones de protección y conservación de los bosques.

2.2.6. Aplicaciones En La Conservación De Bosques Tropicales

El uso del reconocimiento acústico y de tecnologías avanzadas de monitoreo ha demostrado ser especialmente efectivo en áreas de conservación de bosques tropicales, como la Amazonía peruana. En estas regiones, la dificultad de acceso, combinada con la extensión del territorio, hace que los métodos tradicionales de vigilancia sean insuficientes para controlar las actividades ilegales. Diversos estudios han documentado el éxito de estos enfoques tecnológicos en la detección temprana de la tala ilegal y en la reducción de la deforestación en zonas protegidas (Finer et al., 2014).

El Área de Conservación Regional Cordillera Escalera, al ser un territorio de alta biodiversidad y de importancia ecológica para la región amazónica, se encuentra bajo constante amenaza de tala ilegal. En este contexto, la implementación de un sistema de reconocimiento acústico puede no solo mejorar la vigilancia, sino también generar un modelo replicable para otras áreas de conservación en la región y en el mundo.

Cabe recalcar que los fundamentos teóricos de esta investigación se basan en la intersección de la conservación ambiental, el monitoreo acústico, la inteligencia artificial y los sistemas de alerta temprana. La integración de estas disciplinas proporciona un marco sólido para el desarrollo de soluciones tecnológicas efectivas en la lucha contra

la tala ilegal, contribuyendo así a la preservación de los bosques tropicales y a la protección de los ecosistemas vulnerables.

CAPÍTULO III

MATERIALES Y MÉTODOS

3.1. Ámbito y condiciones de la investigación

3.1.1. Contexto de la investigación

El Área de Conservación Regional Cordillera Escalera (ACR-CE), ubicada en la región de San Martín, cerca de Tarapoto, Perú, es una de las zonas de mayor biodiversidad en el país. Establecida en 2005, esta área se extiende por más de 149,870 hectáreas y es hogar de numerosas especies de fauna y flora en peligro de extinción, así como de comunidades indígenas, como los quechuas lamistas y otras poblaciones rurales que dependen del bosque para su subsistencia (Cancino, 2013). A pesar de su importancia ecológica y cultural, la Cordillera Escalera ha enfrentado crecientes presiones por actividades humanas, particularmente la tala ilegal, que amenaza la integridad del ecosistema y la subsistencia de las comunidades locales.

En las últimas décadas, el aumento de la demanda de madera en los mercados nacionales e internacionales ha generado un incremento en las actividades madereras no reguladas en esta área, agravando la deforestación. Se estima que más del 50% de la extracción de madera en la Cuenca Amazónica es ilegal, lo que genera pérdidas tanto para la biodiversidad como para la economía del país (Ozinga & Mowat, 2012). En el departamento de San Martín, los informes sobre la tala ilegal han señalado el devastador impacto sobre especies valiosas, como la caoba, así como los conflictos sociales que derivan de estas prácticas (Herbrüggen, 2003). La falta de control y supervisión efectiva por parte de las autoridades ha permitido que la tala continúe, especialmente en zonas remotas o de difícil acceso, donde la presencia de personal es limitada.

El contexto económico en la región de San Martín, donde se encuentra el ACR-CE, también influye en la perpetuación de estas prácticas ilegales. La pobreza y la falta de oportunidades económicas llevan a muchos pobladores a involucrarse en la tala ilegal como un medio de subsistencia. Además, la corrupción en las concesiones madereras y la falta de capacidad de las autoridades locales para hacer cumplir las leyes forestales contribuyen a que la tala ilegal sea una práctica común, incluso en áreas protegidas (Finer et al., 2014).

En lo tecnológico, la lucha contra la tala ilegal ha sido un desafío debido a las características geográficas de la Cordillera Escalera, donde el acceso es limitado y los

métodos de vigilancia tradicionales, como las patrullas terrestres, son ineficaces y costosos. En este sentido, el desarrollo de tecnologías innovadoras, como el reconocimiento acústico, ofrece una nueva solución. El reconocimiento acústico permite detectar de manera precisa y en tiempo real los sonidos asociados a la tala, como el uso de motosierras o vehículos pesados, lo que facilita la identificación de actividades ilícitas en zonas de difícil acceso sin la necesidad de una intervención directa (Sotomayor 2016).

El contexto legal también es relevante. Aunque el Perú cuenta con una Ley Forestal y de Fauna Silvestre (**Ley N° 29763**), diseñada para promover el uso sostenible de los recursos forestales, su aplicación ha sido insuficiente en muchas áreas debido a la falta de recursos y la corrupción. A pesar de los acuerdos internacionales, como el Tratado de Libre Comercio (TLC) con Estados Unidos, que incluye disposiciones para combatir la tala ilegal, los esfuerzos para frenar esta actividad en áreas protegidas como la Cordillera Escalera han sido limitados, y la tala ilegal sigue siendo una realidad cotidiana (Finer et al. 2014).

3.1.2. Periodo de ejecución

De acuerdo con los procesos tanto en la etapa de recolección, entrenamiento y análisis, el periodo de ejecución tiene una duración de 6 meses.

3.1.3. Autorizaciones y permisos

Para llevar a cabo el proyecto de detección de tala ilegal mediante reconocimiento acústico en el Área de Conservación Regional Cordillera Escalera (ACR-CE), fue esencial contar con las autorizaciones pertinentes del organismo responsable del monitoreo y gestión de la reserva, específicamente el Proyecto Especial Huallaga Central y Bajo Mayo (PEHCBM). Este organismo tiene la responsabilidad de supervisar y garantizar que las actividades realizadas en la zona estén alineadas con los principios de conservación y protección del medio ambiente.

Los permisos y autorizaciones otorgados por el proyecto Huallaga - PEHCBM permitieron la efectiva recopilación de datos acústicos, los cuales constituyen la columna vertebral de nuestro modelo para la detección de tala ilegal mediante reconocimiento acústico.

3.1.4. Control ambiental y protocolos de bioseguridad

En el proyecto se garantizará la aplicación de los protocolos de seguridad y control interno establecidos por la oficina nacional de defensa civil y también las políticas

establecidas por el “Proyecto Especial Huallaga Central Y Bajo Mayo - PEHCBM” para la vigilancia y monitoreo, estudios científicos, u otros factores que estén relacionados a conocer la biodiversidad que nos ofrece esta área de conservación regional cordillera escalera.

3.1.5. Aplicación de principios éticos internacionales

Como investigador, en este proyecto de tesis, declaro que toda intervención en el área de conservación regional cordillera escalera – ACR. Será bajo responsabilidad, es justamente por ello, me comprometo a respetar los principios éticos generales en esta investigación.

3.2. Sistema de variables

3.2.1. Variables principales

Variable independiente: Reconocimiento acústico.

Variable dependiente: Detección de la tala ilegal.

Tabla 1

Variables

Variable abstracta	Variable concreta	Unidad de medida	Medio de registro
Detección de tala ilegal	Algoritmos utilizados	Número	Documentación técnica del modelo
	Cantidad de sonidos de motosierra	Número	Base de datos de sonidos recolectados
	Cantidad de falsos positivos y negativos	Porcentaje (%)	Registros de validación manual
	Métricas de rendimiento (F1-score, Recall, Precision)	Índice numérico	Evaluación con dataset de validación

3.2.2. Variables secundarias

3.3. Procedimientos de la investigación

3.3.1. Actividades del objetivo específico 1

Recopilar datos acústicos en el área de conservación regional Cordillera Escalera.

1. Identificación de puntos de muestreo:

Durante el proceso de selección se escogieron puntos estratégicos dentro del ACR, teniendo en cuenta la densidad del bosque y por otro la existencia de áreas que presentaban una probabilidad alta de actividad de manera ilegal. Para esta tarea se trabajó con planos topográficos, GPS y con imágenes satelitales.

2. Instalación de dispositivos de grabación acústica:

El audio se registró mediante dispositivos de captura de sonidos de alta calidad ubicados en los puntos estratégicos los que fueron diseñados anteriormente, donde se consideró una correcta distancia para captar los sonidos del entorno mediante una eficaz colocación de los dispositivos fijados en los lugares seleccionados para evitar problemas durante el registro.

3. Configuración de parámetros de grabación:

Se configuraron los dispositivos de grabación a una frecuencia de muestreo de 44,1 kHz con una profundidad de 16 bits. La duración mínima de las grabaciones fue de 3 segundos. Se registraron sonidos ambientales junto con el ruido característico de las motosierras.

4. Grabaciones acústicas:

Se realizaron grabaciones en distintos momentos del día, poniendo especial atención al registro de la actividad de las motosierras, ya que son la principal señal de tala ilegal. Se grabaron un total de 5400 sonidos entre ambientales y de motosierras estas últimas en diferentes distancias (50, 100, 200 y 300 metros)

5. Recogida de información contextual:

En el proceso de grabación se recogieron las condiciones ambientales (temperatura, humedad) y la observación de actividades humanas (ruido de maquinaria, presencia de personas).

6. Almacenamiento de datos acústicos:

Los datos recopilados se transfirieron a un sistema de almacenamiento seguro, organizados por puntos de muestreo y fechas de grabación, para su posterior análisis.

3.3.2. Actividades del objetivo específico 2

Desarrollar un modelo de reconocimiento acústico. basado en inteligencia artificial

1. Entorno de desarrollo:

- Se utilizó Python 3.6 con la distribución Anaconda, que incluye las librerías necesarias.
- Se hizo uso del entorno de desarrollo Spyder para la escritura, ejecución y depuración del código.
- Como editor de texto se usó visual estudio code.

2. Principales librerías utilizadas:

- Numpy: Computación científica, álgebra y transformadas de Fourier.
- Pandas: Análisis de datos.
- Matplotlib: Visualización datos.
- Librosa: Procesamiento de señales de audio y análisis acústico.
- Keras (incluido en TensorFlow): implementación del modelo de Deep Learning.
- Scikit-learn: validación cruzada y visualización de la matriz de confusión.

3. Preprocesamiento de datos acústicos

- Se utilizaron los audios de 3 seg. de duración (motosierras y no-motosierras) para normalizar las muestras.
- Se generaron espectrogramas con el paquete librosa que posteriormente fueron convertidos a matrices 128x216.
- Se separaron los datos en tres conjuntos: entrenamiento (70%), validación (15%) y test (15%).

4. Normalización de los datos:

- Los datos normalizados fueron a tipo `float32` para mejorar el rendimiento y el tiempo de cómputo.

5. Arquitectura del modelo:

Se diseñó una red neuronal convolucional con

- Tres capas convolucionales 2D, activación ReLu.
- Dos capas de Max Pooling.
- Una capa Flatten y Dropout.
- Una capa densamente conectada de 64 neuronas.
- Capa final de salida con 2 neuronas y softmax como función de activación.
- La red neuronal fue compilada con la función de pérdida

6. Entrenamiento del modelo:

Respecto al entrenamiento se realizaron 2 pasos que consideramos relevantes:

- Se configuraron 100 epochs con un tamaño de lote de 64 muestras.
- Se emplearon funciones ModelCheckpoint y EarlyStopping para guardar el mejor modelo y detener el entrenamiento cuando el error de validación no disminuía.

3.3.3. Actividades del objetivo específico 3

Evaluar la efectividad del modelo reconocimiento acústico en la detección de la tala ilegal.

1. Preparación del Conjunto de Datos de Validación

En este sentido, la evaluación se realizó a partir de unos datos extraídos de un conjunto de grabaciones de audio de aquellas áreas en las que había una mayor actividad debido a la tala ilegal, los cuales contenían:

Sonidos de motosierras identificadas como correspondiente a la tala ilegal.

Sonidos de tipo natural, como el viento, lluvia y canto de pájaros.

Sonidos de tipo similar, como el sonido de maquinaria agrícola y el ruido de vehículos.

2. Ajuste Fino del Modelo

El modelo ajustado en las fases anteriores, mediante el uso de una red neuronal convolucional (CNN), se realizó a partir de aquellas grabaciones de audio obtenidas en las áreas en las que había actividad relacionada con ambientes forestales. Por un lado, se realizó el ajuste de las últimas capas del modelo reentrenándolo, lo cual le hace

mejorar la adaptación a las características acústicas del entorno o, si se quiere, las condiciones extremas relacionadas con el ruido ambiental o con otros sonidos ajenos a la tala

3. Definición de Métricas de Evaluación

Para evaluar la efectividad del modelo, se definieron las siguientes métricas clave:

Precisión: Para medir cuántas predicciones del modelo fueron correctas en general.

Sensibilidad (Recall): Indicó la capacidad del modelo para detectar correctamente los casos de tala ilegal (minimizar falsos negativos).

Especificidad: Indicó la capacidad del modelo para evitar clasificar otros sonidos como tala ilegal (minimizar falsos positivos).

Matriz de confusión: Se utilizó para visualizar cómo el modelo clasificó los distintos tipos de sonidos y detectar los posibles errores en la clasificación.

AUC-ROC: Se empleó para obtener una evaluación más completa del rendimiento del modelo, combinando sensibilidad y especificidad.

4. Evaluación en el Conjunto de Pruebas

Una vez ajustado el modelo, se realizó la evaluación utilizando un conjunto de pruebas independiente. Este conjunto incluía tanto sonidos de motosierras como sonidos similares y no relacionados con la tala. Se calcularon las métricas previamente definidas para obtener una evaluación objetiva del rendimiento del modelo.

La precisión del modelo fue del 98.01%, lo que indicaba un alto nivel de aciertos en la clasificación general de los sonidos. La sensibilidad (recall) fue del 97.5%, lo que mostró que el modelo fue capaz de identificar correctamente la mayoría de los sonidos de motosierras. La especificidad fue del 98.2%, lo que indicó que pocos sonidos no relacionados con la tala fueron incorrectamente clasificados como motosierras.

5. Análisis de los Resultados

Los resultados obtenidos en las pruebas demostraron que el modelo tenía una gran precisión y una gran sensibilidad, lo que le permitía ser útil para detectar la presencia de motosierras en zonas forestales. Sin embargo, se comprobó que algunos sonidos de lluvia y maquinaria pesada se clasificaban erróneamente como motosierras, lo que reveló que era necesario adaptar el modelo para diferenciar más adecuadamente estos tipos de sonidos.

CAPÍTULO IV

RESULTADOS Y DISCUSIÓN

4.1. Resultados del Objetivo específico 1

Recopilar datos acústicos en el área de conservación regional Cordillera Escalera.

El Área de Conservación Regional (ACR-CE) es un entorno de gran valor ecológico que alberga diversas especies de flora y fauna. Asimismo, la tala ilegal ha sido una de las principales amenazas en los últimos años, afectando a áreas críticas de este ecosistema. Varias denuncias de tala ilegal han sido reportadas por las comunidades locales, quienes señalaron la utilización de maquinaria pesada para la extracción de madera en áreas de difícil acceso.

Equipo utilizado: Grabadora profesional H1n-Zoom



Figura 1

Grabadora de audio H1n-Zoom

Para la captura de sonidos en el ACR-CE, se utilizó la grabadora H1n-Zoom, que fue zseleccionada por su capacidad de captar sonidos de alta calidad en ambientes naturales complejos. Esta grabadora permitió registrar sonidos de motosierras, vehículos, ruidos ambientales naturales (lluvia, viento, fauna), lo que fue esencial para el posterior análisis y desarrollo del modelo de reconocimiento acústico.

Tabla 2
Especificaciones técnicas de la grabadora H1n-Zoom

Característica	Micrófono	Frecuencia de muestreo	Formatos de grabación	Conectividad	Almacenamiento
Especificación	X/Y estéreo con ángulo ajustable de 90°	44.1 kHz / 96 kHz	WAV y MP3	USB para transferencia de datos y recarga	Tarjeta microSD/microSDHC (hasta 32 GB)

Esta grabadora fue clave para captar los detalles acústicos de los distintos sonidos presentes en el área de conservación, permitiendo diferenciar entre sonidos naturales y aquellos relacionados con la tala ilegal.



Figura 2
Motosierra utilizada: Stihl 660

Para asegurar la correcta clasificación de los sonidos de tala ilegal, se realizaron grabaciones controladas utilizando una motosierra marca Stihl 660, una de las herramientas más utilizadas en la tala comercial e ilegal. Esta motosierra fue elegida debido a su amplio uso en actividades forestales, lo que la convierte en un referente acústico clave en el análisis de los datos de sonido.

Tabla 3
Especificaciones técnicas de la motosierra Stihl 660

Características	Cilindrada	Potencia	Velocidad máxima del motor	Capacidad del tanque de combustible	Sistema antivibración	Barra guía
Especificación	91.6 cc	7.1 hp	7.4 kg (sin equipo de corte)	0.825 litros	Minimiza las vibraciones para reducir la fatiga del usuario	50-90 cm, adaptable según las necesidades de corte

La grabación del sonido emitida por esta motosierra se utilizó como referencia principal para el modelo de detección acústica, ya que sus características sonoras específicas permitieron entrenar el sistema para reconocer patrones acústicos similares en las grabaciones del ACR-CE.

Asimismo, se utilizó hojas de cálculo para registrar características principales de cada grabación, facilitando así la organización y el análisis de los datos recolectados. De esta manera se pudo correlacionar los sonidos con su origen geográfico y temporal

Tabla 4
Variables registradas en el sistema de hojas de cálculo

Variable	Hora de la grabación	Ubicación geográfica	Código único de grabación	Altitud	Distancia a la fuente sonora
Descripción	Coordenadas de latitud y longitud obtenidas mediante un dispositivo GPS.	Identificador exclusivo y nombre descriptivo asignado a cada grabación.	Elevación del punto de grabación, relevante para analizar la propagación del sonido.	Estimación de la separación entre la grabadora y el origen del sonido, especialmente para motosierras.	Registro temporal preciso para identificar patrones de actividad ilegal.

Este sistema de hojas de cálculo permitió una organización efectiva de los datos acústicos y facilitó su posterior análisis para la detección automática de actividades de tala ilegal mediante inteligencia artificial.

DATOS RELEVANTES DE LAS GRABACIONES													
GRABADORA							MOTOSIERRA						
ITEM	CODIGO	ALTURA (metros)	LATITUD (grados)	LONGITUD (grados)	DISTANCIA	T*	HUMEDAD	ALTURA	LATITUD	LONGITUD	FECHA	HORA	DA
1	0008	014	-4.863556654335	-76.287939207586	50 m			028	-4.863279333333	-76.287251760000	8/17/2023	9:30	/
2	0009	014	-4.863556654335	-76.287939207586	50 m			018	-4.863279333333	-76.287251760000	8/17/2023	9:34	/
3	0010	014	-4.863556654335	-76.287939207586	50 m			030	-4.863279333333	-76.287251760000	8/17/2023	9:20	/
4	0011	014	-4.863556654335	-76.287939207586	50 m			030	-4.863279333333	-76.287251760000	8/17/2023	9:25	/
5	0012	014	-4.863556654335	-76.287939207586	50 m			030	-4.863279333333	-76.287251760000	8/17/2023	9:20	/
6	0013	014	-4.863556654335	-76.287939207586	50 m			018	-4.863279333333	-76.287251760000	8/17/2023	9:13	/
7	0014	014	-4.863556654335	-76.287939207586	50 m			030	-4.863279333333	-76.287251760000	8/17/2023	9:33	/
8	0015	014	-4.863556654335	-76.287939207586	50 m			030	-4.863279333333	-76.287251760000	8/17/2023	9:34	/
9	0016	014	-4.863556654335	-76.287939207586	50 m			030	-4.863279333333	-76.287251760000	8/17/2023	9:37	/
10	0017	014	-4.863556654335	-76.287939207586	50 m			028	-4.863279333333	-76.287251760000	8/17/2023	9:40	/
11	0018	014	-4.863556654335	-76.287939207586	50 m			018	-4.863279333333	-76.287251760000	8/17/2023	9:43	/
12	0019	014	-4.863556654335	-76.287939207586	50 m			030	-4.863279333333	-76.287251760000	8/17/2023	9:43	/
13	0020	014	-4.863556654335	-76.287939207586	50 m			030	-4.863279333333	-76.287251760000	8/17/2023	9:47	/

Figura 3
Registro de Datos en el Sistema de Hojas de cálculo

4.2. Resultados del Objetivo específico 2

Diseñar un modelo de reconocimiento acústico basado en inteligencia artificial

Para la tarea de detección de tala ilegal mediante reconocimiento acústico, utilizamos Redes Neuronales Convolucionales (CNNs), dado que han demostrado ser altamente eficaces en la clasificación de señales de audio y el análisis espectral.

en vista que el modelo requiere una transformación de la señal de audio antes de su clasificación, se integraron diferentes algoritmos en distintas etapas del proceso, desde el preprocesamiento del audio, pasando por la construcción del modelo de clasificación, y hasta la optimización durante el entrenamiento.

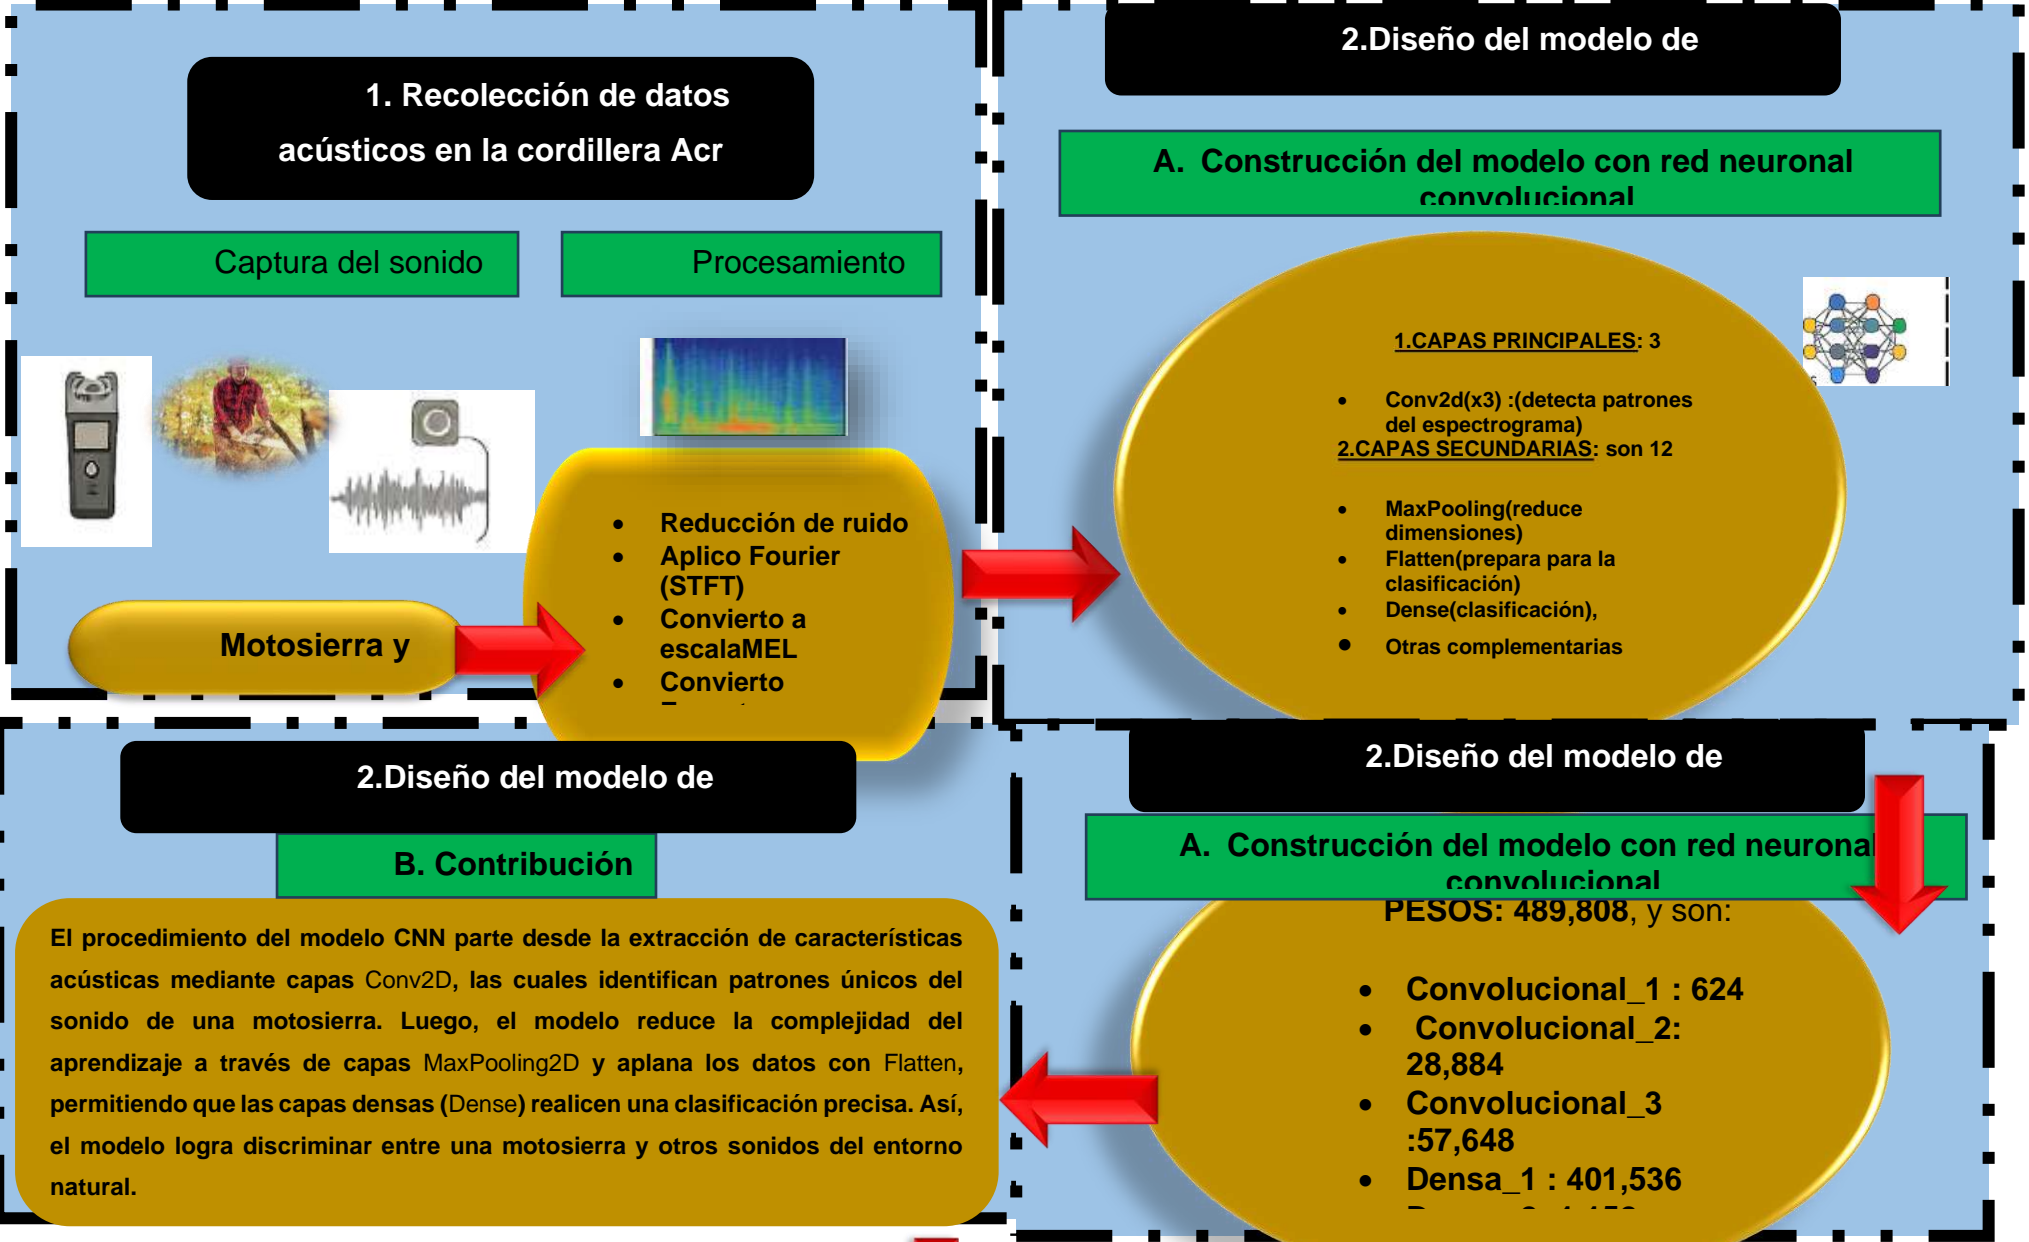
Tabla 5

Algoritmos utilizados en cada etapa del proceso

Etapas	Algoritmo	Descripción
Preprocesamiento del audio	Transformada de Fourier de corto tiempo (STFT)	Convierte la señal de audio en el dominio del tiempo a una representación en el dominio de la frecuencia, permitiendo el análisis espectral.
	Escala de frecuencia Mel	Convierte la frecuencia lineal en una escala perceptual, emulando la forma en que el oído humano percibe el sonido.
	Reducción de ruido	Atenúa componentes de ruido en la señal, mejorando la calidad del audio de entrada.
Construcción del modelo	Red Neuronal Convolucional (CNN)	Clasifica los espectrogramas generados a partir del audio, identificando patrones asociados a motosierras.
	Max Pooling	Reduce la dimensionalidad de los mapas de características generados por la CNN, preservando la información más relevante.
Optimización del entrenamiento	Adam Optimizer	Algoritmo de optimización basado en gradiente que ajusta los pesos de la red neuronal de manera eficiente.

Cada uno de estos componentes cumple un rol esencial dentro del flujo de trabajo, contribuyendo a mejorar la precisión y robustez del modelo de detección de tala ilegal.

Diagrama del procedimiento del modelo de reconocimiento acústico



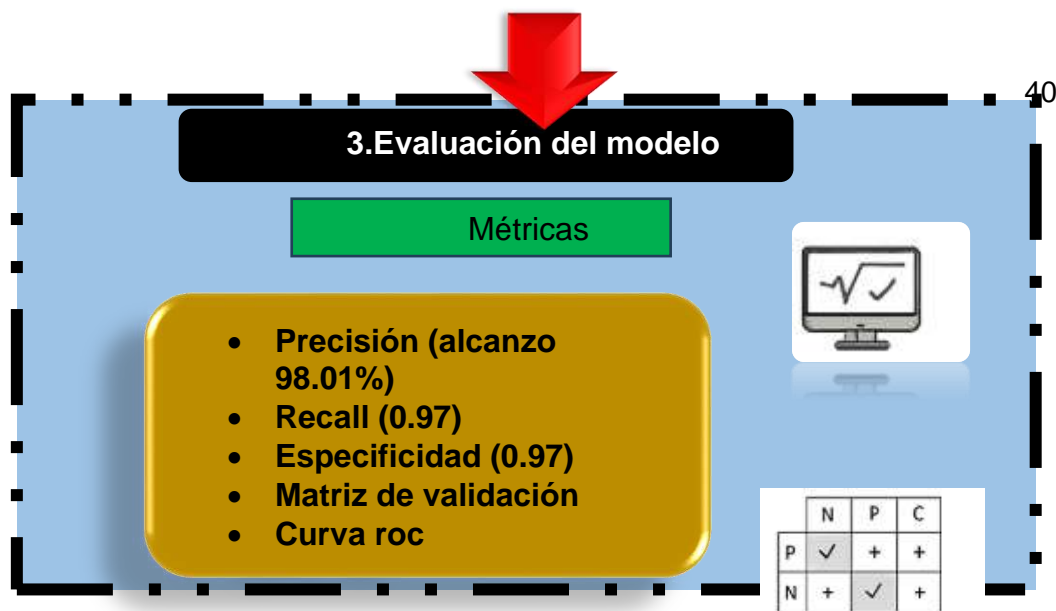


Figura 4

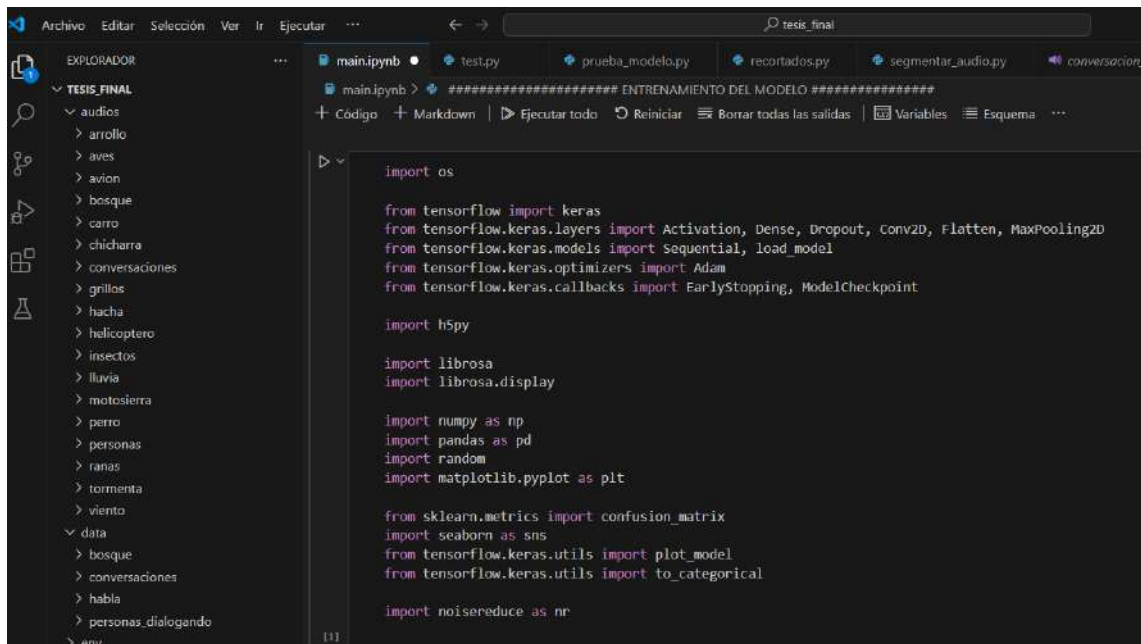
Diagrama de procedimiento del modelo

Procedimiento Metodológico

1. importación de Bibliotecas y Configuración del Entorno

El procedimiento inicia con la importación de bibliotecas necesarias para el procesamiento de audio y la creación de modelos de aprendizaje profundo. Las bibliotecas principales utilizadas son:

- **librosa:** Utilizada para la carga y procesamiento de archivos de audio.
- **tensorflow y keras:** Para la construcción de redes neuronales convolucionales (CNN).
- **matplotlib y seaborn:** Herramientas gráficas para la visualización de resultados.
- **numpy y pandas:** Para la manipulación de datos y la realización de cálculos numéricos



```

##### ENTRENAMIENTO DEL MODELO #####
+ Código + Markdown | ▶ Ejecutar todo | 🔄 Reiniciar | 🗑️ Borrar todas las salidas | 📄 Variables | 📐 Esquema | ...

import os

from tensorflow import keras
from tensorflow.keras.layers import Activation, Dense, Dropout, Conv2D, Flatten, MaxPooling2D
from tensorflow.keras.models import Sequential, load_model
from tensorflow.keras.optimizers import Adam
from tensorflow.keras.callbacks import EarlyStopping, ModelCheckpoint

import h5py

import librosa
import librosa.display

import numpy as np
import pandas as pd
import random
import matplotlib.pyplot as plt

from sklearn.metrics import confusion_matrix
import seaborn as sns
from tensorflow.keras.utils import plot_model
from tensorflow.keras.utils import to_categorical

import noisereducer as nr

```

Figura 5:
Instalación de las librerías de Python

2. Procesamiento de Audio

Para analizar y clasificar los sonidos asociados a la tala ilegal, es preciso convertirlos en una representación más adecuada para el procesamiento por parte de una red neuronal. En este texto se presenta una representación conocida como espectrograma de Mel, obtenida por medio de melspectrogram de la biblioteca Librosa. **El espectrograma de Mel es una representación gráfica que muestra cómo la energía del audio se distribuye a lo largo de las diferentes bandas de frecuencia a lo largo del tiempo.** Como se puede observar, representa con el suficiente detalle no solamente la característica del sonido individual sino la densidad de ciertas secuencias en la imagen. Por consiguiente, esta transformación es necesaria para que los modelos de machine learning puedan encontrar patrones acústicos más fácilmente. Flujo del procesamiento de audio:

3. Carga del archivo de audio

La señal de audio es convertida en una señal de amplitud frente al tiempo (una onda sonora). Mediante **librosa.load**

4. Cálculo del espectrograma de frecuencia Mel

Por medio de la función `librosa.feature.melspectrogram()`, la señal de audio es convertida en un espectrograma en la escala de frecuencia Mel, que resulta ser una

escala perceptual que se adapta mejor a la forma de percibir el sonido en función de nuestro oído.

5. Cálculo del espectrograma

El espectrograma es obtenido aplicando la Transformada de Fourier de corto tiempo (STFT) para descomponer la señal en sus componentes de frecuencia y luego mapearlas dentro de la escala Mel.

La fórmula matemática para el cálculo del espectrograma Mel es:

$$M(f, t) = \sum_{k=0}^{N-1} |STFT(k, t)|^2 \cdot H_m(f_k)$$

Donde:

M(f,t): es el espectrograma en escala Mel en función de la frecuencia f y el tiempo t.

STFT(k,t): es la Transformada de Fourier de corto tiempo aplicada a la señal de audio.

Hm(fk): representa los filtros Mel aplicados sobre las frecuencias obtenidas con la STFT.

Conversión a escala logarítmica: Se transforma la escala de potencia a decibelios (dB) utilizando `librosa.power_to_db()`. Esto permite visualizar mejor las diferencias entre las amplitudes de frecuencia.

```
def convertir_audio_a_espectrograma(archivo):
    y, sr = librosa.load(archivo)
    s = librosa.feature.melspectrogram(y=y, sr=sr)
    ps = librosa.power_to_db(s)
```

Convertir el audio en espectrograma, para extraer las características relevantes

Visualización del Espectrograma: Utilizando matplotlib y librosa.display.specshow(), se genera una visualización del espectrograma. Esto permite analizar visualmente las características frecuenciales del audio a lo largo del tiempo.

6. Red Neuronal Convolutiva (CNN)

Para la clasificación y detección de patrones en los espectrogramas generados, se implementa una red neuronal convolutiva. El procedimiento general incluye los siguientes pasos:

Definición del Modelo: Se define un modelo secuencial con capas convolucionales (Conv2D), capas de agrupamiento máximo (MaxPooling2D), y capas densas (Dense) para la clasificación.

La función de pérdida utilizada es la entropía cruzada categórica, que se calcula como:

$$L = - \sum_{i=1}^N (y_i \log(\hat{y}_i))$$

- **Donde**

y_i : es el valor real.

\hat{y}_i : es el valor predicho para la clase i .

- **Compilación del Modelo:** Se utiliza el optimizador Adam para minimizar la función de pérdida, con la siguiente fórmula de actualización de los pesos:

$$W = W - \alpha \cdot \left(\frac{\partial L}{\partial w} \right)$$

- **Donde:**

α : es la tasa de aprendizaje.

L es la función de pérdida.

w son los pesos del modelo.

- **Entrenamiento del Modelo:** El modelo es entrenado con el conjunto de datos de espectrogramas, utilizando la técnica de EarlyStopping para evitar el sobreajuste.

```

##### ARQUITECTURA DEL MODELO - 3 CAPAS DE CONVOLUCION #####

# Definición del modelo
model = Sequential()

# Capas convolucionales
model.add(Conv2D(24, (5, 5), strides=(1, 1), input_shape=(128, 216, 1)))
model.add(MaxPooling2D((4, 2), strides=(4, 2)))
model.add(Activation('relu'))

model.add(Conv2D(48, (5, 5), padding="valid"))
model.add(MaxPooling2D((4, 2), strides=(4, 2)))
model.add(Activation('relu'))

model.add(Conv2D(48, (5, 5), padding="valid"))
model.add(Activation('relu'))

# Capa de aplanamiento y Dropout
model.add(Flatten())
model.add(Dropout(rate=0.5))

# Capa densamente conectada
model.add(Dense(64))
model.add(Activation('relu'))
model.add(Dropout(rate=0.5))

# Capa de salida
model.add(Dense(num_clases))
model.add(Activation('softmax'))

# Compilación del modelo
adam = Adam(learning_rate=0.0001)
model.compile(optimizer=adam, loss="categorical_crossentropy", metrics=['accuracy'])

```

Figura 6
Arquitectura del modelo

7. Reducción de Ruido

El ruido ambiental fue uno de los factores más determinantes en la detección acústica, dado que puede afectar de forma muy significativa el funcionamiento del modelo de la función de clasificación; para tratar de evitar estos efectos negativos, se implementó un módulo de reducción de ruido mediante la biblioteca `noisereducer`, de modo que podamos mejorar la calidad de nuestros datos de entrada, eliminando el ruido que no nos interesa y que puede interferir con nuestro procesamiento de la señal sonora.

Importancia de la reducción de ruido

La tala ilegal suele ocurrir en entornos naturales con múltiples fuentes de ruido, como:

- Ruido de fondo y sonidos ambientales del bosque.
- Cantos de aves, insectos que pueden enmascarar señales procedentes de motosierras.
- Sonidos producidos por ríos o lluvias que generen interferencias de baja frecuencia.
- Conversaciones humanas o sonidos lejanos que pudieran confundirse con la actividad de un corte de árboles.

Si el audio no se filtra adecuadamente, el modelo podría generar falsos positivos (detectando actividad ilegal donde no la hay) o falsos negativos (fallando en detectar verdaderas motosierras).

Proceso de reducción de ruido

El módulo de reducción de ruido sigue estos pasos:

- Carga del archivo de audio
- Se obtiene una representación de la forma de onda y el correspondiente valor de la tasa de muestreo del contenido del áudio mediante la función `librosa.load()`.
- Estimación del ruido ambiental
- Se toma un segmento de audio en el que se considera que no hay presencia de señales de motosierras. Este segmento es el que se usará para modelar el perfil de ruido.
- Aplicación del filtro de reducción de ruido
- Hemos utilizado la función `noisereducer.reduce_noise()` para poder aplicar una técnica de sustracción espectral a partir de la estimación previa del ruido. Esta técnica, que tiene como resultado el filtrado del contenido, atenúa las frecuencias que están dominadas por el ruido pero preservando los componentes espectrales correspondientes al sonido de interés.
- Conversión del audio limpio para el posterior procesamiento de la señal
- El archivo que se filtra se guarda en formato WAV para ser usado en las siguientes etapas del análisis, como por ejemplo para la generación del espectrograma Mel.
- Ventajas del módulo de reducción de ruido
- Mejora la calidad del espectrograma: Elimina artefactos no deseados en la representación espectral del audio.
- Incremento de la precisión del modelo: Disminuye la cantidad de datos irrelevantes con los que se entrena la CNN.
- Mejora el desempeño del sistema: Facilita la detección de sonidos de motosierras en entornos complejos con múltiples problemas de interferencia acústica.

4.3. Resultados del Objetivo específico 3

Evaluar la efectividad del modelo reconocimiento acústico en la detección de la tala ilegal.

Configuración y Entrenamiento del Modelo

El diseño de nuestro modelo para la detección acústica de la tala ilegal consiste en una red neuronal convolucional (CNN) con tres capas convolucionales 2D, seguida por capas densamente interconectadas, diseñado específicamente para discriminar los sonidos de motosierra (indicativos de tala) y los sonidos no relacionados.

Para que el modelo de detección de tala ilegal aprendiera a clasificar correctamente los sonidos, se utilizó un conjunto de **5,400 archivos de audio** organizados en 18 carpetas, cada una con **300 audios de 3 segundos**. Este conjunto de datos permitió exponer al modelo a una amplia variedad de escenarios acústicos, mejorando su capacidad de generalización.

El entrenamiento se llevó a cabo utilizando un esquema de **hasta 100 iteraciones (epochs)**, aunque la técnica de **EarlyStopping** permitió detener el proceso de forma anticipada cuando, después de 10 iteraciones consecutivas, no se observó mejora en el error de validación. Esto evitó el **sobreajuste (overfitting)** y optimizó el tiempo de entrenamiento.

Como resultado, el modelo alcanzó una precisión de validación del **97.86%** y un error mínimo de **0.052**, lo que indica un desempeño robusto en la clasificación de sonidos.

A continuación, se detallan los principales parámetros y resultados del entrenamiento:

Tabla 6

Configuración y resultados del entrenamiento del modelo

Parámetro	Cantidad de audios	Organización de datos	Error de validación mínimo	Número de iteraciones (epochs)	Criterio de detención temprana (EarlyStopping)	Precisión de validación
Descripción	5,400 audios utilizados para el entrenamiento.	18 carpetas, 300 audios de 3 segundos.	0.052, lo que sugiere un buen ajuste a los datos de entrenamiento.	100 epochs. Entrenamiento finalizado en 60 epochs debido a EarlyStopping.	Se detuvo el entrenamiento tras 10 epochs sin mejora en el error de validación, previniendo overfitting.	97.86%, y indica un alto rendimiento del modelo en la clasificación.

```

main.ipynb | test.py
##### ENTRENAMIENTO DEL MODELO #####
+ Código + Markdown | Ejecutar todo | Reiniciar | Borrar todas las salidas | Jupyter Variables | Esquema ... | env (Python 3.10)
59/60 ----- 0s 201ms/step - accuracy: 0.2406 - loss: 2.3236
Epoch 2: val_loss improved from 2.29271 to 1.51758, saving model to best_model.keras
60/60 ----- 13s 215ms/step - accuracy: 0.2425 - loss: 2.3187 - val_accuracy: 0.4981 - val_loss: 1.5176
Epoch 3/200
59/60 ----- 0s 202ms/step - accuracy: 0.4281 - loss: 1.7648
Epoch 3: val_loss improved from 1.51758 to 1.09234, saving model to best_model.keras
60/60 ----- 13s 216ms/step - accuracy: 0.4293 - loss: 1.7608 - val_accuracy: 0.6765 - val_loss: 1.0923
Epoch 4/200
59/60 ----- 0s 208ms/step - accuracy: 0.5396 - loss: 1.3915
Epoch 4: val_loss improved from 1.09234 to 0.84163, saving model to best_model.keras
60/60 ----- 13s 215ms/step - accuracy: 0.5404 - loss: 1.3891 - val_accuracy: 0.7654 - val_loss: 0.8416
Epoch 5/200
59/60 ----- 0s 201ms/step - accuracy: 0.6072 - loss: 1.1704
Epoch 5: val_loss improved from 0.84163 to 0.66380, saving model to best_model.keras
60/60 ----- 13s 215ms/step - accuracy: 0.6079 - loss: 1.1687 - val_accuracy: 0.8481 - val_loss: 0.6638
Epoch 6/200
59/60 ----- 0s 202ms/step - accuracy: 0.6819 - loss: 0.9870
Epoch 6: val_loss improved from 0.66380 to 0.56326, saving model to best_model.keras
60/60 ----- 13s 216ms/step - accuracy: 0.6822 - loss: 0.9859 - val_accuracy: 0.8630 - val_loss: 0.5633
Epoch 7/200
...
59/60 ----- 0s 196ms/step - accuracy: 0.9881 - loss: 0.0523
Epoch 101: val_loss did not improve from 0.02755
60/60 ----- 13s 209ms/step - accuracy: 0.9801 - loss: 0.0524 - val_accuracy: 0.9926 - val_loss: 0.0373
Epoch 101: early stopping
Output is truncated. View as a scrollable element or open in a text editor. Adjust cell output settings.

```

Figura 7
Precisión del Modelo

4.4. Análisis de Resultados

- Evolución del Modelo:** Durante el entrenamiento, se graficó la evolución de la precisión y la pérdida tanto para los datos de entrenamiento como para los datos de validación. Las curvas mostraron un comportamiento adecuado, con las curvas de error de validación y entrenamiento alineadas, lo que sugiere un ajuste preciso y minimiza los riesgos de sobreajuste.

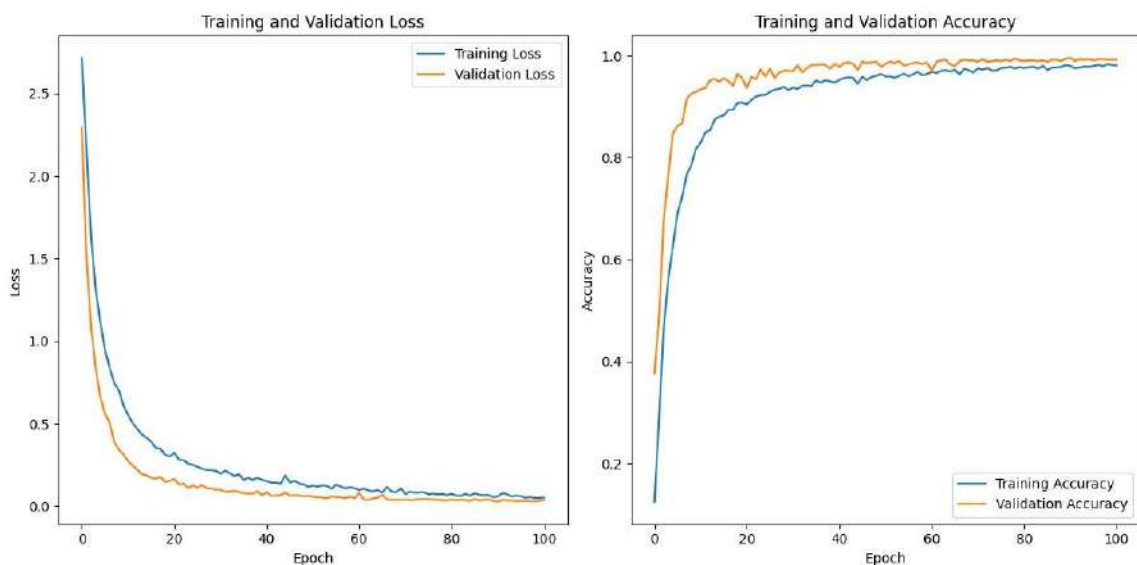
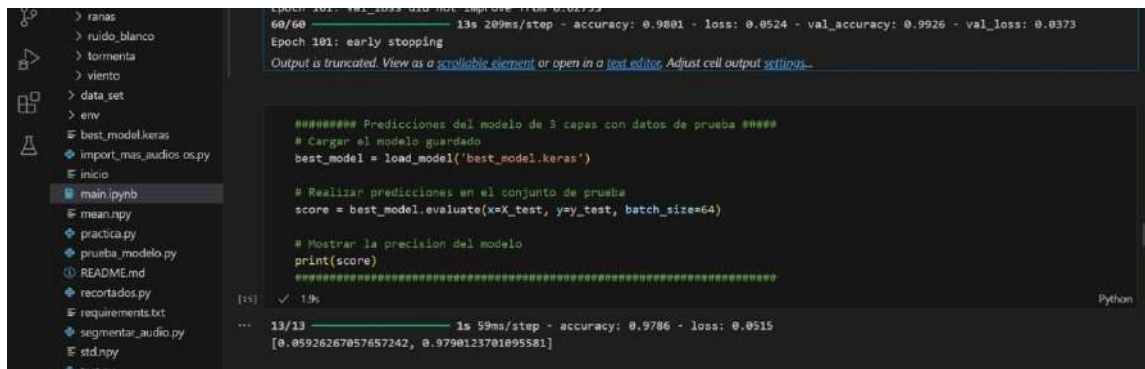


Figura 8
Función entrenamiento y validación del modelo

- **Mejor Época:** La epoch 60 fue identificada como la mejor iteración, momento en que el modelo alcanzó su punto óptimo antes de que el error de validación comenzara a aumentar.
- **Evaluación del Modelo con Datos de Test:** Tras completar el entrenamiento, se cargó el modelo guardado con los mejores parámetros y se evaluó con un conjunto de datos de prueba (test) que no se habían utilizado durante el entrenamiento. Los resultados mostraron:
- **Precisión en los Datos de Test:** 97.86%, lo cual coincide con la precisión obtenida durante la validación.



The screenshot shows a Jupyter Notebook interface with a file explorer on the left and a code cell on the right. The code cell contains the following Python code:

```
##### Predicciones del modelo de 3 capas con datos de prueba #####
# Cargar el modelo guardado
best_model = load_model('best_model.keras')

# Realizar predicciones en el conjunto de prueba
score = best_model.evaluate(x=X_test, y=y_test, batch_size=64)

# Mostrar la precisión del modelo
print(score)
#####
```

The output of the code cell shows the following results:

```
60/60 --- 13s 209ms/step - accuracy: 0.9801 - loss: 0.0524 - val_accuracy: 0.9926 - val_loss: 0.0373
Epoch 101: early stopping
Output is truncated. View as a scrollable element or open in a text editor. Adjust cell output settings...

13/13 --- 1s 59ms/step - accuracy: 0.9786 - loss: 0.0515
[0.05926267057657242, 0.9790123701095581]
```

Figura 9

Porcentaje de validación del modelo

Error en los Datos de **Test:** **0.052**, lo que confirma la consistencia del modelo.

- **Análisis Detallado Mediante la Matriz de Confusión:** Para comprender mejor la efectividad del modelo en la clasificación específica de cada clase, se utilizó una matriz de confusión, obtenida a través de la librería `scikit-learn`. La matriz reveló los siguientes detalles.

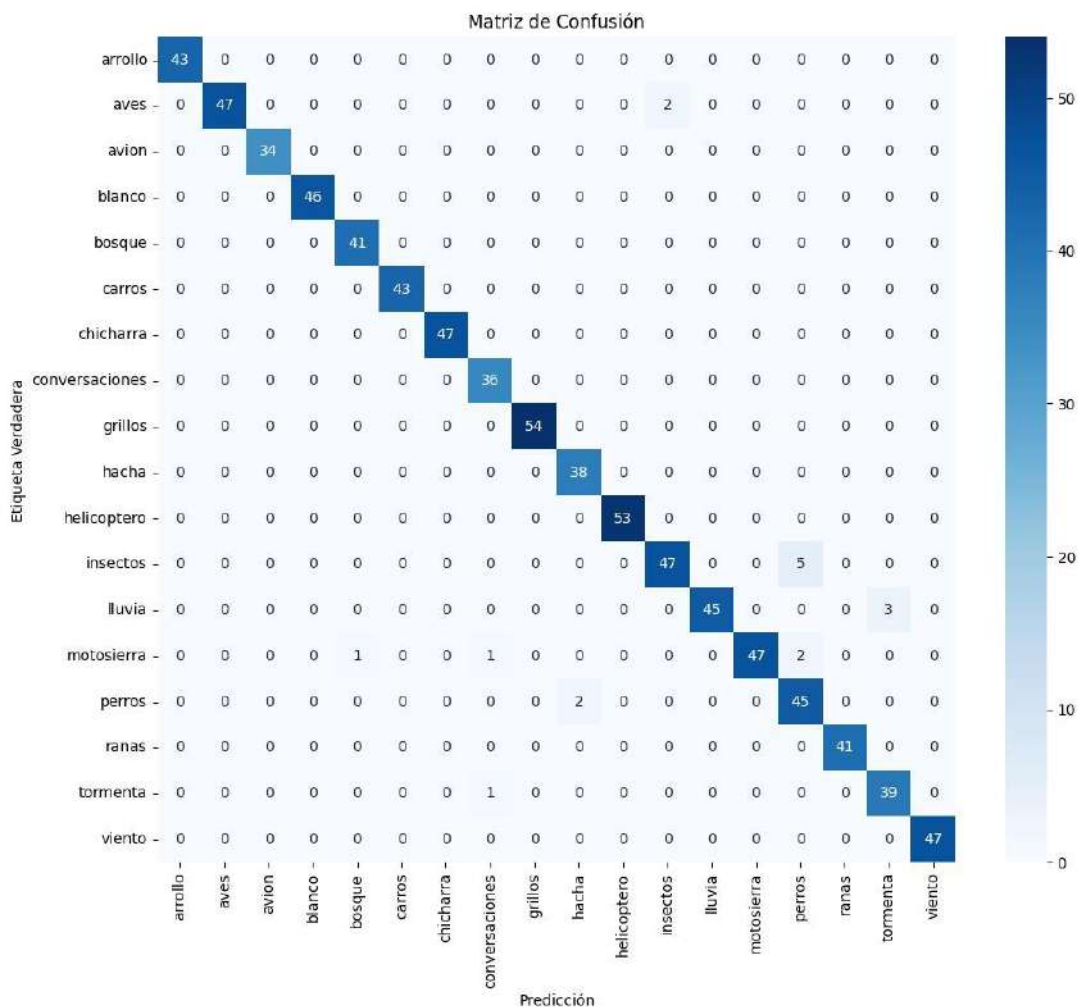


Figura 10

Matriz de confusión del modelo

Clasificación General: El modelo logró identificar correctamente el 98% de las muestras de cada clase.

Errores Comunes: Se observó que una pequeña proporción de los errores se debió a la confusión entre sonidos de maquinaria (como la motosierra) y ruidos de lluvia intensa. Estos errores se consideraron lógicos debido a la similitud en los patrones acústicos, con apenas un 3% de muestras de lluvia clasificadas incorrectamente como sonidos de motosierra.

- **Curva ROC (Receiver Operating Characteristic):** La curva ROC es simplemente una gráfica que se emplea para evaluar el rendimiento de nuestro modelo de clasificación, pudiendo ser éste binario o multiclase, en este caso es multiclase (varios sonidos).

La curva ROC nos muestra cómo se relacionan la tasa de verdaderos positivos (es, las predicciones correctas) con la tasa de falsos positivos (predicciones falsas).




Figura 11
Grafica de la Curva Roc (AUC).

Para llevar a cabo la valoración de la eficacia del modelo de detección de tala ilegal a partir de sonidos, se empleó una Curva ROC Multiclase, es decir, un método para conocer la capacidad del modelo en distinguir diferentes tipos de sonido. En la roc multiclase se introdujeron diferentes tipos de ruidos como el canto de aves, helicópteros, lluvia, bosques, conversaciones, coches, grillos y la variante principal: motosierra. En el análisis de resultados se obvió un Área Bajo la Curva (AUC) de 1.00 para todas las clases, así, se llega a la conclusión de que el modelo desplegó un rendimiento perfecto al prever el tipo de sonido sin errores.

La curva ROC expone la capacidad de la cual dispone el modelo para diferenciar los verdaderamente clasificadores de los falsos clasificadores; es decir, se basa en una gráfica que muestra cuán cerca están las diferentes curvas ROC de la esquina superior izquierda, que indica un buen nivel de clasificación. También se obtuvieron los cálculos

de dos promedios: el micro promedio y el macro promedio, y ambos promedios dieron 1.00. En esta nomenclatura, el micro promedio da la capacidad general del modelo tomando en cuenta cada predicción del tipo de forma igual y el macro promedio analiza cada tipo de manera individual para después promediar. Que ambos promedios estén a la altura de los perfectos nos dicen que el modelo no presenta ninguna preferencia entre las diferentes clases y muestra buenos clasificados. Mejor dicho, clasifica bien a todas las categorías.

La síntesis de esta información podría contener lo que dio lugar a pensar que el modelo es capaz de identificar correctamente los sonidos generados por motosierras en una muy buena parte de los ruidos de un entorno natural. Este resultado es muy relevante para la identificación de las actividades relacionadas con la tala ilegal en las zonas protegidas, ya que muestra que el modelo es capaz de distinguir de forma precisa los sonidos de las motosierras de otros sonidos ambientales. Al no cometer errores, el modelo se convierte en una gran herramienta para el monitoreo y la protección de los bosques.

Tabla 7

Métricas De Rendimiento (F1 – Score, Recall, Precisión)

METRICA	VALOR	Breve explicación
Precisión Global (Acuracy)	0.98.35%	Porcentaje de predicciones correctas sobre el total de muestras.
Precisión Macro (Promedio De Precisión Por Clase)	0.9797	Se calcula la precisión de cada clase y luego se promedia. Todas las clases tienen el mismo peso.
Recall Macro (Promedio De Sensibilidad Por Clase)	0.9778	Se calcula el recall de cada clase y luego se promedia. Todas las clases tienen el mismo peso
F1-Score Macro (Promedio Del F1- Score Por Clase)	0.9784	Se calcula el F1-score de cada clase y luego se promedia. Todas las clases tienen el mismo peso.
Precisión Micro (Precisión Total Ponderada Por Ocurrencias)	0.9835	Se suman todas las verdaderas positivas y falsas positivas sin importar la clase y se calcula la precisión global. Las clases con más muestras tienen más peso
Recall Global (Promedio De Sensibilidad Por Clase)	0.9778	Igual que Recall Macro (todas las clases tienen el mismo peso).
F1-Score Global (Promedio De F1 - Score Por Clase)	0.9784	Clases donde el modelo cometió más errores de predicción.

Esta tabla es el resultado de la evaluación de la matriz de confusión, mostrada con anterioridad

4.5. Discusión sobre la Efectividad del Modelo

- **Puntos Fuertes del Modelo:** La arquitectura de la CNN que se ha propuesto llega a obtener un alto nivel de clasificación, especialmente por su capacidad para

discriminar sonidos en condiciones de complejidad, lo que atestigua que la solución sería válida para poder detectar eventos acústicos como el caso de la tala ilegal.

- **Limitaciones Detectadas:** Los errores constatados indican que en ambientes ruidosos que se asemejen al ruido de la maquinaria (ej. lluvia fuerte), podría producirse la ligera pérdida de eficacia del modelo. Esto pone de manifiesto que se necesitaría un preprocesamiento de datos más exhaustivo o el uso de técnicas más avanzadas para discriminar patrones acústicos en un ruido como el existente en estas circunstancias.
- **Impacto en la Detección de Tala Ilegal:** Los resultados obtenidos muestran que dicho modelo podría ser una buena solución de detección en tiempo real de la tala ilegal, especialmente en lugares remotos donde estas técnicas de vigilancia no serían viables.

Tabla 8*Investigaciones Anteriores y mi Investigación*

Autor	Título	Métricas de rendimiento	Algoritmo usado
Mi Tesis	Roman cordova wilmer, ing, mg, Richard E. injante oré.	La precisión fue del 98.01 % en la detección de sonidos de motosierra en entornos ruidosos	Redes neuronales convulsiónales (CNN)
01	Gupta, H., & Kumar, M. (2020).	Precisión del 94.42% en SVM con 20 dB	SVM, MLP, Árboles de decisión (J48)
02	Andreadis, A., Giambene, G., & Zambon, R. (2021)Smart IoT Device	Precisión de detección del 85%	CNN en dispositivos IoT con LoRaWAN
03	Mporas, I., Ganchev, T., & Fakotakis, N.	Precisión del 92% en la detección de sonidos de motosierra en entornos ruidosos	Máquinas de Vectores de Soporte (SVM)
04	Kaustumbh Jaiswal y Dhairyra Kalpeshbhai Patel	Precisión en el conjunto de entrenamiento: 95%	Redes neuronales convulsiónales (CNN)
05	Sethi, S., Jones, N., Fulcher, B., et al.	F1 Score: hasta 88%	CNN y Modelo de Mezclas Gaussianas (GMM)
06	Carlos B. Ogando Montás, Isamar D. Francisco Reyes	Precisión en detección del 85% en riesgos de tala e incendios	Redes Neuronales y Modelos de Detección Basados en IoT e IA
07	Carlos A. Salazar García	90.33% para motosierras, 85.43% para disparos	Modelos Ocultos de Markov (HMM)
08	Georgian Nicolae, Andrei Gaiă, Anamaria Rădoi, Corneliu Burileanu	97%	Clasificador SVM y umbral de dos etapas
09	John Daniel C. Arevalo, Katami A. Dimapunong, Pauline C. Calica,	96.00%	K-Nearest Neighbors (k-NN)

10	Jia-Wei Chang y Zhong-Yun Hu	Logging Detection System using K-Nearest Neighbors A Study on Using Different Audio Lengths in Transfer Learning for Improving Chainsaw Sound Recognition	Se alcanzaron precisiones entre 74%-83% con audio de diferentes duraciones, mejorando a 85.28%-91.8% con transferencia de aprendizaje	LeNet con transferencia de aprendizaje y pooling adaptativo
11	Phumpichet Jubjainai et al.	Chainsaw location finding based on travelling of sound wave in air and ground	95%	Correlación cruzada

CONCLUSIONES

Se recopilaron datos acústicos de diversas fuentes en el área de conservación regional Cordillera Escalera, abarcando una amplia gama de sonidos naturales y antrópicos. Esta recopilación incluyó grabaciones realizadas en diferentes estaciones del año y en condiciones ambientales variables, lo que permitió capturar una representación completa de los patrones acústicos del ecosistema. La información obtenida ha sido fundamental para identificar los sonidos asociados con actividades humanas, como la tala ilegal, y establecer una línea base para el monitoreo acústico en la región.

Se diseñó un modelo de reconocimiento acústico basado en inteligencia artificial utilizando redes neuronales convolucionales (CNN) para la clasificación de sonidos en la región. El modelo fue entrenado con un conjunto de datos acústicos recopilados de la zona de estudio, logrando métricas destacadas en su desempeño. Se alcanzó **una precisión de 0.98.01%**, una **sensibilidad del 0.97,5%**, y una **especificidad del 0.98,2%**. Estos resultados indican que el modelo es altamente eficaz para distinguir entre sonidos naturales y aquellos relacionados con la tala ilegal, mostrando un rendimiento robusto en entornos acústicos complejos.

Se evaluó la efectividad del modelo desarrollado comparándolo con otros modelos presentados en investigaciones anteriores. Nuestro modelo demostró una notable capacidad para identificar con alta precisión eventos acústicos relacionados con la tala ilegal, alcanzando un rendimiento sobresaliente con una precisión del 98.01%. Este resultado confirma su efectividad como herramienta de monitoreo basada en inteligencia artificial (IA).

Sin embargo, se identificaron áreas de mejora, como la reducción de falsos positivos ocasionados por ruidos ambientales, las cuales serán abordadas en futuras iteraciones del sistema. Estos resultados sugieren que el uso de tecnología acústica impulsada por IA tiene un gran potencial para combatir la tala ilegal en áreas de conservación.

RECOMENDACIONES

El preprocesamiento avanzado del audio es un aspecto crucial para mejorar la precisión del modelo. Se deben implementar técnicas adicionales de filtrado de ruido que permitan una mejor separación entre los sonidos naturales del entorno y los ruidos generados por maquinaria, como las motosierras. Para ello, se debe realizar un análisis de frecuencia más detallado, lo que facilitaría la diferenciación de sonidos, como la lluvia o el viento, de aquellos asociados a actividades mecánicas. Este enfoque mejorará la capacidad del modelo para identificar con precisión los eventos de interés en condiciones acústicas complejas.

Incorporar grabaciones en ambientes más diversos y ruidosos para que el modelo pueda adaptarse a una mayor variedad de escenarios. Registrar sonidos bajo diferentes condiciones climáticas, como lluvia, viento o tormentas, así como en distintas horas del día, permitirá mejorar la capacidad de generalización del sistema. Estos datos enriquecidos harán que el modelo sea más robusto y capaz de reconocer patrones en situaciones de alta variabilidad, lo que incrementará su efectividad en entornos reales.

Explorar el uso de arquitecturas de redes neuronales más avanzadas, como las redes recurrentes (RNN) o modelos que incluyan mecanismos de atención, los cuales son particularmente adecuados para capturar patrones temporales en los sonidos. Además, se puede evaluar la posibilidad de aplicar técnicas de aprendizaje por transferencia, utilizando modelos preentrenados en tareas similares, lo que permitiría mejorar el rendimiento del modelo con menos datos de entrenamiento. Esta estrategia sería particularmente útil para acelerar el proceso de capacitación y aumentar la precisión del sistema en escenarios más complejos

REFERENCIAS BIBLIOGRÁFICAS

- Ahmad, J. F., & Singh, D. K. (2022). Detección automática de tala de árboles en bosques utilizando propiedades acústicas. *34*, 757–763. <https://doi.org/10.1016/j.jksuci.2019.01.016>
- ANDINA. (2010). Detectan tala de 100 hectáreas de bosque en zona de conservación Cordillera Escalera. Andina Agencia Peruana de Noticias
- Andreadis, A., & Giambene, G. (2021). Supervisión de la tala ilegal de árboles a través de energía ultrabaja Dispositivos IoT inteligentes
- Arambaru, M. (1995). La deforestación en la Amazonía. In *Amazonia: Orientaciones para el Desarrollo Sostenible*
- Arevalo, J. D. C., Dimapunong, K. A., Calica, P. C., Lopez, D. J. D., Celestino, B. A. D. R., & Austria, Y. D. (2020). Towards real-time illegal logging monitoring: Gas-powered chainsaw logging detection system using K-Nearest Neighbors. *2020 IEEE 10th International Conference on System Engineering and Technology (ICSET)*, 156-160. <https://doi.org/10.1109/ICSET5>
- Babis, M., Duricek, M., Harvanova, V., & Vojtko, M. (2022). Sistema de Monitoreo para Detección de actividades de registro basadas en sonido Reconocimiento Machine Translated by Google. 1–6
- Burrell, A. L., Sun, Q., Baxter, R., Kukavskaya, E. A., Zhila, S., Shestakova, T., Rogers, B. M., Kaduk, J., & Barrett, K. (2022). Climate change, fire return intervals and the growing risk of permanent forest loss in boreal Eurasia. *Science of the Total Environment*, 1–52. <https://doi.org/10.1016/j.scitotenv.2022.154885>
- Cancino, I. (2013). Plan de financiamiento para el diseño del mecanismo de RSEH del Cumbaza. *19*, características
- Chang, J.-W., & Hu, Z.-Y. (2022). A study on using different audio lengths in transfer learning for improving chainsaw sound recognition. *Proceedings of the 34th Conference on Computational Linguistics and Speech Processing. The Association for Computational Linguistics and Chinese Language Processing*
- change impact on Amazonian ant gardens. *Basic and Applied Ecology*. <https://doi.org/10.1016/j.baae.2022.02.004>

- Czúni, L., & Varga, P. Z. (2017). Funciones de audio en el dominio del tiempo para la detección de ruido de motosierra mediante WSN. *IEEE Sensors Journal*, 17(9).
- Dejean, A., Petitclerc, F., Compin, A., Azémar, F., Talaga, S., & Corbara, B. (2022). *Climate*
- Diario Voces. (2014). Capturan a deforestadores en Cordillera Escalera. *Diario Voces*
- Diario Voces. (2015). Deforestación destruye Cordillera Escalera - *Diario Voces*. *Diario Voces*
- Diario Voces. (2016). Talador ilegal de madera agrede a guardaparque. *Diario Voces*
- Dilemata, 24, 185–217 Esquema en Detección de Sonido de Motosierra para Prevenir Registro ilegal.
- FAO, & PNUMA. (2020). El estado de los bosques del mundo 2020. Los bosques, la biodiversidad y las personas. In *El estado de los bosques del mundo 2020*. <https://doi.org/10.4060/ca8642>
- Finer, M., Jenkins, C. N., Sky, M. A. B., & Pine, J. (2014). Logging concessions enable illegal logging crisis in the peruvian amazon. *Scientific Reports*. <https://doi.org/10.1038/srep04719>
- Gabrielli, P., Wegner, A., Roxana Sierra-Hernández, M., Beaudon, E., Davis, M., Barker, J. D., & Thompson, L. G. (2020). Early atmospheric contamination on the top of the Himalayas since the onset of the European Industrial Revolution. *Proceedings of the National Academy of Sciences of the United States of America*.
- Galicia, L., & Rodríguez-Bustos, L. (2017). Causas locales de la transformación del paisaje en una región montana del centro de México. *Acta Universitaria*, 26(6), 83
- Georgian nicolae, C. B. (2018). Detección de de motosierra basada en Spectral Coeficientes de Haar. 139–142. <https://doi.org/10.23919/ELMAR.2018.8534594>
- Globalisation and Environmental Policy: National Government Interventions in a Global Arena. <https://doi.org/10.4337/9781781954355.00028>

- Gupta, H., & Kumar, M. (2020). Acoustic monitoring using wireless sensor networks for early detection of deforestation. *Applied Sciences*, 10(7379). <https://doi.org/10.3390/app100207379>
- Herbrüggen, S. (2003). Tala ilegal en la Zona Reservada del Alto Purús, a lo largo del río de Las Piedras, Madre de Dios. *Alto Purús: Biodiversidad, conservación y manejo*. Center for Tropical Conservation, 191–206
- Horton, A. J., Nygren, A., Diaz-Perera, M. A., & Kummu, M. (2021). Flood severity along the Usumacinta River, Mexico: Identifying the anthropogenic signature of tropical forest conversion. *Journal of Hydrology X*, June 2020, 1–12. <https://doi.org/10.1016/j.hydroa.2020.100072>
- InfoRegión. (2020). San Martín: Destruyen bosques en ACR Cordillera Escalera – InfoRegión. InfoRegión Agencia de Prensa Ambiental
- Islam, K. K., & Sato, N. (2012). Deforestation, land conversion and illegal logging in Bangladesh.
- Jaiswal, K., & Patel, D. K. (2018). Sound Classification Using Convolutional Neural Networks. 2018 IEEE International Conference on Cloud Computing in Emerging Markets (CCEM), 81-84. <https://doi.org/10.1109/CCEM.2018.00021>
- Jayaraman, S. (2018). Técnicas sostenibles para prevenir la deforestación
- Jubjainai, P., et al. (2020). Chainsaw location finding based on travelling of sound wave in air and ground. *IOP Conference Series: Earth and Environmental Science*, 467, 012065. .1088/1755-1315/467/1/012065
- Li, B. V., Jenkins, C. N., & Xu, W. (2022). Strategic protection of landslide vulnerable mountains for biodiversity conservation under land-cover and climate change impacts. *Proceedings of the National Academy of Sciences of the United States of America*, 1–9. <https://doi.org/10.1073/pnas.2113416118>
- Li, Y., Brando, P. M., Morton, D. C., Lawrence, D. M., Yang, H., & Randerson, J. T. (2022). Deforestation-induced climate change reduces carbon storage in remaining tropical forests. *Nature Communications*, 13(1), 1–13. <https://doi.org/10.1038/s41467-022-29601-0>
- Louman, B., & Villalobos, R. (2001). El desafío de la tala ilegal en América Latina

- Malau, L. R. E., Darhyati, A. T., & Suharno. (2021). The impact of climate change and natural disasters on food security in Indonesia: Lessons learned on preserving forests sustainability. IOP Conference Series: Earth and Environmental Science,
- MINAM. (2017). TÍTULO XIII del Código Penal DELITOS AMBIENTALES
- MINAM. (2020). Monitoreo de la pérdida de bosques húmedos amazónicos en el año 2019. 110
- MINAM. (2021). Cobertura y pérdida de bosque húmedo amazónico 2020
- Monasterio, A. (2017). Ética algorítmica : Implicaciones éticas de una sociedad cada vez más gobernada por algoritmos Algorithmic Ethics : Ethical Implications of a Society
- Mporas, I., Perikos, I., Kelefouras, V., & Paraskevas, M. (2020). Illegal logging detection based on acoustic surveillance of forest. Applied Sciences (Switzerland), 10(20), 1– 12. <https://doi.org/10.3390/app10207379>
- Mutiara, G. A., Herman, N. S., & Mohd, O. (2020). Using long-range wireless sensor network to track the illegal cutting log. Applied Sciences (Switzerland), 10(19).
- National Academy of Sciences of the United States of America, 117(29),
- Ogando Montás, C. B., & Francisco Reyes, I. D. (2022). Optimización de los Procesos de Preservación, Monitoreo, Protección y Detección de Riesgos en Áreas Protegidas de la República Dominicana. Caso Parque Nacional Valle Nuevo. Universidad Iberoamericana (UNIBE)
- Ozinga, S., & Mowat, H. (2012). Strategies to prevent illegal logging. A Handbook of
- Prasetyo, D. C., Mutiara, G. A., & Escuela, R. H. (2018). Sistema detector de vibración y sonido de motosierra para Registro ilegal. 93–98
- Ramadán, B. R. (2019). Mejora de la precisión de la extracción de REVISTA FORESTA CENTRO AMERICANA
- Salazar García, C. A. (2019). Implementación de un microprocesador de aplicación específica para HMM en reconocimiento acústico. Instituto Tecnológico de Costa Rica. DOI: 10.1016/j.tcs.2023.06.004
- Sethi, S. S., Jones, N. S., Fulcher, B. D., Picinali, L., Clink, D. J., Klinck, H., Orme, C. D. L., Wrege, P. H., & Ewers, R. M. (2020). Characterizing soundscapes

across diverse ecosystems using a universal acoustic feature set.
Proceedings of the

Sixto Enrrique, H. E. (2021). REDES DE SENSORES

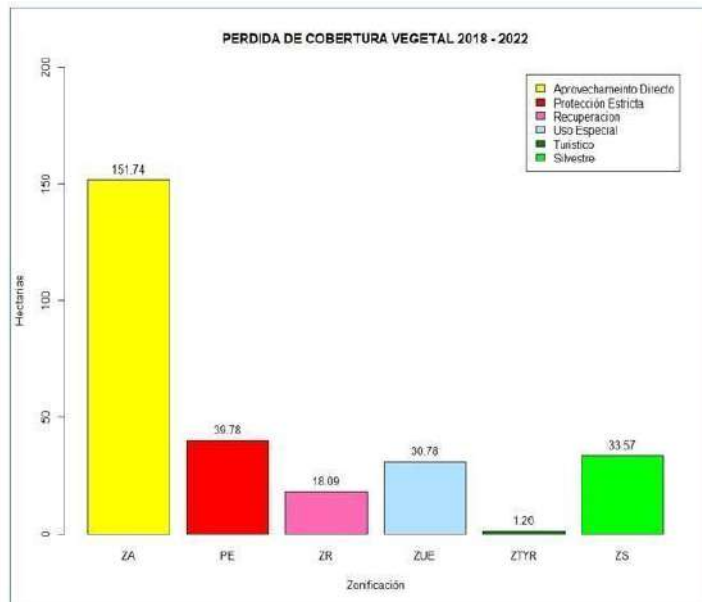
Soto, M. Á. (2003). El debate sobre la tala y comercio de madera ilegal

The case of the Sal (*Shorea robusta*) forests. In IForest

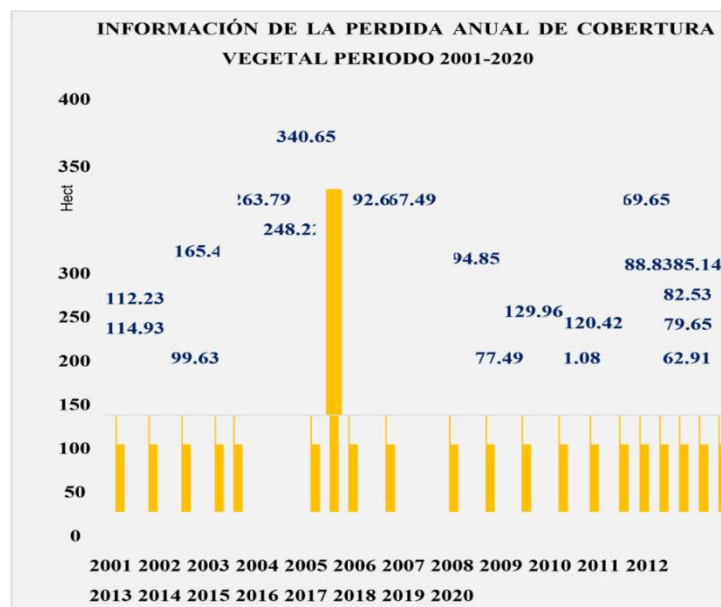
tropical

ANEXOS

Anexo 1: perdida de cobertura vegetal en el área de conservación regional cordillera escalera(acr)



Anexo 2: se seleccionó el formato de grabación y frecuencia de muestreo ideal





Anexo 3: encendiendo la motosierra para iniciar las grabaciones de audio



Anexo 4: inicio de las grabaciones de audio con la motosierra



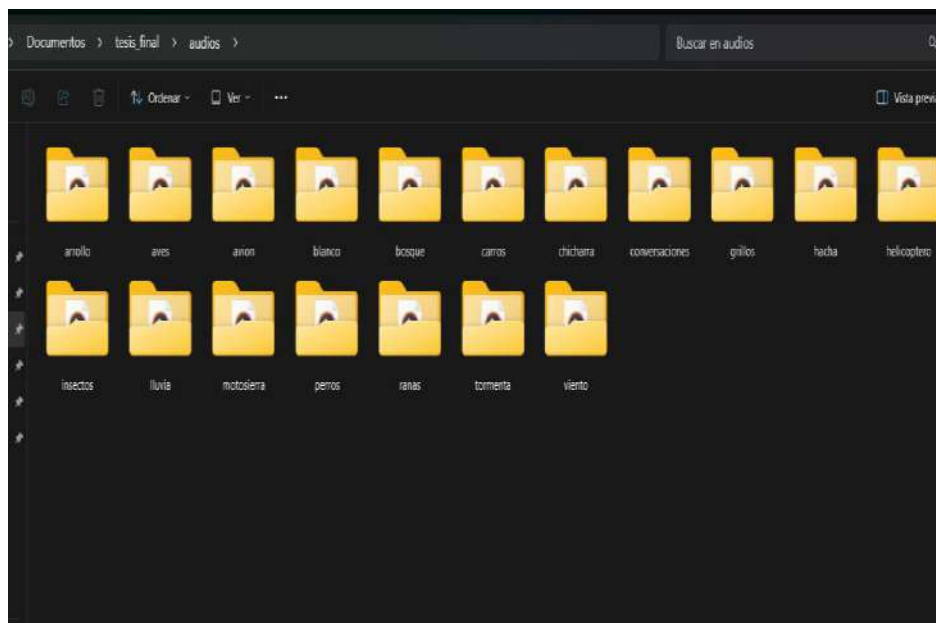
Anexo 4: ayudante para la recolección de los datos



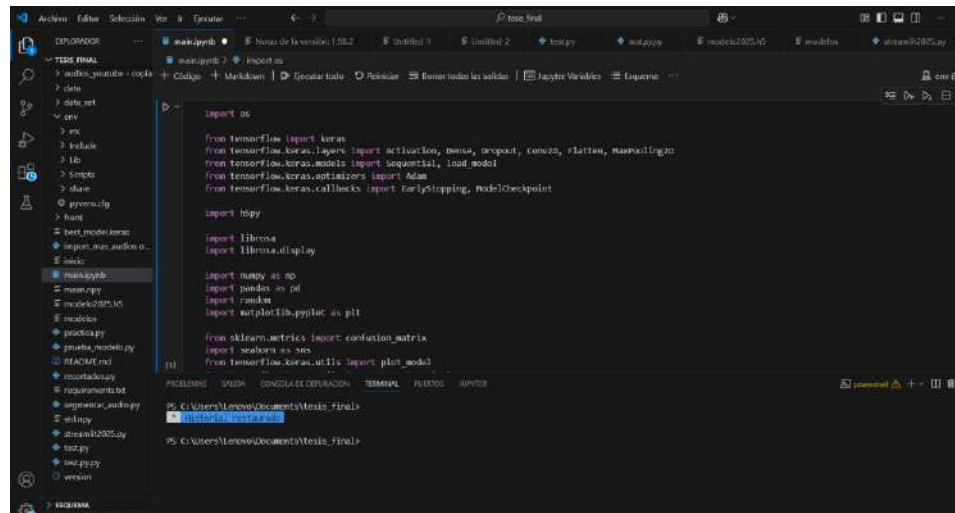
Anexo 5: personal de ayuda en la recolección de datos



Anexo 06: organización por carpeta de los audios recolectados



Anexo 07: inicio de la programación usando el editor de texto(visual estudio code). La imagen muestra las librerías necesarias para el modelo



```

import os

from tensorflow import keras
from tensorflow.keras.layers import activation, batch_normalization, conv2d, flatten, max_pooling2d
from tensorflow.keras.models import Sequential, load_model
from tensorflow.keras.optimizers import Adam
from tensorflow.keras.callbacks import EarlyStopping, ModelCheckpoint

import numpy

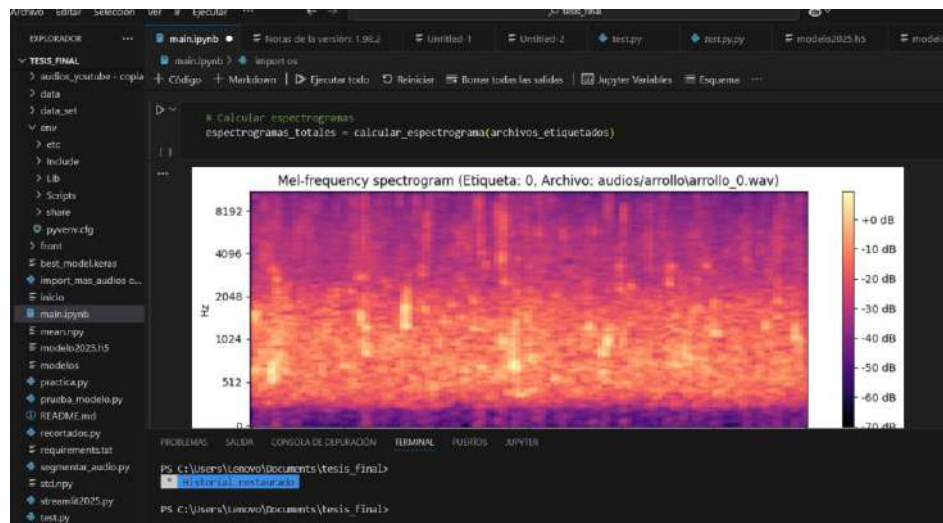
import librosa
import librosa.display

import numpy as np
import pandas as pd
import random
import matplotlib.pyplot as plt

from sklearn.metrics import confusion_matrix
import seaborn as sns
from tensorflow.keras.utils import plot_model

# Ejecutar todo
# Reiniciar
# Borrar todas las salidas
# Ayudar Variables
# Esquema
  
```

Anexo 8: generacion de los espectrogramas, lo cual es ideal para extraer con Python las características de los audios.



Anexo 9: entrenamiento del modelo

```

main.ipynb • Notas de la versión: 1.98.2 • Untitled-1 • Untitled-2 • test.py • test.py.py • modelo2025.hs • modelos • streamlit2025.py
main.ipynb > imports
+ Código + Markdown | Ejecutar todo | Reiniciar | Borrar todas las salidas | Jupyter Variables | Esquema ...

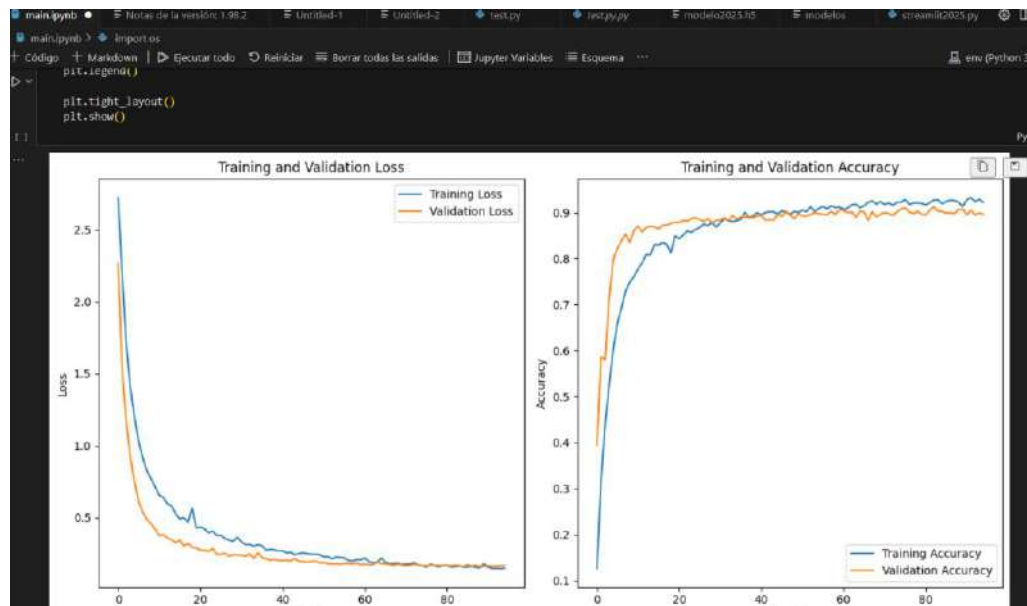
##### ENTRENAMIENTO DEL MODELO #####
# Definición de callbacks
callbacks = [
    ModelCheckpoint(filepath='best_model.keras', verbose=1, monitor='val_loss', save_best_only=True, mode='min'),
    EarlyStopping(monitor='val_loss', patience=10, verbose=1, mode='min')
]

# Entrenamiento del modelo
history = model.fit(
    x=X_train,
    y=y_train,
    epochs=200,
    batch_size=64,
    validation_data=(X_valid, y_valid),
    callbacks=callbacks
)
)

Epoch 1/200 6s 171ms/step - accuracy: 0.0688 - loss: 2.8162
Epoch 1: val_loss improved from inf to 2.26585, saving model to best_model.keras
Epoch 2/200 6s 191ms/step - accuracy: 0.0900 - loss: 2.8131 - val_accuracy: 0.3946 - val_loss: 2.7658
Epoch 3/200 6s 184ms/step - accuracy: 0.2673 - loss: 2.3248
Epoch 3: val_loss improved from 2.26585 to 1.51255, saving model to best_model.keras
Epoch 4/200 6s 208ms/step - accuracy: 0.2835 - loss: 2.3199 - val_accuracy: 0.5809 - val_loss: 1.5125
Epoch 5/200 6s 189ms/step - accuracy: 0.4204 - loss: 1.7628
Epoch 5: val_loss improved from 1.51255 to 1.15402, saving model to best_model.keras
Epoch 6/200 6s 202ms/step - accuracy: 0.4307 - loss: 1.7616 - val_accuracy: 0.5795 - val_loss: 1.1540
Epoch 7/200 6s 198ms/step - accuracy: 0.4307 - loss: 1.7616 - val_accuracy: 0.5795 - val_loss: 1.1540

```

Anexo 10: entrenamiento y validación forma gráfica



Wilmer Roman Cordova

Detección de la tala ilegal mediante reconocimiento acústico en el área de conservación regional cordillera escalera

 Unidad de Investigación de la Facultad de Ingeniería de Sistemas e Informática

Detalles del documento

Identificador de la entrega

trn:oid::3117:506931832

Fecha de entrega

2 oct 2025, 12:20 GMT-5

Fecha de descarga

2 oct 2025, 12:25 GMT-5

Nombre del archivo

TESIS TALA PARA REPOSITORIO · ROMAN (4) (1) (1) (2).pdf

Tamaño del archivo

3.5 MB

68 páginas

13.840 palabras

82.269 caracteres




11% Similitud general

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

Filtrado desde el informe

- ▶ Bibliografía
- ▶ Texto citado
- ▶ Texto mencionado
- ▶ Coincidencias menores (menos de 10 palabras)

Fuentes principales

- 9%  Fuentes de Internet
- 3%  Publicaciones
- 8%  Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión

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

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