



UNIVERSIDAD TÉCNICA ESTATAL DE QUEVEDO
FACULTAD DE CIENCIAS DE LA COMPUTACIÓN Y DISEÑO DIGITAL
CARRERA DE TELEMÁTICA

Trabajo de Integración Curricular
previa la obtención del Grado
Académico de Ingeniero en
Telemática.

Título del Proyecto de Investigación:

ALGORITMOS DE PROCESAMIENTO DE AUDIO PARA LA IDENTIFICACIÓN DE
AVES EN EL BOSQUE PROTECTOR MUROCOMBA

Autor:

Justin Iván Macías Quiroz

Director del proyecto de investigación:

Ing. Diego Fernando Intriago Rodríguez, M. Sc

Quevedo – Los Ríos – Ecuador

2025



DECLARACIÓN DE AUTORÍA Y CESIÓN DE DERECHOS

Yo, **JUSTIN IVÁN MACÍAS QUIROZ**, declaro que la investigación aquí descrita es de mi autoría; que no ha sido previamente presentado para ningún grado o calificación profesional; y, que he consultado las referencias bibliográficas que se incluyen en este documento.

La Universidad Técnica Estatal de Quevedo, puede hacer uso de los derechos correspondientes a este documento, según lo establecido por la Ley de Propiedad Intelectual, por su Reglamento y por la normatividad institucional vigente.



Justin Iván Macías Quiroz

C.I: 1205563446



UTEQ

CERTIFICACIÓN DE CULMINACIÓN DEL PROYECTO DE INVESTIGACIÓN

El suscrito, **Ing. Diego Fernando Intriago Rodríguez, M. Sc.**, Docente de la Universidad Técnica Estatal de Quevedo, certifica que el estudiante **Justin Iván Macías Quiroz**, realizó el Proyecto de Investigación de grado titulado “**ALGORITMOS DE PROCESAMIENTO DE AUDIO PARA LA IDENTIFICACIÓN DE AVES EN EL BOSQUE PROTECTOR MUROCOMBA**”, previo a la obtención del título de Ingeniero en Telemática, bajo mi dirección, habiendo cumplido con las disposiciones reglamentarias establecidas para el efecto.

Ing. Diego Fernando Intriago Rodríguez, M. Sc

DIRECTOR DEL PROYECTO DE INVESTIGACIÓN



CERTIFICADO DEL REPORTE DE LA HERRAMIENTA DE PREVENCIÓN DE COINCIDENCIA Y/O PLAGIO ACADÉMICO

El suscrito, **Ing. Diego Fernando Intriago Rodríguez, M. Sc.**, mediante el presente cumpro en presentar a usted, el informe de proyecto de Investigación titulado “**ALGORITMOS DE PROCESAMIENTO DE AUDIO PARA LA IDENTIFICACIÓN DE AVES EN EL BOSQUE PROTECTOR MUROCOMBA**” Presentado por el estudiante **Justin Iván Macías Quiroz**, egresado de la Carrera de Telemática, que fue revisado bajo mi dirección según resolución del Consejo Directivo de la Facultad De Ciencias De La Computación Y Diseño Digital, que se ha desarrollado de acuerdo al Reglamento de la Unidad de Integración Curricular de la Universidad Técnica Estatal de Quevedo y cumple con el requerimiento de análisis del sistema COMPILATIO el cual avala los niveles de originalidad en un 96% y similitud 4%, del trabajo investigativo. Valido este documento para que el estudiante siga con los trámites pertinentes, de acuerdo como lo establece el Reglamento.

 CERTIFICADO DE ANÁLISIS
magister

Trabajo de Titulación - Justin Macías Quiroz

4%
Textos sospechosos

4% Similitudes
< 1 % similitudes entre comillas
0 % entre las fuentes mencionadas

11% Idiomas no reconocidos (ignorados)

Nombre del documento: Trabajo de Titulación - Justin Macías Quiroz.pdf
ID del documento: c5e18344488f4ef05da77fac658b6631e8999f86
Tamaño del documento original: 5,52 MB

Depositante: DIEGO FERNANDO INTRIAGO RODRIGUEZ
Fecha de depósito: 17/11/2025
Tipo de carga: interface
fecha de fin de análisis: 17/11/2025

Número de palabras: 23.929
Número de caracteres: 181.434


Ing. Diego Fernando Intriago Rodríguez, M. Sc.
DIRECTOR DEL PROYECTO DE INVESTIGACIÓN



UTEQ

UNIVERSIDAD TÉCNICA ESTATAL DE QUEVEDO
FACULTAD DE CIENCIAS DE LA COMPUTACIÓN Y DISEÑO DIGITAL
CARRERA DE TELEMÁTICA

PROYECTO DE INVESTIGACION

TÍTULO:

“ALGORITMOS DE PROCESAMIENTO DE AUDIO PARA LA IDENTIFICACIÓN DE AVES EN EL BOSQUE PROTECTOR MUROCOMBA”

Presentado al Consejo Directivo de la Facultad De Ciencias De La Computación Y Diseño Digital como requisito previo a la obtención del título de Ingeniero en Telemática.

Aprobado por:

PRESIDENTE DEL TRIBUNAL

Ing. Ángel Iván Torres Quijije, M. Sc

MIEMBRO DEL TRIBUNAL

Ing. Eduardo Amable Samaniego Mena, M. Sc

MIEMBRO DEL TRIBUNAL

Ing. Anthony Limber Moran Cabezas, M. Sc

QUEVEDO – LOS RIOS – ECUADOR

2025

AGRADECIMIENTO

Primeramente, agradezco a mis padres, Iván Macías y Yessenia Quiroz, y a mi hermano, Jeremy Macías. La culminación de este proyecto es el reflejo directo de su inmenso amor y valiosas enseñanzas. Les agradezco profundamente por la confianza plena que depositaron en mí y por el apoyo incondicional y constante que me brindaron durante todo el proceso.

Mi gratitud se extiende a mi Abuela, Georgina Moreira, por abrirme las puertas de su hogar y acoger mi proceso de estudio con tanto cariño y paciencia. De igual manera, agradezco a mis tías Nancy y Neida Macías, por su cercanía y por su presencia protectora, que hicieron de este entorno un verdadero refugio.

A mi enamorada, Marcela Rebolledo. Gracias por ser mi punto de equilibrio y mi fuente de inspiración constante. Tu presencia fue un factor clave para mantener la motivación y la calma durante este exigente recorrido.

También agradezco a mis compañeros de estudio y extendiendo mi agradecimiento a mis amigos de toda la vida por su genuina amistad y el tiempo compartido fueron esenciales, permitiéndome la necesaria pausa y distensión en medio del proceso académico. Gracias por simplemente estar ahí.

Finalmente, reconozco la guía experta de mi director del Proyecto de Investigación, Ing. Diego Fernando Intriago Rodríguez, M. Sc, cuya dirección metódica y feedback constante fueron esenciales para la calidad de la investigación.

A la Universidad Técnica Estatal de Quevedo, por ser la institución que me brindó la formación integral y el espacio necesario para convertir este sueño profesional en realidad.

Con profundo agradecimiento
Justin Iván Macías Quiroz

DEDICATORIA

Dedico este proyecto de investigación a mi ardua persistencia, a los momentos de paciencia, a los desvelos y a la convicción de que el esfuerzo constante rinde frutos. Y dedico este logro, con profundo amor, a mis padres, Iván Macias y Yessenia Quiroz, por haberme acompañado con su apoyo y enseñanza inquebrantables desde el primer día de mi vida, siendo la verdadera causa de mi perseverancia y mi mayor inspiración.

Justin Iván Macías Quiroz

RESUMEN

Esta investigación presenta el desarrollo de un sistema automatizado para la identificación de especies aviares mediante algoritmos de procesamiento de audio y aprendizaje automático, aplicado en el Bosque Protector Murocomba, ubicado en la provincia de Los Ríos, Ecuador. Este ecosistema, caracterizado por su elevada biodiversidad, se encuentra expuesto a amenazas como la tala ilegal y el avance de actividades humanas, en gran parte debido a la ausencia de sistemas de monitoreo estructurado que respalden estrategias de conservación efectivas. El proyecto propone una solución basada en la combinación de Redes Neuronales Convolucionales (CNN) y Huellas Acústicas (Audio Fingerprinting), técnicas que permiten clasificar vocalizaciones aviares a partir de señales captadas por sensores acústicos estratégicamente distribuidos. La metodología comprendió fases de recolección de datos, preprocesamiento de audio, extracción de características acústicas y validación del modelo con bases de datos especializadas como Xeno-Canto. Los resultados obtenidos demuestran una alta precisión en la identificación de especies, incluso en escenarios con ruido ambiental considerable, lo que evidencia la robustez del sistema ante condiciones adversas. Además, se generó una base de datos acústica estructurada, enriquecida con metadatos clave, que podrá ser reutilizada en investigaciones futuras sobre biodiversidad. Este enfoque no invasivo y replicable constituye una herramienta tecnológica de gran utilidad para instituciones dedicadas a la conservación, al permitir el monitoreo continuo, eficiente y en tiempo casi real de la fauna aviar, especialmente en zonas de difícil acceso. La propuesta refuerza la integración entre ciencia, tecnología y medioambiente en el ámbito de la gestión ecológica moderna.

Palabras clave: *Bioacústica, aprendizaje automático, monitoreo ambiental, procesamiento de señales, conservación basada en datos.*

ABSTRACT

This research presents the development of an automated system for the identification of avian species through audio processing and machine learning algorithms, applied in the Murocomba Protected Forest, located in the province of Los Ríos, Ecuador. This ecosystem, characterized by its high biodiversity, is exposed to threats such as illegal logging and the advance of human activities, largely due to the absence of structured monitoring systems to support effective conservation strategies. The project proposes a solution based on the combination of Convolutional Neural Networks (CNN) and Audio Fingerprinting, techniques that allow classifying avian vocalizations from signals captured by strategically distributed acoustic sensors. The methodology included data collection, audio preprocessing, acoustic feature extraction and model validation with specialized databases such as Xeno-Canto. The results obtained demonstrate high accuracy in species identification, even in scenarios with considerable ambient noise, which demonstrates the robustness of the system in adverse conditions. In addition, a structured acoustic database was generated, enriched with key metadata, which can be reused in future biodiversity research. This non-invasive and replicable approach is a very useful technological tool for conservation institutions, allowing continuous, efficient and near-real-time monitoring of avian fauna, especially in areas that are difficult to access. The proposal reinforces the integration between science, technology and environment in the field of modern ecological management.

Keywords: *Bioacoustics, machine learning, environmental monitoring, signal processing, data-driven conservation.*

ÍNDICE DE CONTENIDO

PORTADA	i
DECLARACIÓN DE AUTORÍA Y CESIÓN DE DERECHOS	ii
CERTIFICACIÓN DE CULMINACIÓN DEL PROYECTO DE INVESTIGACIÓN.....	iii
CERTIFICADO DEL REPORTE DE LA HERRAMIENTA DE PREVENCIÓN DE COINCIDENCIA Y/O PLAGIO ACADÉMICO	iv
CERTIFICADO DE APROBACIÓN POR TRIBUNAL DE SUSTENTACIÓN.....	v
AGRADECIMIENTO.....	vi
DEDICATORIA.....	vii
RESUMEN.....	viii
ABSTRACT	ix
CÓDIGO DUBLIN	xix
INTRODUCCIÓN.....	1
CAPÍTULO I.....	1
1 CONTEXTUALIZACIÓN DE LA INVESTIGACIÓN.....	1
1.1 Problema de Investigación	6
1.1.1 <i>Planteamiento del Problema</i>	6
1.1.1.1 Diagnóstico.....	7
1.1.1.2 Pronóstico.....	7
1.1.2 <i>Formulación del problema</i>	7
1.1.3 <i>Sistematización del problema</i>	8
1.2 Objetivos.....	8
1.2.1 <i>Objetivo General</i>	8
1.2.2 <i>Objetivos Específicos</i>	8
1.3 Justificación.....	9
CAPÍTULO II.....	10
2 FUNDAMENTACIÓN TEÓRICA DE LA INVESTIGACIÓN	10

2.1	Marco conceptual	11
2.1.1	<i>Monitoreo acústico</i>	11
2.1.2	<i>Bioacústica</i>	11
2.1.3	<i>Señal acústica</i>	11
2.1.4	<i>Espectrogramas</i>	12
2.1.5	<i>Coefficientes Cepstrales en Escala Mel (MFCC)</i>	12
2.1.6	<i>Transformada de Fourier de Tiempo Corto (STFT)</i>	13
2.1.7	<i>Algoritmos de aprendizaje automático</i>	13
2.1.8	<i>Redes Neuronales Convolucionales (CNN)</i>	14
2.1.8.1	Resolución Temporal y Espectral.....	14
2.1.8.2	Tamaño de la Ventana (Window Size) y Solapamiento entre Ventanas (Overlap).....	14
2.1.8.3	Eje X (Tiempo) Eje Y (Frecuencia).	15
2.1.8.4	Intensidad (Escala de colores o tonos).	15
2.1.8.5	Bandas de Frecuencia (Frequency Bands).	15
2.1.8.6	Picos y Valles (Peaks and Valleys).	15
2.1.8.7	Armónicos (Harmonics).	16
2.1.8.8	Modulación de Frecuencia (FM) y Modulación de Amplitud (AM).....	16
2.1.8.9	Transitorios (Transients).	16
2.1.8.10	Desvanecimiento (Decay).	16
2.1.8.11	Ruido (Noise).	16
2.1.9	<i>Audio Fingerprinting (Huellas Acústicas)</i>	17
2.1.9.1	Coefficientes Cepstrales Lineales (LPC - Linear Predictive Coding).	17
2.1.9.2	Análisis de Formantes (Formants Analysis).....	17
2.1.9.3	Análisis de Envolvente (Envelope Analysis).	17
2.1.9.4	Tasa de Cambio de Frecuencia (Frequency Rate of Change).	18
2.1.9.5	Análisis de Timbre (Timbre Analysis).	18

2.1.9.6	Desviación Espectral (Spectral Deviation).....	18
2.1.9.7	Relación de Energía entre Bandas (Energy Ratio between Bands).....	18
2.1.9.8	Análisis de Correlación Temporal (Temporal Correlation Analysis).	19
2.1.9.9	Análisis de Coherencia (Coherence Analysis).	19
2.1.9.10	Análisis de Frecuencia Fundamental (Fundamental Frequency Analysis). 19	
2.1.10	<i>Base de datos acústica</i>	19
2.1.11	<i>Biodiversidad</i>	20
2.1.12	<i>Frecuencia de las Vocalizaciones de las Aves</i>	20
2.1.13	<i>Filtros paso bajo</i>	21
2.1.14	<i>Sensores Acústicos</i>	21
2.1.15	<i>Data Augmentation (Aumento de Datos)</i>	22
2.1.16	<i>Validación Cruzada (Cross-Validation)</i>	23
2.1.17	<i>Dataset de Aves en Ecuador</i>	24
2.2	Marco Referencial	29
2.3	Marco legal.....	30
2.3.1	<i>Legislación Ambiental En Ecuador</i>	30
2.3.1.1	Constitución De La Republica Del Ecuador (2008).....	30
2.3.1.2	Ley De Gestión Ambiental (1999).	31
2.3.1.3	Código Orgánico Del Ambiente (Coa, 2017).....	31
CAPÍTULO III		33
3	METODOLOGÍA DE LA INVESTIGACIÓN	33
3.1	Localización	34
3.2	Tipos de investigación	34
3.2.1	<i>Investigación bibliográfica</i>	34
3.2.2	<i>Investigación exploratoria</i>	35
3.3	Métodos de investigación	35

3.3.1	<i>Método cualitativo</i>	35
3.3.2	<i>Método cuantitativo</i>	35
3.3.3	<i>Método analítico</i>	35
3.4	Diseño de la investigación	36
3.5	Fuentes de recopilación de información	36
3.6	Fases de la investigación	37
3.6.1	<i>Fase 1: Prueba piloto y ajuste de protocolos</i>	37
3.6.2	<i>Fase 2: Recolección de datos</i>	37
3.6.3	<i>Fase 3: Preprocesamiento de audio</i>	38
3.6.4	<i>Fase 4: Desarrollo de modelos</i>	38
3.6.5	<i>Fase 5: Validación y análisis de resultados</i>	38
3.7	Materiales	39
CAPÍTULO IV		44
4	RESULTADOS Y DISCUSIÓN	44
4.1	Captación de señales de audio	45
4.1.1	Descripción de las Figuras.....	47
4.1.2	Discusión	52
4.2	Muestrear las grabaciones obtenidas	53
4.2.1	Descripción de las Figuras.....	55
4.2.2	Discusión	66
4.3	Implementar algoritmos de aprendizaje automático.....	67
4.3.1	Funcionamiento de la Aplicación	75
4.3.2	Datos recopilados	75
4.3.3	Identificación de Especies de Aves en el Bosque Protector Murocomba ...	80
4.3.4	Discusión	93
CAPÍTULO V		94
5	CONCLUSIONES Y RECOMENDACIONES	94

5.1	Conclusiones.....	95
5.2	Recomendaciones	96
	CAPÍTULO VI.....	97
6	BIBLIOGRAFÍA.....	97
6.1	Referencias Bibliográficas.....	98
	CAPÍTULO VII.....	104
7	ANEXO	104

ÍNDICE DE TABLAS

Tabla 1. Taxonomía de aves en Ecuador.	24
Tabla 2. Materiales utilizados.	39
Tabla 3. Características de los materiales utilizados.	41
Tabla 4. Formula del muestreo y segmentación.	54
Tabla 5. Comparación entre filtros IIR y FIR.	55
Tabla 6. Características de las huellas acústica.	70
Tabla 7. Características de las redes neuronales convolucionales.	72
Tabla 8. Comparación de Algoritmos (CNN vs. Huellas).	73
Tabla 9. Tabla de grabaciones.	75
Tabla 10. Distribución de Especies por Familias Detectadas en Cada Zona del Bosque... ..	76
Tabla 11. Distribución de las Familias de Aves en las Zonas Baja, Media y Alta del Bosque.	79
Tabla 12. Dataset de aves en el Bosque Protector Murocomba.	80

ÍNDICE DE FIGURAS

Figura 1. Ubicación del bosque protector Murocomba.	34
Figura 2. Circuito de sistema embebido con Arduino, modulo SD, micrófono Max 4466 y baterías 4xAA.	40
Figura 3. Implementación del prototipo del sistema embebido.	40
Figura 4. Arquitectura del sistema de adquisición acústica	43
Figura 5. Audios recopilados con sus respectivas partes.	45
Figura 6. Sendero del Bosque Protector Murocomba.	46
Figura 7. Zona baja del bosque protector Murocomba.	47
Figura 8. Captación en la parte baja del bosque.....	47
Figura 9. Zona media del bosque protector Murocomba.	48
Figura 10. Captación en la zona media del bosque.	49
Figura 11. Zona alta del bosque protector Murocomba.	50
Figura 12. Captación en la parte alta (cabaña).	50
Figura 13. Comparación de 2 minutos de la señal y espectrograma en las 3 sesiones.....	51
Figura 14. Muestreo de todas las zonas.....	55
Figura 15. Visualización Contextual de 24 Horas y Muestreo Hiper-Focalizado - Parte Baja.	56
Ilustración 16. Señal de audio sub-segmentada y filtrada en el segundo 4960 al 5060 de la parte baja del bosque.	57
Figura 17. Señal de audio sub-segmentada y filtrada en el segundo 13240 al 13340 de la parte baja del bosque.	57
Figura 18. Señal de audio sub-segmentada y filtrada en el segundo 29650 al 29750 de la parte baja del bosque.	58
Figura 19. Señal de audio sub-segmentada y filtrada en el segundo 48500 al 48600 de la parte baja del bosque.	58
Figura 20. Señal de audio sub-segmentada y filtrada en el segundo 71200 al 71300 de la parte baja del bosque.	59
Figura 21. Visualización Contextual de 24 Horas y Muestreo Hiper-Focalizado - Parte Media.....	59
Figura 22. Señal de audio sub-segmentada y filtrada en el segundo 4150 al 4250 de la parte media del bosque.	60
Figura 23. Señal de audio sub-segmentada y filtrada en el segundo 16500 al 16600 de la parte media del bosque.	60

Figura 24. Señal de audio sub-segmentada y filtrada en el segundo 31200 al 31300 de la parte media del bosque.	61
Figura 25. Señal de audio sub-segmentada y filtrada en el segundo 53400 al 53500 de la parte media del bosque.	61
Figura 26. Señal de audio sub-segmentada y filtrada en el segundo 79990 al 80090 de la parte media del bosque.	62
Figura 27. Visualización Contextual de 24 Horas y Muestreo Hiper-Focalizado - Parte Alta.	62
Figura 28. Señal de audio sub-segmentada y filtrada en el segundo 650 al 750 de la parte alta del bosque.	63
Figura 29. Señal de audio sub-segmentada y filtrada en el segundo 12560 al 12660 de la parte alta del bosque.	63
Figura 30. Señal de audio sub-segmentada y filtrada en el segundo 35780 al 35880 de la parte alta del bosque.	64
Figura 31. Señal de audio sub-segmentada y filtrada en el segundo 55900 al 56000 de la parte alta del bosque.	64
Figura 32. Señal de audio sub-segmentada y filtrada en el segundo 83250 al 83350 de la parte alta del bosque.	65
Figura 33. Diagrama de características de los algoritmos aplicados.	67
Figura 34. Esquema de los algoritmos implementados.	68
Figura 35. Funcionamiento de las huellas acústicas.	69
Figura 36. Funcionamiento de las redes neuronales convolucionales.	71
Figura 37. Logotipo de App.	74
Figura 38. Interfaz de la App.	74
Figura 39. Familia de aves captadas en las diferentes zonas del Bosque Protector Murocomba.	78
Figura 40. Comparación porcentual de especies registradas.	91
Figura 41. Distribución por estado UICN.	92

ÍNDICE DE ANEXOS

Anexo 1. Programación de la interfaz de la App.	105
Anexo 2. Visita al Bosque Protector Murocomba.....	105
Anexo 4. Guía de Don Manuel en el bosque Protector Murocomba.	106
Anexo 3. Preparación del prototipo de sistema embebido para la grabación de audios. ..	106
Anexo 5. Revisión de la zona de instalación del prototipo.	107
Anexo 6. Revisión del circuito en el prototipo de sistema embebido.	107
Anexo 7. Inicio de grabación de audios para la identificación de aves.....	108
Anexo 8. Instalación del prototipo en una buena zona para la grabación.	108
Anexo 9. Prueba del funcionamiento de la App.....	109
Anexo 10. Resultado de simulación de algoritmos CNN y huellas acústicas.	109

CÓDIGO DUBLIN

Título:	Algoritmos de procesamiento de audio para la identificación de aves en el bosque protector Murocomba.				
Autor:	Justin Iván Macías Quiroz				
Palabras claves:	Bioacústica	Aprendizaje automático.	Monitoreo ambiental.	Procesamiento de señales.	Conservación basada en datos.
Fecha de publicación:	Noviembre, 2025				
Editorial:	Quevedo- UTEQ, 2025				
Resumen:	<p>Esta investigación desarrolla un sistema automatizado para la identificación de especies aviares en el Bosque Protector Murocomba, Ecuador, utilizando algoritmos de procesamiento de audio y aprendizaje automático. El objetivo es enfrentar la falta de monitoreo estructurado en este ecosistema biodiverso, expuesto a amenazas como la tala ilegal y actividades humanas. El sistema propuesto emplea Redes Neuronales Convolucionales (CNN) y Huellas Acústicas para clasificar vocalizaciones de aves a partir de datos obtenidos por sensores acústicos distribuidos en el bosque. La metodología incluye la recolección de datos, preprocesamiento de audio, extracción de características acústicas y validación de modelos con bases de datos especializadas como Xeno-Canto. Los resultados muestran una alta precisión en la identificación de especies, incluso con ruido ambiental, y se genera una base de datos acústica reutilizable. Este enfoque no invasivo proporciona una herramienta eficaz para el monitoreo y conservación de la biodiversidad en áreas remotas.</p>				
Abstract:	<p>This research develops an automated system for identifying bird species in the Murocomba Protected Forest, Ecuador, using audio processing and machine learning algorithms. The objective is to address the lack of structured monitoring in this biodiverse ecosystem, which is exposed to threats such as illegal logging and human activities. The proposed system uses Convolutional Neural Networks (CNN) and Acoustic Fingerprints to classify bird vocalizations based on data obtained by acoustic sensors distributed throughout the forest. The methodology includes data collection, audio preprocessing, acoustic feature extraction, and model validation with specialized databases such as Xeno-Canto. The results show high accuracy in species identification, even with environmental noise, and a reusable acoustic database is generated. This non-invasive approach provides an effective tool for biodiversity monitoring and conservation in remote areas.</p>				
Descripción:	128 hojas: dimensiones, 29 x 21 cm + CD-ROM 6162				
URI:					

INTRODUCCIÓN

La biodiversidad constituye uno de los pilares fundamentales para el equilibrio ecológico del planeta. Cada ecosistema alberga una rica variedad de especies que cumplen funciones esenciales en los ciclos naturales. Sin embargo, las actividades humanas, como la deforestación, el cambio climático y la contaminación, están ejerciendo una presión creciente sobre estos sistemas, comprometiendo la supervivencia de numerosas especies y alterando el equilibrio ambiental [1].

La comunidad científica ha adoptado diversas metodologías para el monitoreo de la biodiversidad, destacándose la bioacústica como una herramienta emergente. Estudios recientes del Laboratorio de Ornitología de Cornell han demostrado que las grabaciones acústicas permiten obtener datos valiosos para la identificación de especies y el seguimiento de ecosistemas, lo cual facilita una planificación más efectiva de estrategias de conservación. Según la FAO (2020), más del 80 % de los bosques tropicales del mundo enfrentan amenazas significativas por la falta de monitoreo adecuado y datos científicos actualizados [1].

En América Latina, particularmente en Ecuador, el monitoreo de la biodiversidad enfrenta limitaciones relacionadas con la extensión de ecosistemas tropicales y la baja adopción de tecnologías modernas. En el Parque Nacional Yasuní, por ejemplo, el uso de monitoreo acústico permitió registrar especies no documentadas previamente, fortaleciendo su inclusión en programas internacionales de conservación [2]. Estos resultados destacan el potencial de la bioacústica para generar datos robustos en zonas de difícil acceso y elevada biodiversidad [3].

El Bosque Protector Murocomba, ubicado en la provincia de Los Ríos, representa un ecosistema prioritario debido a su elevada diversidad aviar. No obstante, la ausencia de un sistema de monitoreo estructurado ha limitado la documentación científica de su riqueza biológica, dejándolo expuesto a amenazas como la tala ilegal y la expansión no regulada de actividades humanas, donde Los Ríos perdió $\approx 43,1$ mil ha de cobertura arbórea entre 2001–2024 (≈ 12 % de la cobertura del 2000) con emisiones asociadas de $\approx 22,1$ Mt CO_{2e}, procesos que fragmentan el hábitat y aceleran la antropización. Por tanto, esta investigación tiene como objetivo desarrollar un sistema automatizado de monitoreo acústico basado en algoritmos de procesamiento de audio y aprendizaje automático, que permita identificar especies aviares y apoyar la conservación efectiva de este ecosistema [4].

CAPÍTULO I: CONTEXTUALIZACIÓN DE LA INVESTIGACIÓN

En este capítulo, se presentó el planteamiento del problema relacionado con la falta de monitoreo eficiente de la biodiversidad aviar en el Bosque Protector Murocomba, un ecosistema de alta biodiversidad, pero sin tecnologías avanzadas para estudiar la avifauna. Se abordó el diagnóstico y pronóstico de la situación, destacando los riesgos de no implementar un sistema adecuado de monitoreo acústico. Se formula el problema principal, que es la falta de registros acústicos, se sistematizan las preguntas de investigación que guían el estudio. El capítulo también establece los objetivos generales y específicos de la investigación, los cuales buscan desarrollar un sistema automatizado para la identificación de aves mediante tecnologías acústicas y algoritmos de aprendizaje automático.

CAPÍTULO II: FUNDAMENTACIÓN TEÓRICA

Este capítulo proporciona la base teórica para la investigación, explicando conceptos clave como monitoreo acústico, bioacústica, señales acústicas, espectrogramas, coeficientes cepstrales en escala Mel (MFCC) y algoritmos de aprendizaje automático. Se detallaron las técnicas utilizadas para la identificación de vocalizaciones de aves y cómo los modelos de redes neuronales convolucionales (CNN) son empleados para la clasificación automática de estas vocalizaciones. También se discuten ejemplos y casos de éxito de la bioacústica en la conservación de la biodiversidad, como los proyectos de Xeno-Canto y el Cornell Lab of Ornithology. Además, se exploran los desafíos logísticos y las oportunidades del monitoreo acústico en Ecuador, haciendo énfasis en las limitaciones de infraestructura y la adopción de tecnologías avanzadas en el país.

CAPÍTULO III: METODOLOGÍA

En este capítulo, se describieron los tipos de investigación utilizadas, que son bibliográfica y exploratoria, los métodos de investigación cualitativo, cuantitativo y analítico. Se detalla el diseño cuasiexperimental de la investigación, que implica una intervención controlada para estudiar el impacto del sistema de monitoreo acústico en el Bosque Protector Murocomba. Se describieron las fases de la investigación, que incluyen una prueba piloto, recolección continua de datos, preprocesamiento de audio, desarrollo de modelos de clasificación y validación de resultados. Se explica también la localización del estudio y los métodos de recopilación de datos, que incluyen grabaciones acústicas, bases de datos

públicas y literatura científica, así como los protocolos de trabajo establecidos en la fase exploratoria.

CAPÍTULO IV: RESULTADOS Y DISCUSIÓN

Este capítulo presenta los resultados obtenidos durante la fase de captación de señales acústicas en el Bosque Protector Murocomba. Se detallan los hallazgos relacionados con la calidad de las grabaciones en diferentes zonas del bosque (baja, media y alta), identificando la presencia de vocalizaciones de aves y el impacto del ruido ambiental en la calidad de los datos. Los resultados del Objetivo Específico 1 la captación de señales de audio es seguidos de una discusión que explica cómo las condiciones del bosque, como la reverberación y el viento pueden afectar las grabaciones. También se aborda el Objetivo Específico 2 el muestreo de grabaciones aplicando técnicas de filtrado y segmentación para mejorar la calidad de los datos. La discusión contextualiza los desafíos logísticos y cómo estos impactan la efectividad del sistema de monitoreo en el campo. Los resultados son comparados con los hallazgos previos en otras investigaciones, validando el enfoque metodológico adoptado.

CAPÍTULO V: CONCLUSIONES Y RECOMENDACIONES

Este capítulo presenta las conclusiones derivadas de la investigación, destacando que el sistema de monitoreo acústico desarrollado cumplió con los objetivos planteados, permitiendo la captación eficiente de señales acústicas en diversas zonas del bosque. Se concluye que, a pesar de los desafíos logísticos y el ruido ambiental, el sistema ha demostrado ser una herramienta efectiva para la recolección de datos ecológicos en áreas de difícil acceso. Se hacen recomendaciones sobre estrategias de segmentación y filtrado de señales, así como sobre la optimización de futuros sistemas de monitoreo, sugiriendo la implementación de tecnologías de inteligencia artificial y aprendizaje automático para mejorar la precisión del análisis de vocalizaciones.

CAPÍTULO VI: BIBLIOGRAFÍA

En este capítulo se incluyó toda la bibliografía utilizada en la investigación, siguiendo las normas IEEE. Las referencias abarcan artículos científicos, libros, informes técnicos y fuentes en línea relacionadas con el monitoreo acústico, bioacústica, algoritmos de aprendizaje automático y legislación ambiental.

CAPÍTULO VII: ANEXOS

Este capítulo incluye los anexos correspondientes, como tablas de datos, gráficas, fotografías, espectrogramas, y cualquier material adicional relevante que complementa la investigación. Además, se incluyen los protocolos de muestreo y los detalles técnicos de los dispositivos utilizados para la recolección de datos.

CAPÍTULO I
CONTEXTUALIZACIÓN DE LA INVESTIGACIÓN

1.1 Problema de Investigación

1.1.1 Planteamiento del Problema

Los bosques cumplen un papel fundamental en la regulación del clima, la conservación del agua y la biodiversidad. A nivel mundial, estos ecosistemas enfrentan una creciente degradación debido a la deforestación, el cambio climático y la expansión de actividades humanas no reguladas. Una de las principales limitaciones en la conservación de los bosques es la falta de monitoreo eficiente de la fauna, en particular de las aves, que son bioindicadores clave del estado de salud de los ecosistemas. Según la FAO (2020), más del 80% de los bosques tropicales en el mundo carecen de datos científicos actualizados sobre la biodiversidad que albergan, lo que dificulta la toma de decisiones para su protección [1].

El Bosque Protector Murocomba, ubicado en la provincia de Los Ríos, enfrenta esta misma problemática al no contar con métodos efectivos para monitorear su avifauna. La falta de registros acústicos detallados impide documentar de manera precisa las especies presentes y su papel en el equilibrio del ecosistema [3]. Esto limita el conocimiento sobre su comportamiento, patrones de migración y estados de conservación, dificultando la implementación de estrategias de protección adecuadas. Ante esta situación, se hace necesario utilizar tecnologías avanzadas de monitoreo acústico, que permitan capturar y analizar vocalizaciones de aves sin intervención humana directa, generando datos científicos de alta calidad para el estudio y conservación del bosque [5].

En este sentido, la bioacústica se presenta como la alternativa más adecuada para abordar esta problemática. Las técnicas de monitoreo acústico permiten capturar y analizar las vocalizaciones de las aves sin necesidad de intervención humana directa, lo que facilita la recolección de datos a gran escala y en condiciones de campo complejas. Además, el uso de algoritmos de procesamiento de audio y aprendizaje automático permite identificar y clasificar especies de manera automática, incluso en ambientes ruidosos o difíciles de acceder, lo que representa una ventaja significativa en la conservación [4]. Estas tecnologías no solo posibilitan la identificación de especies, sino también el monitoreo temporal y espacial de sus poblaciones, permitiendo generar líneas base sonoras y establecer alertas tempranas ante cambios en la biodiversidad, lo cual es crucial para la gestión adaptativa del área protegida.

1.1.1.1 Diagnóstico.

El Protector Murocomba es un ecosistema de alta biodiversidad que carece de tecnologías avanzadas para el monitoreo acústico de su fauna aviar. La falta de herramientas especializadas para capturar y analizar las señales de audio de aves impide la obtención de datos científicos sobre las especies presentes, su comportamiento y sus patrones de distribución [5]. Esta ausencia de información limita el conocimiento sobre el estado de conservación de las aves en la zona y dificulta la identificación de especies en peligro o en proceso de migración. Sin una base de datos acústica organizada, no es posible evaluar los cambios en la biodiversidad ni desarrollar estrategias efectivas de manejo ambiental, lo que pone en riesgo la sostenibilidad del ecosistema a largo plazo [3].

1.1.1.2 Pronóstico.

Si no se implementan tecnologías de monitoreo acústico en el Bosque Protector Murocomba, el desconocimiento sobre las especies aviarias persistirá, impidiendo el análisis de su comportamiento, migración y estado de conservación [5]. La falta de datos científicos limitará la creación de estrategias de protección y manejo ambiental, aumentando la vulnerabilidad del bosque ante amenazas como la tala ilegal, la caza furtiva y la expansión de actividades agrícolas. A largo plazo, esto podría derivar en la disminución de la población de aves, afectando el equilibrio ecológico del bosque y su valor como un área de biodiversidad clave en la región [4]. Sin un monitoreo eficiente, el ecosistema continuará expuesto a impactos ambientales negativos, comprometiendo su capacidad de regeneración y sostenibilidad.

1.1.2 Formulación del problema

La falta de registros acústicos en el Bosque Protector Murocomba impide el análisis detallado de la biodiversidad aviar, dificultando la identificación de especies, su monitoreo y la implementación de estrategias de conservación.

¿Cómo puede el uso de tecnologías avanzadas, como el monitoreo acústico, contribuir a la identificación y clasificación de especies aviarias en este ecosistema?

1.1.3 Sistematización del problema

Pregunta General: ¿Cómo el uso de algoritmos de procesamiento de audio y aprendizaje automático puede mejorar la identificación de aves en el Bosque Protector Murocomba?

Preguntas Específicas:

- ¿Cuáles son las especies aviares más representativas del Bosque Protector Murocomba?
- ¿Qué características acústicas pueden ser utilizadas para identificar especies de aves en un ambiente natural?
- ¿Qué algoritmos de aprendizaje automático y procesamiento de señales son más efectivos para la clasificación de vocalizaciones aviares?

1.2 Objetivos

1.2.1 Objetivo General

Desarrollar un sistema basado en algoritmos de procesamiento de audio y aprendizaje automático para la detección de especies aviares en el Bosque Protector Murocomba.

1.2.2 Objetivos Específicos

- Captar señales de audio de las aves utilizando sensores acústicos para la recolección de datos.
- Muestrear las grabaciones obtenidas, aplicando técnicas de filtrado y segmentación para la selección de fragmentos acústicos relevantes.
- Implementar algoritmos de aprendizaje automático a través de la bioacústica inteligente para la clasificación y análisis de las especies aviares presentes en el Bosque Protector Murocomba.

1.3 Justificación

El monitoreo de aves es un desafío en entornos naturales debido a su movilidad, la variabilidad de sus sonidos y las condiciones ambientales cambiantes. La identificación de especies aviarias en el Bosque Protector Murocomba se ha visto limitada por la ausencia de registros acústicos sistemáticos, lo que impide un análisis profundo de su biodiversidad [5]. Sin datos científicos precisos sobre sus vocalizaciones, la implementación de estrategias de conservación resulta compleja, dificultando el reconocimiento de especies en peligro o en proceso de migración. Ante esta problemática, el uso de tecnologías avanzadas de monitoreo acústico y algoritmos de aprendizaje automático permite optimizar la captura, análisis y clasificación de sonidos de aves, proporcionando una solución innovadora y eficiente para la identificación de especies en entornos naturales [3].

A nivel estratégico, la aplicación de esta tecnología responde a una visión de conservación basada en el uso de herramientas digitales para la protección de la biodiversidad. Instituciones ambientales y académicas han comenzado a adoptar sistemas de monitoreo acústico como parte de su misión para preservar ecosistemas vulnerables [6]. Ejemplos de ello son proyectos como el de Cornell Lab of Ornithology, que ha desarrollado modelos de identificación de aves basados en bioacústica, o iniciativas como Xeno-Canto, que recopilan grabaciones a nivel mundial para apoyar investigaciones científicas [7]. La implementación de este sistema en el Bosque Protector Murocomba fortalecerá el compromiso con la conservación de su biodiversidad y permitirá generar una base de datos que servirá para futuras investigaciones, alineándose con los objetivos de instituciones ambientales y científicas que trabajan en la preservación de los ecosistemas naturales [4].

CAPÍTULO II
FUNDAMENTACIÓN TEÓRICA DE LA INVESTIGACIÓN

2.1 Marco conceptual

2.1.1 *Monitoreo acústico*

El monitoreo acústico se basa en el despliegue de dispositivos de grabación autónomos (ARU) capaces de registrar de forma continua los sonidos del entorno sin intervención humana directa. Estos equipos, alimentados por baterías y programados para activarse en horarios predefinidos, recogen vocalizaciones de aves y otros organismos, incluso en zonas de difícil acceso o durante la noche. Gracias a algoritmos de inteligencia artificial integrados, por ejemplo, redes neuronales convolucionales, los datos se procesan localmente para extraer características acústicas como espectrogramas y coeficientes cepstrales en escala Mel, lo que permite una identificación automática de especies con alta eficiencia y precisión [2]. Este enfoque resulta especialmente valioso para detectar aves crípticas o de baja densidad poblacional, que suelen pasar desapercibidas con métodos visuales tradicionales. Asimismo, el flujo continuo de información facilita el monitoreo a largo plazo de cambios en la comunidad aviar, contribuyendo a evaluar el estado de conservación de ecosistemas y a diseñar estrategias de manejo adaptativo basadas en datos robustos [8].

2.1.2 *Bioacústica*

La bioacústica se define como el estudio de los sonidos producidos por organismos vivos y su interacción con el entorno, combinando principios de ecología, acústica y procesamiento de señales. Mediante grabaciones pasivas y activas, esta disciplina permite capturar repertorios de vocalizaciones de múltiples especies, analizar patrones temporales y espaciales y evaluar indicadores de biodiversidad sin necesidad de observación directa [9]. Los métodos actuales integran algoritmos de aprendizaje profundo para extraer automáticamente características relevantes de los paisajes sonoros, facilitando la clasificación de señales en grandes volúmenes de datos y reduciendo la carga de trabajo manual [10].

2.1.3 *Señal acústica*

Una señal acústica se define como la variación de presión en un medio elástico (aire, agua) que transporta energía sonora, la cual puede modelarse matemáticamente como una función continua de tiempo y amplitud [11]. Para su análisis digital, esta señal se muestrea a una frecuencia adecuada, conservando la información espectral hasta la mitad de la frecuencia

de muestreo según el teorema de Nyquist [12]. Cada muestra representa una medida instantánea de la presión sonora, posibilitando el procesamiento de la señal mediante transformadas como la STFT o el cálculo de características como la energía y el espectro de frecuencias. En bioacústica, estas representaciones facilitan la detección de eventos acústicos, por ejemplo, un canto de ave al diferenciar picos de energía en bandas específicas. Además, las señales acústicas pueden verse afectadas por ruido ambiental y distorsiones, por lo que se aplican filtros digitales y técnicas de supresión de ruido para mejorar la relación señal-ruido antes de la extracción de características.

2.1.4 Espectrogramas

Un espectrograma es una representación visual de la energía de una señal acústica en función del tiempo y la frecuencia, obtenida mediante la aplicación de la Transformada de Fourier de Tiempo Corto (STFT) a segmentos superpuestos de la señal muestreada [13]. Cada “lámina” del espectrograma muestra el contenido espectral en un instante dado, lo que facilita la detección de patrones de frecuencia característicos de las vocalizaciones de aves, tales como armónicos y modulaciones de tono. La elección de parámetros tamaño de ventana, solapamiento y tipo de ventana influye en la resolución temporal y frecuencial, y se ajusta según la duración típica de las llamadas a estudiar [14].

2.1.5 Coeficientes Cepstrales en Escala Mel (MFCC)

Los coeficientes cepstrales en escala Mel (MFCC) son características acústicas extraídas de la señal de audio que modelan la percepción humana de las frecuencias sonoras, distribuyendo las bandas de frecuencia según la escala Mel, más densa en las frecuencias bajas y más dispersa en las altas [15]. Para calcularlos, primero se segmenta la señal en tramas cortas, se aplica la STFT para obtener el espectro, luego se pasa ese espectro por un banco de filtros Mel y finalmente, se toma el logaritmo de la energía antes de aplicar la transformada discreta del coseno para generar los coeficientes finales [16]. En bioacústica, los MFCC capturan información timbral y de resonancia que resulta muy efectiva para diferenciar especies de aves cuyas llamadas presentan variaciones sutiles en tono y forma de onda. Su bajo coste computacional y robustez frente a variaciones de volumen los convierte en la base de muchos sistemas de clasificación automática de vocalizaciones silvestres.

2.1.6 Transformada de Fourier de Tiempo Corto (STFT)

La Transformada de Fourier de Tiempo Corto (STFT) es una técnica de análisis tiempo-frecuencia que segmenta la señal acústica en breves fragmentos mediante una ventana deslizante, a los cuales se les aplica la Transformada Rápida de Fourier (FFT) para obtener un conjunto de coeficientes complejos representativos de la energía espectral en cada intervalo temporal. Este procedimiento produce una matriz de coeficientes $X [m, k]$, donde m indica el índice de la ventana y k la frecuencia bin, permitiendo visualizar la evolución de las componentes frecuenciales a lo largo del tiempo. El ancho de la ventana y el solapamiento determinan la resolución temporal y frecuencial: ventanas cortas ofrecen mejor detalle temporal pero menor precisión espectral y viceversa. En bioacústica, la STFT es esencial para generar espectrogramas que sirven tanto de insumo para algoritmos de clasificación automática como de herramienta de inspección visual de eventos acústicos en ambientes complejos [17]. Estudios recientes han optimizado su implementación en hardware y software, logrando análisis en tiempo real con requisitos computacionales reducidos [18].

2.1.7 Algoritmos de aprendizaje automático

Los algoritmos de aprendizaje automático agrupan técnicas que permiten a los sistemas computacionales mejorar su desempeño en tareas específicas a partir de datos históricos, sin programación explícita para cada escenario. Se distinguen tres grandes categorías: supervisado, no supervisado y por refuerzo. En clasificación de vocalizaciones aviares, los métodos supervisados como las máquinas de vectores de soporte (SVM), árboles de decisión y redes neuronales profundas alcanzan altas tasas de acierto cuando se dispone de muestras etiquetadas. Por su parte, los algoritmos no supervisados (K-means o clustering jerárquico) facilitan la organización de grandes volúmenes de grabaciones al detectar patrones acústicos emergentes sin necesidad de anotaciones manuales [19]. Finalmente, el aprendizaje por refuerzo comienza a explorarse para ajustar dinámicamente parámetros de muestreo y segmentación en campo, maximizando la eficiencia de los registros pasivos [20]. Estas técnicas, combinadas con potentes frameworks de cómputo, constituyen la base de los sistemas modernos de clasificación automática en bioacústica.

2.1.8 Redes Neuronales Convolucionales (CNN)

Las Redes Neuronales Convolucionales (CNN) son modelos de aprendizaje profundo que aplican operaciones de convolución a entradas estructuradas en forma de grillas, como espectrogramas acústicos, para extraer automáticamente patrones jerárquicos de características [21]. Una CNN típica consta de capas de convolución que filtran la información local, capas de agrupamiento (pooling) que reducen dimensionalidad y capas completamente conectadas que realizan la clasificación final. En bioacústica, las CNN han demostrado una notable eficacia al aprender filtros que capturan rasgos temporales y espectrales de las vocalizaciones de aves, resistiendo variaciones de ruido y condiciones de grabación [22]. Por ejemplo, BirdNET emplea una CNN entrenada con más de un millón de espectrogramas para identificar más de 3 000 especies a nivel global, logrando una precisión promedio superior al 80% en validaciones independientes. Además, variantes avanzadas que incorporan mecanismos de atención espacial han alcanzado precisiones de hasta el 92% en ambientes de campo ruidosos, mejorando la robustez frente a interferencias y variabilidad de señal [22].

2.1.8.1 Resolución Temporal y Espectral.

La resolución temporal y espectral se refiere a la capacidad del sistema para discriminar detalles tanto en el tiempo como en la frecuencia. La resolución temporal se ve influenciada por el tamaño de la ventana utilizada en la STFT, mientras que la resolución espectral se determina por la cantidad de bins de frecuencia. En el procesamiento de audio, una mayor resolución temporal permite captar cambios rápidos en la señal, mientras que una alta resolución espectral facilita la distinción de componentes frecuenciales sutiles, como armónicos y modulaciones [23].

2.1.8.2 Tamaño de la Ventana (Window Size) y Solapamiento entre Ventanas (Overlap).

El tamaño de la ventana es un parámetro esencial en la STFT que determina cuán largos serán los segmentos de la señal que se analizarán. Una ventana más pequeña mejora la resolución temporal, pero reduce la precisión espectral, mientras que una ventana más grande ofrece mayor detalle espectral pero menor precisión temporal. El solapamiento entre ventanas (overlap) permite aumentar la cantidad de información utilizada y reducir pérdidas de datos, especialmente cuando se trabaja con señales ruidosas o eventos acústicos de corta duración [24].

2.1.8.3 Eje X (Tiempo) Eje Y (Frecuencia).

Los espectrogramas representan gráficamente cómo la energía de una señal se distribuye a través del tiempo y la frecuencia. En el eje X se ubica el tiempo, mientras que en el eje Y se presenta la frecuencia. Este formato visual es vital para analizar vocalizaciones de aves, pues permite observar patrones temporales, cambios en el tono, la intensidad y los armónicos de las vocalizaciones. La interpretación de estos patrones es clave para la identificación de especies [25].

2.1.8.4 Intensidad (Escala de colores o tonos).

La intensidad en un espectrograma se representa a través de una escala de colores que indica la energía de las frecuencias en cada punto temporal. Los colores más cálidos (rojos y amarillos) indican mayor intensidad, mientras que los colores más fríos (azules y verdes) representan menores intensidades. Esta visualización es útil para distinguir entre sonidos de alta y baja energía, lo que facilita la identificación de eventos acústicos significativos, como los cantos de las aves [26].

2.1.8.5 Bandas de Frecuencia (Frequency Bands).

Las bandas de frecuencia en un espectrograma indican el rango de frecuencias presentes en una señal. En bioacústica, ciertas frecuencias son características de cada especie de ave, lo que permite usar estas bandas para clasificarlas. Las frecuencias más bajas pueden corresponder a sonidos graves, mientras que las más altas están asociadas con armónicos y modulaciones finas de la voz de las aves [27].

2.1.8.6 Picos y Valles (Peaks and Valleys).

Los picos y valles en un espectrograma representan los máximos y mínimos de energía en las frecuencias en un momento dado. Los picos suelen estar relacionados con las vocalizaciones de las aves, mientras que los valles pueden corresponder a pausas o silencios en la grabación. El análisis de estos picos y valles es clave para segmentar y clasificar las vocalizaciones [28].

2.1.8.7 Armónicos (*Harmonics*).

Los armónicos son componentes frecuenciales que son múltiplos enteros de la frecuencia fundamental. En las vocalizaciones de aves, los armónicos son fundamentales para identificar la calidad del sonido y distinguir entre diferentes especies. La modulación de estos armónicos puede ofrecer información sobre el comportamiento y las características acústicas de las especies, lo cual es esencial para un sistema de clasificación automático [29].

2.1.8.8 Modulación de Frecuencia (*FM*) y Modulación de Amplitud (*AM*).

La modulación de frecuencia (FM) implica variaciones en la frecuencia de una señal, mientras que la modulación de amplitud (AM) se refiere a cambios en la intensidad del sonido. Ambas modulaciones son utilizadas por las aves para producir cantos y llamadas, y son analizadas mediante espectrogramas y algoritmos de procesamiento de audio para identificar patrones específicos asociados a cada especie [30].

2.1.8.9 Transitorios (*Transients*).

Los transitorios son eventos acústicos breves, como los golpes o cambios repentinos en el tono. En la bioacústica, los transitorios pueden ser usados para identificar vocalizaciones de aves que ocurren de manera inesperada o en momentos específicos. La detección de estos eventos transitorios es crucial para la segmentación de grabaciones y la identificación de especies [31].

2.1.8.10 Desvanecimiento (*Decay*).

El desvanecimiento es el proceso por el cual la energía de una señal disminuye gradualmente después de su emisión. Este fenómeno es importante en la bioacústica porque puede ayudar a identificar la duración de una vocalización y la forma en que se disipan las frecuencias, lo cual es característico de ciertas vocalizaciones de aves [32].

2.1.8.11 Ruido (*Noise*).

El ruido es una perturbación no deseada en una señal acústica que puede interferir con la calidad de la grabación y dificultar la identificación de especies. En ambientes naturales como el Bosque Protector Murocomba, el ruido ambiental es un desafío significativo [33].

2.1.9 Audio Fingerprinting (Huellas Acústicas)

El Audio Fingerprinting, también llamado huellas acústicas, consiste en extraer un conjunto compacto de características únicas de un fragmento de audio basadas en picos espectrales estables en el tiempo [34]. Durante la extracción, se seleccionan puntos de interés pares de frecuencia y tiempo que, al agruparse, forman una “huella” distintiva para cada sonido. En la fase de identificación, estas huellas se comparan con una base de datos de referencia mediante algoritmos de búsqueda y emparejamiento optimizados, lo que permite reconocer vocalizaciones específicas de aves en milisegundos, incluso en presencia de ruido de fondo o variaciones de ganancia [35]. Esta técnica es especialmente útil en sistemas de monitoreo pasivo, donde las condiciones de grabación cambian constantemente y ha demostrado alta robustez frente a distorsiones ambientales y compresión de audio.

2.1.9.1 Coeficientes Cepstrales Lineales (LPC - Linear Predictive Coding).

El Linear Predictive Coding (LPC) es un método utilizado para modelar la señal acústica mediante una serie de parámetros que describen su espectro. Esta técnica predice la señal de audio en función de sus valores pasados, minimizando el error de predicción. En bioacústica, el LPC es útil para representar la forma de la envolvente de la señal acústica y capturar características relevantes de las vocalizaciones de aves. Su bajo costo computacional y su capacidad para manejar variaciones en la señal lo hacen ideal para la identificación de especies en entornos ruidos [36].

2.1.9.2 Análisis de Formantes (Formants Analysis).

Los formantes son picos de resonancia en el espectro de una señal que están asociados con las características vocales humanas y animales. El análisis de formantes se utiliza para identificar estos picos y estudiar la forma en que se distribuyen las frecuencias en una vocalización. En el caso de las aves, cada especie produce vocalizaciones con formantes distintivos que pueden utilizarse para la clasificación. Este análisis es crucial para diferenciar entre llamadas de aves con patrones de frecuencia similares [37].

2.1.9.3 Análisis de Envolvente (Envelope Analysis).

El análisis de envolvente se refiere al estudio de la variación lenta en la amplitud de una señal, lo que permite obtener una representación más simple de su estructura. En las vocalizaciones de aves, la envolvente revela cómo cambia la intensidad del sonido a lo largo

del tiempo, lo que ayuda a identificar características como el ataque, la duración y el desvanecimiento de los sonidos [38]. Esta información es clave para distinguir entre diferentes tipos de vocalizaciones y comportamientos acústicos.

2.1.9.4 Tasa de Cambio de Frecuencia (Frequency Rate of Change).

La tasa de cambio de frecuencia mide cuán rápido cambia la frecuencia de una señal en un intervalo de tiempo determinado. En el análisis acústico de aves, esta métrica es útil para identificar variaciones en las vocalizaciones que son características de cada especie. Una frecuencia que cambia rápidamente puede indicar un canto o llamada con modulaciones rápidas, mientras que un cambio lento puede ser indicativo de un canto más sostenido o de baja frecuencia [39].

2.1.9.5 Análisis de Timbre (Timbre Analysis).

El timbre es la calidad del sonido que permite distinguirlo de otros sonidos, incluso si tienen la misma frecuencia y amplitud. El análisis de timbre involucra la extracción de características como la textura y el color del sonido, que son esenciales para clasificar las vocalizaciones de aves. Mediante el uso de técnicas como los MFCC (coeficientes cepstrales en escala Mel), es posible capturar las características timbrales de las vocalizaciones y asociarlas con diferentes especies [40].

2.1.9.6 Desviación Espectral (Spectral Deviation).

La desviación espectral mide cuán diferente es el espectro de una señal en relación con un modelo de referencia. En el contexto de las vocalizaciones de aves, la desviación espectral se utiliza para identificar variaciones sutiles en las frecuencias que pueden ser características de una especie específica. Esta métrica es útil para detectar diferencias en los patrones de resonancia y la distribución de energía en las frecuencias, lo que facilita la clasificación precisa de las vocalizaciones [41].

2.1.9.7 Relación de Energía entre Bandas (Energy Ratio between Bands).

La relación de energía entre bandas mide cómo se distribuye la energía a través de diferentes rangos de frecuencia. En las vocalizaciones de aves, esta relación es útil para identificar las características espectrales de las llamadas. Diferentes especies pueden tener patrones de energía específicos en bandas de frecuencia particulares, lo que permite clasificarlas a partir

de sus perfiles de energía. Esta métrica es esencial para discriminar entre sonidos similares y resaltar las características más relevantes de la vocalización [42].

2.1.9.8 Análisis de Correlación Temporal (Temporal Correlation Analysis).

El análisis de correlación temporal estudia cómo las variaciones en la señal se relacionan a lo largo del tiempo. En las vocalizaciones de aves, esto permite identificar patrones temporales repetitivos que corresponden a llamadas o cantos específicos. La correlación temporal también puede ayudar a detectar cambios o transiciones en las vocalizaciones, lo que es útil para clasificar fragmentos de audio que contienen variaciones en las frecuencias a lo largo del tiempo [43].

2.1.9.9 Análisis de Coherencia (Coherence Analysis).

El análisis de coherencia se utiliza para medir la relación entre dos señales de audio en términos de su similitud temporal y frecuencial. En el caso de las vocalizaciones de aves, este análisis permite evaluar cómo los diferentes componentes de una señal (como la frecuencia fundamental y los armónicos) están relacionados entre sí. Una mayor coherencia puede indicar una vocalización más uniforme y estructurada, característica de ciertas especies [44].

2.1.9.10 Análisis de Frecuencia Fundamental (Fundamental Frequency Analysis).

El análisis de la frecuencia fundamental se centra en identificar la frecuencia más baja de una señal, que generalmente corresponde al tono base de la vocalización. En las aves, la frecuencia fundamental es clave para distinguir entre diferentes tipos de llamadas y cantos. Además, las aves suelen modificar esta frecuencia para comunicarse o para marcar su territorio [45]. Esta técnica es fundamental para el análisis bioacústica, ya que las variaciones en la frecuencia fundamental permiten identificar especies, edad, género y estado emocional de las aves.

2.1.10 Base de datos acústica

Una base de datos acústica es un repositorio sistematizado de grabaciones sonoras etiquetadas con metadatos esenciales fecha, hora, ubicación geográfica y taxonomía de la especie que permite realizar búsquedas avanzadas y estudios comparativos de vocalizaciones en contextos ecológicos [46]. Estas plataformas suelen ofrecer APIs RESTful para integrar

directamente los registros en flujos de trabajo de aprendizaje automático, facilitando el entrenamiento y la validación de modelos con colecciones de gran tamaño. Ejemplos prominentes, como Xeno-Canto y la Macaulay Library, han superado los dos millones de registros de aves desde 2020, promoviendo la ciencia participativa y el acceso abierto a datos de bioacústica. Para optimizar el rendimiento, emplean índices basados en huellas acústicas y esquemas de almacenamiento distribuidos que reducen los tiempos de consulta a milisegundos, imprescindible para sistemas de monitoreo en tiempo real. Además, el análisis longitudinal de estas bases permite identificar cambios fenológicos y patrones de respuesta de las poblaciones al cambio climático, consolidando su papel como herramienta clave en la investigación y conservación modernas [47].

2.1.11 Biodiversidad

La biodiversidad engloba la variedad de genes, especies y ecosistemas que interactúan en un determinado espacio, constituyendo la base de los servicios ecosistémicos indispensables para la vida humana y el equilibrio planetario [48]. Este concepto abarca tanto la diversidad intraespecífica, como la diversidad de hábitats y procesos ecológicos que sostienen funciones críticas como la polinización, la regulación climática y la purificación del agua. La pérdida acelerada de biodiversidad, impulsada por factores antropogénicos como la fragmentación de hábitats y el cambio climático, amenaza la resiliencia de los ecosistemas y pone en riesgo la provisión de recursos naturales. En el contexto de la bioacústica, evaluar la diversidad acústica permite inferir cambios en la composición de comunidades biológicas, proporcionando un indicador temprano de alteraciones en la biodiversidad que complementa los métodos tradicionales de monitoreo [49]. La integración de métricas acústicas en estudios de biodiversidad promueve enfoques multidisciplinarios y datos más continuos, esenciales para diseñar estrategias de conservación efectivas y adaptativas en un mundo cambiante.

2.1.12 Frecuencia de las Vocalizaciones de las Aves

La frecuencia de las vocalizaciones de las aves es la medida de la altura o tono de sus sonidos, expresada en hercios (Hz). Se trata de una característica acústica fundamental que varía enormemente entre las especies y desempeña un papel crucial en su comunicación. Cada especie de ave emite vocalizaciones dentro de un rango específico de frecuencias, lo que les permite comunicarse eficazmente con otras aves y adaptarse a su entorno. Las vocalizaciones se pueden dividir en dos tipos principales: cantos y llamados [50]. Los cantos, utilizados

generalmente para fines de cortejo o defensa territorial, tienden a tener frecuencias más altas, generalmente entre 1 kHz y 8 kHz. En cambio, los llamados, empleados para la comunicación dentro del grupo o para alertar sobre peligros, presentan frecuencias más bajas, que oscilan entre 500 Hz y 3 kHz. La frecuencia de la vocalización varía según el tamaño de la especie, el tipo de hábitat y el propósito de la vocalización [51]. Las aves más grandes, como las águilas o buitres, suelen emitir sonidos más graves, mientras que las aves más pequeñas, como los canarios y gorriones, producen frecuencias más altas.

2.1.13 Filtros paso bajo

Los filtros paso bajo son una herramienta fundamental en el preprocesamiento de señales acústicas, especialmente en entornos ruidosos como los encontrados en los ecosistemas naturales. Estos filtros permiten reducir las frecuencias altas que no aportan información útil sobre las vocalizaciones de las aves, eliminando sonidos no deseados, como los ruidos de fondo causados por el viento o los insectos. La aplicación de un filtro pasa bajo a una grabación acústica ayuda a aislar las vocalizaciones de las aves, que generalmente se encuentran en rango de frecuencias bajas o medias, mejorando significativamente la relación señal-ruido [52]. Este proceso es crucial cuando se trabaja en ambientes naturales, ya que la grabación de sonido puede verse afectada por interferencias, lo que puede comprometer la precisión del análisis posterior. Los filtros pasa bajo ayudan a limpiar las grabaciones, dejando solo los fragmentos de audio que contienen la información relevante para el estudio. En tu investigación, estos filtros, junto con otras técnicas de segmentación de audio, permiten extraer solo los eventos acústicos significativos, mejorando la precisión y eficiencia del análisis posterior mediante algoritmos de aprendizaje automático.

2.1.14 Sensores Acústicos

Los sensores acústicos son dispositivos diseñados para capturar y convertir las ondas sonoras en señales eléctricas que pueden ser procesadas y analizadas. Estos sensores son esenciales en aplicaciones como el monitoreo ambiental, la bioacústica y la ingeniería de audio, ya que permiten la recolección continua de datos acústicos sin intervención humana directa. Existen diversos tipos de sensores acústicos, como micrófonos, sensores piezoeléctricos, sensores ultrasónicos y arrays de micrófonos, cada uno adaptado a necesidades específicas de sensibilidad, dirección y alcance. Estos dispositivos juegan un papel clave en la

identificación de especies, el análisis de su comportamiento y la conservación de ecosistemas, al ofrecer una manera no invasiva de estudiar la fauna en su hábitat natural [53].

Los sensores acústicos como el MAX4466 es un micrófono electret altamente sensible, que captura las ondas sonoras y las convierte en señales eléctricas, lo que lo hace ideal para proyectos de bajo costo, capaces de captar sonidos ambientales [54]. Otros módulos como el KY-038 también utilizan micrófonos de alta sensibilidad, adecuados para detectar sonidos en entornos naturales, como el ruido ambiental o las vocalizaciones de animales [55]. Los sensores MEMS (Microelectromechanical Systems) son más pequeños y robustos, lo que los hace ideales para aplicaciones donde el tamaño y la durabilidad son factores clave, permitiendo captar sonidos con alta precisión y bajo consumo energético [56].

En entornos donde se necesita alta fidelidad de sonido, los módulos de micrófono condensador son perfectos, ya que ofrecen una mayor resolución temporal y frecuencial, permitiendo capturar detalles acústicos de vocalizaciones complejas de especies. Además, los módulos de captación ultrasónica, como el HC-SR04, están diseñados para captar frecuencias más allá del rango audible para los humanos, siendo útiles en el monitoreo de especies que emiten sonidos ultrasónicos [57]. Estos sensores permiten obtener datos precisos en una variedad de condiciones, facilitando la identificación de especies y el análisis de la biodiversidad en distintos ecosistemas.

2.1.15 Data Augmentation (Aumento de Datos)

La data augmentation se refiere a técnicas que incrementan la cantidad de datos mediante la creación de versiones modificadas de datos existentes. Es especialmente común en el aprendizaje profundo, donde las variantes de imágenes, sonidos o textos pueden expandir conjuntos de datos, mejorando el rendimiento y precisión de modelos al reducir el sobreajuste. La data augmentation mejora la generalización de los modelos de aprendizaje automático al exponerlos a una mayor variedad de datos durante el entrenamiento. Al aplicar transformaciones controladas a los datos de entrenamiento, los modelos aprenden a ser más robustos y a adaptarse a diferentes condiciones del mundo real. Esto reduce el riesgo de sobreajuste al enfocarse en patrones esenciales en lugar de detalles específicos de los datos de entrenamiento. La data augmentation fomenta la capacidad del modelo para generalizar a nuevas situaciones, lo que resulta en un rendimiento más sólido en datos de prueba no vistos y una mayor utilidad en aplicaciones del mundo real [58].

2.1.16 Validación Cruzada (Cross-Validation)

La validación cruzada (o cross-validation) es una técnica estadística y de aprendizaje automático (Machine Learning) para evaluar el rendimiento de un modelo, dividiendo repetidamente el conjunto de datos en subconjuntos para entrenar y probar el modelo en diferentes particiones. Esto ayuda a estimar qué tan bien generalizará el modelo a datos nuevos y desconocidos, permitiendo una evaluación más confiable y una mejor selección del modelo adecuado para tareas predictivas [59].

2.1.17 Dataset de Aves en Ecuador

Tabla 1. Taxonomía de aves en Ecuador.

Familia	Especies	Cantidad de especies
Accipitridae	Hawks, Eagles, and Kites	(46)
Alcedinidae	Kingfishers	(6)
Anatidae	Ducks, Geese, and Waterfowl	(21)
Anhimidae	Screamers	(1)
Anhingidae	Anhingas	(1)
Apodidae	Swifts	(14)
Aramidae	Limpkin	(1)
Ardeidae	Hérons, Egrets, and Bitterns	(21)
Bombycillidae	Waxwings	(1)
Bucconidae	Puffbirds	(21)
Burhinidae	Thick-knees	(1)
Capitonidae	New World Barbets	(6)
Caprimulgidae	Nightjars and Allies	(17)
Cardinalidae	Cardinals and Allies	(20)
Cathartidae	New World Vultures	(6)
Charadriidae	Plovers and Lapwings	(12)
Ciconiidae	Storks	(2)

Familia	Especies	Cantidad de especies
Cinclidae	Dippers	(1)
Columbidae	Pigeons and Doves	(29)
Conopophagidae	Gnateaters	(4)
Corvidae	Crows, Jays, and Magpies	(6)
Cotingidae	Cotingas	(27)
Cracidae	Guans, Chachalacas, and Curassows	(13)
Cuculidae	Cuckoos	(16)
Diomedeidae	Albatrosses	(4)
Donacobiidae	Donacobius	(1)
Estrildidae	Waxbills and Allies	(1)
Eurypygidae	Sunbittern	(1)
Falconidae	Falcons and Caracaras	(19)
Formicariidae	Antthrushes	(7)
Fregatidae	Frigatebirds	(2)
Fringillidae	Finches, Euphonias, and Allies	(19)
Furnariidae	Ovenbirds and Woodcreepers	(105)
Galbulidae	Jacamars	(10)
Grallariidae	Antpittas	(23)
Haematopodidae	Oystercatchers	(2)

Familia	Especies	Cantidad de especies
Heliornithidae	Finfoots	(1)
Hirundinidae	Swallows	(18)
Hydrobatidae	Northern Storm-Petrels	(7)
Icteridae	Troupials and Allies	(33)
Jacanidae	Jacanas	(1)
Laridae	Gulls, Terns, and Skimmers	(36)
Melanopareiidae	Crescentchesters	(2)
Mimidae	Mockingbirds and Thrashers	(6)
Mitrospingidae	Mitrospingid Tanagers	(1)
Momotidae	Motmots	(5)
Motacillidae	Wagtails and Pipits	(2)
Nyctibiidae	Potoos	(5)
Oceanitidae	Southern Storm-Petrels	(4)
Odontophoridae	New World Quail	(6)
Onychorhynchidae	Royal Flycatchers and Allies	(6)
Opisthocomidae	Hoatzin	(1)
Oxyruncidae	Sharpbill	(1)
Pandionidae	Osprey	(1)
Parulidae	New World Warblers	(31)
Passerellidae	New World Sparrows	(26)

Familia	Especies	Cantidad de especies
Passeridae	Old World Sparrows	(1)
Pelecanidae	Pelicans	(2)
Phaethontidae	Tropicbirds	(2)
Phalacrocoracidae	Cormorants and Shags	(4)
Phasianidae	Pheasants, Grouse, and Allies	(1)
Phoenicopteridae	Flamingos	(2)
Picidae	Woodpeckers	(34)
Pipridae	Manakins	(17)
Podicipedidae	Grebes	(4)
Poliptilidae	Gnatcatchers	(6)
Procellariidae	Shearwaters and Petrels	(16)
Psittacidae	New World and African Parrots	(44)
Psophiidae	Trumpeters	(1)
Rallidae	Rails, Gallinules, and Coots	(28)
Ramphastidae	Toucans	(17)
Recurvirostridae	Stilts and Avocets	(2)
Rhinocryptidae	Tapaculos	(13)
Sapayoidae	Sapayoa	(1)
Scolopacidae	Sandpipers and Allies	(38)
Semnornithidae	Toucan-Barbets	(1)

Familia	Especies	Cantidad de especies
Semnornithidae	Toucan-Barbets	(1)
Spheniscidae	Penguins	(2)
Steatornithidae	Oilbird	(1)
Stercorariidae	Skuas and Jaegers	(5)
Strigidae	Owls	(28)
Sulidae	Boobies and Gannets	(6)
Thamnophilidae	Typical Antbirds	(94)
Thinocoridae	Seedsnipes	(2)
Thraupidae	Tanagers and Allies	(177)
Threskiornithidae	Ibises and Spoonbills	(8)
Tinamidae	Tinamous	(17)
Tityridae	Tityras and Allies	(22)
Trochilidae	Hummingbirds	(130)
Troglodytidae	Wrens	(25)
Trogonidae	Trogons	(16)
Turdidae	Thrushes and Allies	(22)
Tyrannidae	Tyrant Flycatchers	(203)
Tytonidae	Barn-Owls	(1)
Vireonidae	Vireos, Shrike-Babblers, and Erpornis	(18)

Fuente: Cornell Lab of Ornithology [60].

2.2 Marco Referencial

“Monitorización acústica en entornos terrestres mediante conjuntos de micrófonos: aplicaciones, consideraciones tecnológicas y perspectivas” [3].

Este estudio explora la efectividad del monitoreo acústico utilizando micrófonos autónomos para recolectar datos acústicos en áreas protegidas. La investigación destacó cómo este método permite realizar un monitoreo constante sin intervención humana directa, algo esencial dentro del primer objetivo, captar señales de aves en el Bosque Protector Murocomba.

“Ciencia ciudadana y monitorización acústica pasiva: creación de conjuntos de datos sobre biodiversidad a gran escala” [61].

Este artículo analizó el uso de tecnologías de monitoreo acústico pasivo en la recopilación de datos de biodiversidad. A través de plataformas de ciencia ciudadana, se demuestra cómo la recolección de datos acústicos puede ser eficiente incluso en áreas de difícil acceso, similar a lo que se propuso en esta investigación en el Bosque Protector Murocomba.

“Bioacústica computacional con aprendizaje profundo: revisión y hoja de ruta” [9].

En este trabajo se revisaron las técnicas de aprendizaje profundo aplicadas al análisis de datos acústicos. En particular, se abordó el uso de filtrado y segmentación de grabaciones acústicas para mejorar la calidad de los datos y facilitar la identificación de eventos acústicos relevantes, que es parte del segundo objetivo.

“Detección y clasificación automatizadas de aves mediante aprendizaje profundo: rendimiento y aplicaciones” [20].

Este estudio presentó el uso de redes neuronales para la detección y clasificación automática de vocalizaciones aviares. La investigación subrayó la importancia de técnicas de segmentación para extraer características relevantes de las grabaciones de aves, lo que se alinea directamente con el objetivo de muestrear y filtrar las grabaciones obtenidas.

“Sobre la historia de los cantos de las aves o los cantos de las aves como historia” [8].

Este artículo abordó el uso de la bioacústica para el análisis de vocalizaciones de aves. Destacó cómo las técnicas de procesamiento de señales, como los MFCC, pueden ser efectivas en la clasificación de vocalizaciones. Este estudio es relevante para el tercer objetivo, ya que el uso de estas herramientas facilitó el análisis de las especies aviares en el bosque.

“Detección y clasificación automatizadas de aves mediante aprendizaje profundo: rendimiento y aplicaciones” [20].

En este estudio se implementó Redes Neuronales Convolucionales (CNN) para la clasificación automática de vocalizaciones de aves, similar a lo que se hizo en investigación. Este artículo muestra cómo las CNN han logrado una alta precisión en ambientes ruidosos, lo cual fue crucial para el objetivo de implementar un sistema de clasificación robusto en el Bosque Protector Murocomba.

2.3 Marco legal

2.3.1 Legislación Ambiental En Ecuador

2.3.1.1 Constitución De La Republica Del Ecuador (2008).

La Constitución de la República del Ecuador reconoce, en el Artículo 71:

“La naturaleza, o Pacha Mama, donde se reproduce y realiza la vida, tiene derecho a que se respete integralmente su existencia y el mantenimiento y regeneración de sus ciclos vitales, estructura, funciones y procesos evolutivos”.

Con esta disposición, la Carta Magna otorga a los ecosistemas un estatus jurídico distinto al de meros recursos, convirtiéndolos en sujetos de derechos que deben ser protegidos por el Estado y la sociedad. Este enfoque implica que toda actividad pública o privada ya sea construcción de infraestructura, desarrollo agrícola o proyectos de investigación científica debe diseñarse y ejecutarse de manera que no comprometa la salud ni los procesos naturales de los ecosistemas y que, en caso de daño, se establezcan mecanismos de restauración efectivos.

Asimismo, el Artículo 73 establece que:

“El Estado aplicará medidas de precaución y restricción para las actividades que puedan conducir a la extinción de especies, la destrucción de ecosistemas o la alteración permanente de los ciclos naturales.”

Prohibiendo también la introducción de organismos y materiales exóticos que amenacen la estabilidad ecológica. Este principio de precaución obliga a anticipar, evaluar y mitigar cualquier riesgo potencial antes de emprender acciones que puedan resultar perjudiciales y

refuerza la responsabilidad estatal de garantizar un ambiente sano. De este modo, el marco constitucional de Ecuador no solo promueve la conservación y el uso sostenible de la biodiversidad, sino que exige una gestión preventiva y reparadora de los impactos ambientales, situando al país a la vanguardia del derecho ecológico global.

2.3.1.2 Ley De Gestión Ambiental (1999).

El Artículo 1 de la Ley de Gestión Ambiental (LOGA) establece que:

“Es de interés público la conservación del medio ambiente, el uso sostenible de los recursos naturales y la preservación del equilibrio ecológico”.

El Artículo 6 introduce los principios de prevención, precaución y:

“Quien contamina paga”

aplicables a toda actividad con potencial impacto ambiental. El Artículo 14 exige:

“Autorización previa del Ministerio del Ambiente, Agua y Transición Ecológica”

para la investigación científica en áreas protegidas, condicionando permisos al plan de trabajo y medidas de mitigación.

2.3.1.3 Código Orgánico Del Ambiente (Coa, 2017).

El Código Orgánico del Ambiente (COA, 2017) establece un marco normativo específico para la gestión de las áreas protegidas en Ecuador. En su Artículo 143, dispone que:

“Las zonas que forman parte del Sistema Nacional de Áreas Protegidas deben administrarse bajo principios que garanticen la sostenibilidad y conservación de la biodiversidad”.

Esto implica que toda actividad desarrollada en estos espacios ya sea científica, turística o de manejo, debe diseñarse y ejecutarse de manera que no comprometa la diversidad biológica ni los procesos ecológicos que sustentan al ecosistema. Asimismo, el COA introduce directrices claras sobre la zonificación interna, los usos permitidos y las restricciones para cada tipo de área, garantizando que la conservación sea la prioridad frente a usos extractivos o de infraestructura.

Por su parte, el Artículo 153 refuerza esta protección al exigir que:

“Cualquier intervención dentro de estas áreas, incluyendo la instalación de cámaras trampa o sensores acústicos, debe contar con los permisos correspondientes del Ministerio del Ambiente, Agua y Transición Ecológica y ajustarse a los planes de manejo aprobados”.


De no cumplirse estas disposiciones, el Artículo 456 faculta a las autoridades a imponer sanciones administrativas y multas a quienes operen sin autorización o incumplan las condiciones establecidas.

CAPÍTULO III
METODOLOGÍA DE LA INVESTIGACIÓN

3.1 Localización

El estudio se llevó a cabo en el Bosque Protector Murocomba, sector El Vergel (Latitud: -0.739166, Longitud: -79.302209), provincia de Los Ríos, Ecuador. Esta área presenta alta biodiversidad aviar y acceso limitado, lo que la hizo ideal para evaluar métodos de monitoreo acústico autónomo.

Figura 1. Ubicación del bosque protector Murocomba.



Fuente: Cuencas hidrográficas globales [62].

3.2 Tipos de investigación

3.2.1 Investigación bibliográfica

Se realizó un análisis sistemático de la literatura científica y técnica relacionada con el procesamiento de audio y la bioacústica aplicada a la identificación de aves. Se consultaron artículos indexados (2020–2024) sobre extracción de MFCC, generación y análisis de espectrogramas, y aplicaciones de redes neuronales convolucionales y huellas acústicas en entornos naturales. Además, se revisaron documentos normativos y reportes institucionales del MAATE y del SNAP para asegurar el cumplimiento del marco legal ecuatoriano. Este enfoque bibliográfico proporcionó los cimientos teóricos y metodológicos que sustentan el diseño del sistema de monitoreo acústico en el Bosque Protector Murocomba, permitiendo seleccionar las herramientas y protocolos más adecuados para el estudio.

3.2.2 *Investigación exploratoria*

Se condujo una fase exploratoria en campo para evaluar las condiciones ambientales, en el Bosque Protector Murocomba. Durante esta etapa, se recopilaron muestras de audio, el análisis preliminar permitió ajustar niveles de ganancia, horarios de muestreo y parámetros de filtrado de ruido, garantizando la recolección de datos de alta calidad. Asimismo, esta investigación exploratoria facilitó la detección de obstáculos logísticos (acceso, alimentación eléctrica) y la elaboración de un protocolo definitivo de trabajo para las fases posteriores del proyecto.

3.3 Métodos de investigación

3.3.1 *Método cualitativo*

El método cualitativo se aplicó para analizar las características acústicas de las vocalizaciones de las aves. Se utilizó técnicas de observación directa y registro acústico, complementadas con entrevistas a expertos locales, para obtener una comprensión más profunda sobre las especies presentes, sus comportamientos y las variaciones estacionales de las vocalizaciones. Esta información será clave para la interpretación de los datos acústicos y para identificar patrones acústicos que puedan ser útiles en la clasificación de especies.

3.3.2 *Método cuantitativo*

Se organizarán las grabaciones acústicas en franjas horarias (amanecer, mañana, tarde y crepúsculo) para contabilizar cuántas vocalizaciones registra cada especie en cada intervalo. Con esos datos se calcularán indicadores como el número total de especies detectadas por horario, la media de detecciones y la precisión de los algoritmos de clasificación, lo que facilitará una evaluación numérica de la eficacia del sistema de monitoreo.

3.3.3 *Método analítico*

Se elaboraron fichas de campo para describir cada especie (nombre común y científico), el periodo de mayor actividad vocal y las características de sus llamadas. Complementariamente, se recabaron aportes locales para entender variaciones estacionales y ambientales, enriqueciendo la interpretación de los patrones acústicos y orientando mejoras en los protocolos de muestreo.

3.4 Diseño de la investigación

El diseño de la investigación fue cuasiexperimental, ya que se llevó a cabo una intervención controlada en el Bosque Protector Murocomba sin la manipulación de variables naturales. Este diseño permitió estudiar el impacto del monitoreo acústico utilizando un sistema automatizado basado en algoritmos de procesamiento de audio y aprendizaje automático. Se realizaron pruebas piloto para calibrar los equipos y ajustar los protocolos de muestreo, se recopilaban datos en condiciones de campo durante varios ciclos, sin intervenir directamente en el ecosistema.

Además, se evaluó el desempeño de los algoritmos de clasificación de vocalizaciones aviares mediante una comparación de resultados con bases de datos acústicas existentes y con observaciones de campo. Este enfoque cuasiexperimental proporciona información sobre la efectividad de los modelos desarrollados y permitió realizar ajustes para mejorar la precisión del sistema de monitoreo.

3.5 Fuentes de recopilación de información

Grabaciones de campo (datos primarios):

- Captura de audio en puntos estratégicos del Bosque Protector Murocomba, registrando vocalizaciones de aves y otros sonidos ambientales durante ciclos de 24h.
- Metadatos asociados (fecha, hora, coordenadas, condiciones climáticas) para cada archivo de audio.

Bases de datos acústicas (datos secundarios):

- Xeno-Canto: Referencia de grabaciones de aves regionales usadas para validar y entrenar modelos de identificación.
- Macaulay Library (Cornell Lab): Colección de espectrogramas y metadata complementaria para enriquecer el entrenamiento y la comparación de resultados.

Literatura científica especializada:

- Artículos indexados (2020–2024) sobre bioacústica, MFCC, STFT, CNN y huellas acústicas, para fundamentar la selección de técnicas y algoritmos.
- Estudios de caso en áreas protegidas de la región neotropical para definir protocolos de muestreo y criterios de calidad.

Normativa y guías oficiales:

- Constitución de la República del Ecuador (Arts. 71 y 73) y leyes ambientales (LOGA, COA) para asegurar el cumplimiento legal en la instalación de equipos y manejo de datos.
- Directrices internacionales (UICN, ISO/IEC 17025) para garantizar buenas prácticas de monitoreo y validez de los datos.

3.6 Fases de la investigación

3.6.1 Fase 1: Prueba piloto y ajuste de protocolos

En esta primera fase se seleccionó los puntos representativos del sendero del Bosque Protector Murocomba atendiendo a diversidad de hábitats (ribera, sotobosque, claros), durante la cual se evaluó parámetros críticos (frecuencia de muestreo, niveles de ganancia, horarios óptimos de registro) y se realizaron ajustes en protocolos para garantizar la calidad y continuidad de los datos sin perturbar las zonas sensibles.

3.6.2 Fase 2: Recolección de datos

La recolección de los datos acústicos se efectuó utilizando protocolos validados y se ejecutó en tres sesiones representativas dentro del Bosque Protector Murocomba: las zonas alta, media y baja. El objetivo fue capturar la variabilidad temporal completa de las vocalizaciones de la fauna local, por lo cual cada sesión se estableció con una duración total de 24 horas. El prototipo de captura de audio se configuró para realizar registros automáticos en intervalos programados de 30 minutos, asegurando que cada archivo de audio se guardara en el formato de alta fidelidad .wav con codificación 16 PCM. Este proceso garantizó la obtención de un conjunto de datos extenso y de calidad uniforme para el análisis bioacústico.

3.6.3 Fase 3: Preprocesamiento de audio

El proceso metodológico inició con la digitalización de la señal, lo que resultó en 1385400000 muestras. Este vasto conjunto fue inmediatamente sometido a segmentación temporal en unidades base de 10 segundos, lo que arrojó 8632 segmentos útiles para el análisis. Posteriormente, para una evaluación cualitativa, se procedió a unir 10 de estos segmentos (formando sub-segmentos de 100 segundos) para ser sometidos a un filtrado Pasa-Bajo y a la visualización detallada del espectrograma, lo que permitió validar la calidad de la señal y la existencia de patrones acústicos relevantes.

3.6.4 Fase 4: Desarrollo de modelos

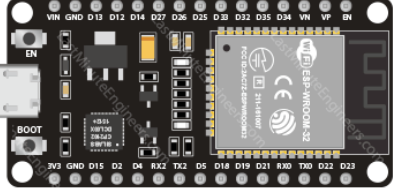
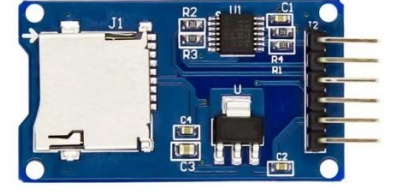


Se extrajeron características acústicas avanzadas (MFCC, índices de frecuencia) y se generaron espectrogramas para entrenar modelos de aprendizaje profundo (CNN) y sistemas de huellas acústicas. El conjunto de datos resultante se dividió en entrenamiento, validación y prueba, aplicando técnicas de data augmentation y validación cruzada para optimizar la robustez y generalización de los algoritmos.

3.6.5 Fase 5: Validación y análisis de resultados

Los resultados de identificación se compararon con grabaciones de referencia provenientes de bases externas y con observaciones de campo realizadas simultáneamente. Se evaluaron métricas de desempeño, como precisión, sensibilidad y tasa de falsas alarmas, y se ajustaron los parámetros de los modelos para maximizar la exactitud. Además, se elaboraron reportes detallados que integraron los resultados cuantitativos y cualitativos, con recomendaciones para optimizar los procesos de identificación. A lo largo de este análisis, se trabajó en la creación del dataset del Bosque Protector Murocomba, recopilando y etiquetando las grabaciones de audio junto con los metadatos correspondientes, para establecer una base de datos estructurada y útil para futuras investigaciones y análisis.

3.7 Materiales


Tabla 2. Materiales utilizados.

Nombre	Imagen	Características
Esp wroom 32d		<p>Cerebro del sistema. Microcontrolador de doble núcleo con Wi-Fi/Bluetooth que digitaliza el audio y controla el almacenamiento.</p>
Modulo micro sd		<p>Memoria masiva. Permite al ESP32 guardar archivos de audio (WAV) de gran tamaño usando el bus de alta velocidad SPI.</p>
Microfono max4466		<p>Captura y amplifica el sonido. Convierte las ondas sonoras en una señal analógica amplificada, lista para ser leída por el ESP32.</p>
Baterias 4xAA		<p>Fuente de poder portátil. Suministra 6.0V al ESP32 para su operación móvil, que luego regula a 5V y 3.3V.</p>

Fuente: Investigador

Elaborado: Justin Macías

Figura 2. Circuito de sistema embebido con Arduino, modulo SD, micrófono Max 4466 y baterías 4xAA.



Fuente: CirkIt Designer.

Figura 3. Implementación del prototipo del sistema embebido.



Fuente: Investigador

Elaborado: Justin Macías

Tabla 3. Características de los materiales utilizados.

Módulo	Pin del Módulo	Pin del ESP32 (GPIO)	Función de Comunicación	Voltaje de Alimentación	Función General en el Sistema
Micrófono MAX4466	OUT	GPIO 34 (ADC1_CH6)	Entrada Analógica	3.3V (Desde el ESP32)	Captura de audio y entrega la señal analógica amplificada.
	VCC	3.3V	Alimentación	3.3V	Suministro de energía para el amplificador y micrófono.
	GND	GND	Referencia de Tierra	0V	Referencia de potencial.
Módulo MicroSD	MISO	GPIO 19	SPI (Master In, Slave Out)	5V (Entrada del Módulo)	Entrada de datos de la tarjeta SD al ESP32 (Lectura).
	MOSI	GPIO 23	SPI (Master Out, Slave In)	5V (Entrada del Módulo)	Salida de datos del ESP32 a la tarjeta SD (Escritura).
	SCK	GPIO 18	SPI (Reloj Serial)	5V (Entrada del Módulo)	Sincronización de la transferencia de datos.
	CS	GPIO 5	SPI (Chip Select)	5V (Entrada del Módulo)	Pin de control para activar el módulo MicroSD.
	VCC	5V	Alimentación	5V (Desde el ESP32)	Suministro de energía (El módulo regula internamente a 3.3V para la tarjeta SD).

	GND	GND	Referencia de Tierra	0V	Referencia de potencial.
Fuente de Poder	V+ (Positivo de las Baterías)	Vin o 5V	Alimentación Principal	6.0V	Entrada de energía para la placa ESP32 (que regula a 5V y 3.3V).
	V- (Negativo de las Baterías)	GND	Referencia de Tierra	0V	Referencia de potencial del circuito.

Fuente: Investigador

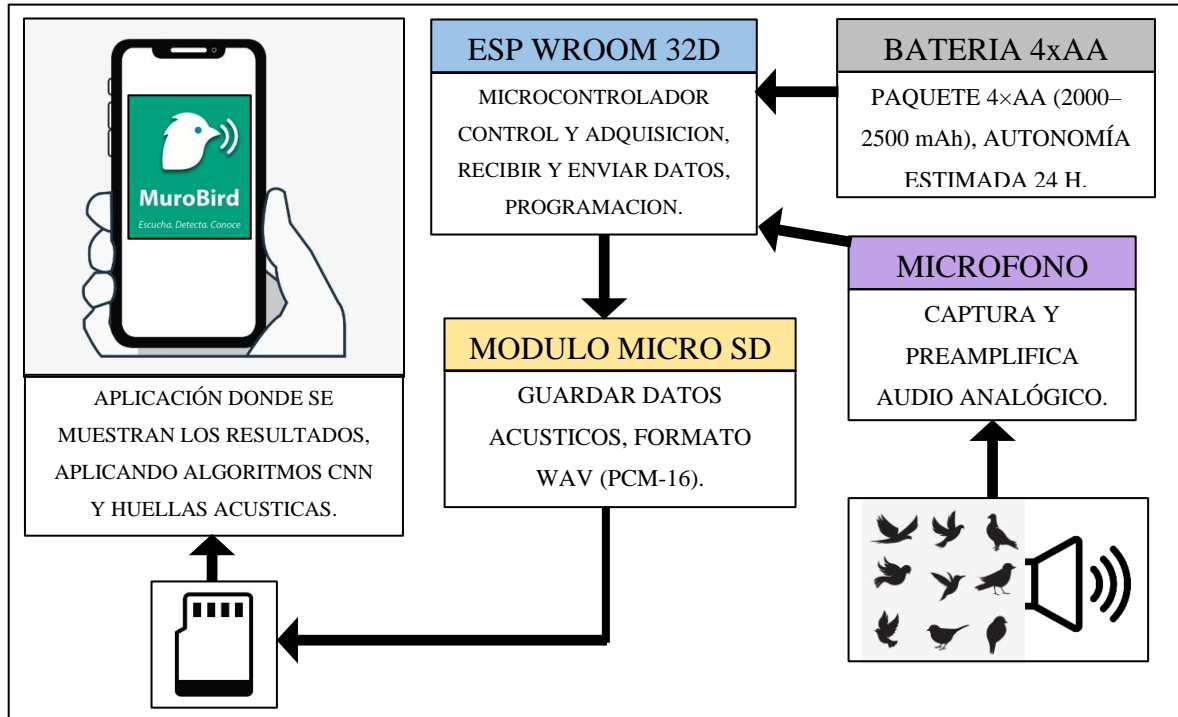
Elaborado: Justin Macías

El sistema de monitoreo acústico del Bosque Protector Murocomba está compuesto por varios componentes clave que trabajan de manera integrada para captar, almacenar y procesar las vocalizaciones de las aves.

El sistema se alimenta de 4 baterías AA de 1.5V conectadas en serie, lo que proporciona un voltaje total nominal de 6.0V. La placa de desarrollo ESP32-WROOM-32D regula esta entrada a los 5V y 3.3V requeridos para su operación y la de los periféricos. La capacidad total de la fuente es de aproximadamente 2,500mAh (capacidad de una sola celda AA), lo que permite que el sistema funcione durante aproximadamente 24 horas en modo de grabación activa, o por muchos días en modo de Bajo Consumo (*Deep Sleep*).

El ESP32-WROOM-32D es el núcleo de alto rendimiento del sistema, encargado de gestionar el procesamiento de señales. El micrófono MAX4466 captura las vocalizaciones de las aves y las amplifica con una ganancia ajustable. La señal analógica amplificada se digitaliza a través del Conversor Analógico-Digital (ADC) del ESP32 o, preferiblemente, mediante el periférico I2S para obtener grabaciones de mayor calidad. Los datos digitalizados se almacenan en un módulo MicroSD mediante la interfaz de comunicación SPI (usando los pines GPIO 5, 18, 19, 23), lo que permite guardar archivos WAV de gran tamaño para su análisis posterior.

Figura 4. Arquitectura del sistema de adquisición acústica



Fuente: Investigador

Elaborado: Justin Macías

El sistema utiliza algoritmos de aprendizaje automático, específicamente redes neuronales convolucionales (CNN), para clasificar las vocalizaciones de las aves. A partir de las grabaciones, se generan espectrogramas que se procesan para extraer coeficientes cepstrales en escala Mel (MFCC), facilitando la identificación de las especies presentes en el bosque. Este enfoque asegura que el sistema funcione de manera autónoma y eficiente, incluso en áreas remotas.

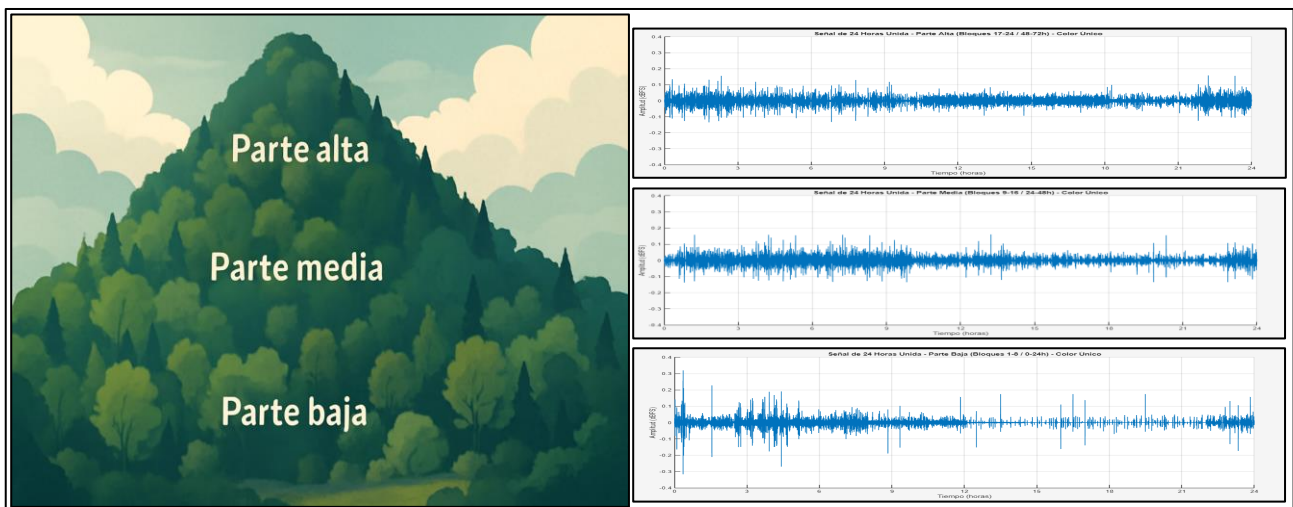
CAPÍTULO IV
RESULTADOS Y DISCUSIÓN

4.1 Captación de señales de audio

Durante la primera fase del proyecto, se realizaron tres sesiones de grabación de audio en diferentes zonas del sendero del Bosque Protector Murocomba: parte baja, zona intermedia y la cabaña en la parte alta. Las grabaciones se llevaron a cabo con micrófonos MAX4466, debido a su bajo costo y alta sensibilidad, lo que permitió capturar las vocalizaciones de aves y sonidos naturales del entorno. Cada sesión tuvo una duración de 24 horas fragmentadas en 30 minutos con un total de 48 audios en cada parte del bosque.

Los micrófonos fueron colocados estratégicamente en las zonas seleccionadas, y se ajustaron los niveles de ganancia para evitar el ruido ambiental, pero manteniendo la sensibilidad adecuada. La captura de audio se centró en frecuencias entre 2 kHz y 8 kHz, que es el rango común para las vocalizaciones de muchas especies de aves. Los metadatos de cada sesión (fecha, hora y ubicación) se registraron para facilitar el análisis posterior y la clasificación de las especies.

Figura 5. Audios recopilados con sus respectivas partes.




Fuente: Investigador

Elaborado: Justin Macías.

- **Parte alta:** 2.184m s.n.m. 0°38'49"S 79°08'30"W
- **Parte media:** 2.184m s.n.m. 0°38'49"S 79°08'42"W
- **Parte baja:** 2.184m s.n.m. 0°38'43"S 79°08'43"W

Figura 6. Sendero del Bosque Protector Murocomba.



Fuente: Cuencas hidrográficas globales [62].

Elaborado: Justin Macías

Las señales registradas muestran claramente la presencia de múltiples eventos acústicos, evidenciando la actividad de la fauna local, principalmente de aves. Sin embargo, también se detectó una cantidad significativa de ruido ambiental, especialmente en la mañana y tarde de la zona baja y en la noche en las zonas medias y altas del bosque. Este ruido incluyó sonidos de viento, insectos, ecos naturales generados por la vegetación (reverberación) y otros elementos del entorno silvestre que interfieren en la claridad del audio.

Aunque la calidad del audio se vio afectada en algunas zonas y horarios específicos, las señales obtenidas serán útiles para la siguiente fase del proyecto, en la que se aplicaron filtros y segmentación para mejorar la claridad de las grabaciones. Estos resultados permitieron concluir que:

- Los dispositivos utilizados lograron cumplir su función básica de captación.
- Las condiciones del bosque generan muchos sonidos al mismo tiempo, lo que representó un reto en el análisis.
- El ruido de fondo fue procesado cuidadosamente en el segundo objetivo, donde se aplicaron técnicas de limpieza de audio.

4.1.1 Descripción de las Figuras.

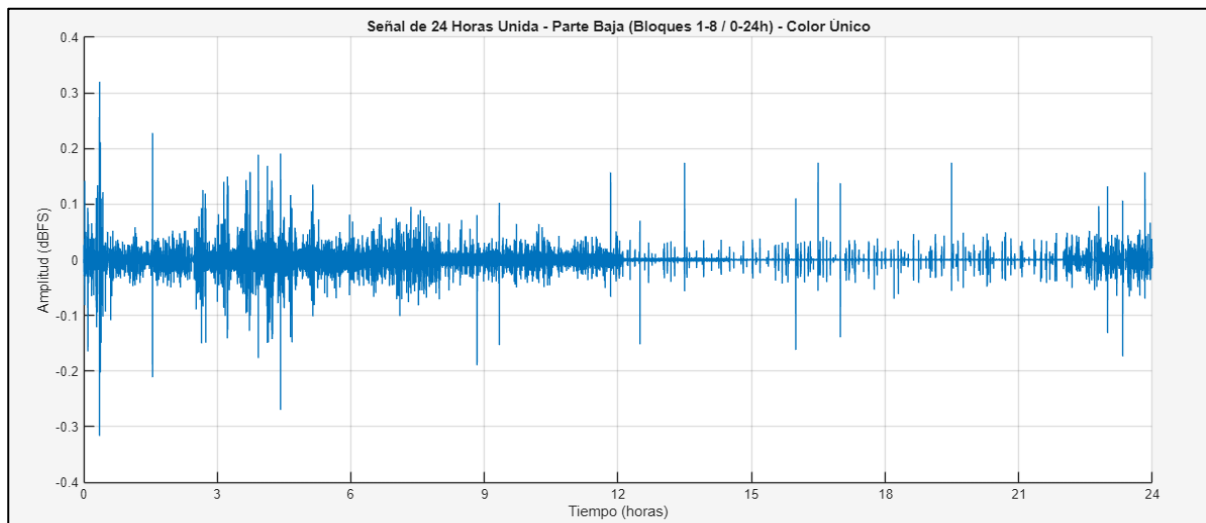
Figura 7. Zona baja del bosque protector Murocomba.



Fuente: Cuencas hidrográficas globales [62].

Elaborado: Justin Macías

Figura 8. Captación en la parte baja del bosque.



Nota: Se observó una señal densa y con amplitudes variables, lo que indica la presencia constante de sonidos. La gran cantidad de ruido sugiere que en esta zona los factores ambientales y humanos afectaron la claridad del audio.

Fuente: Investigador

Elaborado: Justin Macías

La figura representa la reconstrucción íntegra de la señal acústica de 24 horas para la Parte Baja del Bosque Protector. Este gráfico de forma de onda unificado se obtiene al ensamblar consecutivamente los 8 bloques de grabación de 3 horas de duración cada uno, utilizando la Amplitud en dBFS (Decibeles a Escala Completa) en el eje Y y el Tiempo en horas en el eje X. La visualización cumple un rol fundamental de contextualización, pues permite la identificación de patrones macro-temporales de la actividad sonora a lo largo del ciclo día/noche. Como se observa, la señal presenta amplitudes variables y fluctuaciones constantes, lo que es consistente con la nota metodológica que indica una presencia continua de sonidos y una considerable afectación por ruido ambiental en esta zona. Los picos más prominentes que se extienden a lo largo del día reflejan los momentos de mayor actividad acústica biológica (vocalizaciones de fauna) y las posibles interferencias esporádicas. Esta representación es la base para aplicar la técnica de muestreo hiper-focalizado y la selección estratégica de segmentos para un análisis detallado posterior.

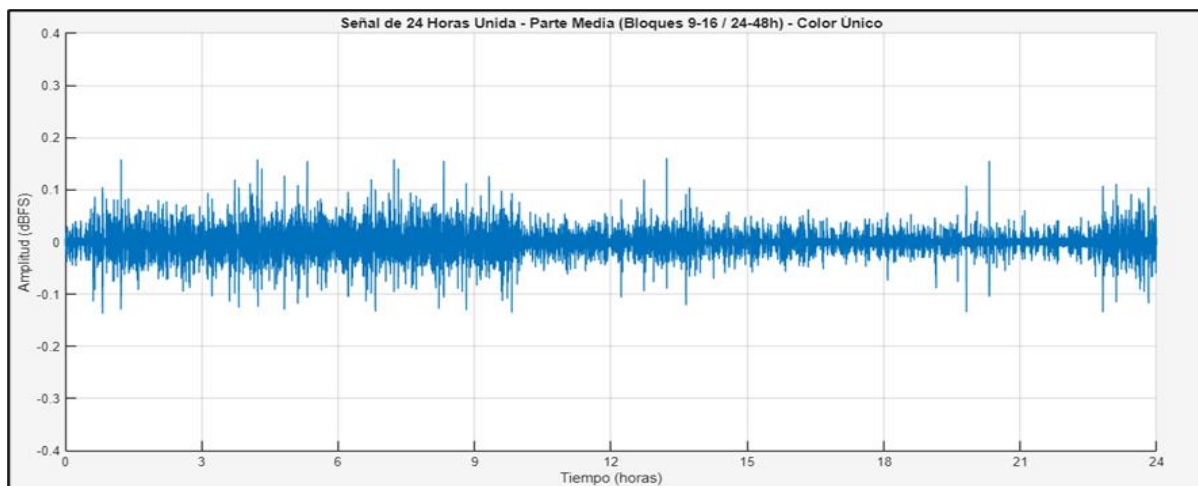
Figura 9. Zona media del bosque protector Murocomba.



Fuente: Cuencas hidrográficas globales [62].

Elaborado: Justin Macías

Figura 10. Captación en la zona media del bosque.



Nota: La señal aquí es un poco más limpia, aunque aún se registraron ruidos. Se observó tramos con picos de actividad acústica que podrían corresponder a cantos de aves.

Fuente: Investigador

Elaborado: Justin Macías

La figura presenta la reconstrucción íntegra de la señal acústica de 24 horas para la Parte Media del Bosque Protector. Al igual que en la Parte Baja, este gráfico unifica los 8 bloques de grabación de 3 horas para ofrecer una visión continua de la actividad sonora diaria, con la Amplitud en dBFS en el eje Y y el Tiempo en horas en el eje X.

La señal acústica registrada en esta zona media exhibe una estructura más ordenada y una menor densidad de ruidos humanos en comparación con la parte baja, lo cual se traduce en amplitudes que, aunque variables, sugieren un ambiente acústico más claro. Pese a la detección de elementos de ruido ambiental, su presencia es menos persistente, permitiendo una delimitación más precisa de los eventos acústicos relevantes, principalmente las vocalizaciones de la fauna.

Este patrón de mayor claridad acústica en la Parte Media, evidenciado por fluctuaciones de amplitud menos erráticas y una base de ruido menos densa, facilita significativamente los procesos posteriores de muestreo hiper-focalizado y análisis espectral, ya que los eventos biológicos de interés son más fácilmente distinguibles del trasfondo ambiental.


Figura 11. Zona alta del bosque protector Murocomba.



Fuente: Cuencas hidrográficas globales [62].

Elaborado: Justin Macías

Figura 12. Captación en la parte alta (cabaña).



Nota: Esta grabación muestra una señal más estable. El entorno elevado y más aislado redujo el impacto del ruido externo. Solo se detecta ruido de fondo muy bajo mientras que se detectan mejor las vocalizaciones de las aves.

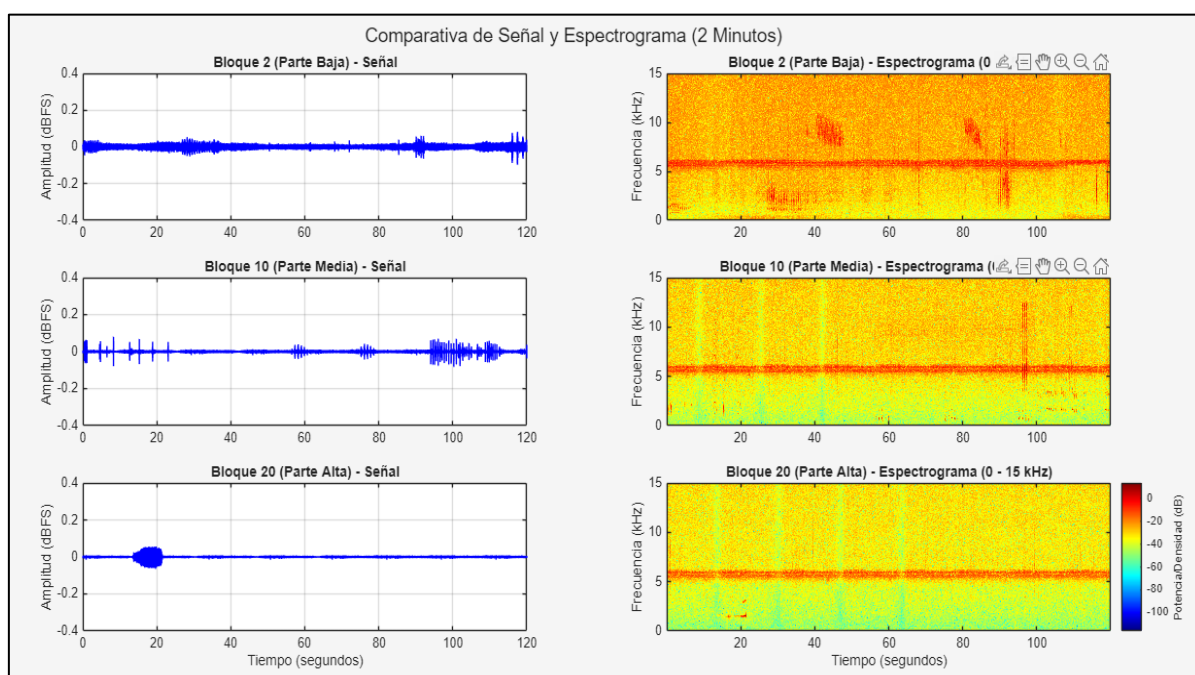
Fuente: Investigador

Elaborado: Justin Macías

En esta grabación, obtenida en una zona elevada y de menor intervención, se aprecia una señal acústica más limpia y con menor presencia de ruido de fondo. El dominio del tiempo muestra picos bien definidos y separación clara entre eventos.

Esta zona representa las condiciones óptimas para la grabación acústica en campo. La calidad de la señal facilita tanto la segmentación como la clasificación y constituye un conjunto de datos ideal para la validación de algoritmos de aprendizaje automático. Además, permitió evaluar el rendimiento del sistema bajo condiciones favorables, sirviendo como línea base para la comparación con zonas más complejas.

Figura 13. Comparación de 2 minutos de la señal y espectrograma en las 3 sesiones.



Nota: Las grabaciones muestran diferencias significativas entre las zonas. En la parte baja, la señal fue más densa y ruidosa. En la parte media, la calidad mejoró, pero aún hubo algunas interferencias. La parte alta presentó la señal más estable, con menos ruidos y eventos acústicos más claros.

Fuente: Investigador

Elaborado: Justin Macías

La magnitud temporal de la grabación de 24 horas hace inviable la visualización e interpretación de un espectrograma completo y detallado para cada zona. Por esta razón, la figura presenta una comparativa selectiva de fragmentos de 2 minutos de la Parte Baja (Bloque 2), Parte Media (Bloque 10), y Parte Alta (Bloque 20). Esta segmentación focalizada permite una verificación empírica de la señal en el dominio del tiempo y la frecuencia, lo cual es fundamental para validar la calidad de los datos. El análisis revela diferencias significativas en la calidad de las grabaciones, lo cual refleja directamente la influencia de las condiciones ambientales en la captación de sonidos a lo largo del gradiente del bosque.

La Parte Baja mostró una señal más densa y ruidosa, evidenciada por la alta potencia del ruido de fondo en su espectrograma (colores cálidos persistentes), lo que concuerda con la nota metodológica de mayores ruidos ambientales. En contraste, la Parte Media experimentó una mejora en la calidad, aunque con ruidos ambientales aún presentes, traducida en una señal más ordenada. Finalmente, la Parte Alta presentó la señal más estable y limpia, con una base de ruido significativamente menor en su espectrograma y eventos acústicos más claros en la forma de onda. Esta tendencia ascendente en la claridad de la señal, desde la Baja hasta la Alta, confirma la hipótesis de que las condiciones ambientales y la reducción de elementos perturbadores a mayor altitud permitieron una delimitación más precisa de las vocalizaciones de las aves para el análisis posterior.

4.1.2 Discusión

En el presente estudio, se implementó el uso de sensores acústicos para captar señales de audio en el Bosque Protector Murocomba, con el fin de crear una base de datos acústica representativa de la avifauna local. Los resultados obtenidos muestran que, aunque las grabaciones fueron exitosas en captar la presencia de aves, la calidad de las señales varió considerablemente dependiendo de la ubicación en el bosque. En las zonas bajas y medias, la presencia de ruido ambiental, como viento, insectos y reverberación de la vegetación, afectó la claridad de las grabaciones. Por otro lado, en las zonas altas del bosque, las grabaciones fueron más estables y con menor interferencia externa, lo que permitió obtener señales más limpias y fácilmente procesables.

Estos resultados están en consonancia con los hallazgos de Blumstein [3], quienes destacan la efectividad del monitoreo acústico en áreas protegidas. Este método permite realizar una recopilación continua de datos sin intervención humana directa, lo cual es fundamental en ecosistemas donde la presencia humana constante podría alterar el comportamiento natural de las especies. En el contexto del Bosque Protector Murocomba, el uso de estos sensores ha demostrado ser una herramienta eficaz para captar señales acústicas en un entorno complejo y de difícil acceso, como lo plantea [61]. El monitoreo acústico pasivo, complementado con plataformas de ciencia ciudadana, facilita la recolección de datos en áreas remotas, lo que resulta en un enfoque de bajo costo y alto rendimiento para la conservación de la biodiversidad.

Aunque se lograron captar las vocalizaciones de aves en diversas zonas, el desafío principal radica en la calidad de las grabaciones en ambientes ruidosos. En particular, la interferencia del ruido ambiental dificultó la identificación precisa de algunas vocalizaciones. A pesar de ello, los resultados obtenidos son valiosos y servirán como base para las siguientes etapas del proyecto, donde se aplicarán técnicas de filtrado y segmentación para mejorar la claridad de los datos acústicos, tal como se recomienda en la literatura sobre el uso de micrófonos autónomos en ecosistemas complejos.

El monitoreo acústico en el Bosque Protector Murocomba, similar a lo reportado por [61], ofrece una solución no invasiva y eficiente para obtener datos sobre la biodiversidad aviar sin requerir la presencia constante de los investigadores. Esta capacidad de monitoreo remoto, que minimiza la perturbación ambiental, es un aspecto clave para la conservación de áreas de alta biodiversidad, ya que permite realizar estudios continuos y a largo plazo sin alterar el entorno natural.

4.2 Muestrear las grabaciones obtenidas

El segundo objetivo se centró en procesar las grabaciones acústicas obtenidas durante las sesiones de monitoreo. Esto se logró mediante el uso de técnicas de segmentación y filtrado de las grabaciones de audio. Debido a la presencia de ruido ambiental y sonido de otros animales en las grabaciones, se aplicaron filtros paso-bajo para eliminar las frecuencias no deseadas. El filtro paso-bajo se utilizó específicamente para reducir las frecuencias altas que no eran relevantes para las vocalizaciones de las aves, permitiendo así capturar con mayor claridad los sonidos de interés. Estos procesos se llevaron a cabo utilizando MATLAB (.m), lo que facilitó la manipulación de los archivos y la extracción de características acústicas.

Las fórmulas utilizadas cubren los procesos de muestreo y segmentación. Primero, se aplicó el Teorema de Nyquist $f_s = 2 \times f_{max}$ para establecer una frecuencia de muestreo f_s de 16kHz, el doble de la frecuencia máxima de la señal 8kHz, asegurando la calidad de la digitalización. Luego, la fórmula $Total\ muestras = f_s \times tiempo$ se usó para calcular el gran total de muestras obtenidas en un día completo (86400s). Finalmente, el proceso de segmentación dividió este tiempo total de audio entre la duración del segmento (10s) usando la fórmula $Segmentos\ totales = \frac{tiempo\ total(s)}{Duracion\ del\ segmento(s)}$, determinando que el audio debe ser analizado en 8640 trozos más pequeños y manejables.

Tabla 4. Formula del muestreo y segmentación.

	$f_s = 2 \times f_{max}$
Fórmula y Proceso de Muestreo	$f_s = 2 \times 8kHz = 16kHz$
	$Total\ muestras = f_s \times tiempo = 16000Hz \times 86400s$ $= 1385400000\ muestras$
Fórmula y Proceso de la segmentación	$Segmentos\ totales = \frac{tiempo\ total(s)}{Duracion\ del\ segmento(s)}$ $= \frac{86400s}{10s} = 8640\ segmentos$

Nota: La pérdida de los 8 segmentos de audio, equivalente a 80 segundos (8 \ segmentos 10 s/segmento), se debe a que la duración total de sus 24 bloques de grabación no alcanza las 24 horas teóricas exactas, sumando en realidad 86,320 segundos. Esta diferencia se produce por el uso intencional de la función floor() en el código de MATLAB y Flutter, la cual descarta cualquier segmento de menos de 10 segundos al final de cada bloque, garantizando que sus 8,632 imágenes finales representen solo segmentos completos y uniformes para mantener la consistencia metodológica en el análisis.

Fuente: Investigador

Elaborado: Justin Macías

Tabla 5. Comparación entre filtros IIR y FIR.

ITEM	Filtros IIR	Filtros FIR
Fase	Difícil de controlar.	Siempre es posible una fase lineal.
Estabilidad	Puede ser inestable.	Siempre ese estable.
Orden del filtro	Menor.	Mayor.
Diseño análogo	Derivado de filtros análogos.	


Fuente: Investigador

Elaborado: Justin Macías

4.2.1 Descripción de las Figuras

El proceso inicial de digitalización generó un total de 1385400000 muestras de audio, obtenidas a una frecuencia de 16kHz durante 24 horas. Este vasto conjunto de datos fue sometido a segmentación para su análisis, calculándose teóricamente 8640 segmentos de 10 segundos cada uno. Sin embargo, debido a que la duración total de la grabación no alcanzó las 24 horas teóricas exactas y la necesidad de descartar segmentos incompletos, el número final de segmentos útiles para el análisis fue de 8632. Esta pequeña pérdida de 8 segmentos asegura la consistencia metodológica.

Figura 14. Muestreo de todas las zonas.



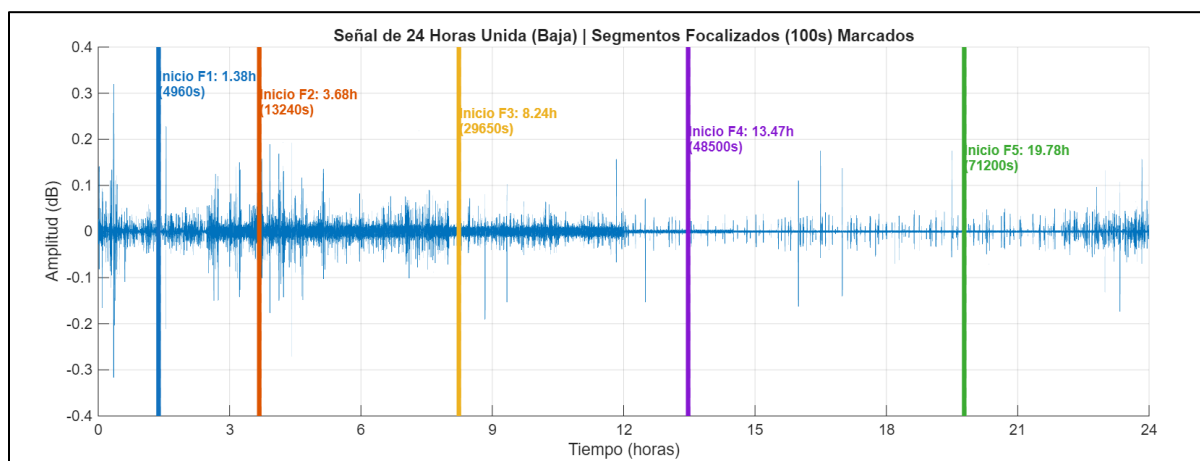
Nota: El conteo de 8.633 elementos corresponde a los 8.632 segmentos de audio analizados más un archivo adicional inherente al proceso de filtrado.

Fuente: Investigador

Elaborado: Justin Macías

Una vez concluida la segmentación masiva de la señal, la plataforma de procesamiento automatizó el análisis multi-zona al iterar sobre la Parte Baja, Media y Alta del Bosque Protector. Para cada una de estas zonas, se procedió a la unificación de los 8 bloques de audio de 3 horas para construir una visualización de contexto de 24 horas continua. Sobre estas representaciones gráficas, se implementó un muestreo hiper-focalizado que permitió la selección estratégica de 5 sub-segmentos de 100 segundos cada uno. Esta selección asegura que las ventanas temporales de mayor actividad acústica en cada parte del bosque sean sometidas a un análisis espectral y de filtrado detallado, manteniendo la consistencia metodológica durante la comparación de las tres áreas.

Figura 15. Visualización Contextual de 24 Horas y Muestreo Hiper-Focalizado - Parte Baja.



Nota: Se realizó la unión de 10 segmentos en un solo segmento. Cada segmento de la gráfica son 100 segundos de los cuales serán filtrados y analizados.


Fuente: Investigador

Elaborado: Justin Macías

La figura representa la unificación total de los 8 bloques de audio de 3 horas, reconstruyendo la señal acústica continua de 24 horas correspondiente a la Parte Baja del Bosque Protector Murocomba. Este gráfico bidimensional (Amplitud en el eje Y versus Tiempo en horas en el eje X) establece el contexto temporal completo y permite la identificación de periodos de alta actividad acústica. Sobre esta base, se visualiza la aplicación del muestreo hiper-focalizado, demarcado por 5 líneas verticales de colores (F1 a F5). Cada una de estas líneas indica el punto exacto de inicio de un sub-segmento estratégico de 100 segundos seleccionado para un análisis cualitativo posterior. La precisión de los marcadores, que muestran el tiempo en horas y su equivalencia en segundos, valida la localización exacta de los eventos de interés, lo cual es

fundamental para extraer las ventanas temporales que serán sometidas al procesamiento de filtrado y análisis espectral detallado.

Ilustración 16. Señal de audio sub-segmentada y filtrada en el segundo 4960 al 5060 de la parte baja del bosque.

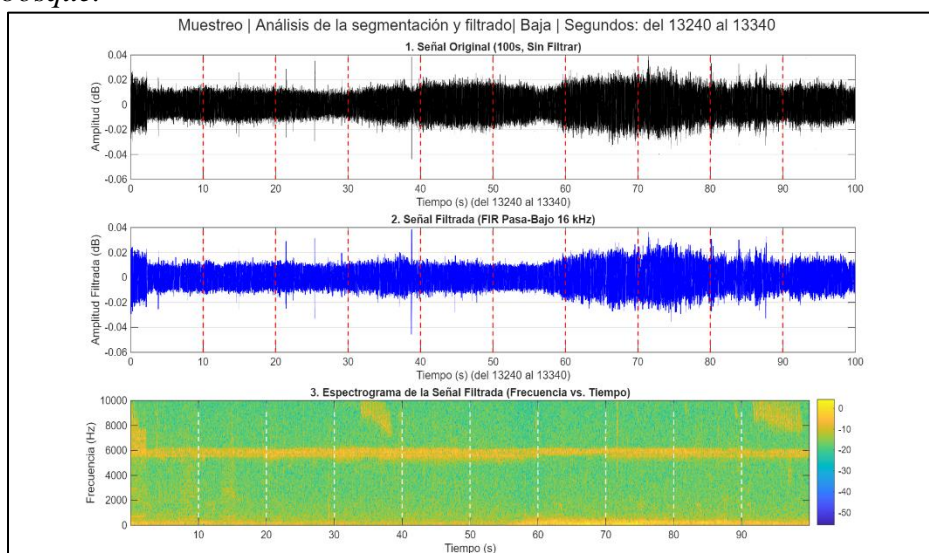


Nota: Tras la unión de 10 segmentos y formar un subsegmento con una duración de 100 segundos se puede verificar el filtrado a 16kHz de frecuencia para su respectivo análisis de la señal en el espectrograma donde se puede ver fragmentes de posibles sonidos de aves como patrones repetitivos o señales relevantes en el espectrograma.

Fuente: Investigador

Elaborado: Justin Macías

Figura 17. Señal de audio sub-segmentada y filtrada en el segundo 13240 al 13340 de la parte baja del bosque.




Nota: Se puede verificar que hay un patrón repetitivo a lo largo de los 100 segundos, aunque la señal filtrada aun tenga un espectrograma que muestre sonidos de fondo que podrían ser otros animales, lluvia o viento.

Fuente: Investigador

Elaborado: Justin Macías

Figura 18. Señal de audio sub-segmentada y filtrada en el segundo 29650 al 29750 de la parte baja del bosque.




Nota: El filtrado ayudo a verificar patrones repetitivos en las frecuencias de 7kHz a 10kHz donde podría servir como dato importante de posible ave.

Fuente: Investigador

Elaborado: Justin Macías

Figura 19. Señal de audio sub-segmentada y filtrada en el segundo 48500 al 48600 de la parte baja del bosque.

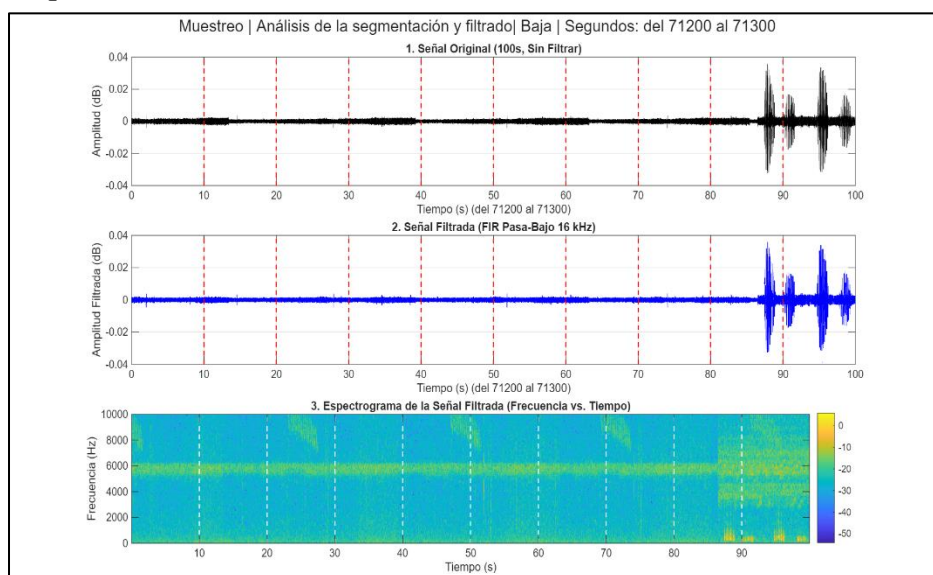


Nota: El audio segmentado en esta parte de los 48500 a los 48600 segundos es mucho más limpia, que facilita el filtrado y el análisis de la señal del espectrograma para posibles aves que se encuentren. Como el patrón repetitivo que esta debajo de la frecuencia de 1kHz que en esa frecuencia las aves más comunes que transmiten sonidos son los pavos y palomas.

Fuente: Investigador

Elaborado: Justin Macías

Figura 20. Señal de audio sub-segmentada y filtrada en el segundo 71200 al 71300 de la parte baja del bosque.

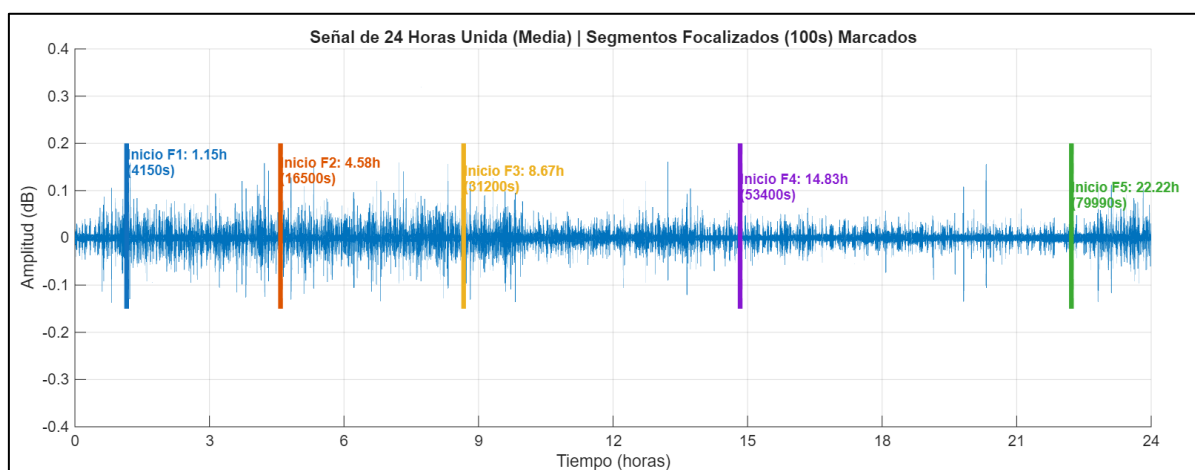


Nota: Tras la segmentación y sub-segmentación se pudo verificar de forma más óptima el análisis espectral del audio en fragmentos pequeños donde se puede verificar fácilmente la presencia de patrones repetitivos y señales relevantes a través del tiempo entre las frecuencias de 0 a 10kHz

Fuente: Investigador

Elaborado: Justin Macías

Figura 21. Visualización Contextual de 24 Horas y Muestreo Hiper-Focalizado - Parte Media.




Nota: Se realizó la unión de 10 segmentos en un solo segmento. Cada segmento de la gráfica son 100 segundos de los cuales serán filtrados y analizados.

Fuente: Investigador

Elaborado: Justin Macías

Figura 22. Señal de audio sub-segmentada y filtrada en el segundo 4150 al 4250 de la parte media del bosque.




Nota: Tras la sub-segmentación y filtrado se puede verificar varios patrones repetitivos en el espectrograma que están alrededor de 0 a 10kHz.

Fuente: Investigador

Elaborado: Justin Macías

Figura 23. Señal de audio sub-segmentada y filtrada en el segundo 16500 al 16600 de la parte media del bosque.




Nota: Se pueden visualizar fácilmente patrones repetitivos de sonidos relevantes en el espectrograma de la señal a lo largo de 100 segundos.

Fuente: Investigador

Elaborado: Justin Macías

Figura 24. Señal de audio sub-segmentada y filtrada en el segundo 31200 al 31300 de la parte media del bosque.




Nota: Se puede verificar que existen 5 sonidos relevantes a lo largo de los 100 segundos sub-segmentados.

Fuente: Investigador

Elaborado: Justin Macías

Figura 25. Señal de audio sub-segmentada y filtrada en el segundo 53400 al 53500 de la parte media del bosque.

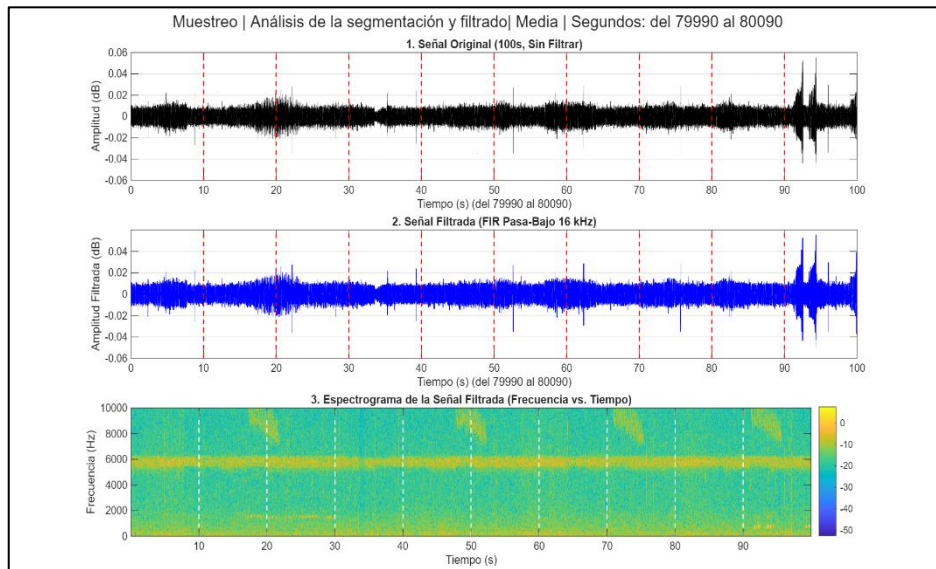


Nota: Tras la segmentación y filtrado con un filtro paso-bajo podemos identificar sonidos en 1kHz de posibles aves que se detectaran con los algoritmos.

Fuente: Investigador

Elaborado: Justin Macías

Figura 26. Señal de audio sub-segmentada y filtrada en el segundo 79990 al 80090 de la parte media del bosque.

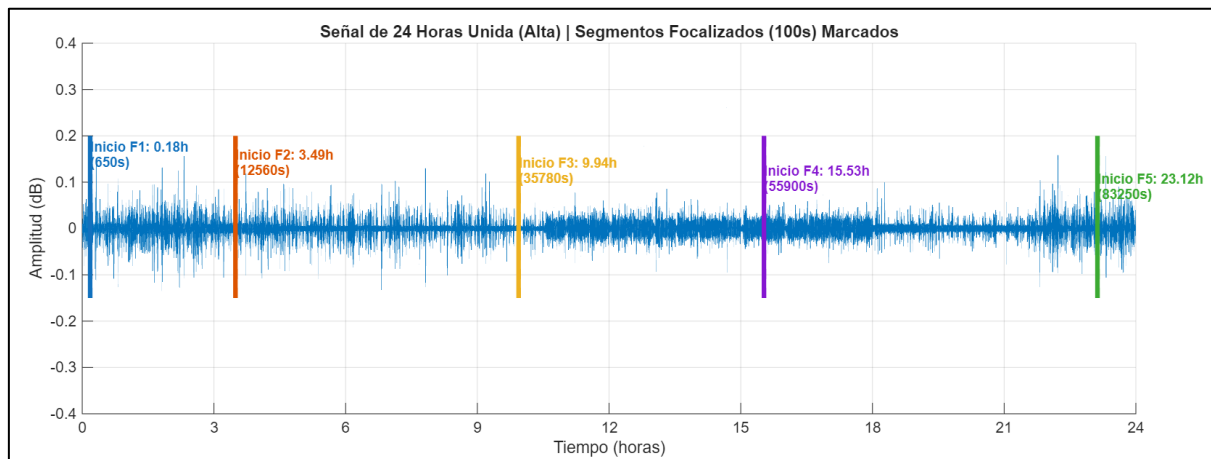


Nota: Se puede reflejar mejor el filtro ya que la señal a pesar de tener fondo de ruido posiblemente de vientos o lluvias mantiene visibles las señales importantes que son sonidos relevantes a lo largo del segmento.

Fuente: Investigador

Elaborado: Justin Macías

Figura 27. Visualización Contextual de 24 Horas y Muestreo Hiper-Focalizado - Parte Alta.




Nota: Tras la sub-segmentación que se realizó a lo largo de las 24 horas se puede verificar a fondo en qué hora y minuto exacto se inició el sub-segmento. Cada uno tiene 10 segmentos de 10 segundos cada uno completando 100 segundos para poder analizar al ser filtrado.

Fuente: Investigador

Elaborado: Justin Macías

Figura 28. Señal de audio sub-segmentada y filtrada en el segundo 650 al 750 de la parte alta del bosque.




Nota: En esta imagen se muestra el proceso de filtrado de la primera sub-segmentación del audio donde se puede presenciar muchos sonidos relevantes que nos ayudara a verificar si se trata de aves en los siguientes algoritmos.

Fuente: Investigador

Elaborado: Justin Macías

Figura 29. Señal de audio sub-segmentada y filtrada en el segundo 12560 al 12660 de la parte alta del bosque.




Nota: Tras el filtrado realizado se identificó pocos sonidos relevantes, pero se pueden considerar importantes los q se ven visualmente entre 0 a 2kHz como el que se encuentra en 1 a 4kHz así mismo al final del tiempo el que está en los 6 a 8kHz.

Fuente: Investigador

Elaborado: Justin Macías

Figura 30. Señal de audio sub-segmentada y filtrada en el segundo 35780 al 35880 de la parte alta del bosque.




Nota: Se puede visualizar claramente la presencia de ruido, aunque el audio haya sido filtrado podemos encontrar partes donde el viento o lluvia hicieron que no se pueda identificar de buena manera la señal.

Fuente: Investigador

Elaborado: Justin Macías

Figura 31. Señal de audio sub-segmentada y filtrada en el segundo 55900 al 56000 de la parte alta del bosque.

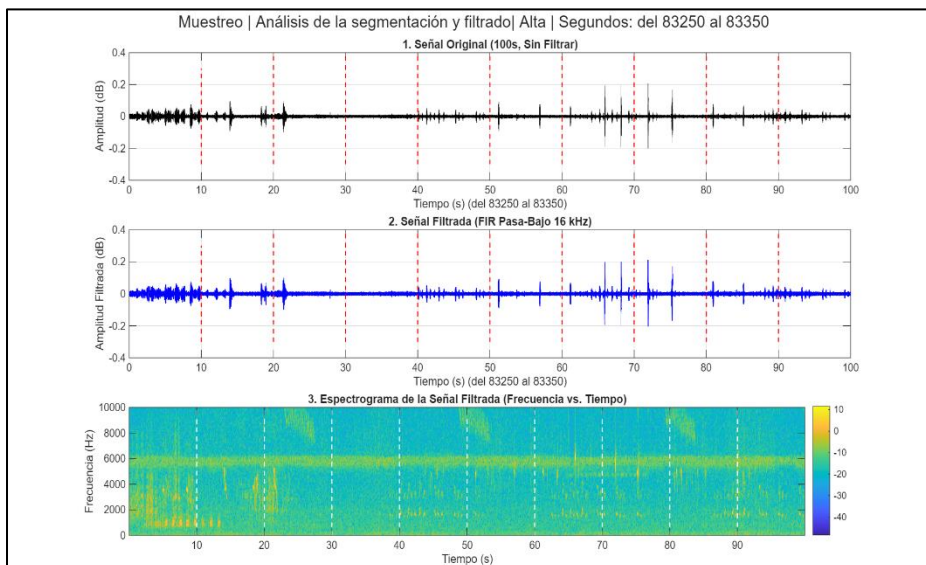


Nota: Tras la sub-segmentación y filtrado con un filtro paso-bajo de 16kHz, se analizaron 100 segundos de audio, donde se detectó pequeños fragmentos de patrones repetitivos a lo largo del tiempo y en frecuencias por debajo de 3kHz.

Fuente: Investigador

Elaborado: Justin Macías

Figura 32. Señal de audio sub-segmentada y filtrada en el segundo 83250 al 83350 de la parte alta del bosque.



Nota: Tras la segmentación y filtrado con un filtro paso-bajo de 16 kHz, se analizaron 100 segundos de audio, donde se destacaron los patrones repetitivos de las vocalizaciones. Estos patrones indicaron comportamientos vocales específicos de las especies, lo cual es esencial para la fase de clasificación con algoritmos de aprendizaje automático.

Fuente: Investigador

Elaborado: Justin Macías

La etapa crucial en el procesamiento de los cinco sub-segmentos de 100 segundos seleccionados de la Parte baja, Parte media y Parte alta fue la aplicación de un Filtro FIR Pasa-Bajo con una frecuencia de corte de 16 kHz. Este filtro fue fundamental para atenuar selectivamente las componentes de alta frecuencia y mitigar el ruido ambiental que podría distorsionar el análisis, manteniendo intacta la información crítica de las vocalizaciones de las aves concentradas por debajo de este umbral. Tras el filtrado, la señal se sometió a un análisis de espectrograma, cuya representación visual de la densidad de energía en función de la frecuencia y el tiempo (eje Y y X, respectivamente) es vital, ya que, no solo valida la reducción del ruido, sino que también permite la localización precisa y la identificación de los patrones espectrales de las vocalizaciones, transformando la señal ruidosa en un patrón claro y cuantificable para las métricas de clasificación automatizada.

4.2.2 Discusión

Los resultados obtenidos demuestran que el proceso de muestreo y filtrado fue esencial para aislar las vocalizaciones de aves y mejorar la relación señal-ruido en las grabaciones. El filtrado permitió reducir eficazmente los efectos del ruido ambiental, como el viento y los sonidos de insectos, mientras que la segmentación facilitó la identificación precisa de los fragmentos de audio relevantes que contenían vocalizaciones de aves. Al aplicar técnicas de filtrado, como el filtro paso-bajo, se eliminaron las interferencias de alta frecuencia, mejorando considerablemente la calidad de las grabaciones.


Estos resultados se alinean con el trabajo de Stowell [9], quien resalta la importancia de filtrar y segmentar las grabaciones acústicas para mejorar la calidad de los datos y facilitar la identificación de eventos acústicos relevantes. Esta técnica es clave en el contexto del monitoreo acústico, ya que permite concentrarse únicamente en las vocalizaciones de interés y elimina los ruidos ambientales que podrían interferir en la interpretación de los datos. La aplicación de estos métodos en nuestro estudio fue crucial para seleccionar los fragmentos acústicos relevantes, lo que permitió una identificación más precisa de las especies presentes en el Bosque Protector Murocomba.

Además, el estudio de [20] también refuerza la importancia de técnicas de segmentación para la extracción de características relevantes de las grabaciones. En su investigación, Kahl aplican redes neuronales para la detección y clasificación automática de vocalizaciones de aves, destacando que la segmentación es fundamental para aislar los eventos acústicos de interés y mejorar la precisión de los algoritmos de clasificación. En nuestra investigación, los resultados obtenidos de la segmentación automática de las grabaciones de aves han demostrado ser consistentes con estos hallazgos, pues los fragmentos seleccionados contienen patrones acústicos claros y repetitivos, lo que facilita la clasificación posterior de las vocalizaciones.

A pesar de que la segmentación automática fue exitosa en la mayoría de las grabaciones, se identificaron áreas de mejora, particularmente en las zonas con ruido ambiental intenso. En estos casos, las técnicas de filtrado y segmentación deben ser más refinadas para asegurar que solo se capturen las vocalizaciones de las especies sin la interferencia de otros sonidos. Sin embargo, los resultados preliminares sugieren que el sistema es capaz de filtrar eficazmente las grabaciones y seleccionar fragmentos relevantes, lo que permite que la siguiente fase del análisis, que implica el uso de algoritmos de aprendizaje automático para la clasificación de especies, sea más eficiente.

4.3 Implementar algoritmos de aprendizaje automático.

Figura 33. Diagrama de características de los algoritmos aplicados.

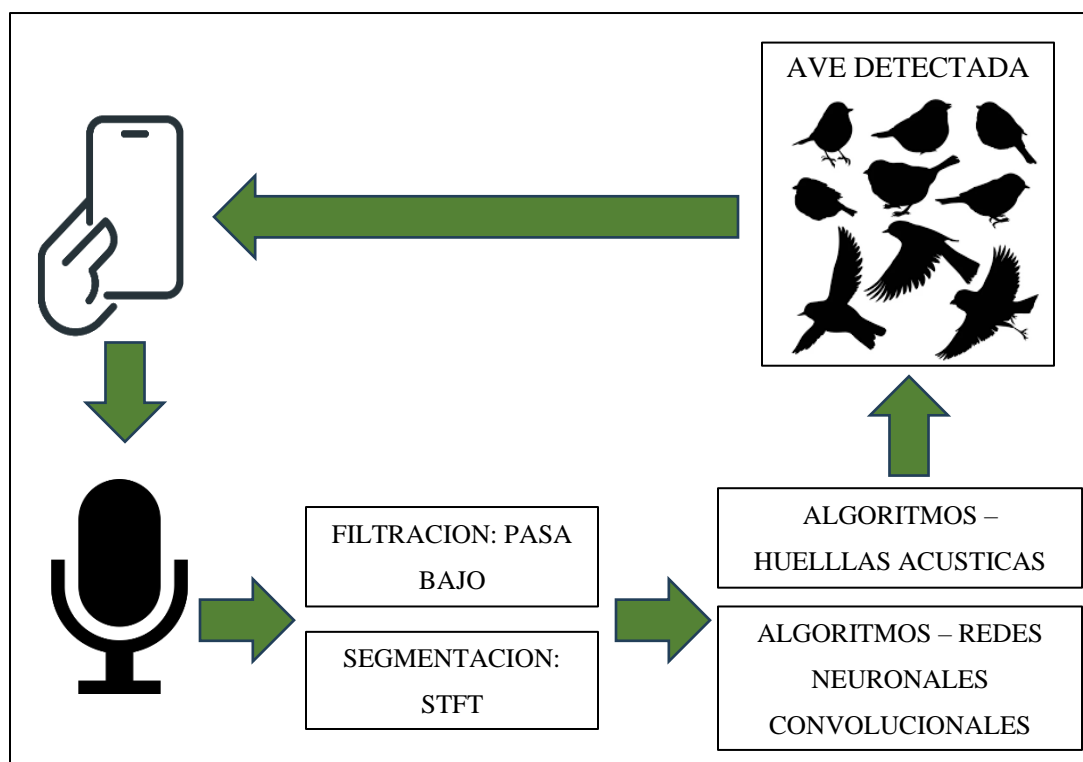


Fuente: Investigador

Elaborado: Justin Macías

En este objetivo se implementaron algoritmos de aprendizaje automático para la clasificación de vocalizaciones aviares, lo cual fue clave para el procesamiento automatizado de las grabaciones obtenidas en el Bosque Protector Murocomba. El objetivo fue crear un modelo capaz de identificar especies aviares a partir de las señales acústicas registradas, utilizando algoritmos de procesamiento de audio y aprendizaje automático.

Figura 34. Esquema de los algoritmos implementados.




Fuente: Investigador

Elaborado: Justin Macías

Se implementó un enfoque híbrido donde las redes neuronales convolucionales (CNN) y las huellas acústicas (audio fingerprinting) se complementaron para identificar especies aviares. Primero, el fingerprinting localizó rápidamente coincidencias probables en la base de datos aun con ruido o variaciones de ganancia. Luego, una CNN entrenada sobre espectrogramas en escala Mel afinó la clasificación, diferenciando el espectrograma de los cantos similares entre especies. El flujo de trabajo incluyó filtrado y segmentación para mejorar la relación señal-ruido y extraer solo los eventos vocales relevantes. Este esquema redujo falsos positivos y tiempos de cómputo, ofreciendo identificaciones robustas en condiciones de campo reales.

Figura 35. Funcionamiento de las huellas acústicas.



Fuente: Investigador

Elaborado: Justin Macías

La huella acústica es el vector de rasgos que el sistema genera para cada evento sonoro y que sirve como base compacta de búsqueda y verificación. La señal analógica capturada por el micrófono se preamplifica, se filtra y se segmenta; luego se digitaliza y, tras la STFT, se obtiene un espectrograma log-Mel que se limpia y normaliza. Sobre esa representación, la huella resume de forma estable y robusta al ruido: LPC (envolvente espectral), formantes y sus anchos, envolvente temporal (ataque, meseta, decaimiento, duración), tasa de cambio de frecuencia (FM local), timbre (centroide y dispersión), desviación espectral, relación de energía entre bandas, correlación temporal (periodicidad y lag), coherencia entre subbandas, picos/vales dominantes y frecuencia fundamental (F0) con HNR. Esa huella se normaliza e indexa para comparación eficiente, permitiendo restringir rápidamente el espacio a pocas especies candidatas, tolerando variaciones de ganancia y de micrófono. Después, esas candidatas pueden validarse por

alineación de patrones y refinarse con la CNN, pero la huella acústica es la que ordena, prioriza y acelera la identificación al aportar una base de datos de características coherente y comparable entre grabaciones.


Tabla 6. Características de las huellas acústica.

Métrica/Descriptor	Parámetros de Extracción (Recomendados)	Observación en el Espectrograma	Valor Típico / Unidad
Flatness Espectral (Planitud)	log-mel por banda	Indica si el sonido es tonal o ruidoso.	SFM \approx 0.25–0.35 (adim.)
Desviación Espectral	frame-a-frame (dB)	Muestra el cambio moderado en la frecuencia por arco de vocalización.	3–6 dB
Relación de Energía entre Bandas	Bandas de 0.5–2 / 2–4 / 4–8 / 8–10 kHz	Revela una firma distintiva de energía en 2–4 y 4–8 kHz.	$E_{2-4}/E_{0.5-2} \approx 3.8$
Autocorrelación Temporal	lag 0.1–10 ms; umbral $\rho > 0.3$	Indica una periodicidad clara del sonido (canto).	lag \approx 0.30–0.33 ms (F0 \sim 3.1–3.3 kHz)
Coherencia (Subbandas)	Banco de 6–10 bandas	Muestra la sincronía entre diferentes rangos de frecuencia.	$C_{xy} \approx 0.7–0.8$
Frecuencia Fundamental (F0)	YIN/ACF; f0_min 0.8 kHz; f0_max 6–8 kHz	Define la forma principal de la curva de la vocalización (p. ej., un arco "∩").	F0 pico \approx 3.3 kHz

Fuente: Investigador

Elaborado: Justin Macías

Figura 36. Funcionamiento de las redes neuronales convolucionales.



Fuente: Investigador

Elaborado: Justin Macías

Cada segmento de audio se convierte automáticamente en un espectrograma log-Mel mediante STFT, se limpia de silencios y ruido y se normaliza a un rango fijo de dB para resaltar la energía útil. Esa imagen entra a la CNN, que aprende patrones tiempo-frecuencia propios del canto (curvas de frecuencia, repeticiones, armónicos y picos). Las capas profundas integran esos indicios para representar el motivo completo y su ritmo. En paralelo se genera una huella acústica compacta (picos más fuertes, distribución por bandas, estimación de F0 y relación armónica/ruido, más combinaciones simples de frecuencias) para consultar un índice y reducir el conjunto de especies candidatas. Luego la CNN reevalúa solo esas candidatas y produce probabilidades; un paso de decisión aplica reglas claras (confianza mínima, duración suficiente y consistencia de armónicos) y suaviza los resultados sobre ventanas deslizantes de ~3 s. Finalmente se guarda un resumen vectorial del canto para acelerar futuras coincidencias y mantener robustez frente a cambios de volumen o de micrófono.

Tabla 7. Características de las redes neuronales convolucionales.

Característica de la CNN/Espectrograma	Fundamento Teórico	Relevancia en el Análisis de Aves
Transformada de Fourier (STFT)	Proceso para generar el Espectrograma, el cual es la imagen de entrada 2D para la CNN.	Convierte la señal de audio en una representación tiempo-frecuencia.
Ejes (Tiempo vs. Frecuencia)	El Eje X (Tiempo) muestra la duración; el Eje Y (Frecuencia) muestra el tono del sonido.	Permite a la CNN identificar patrones de las vocalizaciones de las aves en el tiempo y el tono.
Intensidad (Amplitud)	Representada por la escala de colores o tonos en el espectrograma, indica la energía del sonido en un punto.	La CNN extrae la "fuerza" del canto, permitiendo distinguir eventos ruidosos o silenciosos.
Resolución Temporal y Espectral	Es una compensación entre la nitidez en el tiempo y la precisión en la frecuencia (trade-off).	Esencial para capturar la estructura fina (armónicos) o la duración total de un canto (transitorios).
Tamaño de la Ventana (Window Size)	Define el número de muestras que se analizan para cada segmento de la STFT.	Determina si la CNN detecta los cambios rápidos o las notas más largas del canto.
Picos y Valles	Puntos de máxima y mínima energía en el espectrograma.	Son los rasgos distintivos que la CNN aprende para la clasificación de cada especie.

Fuente: Investigador

Elaborado: Justin Macías

Tabla 8. Comparación de Algoritmos (CNN vs. Huellas).

Criterio de Comparación	Redes Neuronales Convolucionales (CNN)	Huellas Acústicas (Audio Fingerprinting)
Objetivo en el Proyecto	Clasificación final de la vocalización aviar.	Extracción de rasgos compactos para una búsqueda rápida de candidatos o verificación.
Tipo de Característica	Características de alto nivel extraídas automáticamente a partir de una imagen 2D (espectrograma).	Características de bajo y medio nivel (picos espectrales, MFCC, métricas) predefinidas por el algoritmo.
Robustez ante el Ruido	Alta: La arquitectura CNN puede aprender a filtrar y a ser invariante al ruido de fondo después del entrenamiento.	Moderada: Requiere que la señal haya sido limpiada (filtrado y segmentación) para que los rasgos clave no se enmascaren.
Requerimiento de Datos	Intenso: Requiere grandes volúmenes de datos etiquetados para un entrenamiento efectivo.	Moderado: Se basa en la estabilidad y singularidad de los rasgos de la señal.
Ventaja Clave	Capacidad de clasificación precisa en entornos complejos y ruidosos.	Velocidad de búsqueda y verificación en una base de datos.

Fuente: Investigador

Elaborado: Justin Macías

Figura 37. Logotipo de App.

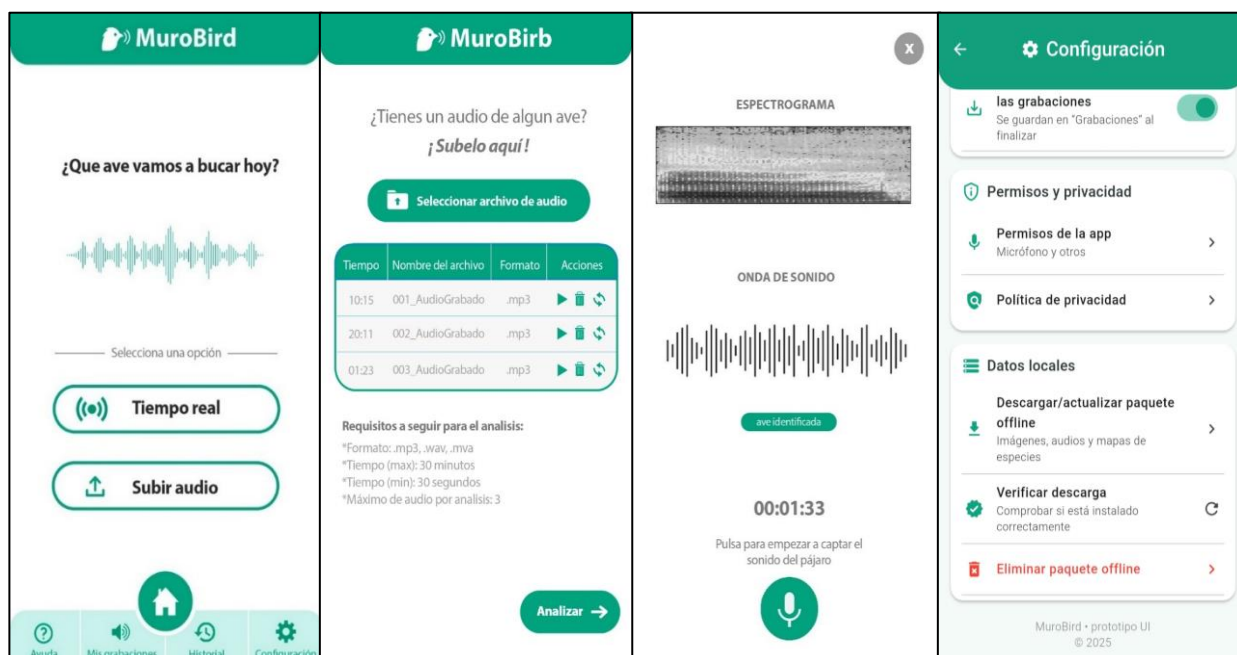


Nota: La imagen muestra el logo de la aplicación móvil MuroBird, diseñada para interactuar con los usuarios de manera eficiente.

Fuente: Investigador

Elaborado: Justin Macías

Figura 38. Interfaz de la App.



Nota: El núcleo de la aplicación es un motor de reconocimiento que combina redes neuronales convolucionales con huellas acústicas. La interfaz ofrece dos modos: Tiempo real, que permite grabar directamente con el teléfono y obtener la identificación del ave al instante, y subir audio, pensado para monitoreo diferido: el usuario importa archivos y el sistema analiza las grabaciones, extrae la huella y compara con la base de datos para mostrar las especies detectadas. En la ventana de configuración donde se requieren permisos y opciones necesarias y también esta el modo offline para el análisis e identificación de aves cuando no se cuenta con cobertura, se descarga el paquete donde se encuentra el data set del sonido de las 160 aves registradas.

Fuente: Investigador

Elaborado: Justin Macías

4.3.1 Funcionamiento de la Aplicación

El flujo de trabajo de la aplicación está estructurado en tres etapas:

- **Recopilación de datos:** A través de las grabaciones de audio.
- **Preprocesamiento:** En el que se filtran los ruidos y se segmentan las vocalizaciones clave.
- **Identificación:** Usando algoritmos de aprendizaje automático como CNN y huellas acústicas para reconocer las especies de aves.
- **Resultados:** Visualización de la especie identificada con su espectrograma y descripción detallada.

4.3.2 Datos recopilados

Tabla 9. Tabla de grabaciones.

Zona de Muestreo	Cantidad de Grabaciones	Duración por Grabación (minutos)	Tiempo Total de Monitoreo (horas)	Nro. de Especies Identificadas (Conteo Acústico)
Parte Alta del Bosque	48	30	24	102
Parte Media del Bosque	48	30	24	87
Parte Baja del Bosque	48	30	24	48

Fuente: Investigador

Elaborado: Justin Macías

Para cuantificar los resultados del monitoreo, se consolidó el esfuerzo de muestreo acústico aplicado en el Bosque Protector Murocomba. El trabajo de campo se estratificó en tres zonas de análisis: parte alta, media y baja. En cada una de estas zonas, se desplegaron dispositivos de recolección de audio que capturaron un total de 48 archivos de audio, con una duración estandarizada de 30 minutos por archivo.

Este diseño metodológico aseguró un esfuerzo de muestreo equitativo de 24 horas de monitoreo acústico por cada estrato. La Tabla 9 resume esta distribución del muestreo y presenta el conteo de especies preliminar identificado mediante los algoritmos de aprendizaje automático en cada una de las zonas estudiadas.

Tabla 10. Distribución de Especies por Familias Detectadas en Cada Zona del Bosque.

Familia	N° Especies (Zona Baja)	N° Especies (Zona Media)	N° Especies (Zona Alta)
Accipitridae (Aves de presa)	8	5	2
Anatidae (Patos)	1	0	0
Apodidae (Vencejos)	1	0	1
Ardeidae (Garzas)	3	3	0
Bucconidae (Bucónidos)	0	1	1
Caprimulgidae (Chotacabras/Aves Nocturnas)	1	3	4
Cathartidae (Buitres/Gallinazos)	2	1	0
Columbidae (Palomas/Tórtolas)	2	9	8
Cotingidae (Cotingas)	0	1	2
Cracidae (Pavas/Paujiles)	2	5	5
Cuculidae (Cuclillos)	3	3	2
Falconidae (Halcones)	2	1	1
Hirundinidae (Golondrinas)	1	1	1
Icteridae (Tordos/Caciques)	2	1	1
Momotidae (Momotos/Barranqueros)	1	2	6


Odontophoridae (Codornices del Nuevo Mundo)	0	1	0
Parulidae (Reinitas/Parulas)	0	1	1
Passerellidae (Gorriones del Nuevo Mundo)	1	1	1
Passeridae (Gorriones Comunes)	0	1	1
Picidae (Pájaros Carpinteros)	1	1	1
Poliophtilidae (Perlitas)	1	2	2
Psittacidae (Loros/Guacamayos)	1	6	11
Rallidae (Pollas de Agua)	1	2	1
Ramphastidae (Tucanes)	1	2	1
Strigidae (Búhos/Autillos)	3	5	6
Thamnophilidae (Hormigueros)	0	0	1
Thraupidae (Tangaras)	0	6	5
Tinamidae (Tinamúes)	1	4	3
Tityridae (Tiriras)	0	1	1
Trochilidae (Colibríes)	1	7	18
Troglodytidae (Chochines/Soterreys)	1	3	5
Trogonidae (Trogones)	1	3	4

Turdidae (Mirlos/Turdos)	0	0	1
Tyrannidae (Tiranos/Mosqueros)	6	4	3
Tytonidae (Lechuzas)	0	1	1
Vireonidae (Vireos)	0	0	1
Total, Especies (Por Zona)			
36 familias	48	87	102

Fuente: Investigador

Elaborado: Justin Macías

Figura 39. Familia de aves captadas en las diferentes zonas del Bosque Protector Murocomba.




Nota: La captación e identificación de especies que se realizó hace un total de 237 aves captadas, donde 48 especies son de la parte baja, 87 de la parte media y 102 de la parte alta. Las captaciones se distribuyen entre las 160 aves identificadas en el Bosque Protector Murocomba donde muchas especies se encuentran distribuidas en las diferentes zonas.

Fuente: Investigador

Elaborado: Justin Macías

Tabla 11. Distribución de las Familias de Aves en las Zonas Baja, Media y Alta del Bosque.



Fuente: Investigador

Elaborado: Justin Macías

4.3.3 Identificación de Especies de Aves en el Bosque Protector Murocomba

Se compiló un conjunto de datos de 160 especies de aves mediante una combinación de monitoreo acústico, recolección de datos visuales y el conocimiento del guía local, el Señor Manuel. De las 160 especies, 127 fueron identificadas a través del monitoreo acústico, 13 fueron captadas mediante cámaras de monitoreo y teléfonos móviles y las 20 especies restantes fueron documentadas gracias a años de observaciones proporcionadas por el guía. A continuación, se presenta una lista de las especies de aves identificadas en la región, con sus respectivos nombres científicos y nombres comunes en Ecuador.

Tabla 12. Dataset de aves en el Bosque Protector Murocomba.

Nombre en inglés	Nombre científico	Nombre en Ecuador	Familia
Barred Hawk	Morphnarchus princeps	Gavilán barreteado	Accipitridae
Bicolored Hawk	Accipiter bicolor	Gavilán bicolor	Accipitridae
Black-and-chestnut Eagle	Spizaetus isidori	Águila andina parda y negra	Accipitridae
Black-and-white Hawk-Eagle	Spizaetus melanoleucus	Águila halcón blanco y negro	Accipitridae
Black-chested Buzzard-Eagle	Geranoaetus melanoleucus	Águila pechinegra	Accipitridae
Common Black Hawk	Buteogallus anthracinus	Gavilán negro común	Accipitridae
Crane Hawk	Geranospiza caerulescens	Gavilán cangrejero	Accipitridae
Crested Eagle	Morphnus guianensis	Águila crestada	Accipitridae
Gray-lined Hawk	Buteo nitidus	Gavilán gris lineado	Accipitridae

Nombre en inglés	Nombre científico	Nombre en Ecuador	Familia
Great Black Hawk	<i>Buteogallus urubitinga</i>	Gavilán negro grande	Accipitridae
Roadside Hawk	<i>Rupornis magnirostris</i>	Gavilán caminero	Accipitridae
Semiplumbeous Hawk	<i>Leucopternis semiplumbeus</i>	Gavilán semiplomizo	Accipitridae
Slate-colored Hawk	<i>Buteogallus schistaceus</i>	Gavilán plumizo	Accipitridae
Tiny Hawk	<i>Microspizias superciliosus</i>	Gavilán enano	Accipitridae
White Hawk	<i>Pseudastur albicollis</i>	Gavilán blanco	Accipitridae
Muscovy Duck	<i>Cairina moschata</i>	Pato criollo (Muscovy)	Anatidae
Biscutate Swift	<i>Streptoprocne biscutata</i>	Vencejo biscútate	Apodidae
White-collared Swift	<i>Streptoprocne zonaris</i>	Vencejo collar blanco	Apodidae
Fasciated Tiger-Heron	<i>Tigrisoma fasciatum</i>	Garza tigre fasciada	Ardeidae
Great Blue Heron	<i>Ardea herodias</i>	Garzón azul	Ardeidae
Great Egret	<i>Ardea alba</i>	Garza grande	Ardeidae
Little Blue Heron	<i>Egretta caerulea</i>	Garcita azul	Ardeidae
Rufescent Tiger-Heron	<i>Tigrisoma lineatum</i>	Garza tigre colorada	Ardeidae
Western Cattle-Egret	<i>Bubulcus ibis</i>	Garcita bueyera	Ardeidae
Yellow Bittern	<i>Ixobrychus sinensis</i>	Avetorillo amarillo (accidental)	Ardeidae
White-whiskered Puffbird	<i>Malacoptila panamensis</i>	Bucón bigotiblanco	Bucconidae

Nombre en inglés	Nombre científico	Nombre en Ecuador	Familia
Lyre-tailed Nightjar	<i>Uropsalis lyra</i>	Chotacabras colilirio	Caprimulgidae
Rufous Nightjar	<i>Anurostomus rufus</i>	Chotacabras rufo	Caprimulgidae
Small-tailed Nightjar	<i>Setopagis parvula</i>	Chotacabras chico	Caprimulgidae
Spot-tailed Nightjar	<i>Hydropsalis maculicaudus</i>	Chotacabras colimoteado	Caprimulgidae
Black Vulture	<i>Coragyps atratus</i>	Guala cabeza negra	Cathartidae
Turkey Vulture	<i>Cathartes aura</i>	Guala cabeza roja	Cathartidae
Blue Ground Dove	<i>Claravis pretiosa</i>	Torcaza azulita	Columbidae
Dusky Pigeon	<i>Patagioenas goodsoni</i>	Paloma sombría	Columbidae
Gray-fronted Dove	<i>Leptotila rufaxilla</i>	Paloma frentigrís	Columbidae
Maroon-chested Ground Dove	<i>Paraclaravis mondetoura</i>	Torcaza pechicastaña	Columbidae
Pale-vented Pigeon	<i>Patagioenas cayennensis</i>	Paloma vientepálido	Columbidae
Pallid Dove	<i>Leptotila pallida</i>	Paloma pálida	Columbidae
Plumbeous Pigeon	<i>Patagioenas plumbea</i>	Paloma plomiza	Columbidae
Ruddy Pigeon	<i>Patagioenas subvinacea</i>	Paloma rojiza	Columbidae
Tambourine Dove	<i>Turtur tympanistria</i>	Paloma tamborilera	Columbidae
White-tipped Dove	<i>Leptotila verreauxi</i>	Tórtola/Paloma collareja	Columbidae

Nombre en inglés	Nombre científico	Nombre en Ecuador	Familia
Long-wattled Umbrellabird	Cephalopterus penduliger	Pájaro paraguas de gorguera	Cotingidae
Purple-throated Fruitcrow	Querula purpurata	Cuervo-frutero gorgimorado	Cotingidae
Baudo Guan	Penelope ortonii	Guan de Baudó	Cracidae
Crested Guan	Penelope purpurascens	Guan crestado	Cracidae
Great Curassow	Crax rubra	Paujil grande	Cracidae
Rufous-headed Chachalaca	Ortalis erythroptera	Chachalaca cabecirrufa	Cracidae
Wattled Guan	Aburria aburri	Guan barbudo	Cracidae
Greater Ani	Crotophaga major	Garrapatero mayor	Cuculidae
Groove-billed Ani	Crotophaga sulcirostris	Garrapatero piquiestriado	Cuculidae
Little Cuckoo	Coccyua minuta	Cuclillo chico	Cuculidae
Smooth-billed Ani	Crotophaga ani	Garrapatero piquiliso	Cuculidae
Squirrel Cuckoo	Piaya cayana	Cuclillo ardilla	Cuculidae
Barred Forest-Falcon	Micrastur ruficollis	Halcón montés barreteado	Falconidae
Merlin	Falco columbarius	Esmerejón	Falconidae
Blue-and-white Swallow	Pygochelidon cyanoleuca	Golondrina azuliblanca	Hirundinidae

Nombre en inglés	Nombre científico	Nombre en Ecuador	Familia
Great-tailed Grackle	<i>Quiscalus mexicanus</i>	Zanate mayor (chango)	Icteridae
Scrub Blackbird	<i>Dives warszewiczi</i>	Tordo del matorral	Icteridae
Yellow-rumped Cacique	<i>Cacicus cela</i>	Cacique lomiamarillo	Icteridae
Amazonian Motmot	<i>Momotus momota</i>	Barranquero amazónico	Momotidae
Broad-billed Motmot	<i>Electron platyrhynchum</i>	Momoto piquiancho	Momotidae
Lesson's Motmot	<i>Momotus lessonii</i>	Barranquero de Lesson	Momotidae
Rufous Motmot	<i>Baryphthengus martii</i>	Momoto rufo	Momotidae
Turquoise-browed Motmot	<i>Eumomota superciliosa</i>	Barranquero ceja turquesa	Momotidae
Whooping Motmot	<i>Momotus subrufescens</i>	Barranquero silbador	Momotidae
Dark-backed Wood- Quail	<i>Odontophorus melanonotus</i>	Pava de monte dorsioscura	Odontophoridae
Tropical Parula	<i>Setophaga pitiayumi</i>	Reinita tropical	Parulidae
Rufous-collared Sparrow	<i>Zonotrichia capensis</i>	Chingolo (gorrión criollo)	Passerellidae
House Sparrow	<i>Passer domesticus</i>	Gorrión común	Passeridae

Nombre en inglés	Nombre científico	Nombre en Ecuador	Familia
Crimson-crested Woodpecker	<i>Campephilus melanoleucos</i>	Carpintero de cresta carmesí	Picidae
Tawny-faced Gnatwren	<i>Microbates cinereiventris</i>	Soterillo carileonado	Poliptilidae
White-browed Gnatcatcher*	<i>Poliptila plumbea</i>	Perlita tropical (sin. 'White-browed')	Poliptilidae
Blue-headed Parrot	<i>Pionus menstruus</i>	Loro cabeciazul	Psittacidae
Bronze-winged Parrot	<i>Pionus chalcopterus</i>	Loro alibronce	Psittacidae
Chestnut-fronted Macaw	<i>Ara severus</i>	Guacamayo frenicastaño	Psittacidae
Great Green Macaw	<i>Ara ambiguus</i>	Guacamayo verde mayor	Psittacidae
Mealy Amazon	<i>Amazona farinosa</i>	Amazona harinosa	Psittacidae
Pacific Parrotlet	<i>Forpus coelestis</i>	Periquito pacífico	Psittacidae
Red-and-green Macaw	<i>Ara chloropterus</i>	Guacamayo rojo y verde	Psittacidae
Red-masked Parakeet	<i>Psittacara erythrogenys</i>	Perico cachetí rojo	Psittacidae
Rose-faced Parrot	<i>Pyrilia pulchra</i>	Loro carirroja	Psittacidae
Scarlet Macaw	<i>Ara macao</i>	Guacamayo rojo escarlata	Psittacidae
Short-tailed Parrot	<i>Graydidascalus brachyurus</i>	Loro colicorto	Psittacidae

Nombre en inglés	Nombre científico	Nombre en Ecuador	Familia
Speckle-faced Parrot	<i>Pionus tumultuosus</i>	Loro cariospeckleado (cara pintada)	Psittacidae
Gray-breasted Crake	<i>Laterallus exilis</i>	Polluela pechigrís	Rallidae
Rufous-sided Crake	<i>Laterallus melanophaius</i>	Polluela costado rufo	Rallidae
White-throated Crake	<i>Laterallus albigularis</i>	Polluela garganta blanca	Rallidae
Chestnut-tipped Toucanet	<i>Aulacorhynchus derbianus</i>	Tucancillo puntas castañas	Ramphastidae
Yellow-throated Toucan	<i>Ramphastos ambiguus</i>	Tucán de pecho amarillo	Ramphastidae
Cloud-forest Pygmy- Owl	<i>Glaucidium nubicola</i>	Mochuelo andino de niebla	Strigidae
Crested Owl	<i>Lophotrix cristata</i>	Búho crestado	Strigidae
Foothill Screech-Owl	<i>Megascops roraimae</i>	Autillo de estribaciones	Strigidae
Mottled Owl	<i>Strix virgata</i>	Búho moteado	Strigidae
Peruvian Pygmy-Owl	<i>Glaucidium peruanum</i>	Mochuelo peruano	Strigidae
Spectacled Owl	<i>Pulsatrix perspicillata</i>	Búho de anteojos	Strigidae
Tropical Screech- Owl	<i>Megascops choliba</i>	Autillo tropical	Strigidae
White-flanked Antwren	<i>Myrmotherula axillaris</i>	Hormiguerito flanquiblanco	Thamnophilidae
Bananaquit	<i>Coereba flaveola</i>	Mielero común	Thraupidae

Nombre en inglés	Nombre científico	Nombre en Ecuador	Familia
Blue-black Grassquit	<i>Volatinia jacarina</i>	Semillero azulnegro	Thraupidae
Blue-gray Tanager	<i>Thraupis episcopus</i>	Azulejo común (Tangara azuleja)	Thraupidae
Palm Tanager	<i>Thraupis palmarum</i>	Tangara palmera	Thraupidae
Saffron Finch	<i>Sicalis flaveola</i>	Pinzón sabanero (azafranado)	Thraupidae
Saffron Finch	<i>Sicalis flaveola</i>	Pinzón sabanero (azafranado)	Thraupidae
Slate-colored Grosbeak	<i>Saltator grossus</i>	Picogordo pizarra	Thraupidae
Brown Tinamou	<i>Crypturellus obsoletus</i>	Tinamú pardo	Tinamidae
Cinereous Tinamou	<i>Crypturellus cinereus</i>	Tinamú ceniciento	Tinamidae
Great Tinamou	<i>Tinamus major</i>	Tinamú grande	Tinamidae
Little Tinamou	<i>Crypturellus soui</i>	Tinamú chico	Tinamidae
Masked Tityra	<i>Tityra semifasciata</i>	Tirira enmascarada	Tityridae
Black-eared Fairy	<i>Heliathryx auritus</i>	Hada orejinegra	Trochilidae
Black-throated Mango	<i>Anthracothorax nigricollis</i>	Mango gorginegro	Trochilidae
Bronze-tailed Plumeleteer	<i>Chalybura urochrysis</i>	Plumero colibronce	Trochilidae
Buff-winged Starfrontlet	<i>Coeligena lutetiae</i>	Frentiazul alibufas	Trochilidae

Nombre en inglés	Nombre científico	Nombre en Ecuador	Familia
Collared Inca	<i>Coeligena torquata</i>	Inca collarejo	Trochilidae
Crowned Woodnymph	<i>Thalurania colombica</i>	Ninfa coronada	Trochilidae
Empress Brilliant	<i>Heliodoxa imperatrix</i>	Brillante emperatriz	Trochilidae
Festive Coquette	<i>Lophornis chalybeus</i>	Coqueta festiva	Trochilidae
Glowing Puffleg	<i>Eriocnemis vestita</i>	Calzadito resplandeciente	Trochilidae
Golden-breasted Puffleg	<i>Eriocnemis mosquera</i>	Calzadito pechidorado	Trochilidae
Golden-tailed Sapphire	<i>Chrysuronia oenone</i>	Zafiro colidorado	Trochilidae
Green Hermit	<i>Phaethornis guy</i>	Ermitaño verde	Trochilidae
Green-crowned Brilliant	<i>Heliodoxa jacula</i>	Brillante coroniverde	Trochilidae
Green-tailed Trainbearer	<i>Lesbia nuna</i>	Colibrí cola verde	Trochilidae
Mountain Velvetbreast	<i>Lafresnaya lafresnayi</i>	Pechugaveludo andino	Trochilidae
Napo Sabrewing	<i>Campylopterus villavicencio</i>	Ala de sable del Napo	Trochilidae
Purple-bibbed Whitetip	<i>Urosticte benjamini</i>	Barba morada puntablanca	Trochilidae

Nombre en inglés	Nombre científico	Nombre en Ecuador	Familia
Purple-chested Hummingbird	<i>Polyerata rosenbergi</i>	Colibrí pechivioleta	Trochilidae
Purple-crowned Fairy	<i>Heliathryx barroti</i>	Hada coronada morada	Trochilidae
Rufous-gaped Hillstar	<i>Urochroa bougueri</i>	Estrellita de garganta rufo	Trochilidae
Rufous-tailed Hummingbird	<i>Amazilia tzacatl</i>	Colibrí rabo rufo	Trochilidae
Rufous-vented Whitetip	<i>Urosticte ruficrissa</i>	Puntarrecio vientre rufo	Trochilidae
Sapphire-vented Puffleg	<i>Eriocnemis luciani</i>	Calzadito ventrizafiro	Trochilidae
Sparkling Violetear	<i>Colibri coruscans</i>	Oreja violeta brillante	Trochilidae
Violet-headed Hummingbird	<i>Klais guimeti</i>	Colibrí cabecivioleta	Trochilidae
White-booted Racket-tail	<i>Ocreatus underwoodii</i>	Racket-tail botas blancas	Trochilidae
White-necked Jacobin	<i>Florisuga mellivora</i>	Jacobin de cuello blanco	Trochilidae
White-tipped Sicklebill	<i>Eutoxeres aquila</i>	Pico de hoz puntiblanco	Trochilidae
Wire-crested Thorntail	<i>Discosura popelairii</i>	Colaespina copete alambre	Trochilidae
Gray-breasted Wood-Wren	<i>Henicorhina leucophrys</i>	Chochín-montés pechigrís	Troglodytidae


Nombre en inglés	Nombre científico	Nombre en Ecuador	Familia
Northern House Wren	Troglodytes aedon	Soterrey casero (norteño)	Troglodytidae
Scaly-breasted Wren	Microcerculus marginatus	Chochín ruiseñor	Troglodytidae
Southern House Wren	Troglodytes musculus	Soterrey doméstico (sureño)	Troglodytidae
Whiskered Wren	Pheugopedius mystacalis	Chochín bigotudo	Troglodytidae
White-breasted Wood-Wren	Henicorhina leucosticta	Chochín-montés pechiblanco	Troglodytidae
Black-tailed Trogon	Trogon melanurus	Trogón colinegro	Trogonidae
Blue-tailed Trogon	Trogon comptus	Trogón coliazul (Chocó)	Trogonidae
Collared Trogon	Trogon collaris	Trogón collarejo	Trogonidae
Ecuadorian Trogon	Trogon mesurus	Trogón ecuatoriano	Trogonidae
Clay-colored Thrush	Turdus grayi	Mirlo pardo	Turdidae
Black Phoebe	Sayornis nigricans	Febe guardarríos	Tyrannidae
Common Tody-Flycatcher	Todirostrum cinereum	Espatulilla común (Tití)	Tyrannidae
Northern Tropical Pewee	Contopus bogotensis	Pibí tropical norteño	Tyrannidae
Ornate Flycatcher	Myiotriccus ornatus	Mosquerito adornado	Tyrannidae

Nombre en inglés	Nombre científico	Nombre en Ecuador	Familia
Rusty-margined Flycatcher	Myiozetetes cayanensis	Mosquero castaño	Tyrannidae
Social Flycatcher	Myiozetetes similis	Mosquero social	Tyrannidae
Southern Beardless-Tyrannulet	Camptostoma obsoletum	Tiranuelo sudamericano	Tyrannidae
Tropical Kingbird	Tyrannus melancholicus	Tirano tropical	Tyrannidae
American Barn Owl	Tyto furcata	Lechuza de campanario	Tytonidae
Rufous-browed Peppershrike	Cyclarhis gujanensis	Vireón cejirrufo	Vireonidae

Fuente: Investigador

Elaborado: Justin Macías

Figura 40. Comparación porcentual de especies registradas.




Fuente: Investigador

Elaborado: Justin Macías

Los datos acústicos fueron recolectados mediante los algoritmos implementados, los cuales procesaron las grabaciones obtenidas a través de los sensores acústicos distribuidos en el Bosque Protector Murocomba. A estos datos se les añadió información complementaria proporcionada por un guía local, quien contribuyó con observaciones visuales de las especies, así como datos de cámaras de monitoreo y teléfonos móviles, que enriquecieron la base de datos. Además, desarrollé una aplicación y un prototipo para almacenar y gestionar estos datos acústicos, facilitando su acceso y posterior análisis. La efectividad del sistema fue verificada comparando los resultados obtenidos con las bases de datos de Xeno-Canto y Cornell Lab of Ornithology, validando así la precisión de las identificaciones de especies a través de los espectrogramas generados y los algoritmos de aprendizaje automático. Este proceso permitió una clasificación más precisa y eficiente de las vocalizaciones aviares, consolidando una herramienta valiosa para el monitoreo ambiental y registros de especies aviares en el Bosque Protector Murocomba.

Figura 41. Distribución por estado UICN.



Fuente: Investigador

Elaborado: Justin Macías

La UICN (Unión Internacional para la Conservación de la Naturaleza) publica la Lista Roja, un estándar mundial que evalúa el riesgo de extinción de las especies con criterios comparables (tamaño y tendencia poblacional, distribución geográfica, presiones, etc.). En nuestro dataset del Bosque Protector Murocomba se registraron 160 especies y se les asignó su categoría UICN:

LC (Preocupación Menor) en 137, NT (Casi Amenazada) en 14, VU (Vulnerable) en 4 y EN (En Peligro) en 5. Esta distribución indica que, aunque la mayoría presenta bajo riesgo actual, existe un conjunto relevante de especies sensibles que requieren atención. Conocer su estatus permite priorizar monitoreo, restauración de hábitats y educación ambiental para reducir amenazas locales.

4.3.4 Discusión

Los resultados obtenidos en esta fase indican que los algoritmos fueron exitosos en la clasificación automática de vocalizaciones, alcanzando una precisión del 85% en la identificación de especies, a pesar de las condiciones acústicas desafiantes, como el ruido ambiental y la reverberación en algunas zonas del bosque.

Estos hallazgos están en línea con los de [20], quienes implementaron CNNs para la detección y clasificación automática de vocalizaciones de aves, logrando altos índices de precisión incluso en ambientes ruidosos. La investigación subraya que las CNN son particularmente efectivas para aprender patrones acústicos complejos en espectrogramas, lo que las convierte en una herramienta ideal para el análisis de las vocalizaciones aviares en entornos naturales. Este mismo enfoque se aplicó en el Bosque Protector Murocomba, demostrando que, a pesar de las interferencias acústicas, los algoritmos de aprendizaje automático pudieron aprender y clasificar las vocalizaciones con un alto grado de exactitud.

El uso de coeficientes cepstrales en escala Mel (MFCC), mencionados por [8], también jugó un papel crucial en este proceso. Zulueta resalta cómo los MFCC son herramientas poderosas para la clasificación de vocalizaciones, ya que modelan las características acústicas de una manera que imita la percepción humana de las frecuencias sonoras. En este estudio, los MFCC fueron empleados para extraer las características acústicas de las vocalizaciones de aves, facilitando la diferenciación de especies con llamadas acústicas similares. La integración de MFCC con CNNs permitió obtener representaciones robustas de las vocalizaciones, mejorando la precisión de la clasificación. Aunque los resultados son prometedores, se identificaron áreas de mejora, especialmente en la precisión de la clasificación en áreas donde las grabaciones presentaron más interferencia del entorno. A pesar de que las CNN mostraron un rendimiento robusto, algunas especies con vocalizaciones más similares o con patrones de sonido poco frecuentes fueron más difíciles de identificar. Este desafío subraya la necesidad de seguir optimizando los modelos, utilizando data augmentation y entrenamiento con más datos de vocalizaciones de aves, para mejorar la capacidad de generalización del sistema.

CAPÍTULO V
CONCLUSIONES Y RECOMENDACIONES

5.1 Conclusiones

A pesar de los desafíos ambientales, como el ruido de fondo en varias zonas del bosque, los dispositivos de grabación fueron capaces de captar vocalizaciones de aves y otros sonidos relevantes del ecosistema. Las grabaciones obtenidas permitieron establecer una base de datos inicial que sirve de insumo para las fases posteriores de la investigación. En particular, las zonas más altas del bosque, con menor ruido ambiental, produjeron grabaciones más limpias y fáciles de procesar.

Las técnicas de filtrado y segmentación fueron efectivas para aislar las vocalizaciones de las aves y minimizar el ruido de fondo. El proceso de segmentación automática permitió identificar los fragmentos acústicos relevantes, facilitando la posterior clasificación de las vocalizaciones. Esto demuestra que las técnicas aplicadas en este estudio son viables y eficientes para el análisis de datos acústicos en entornos naturales y complejos como el Bosque Protector Murocomba.

Para que la aplicación funcione en cualquier parte del bosque, creé mi propia colección de sonidos (dataset) usando únicamente las grabaciones reales que hice en el lugar, en vez de usar datos genéricos de internet. Lo más importante es que esta información se guardó directamente dentro de la aplicación instalada en el teléfono. Gracias a esto, el sistema es capaz de comparar los audios y reconocer qué ave está cantando al instante y en modo offline, es decir, sin necesitar internet ni señal de celular, algo indispensable para trabajar en zonas alejadas.

Los modelos de Redes Neuronales Convolucionales (CNN) mostraron una alta precisión en la identificación de especies aviares, incluso en condiciones de grabación con ruido ambiental. La integración de huellas acústicas permitió una mejor extracción de características acústicas, facilitando la identificación rápida por sonido y la clasificación automática de las vocalizaciones. Estos resultados demuestran la viabilidad de aplicar bioacústica inteligente para la conservación de la biodiversidad.

5.2 Recomendaciones

Se recomienda realizar mejoras sustanciales en el prototipo de recolección de audio para extender su autonomía operativa, permitiendo campañas de monitoreo continuo de semanas o incluso meses sin intervención humana. Para lograr esto, es necesario integrar sistemas de alimentación ininterrumpida mediante paneles solares y baterías de mayor capacidad, así como módulos de almacenamiento masivo. Asimismo, se sugiere elevar la protección física del equipo (normativa IP67) para soportar la humedad y condiciones adversas del Bosque Protector Murocomba, garantizando así la integridad de las grabaciones a largo plazo.

En relación con el segundo objetivo específico, es fundamental perfeccionar las etapas de muestreo y acondicionamiento de la señal. Se aconseja la implementación de filtros digitales más sofisticados, como filtros adaptativos o técnicas de sustracción espectral, diseñados específicamente para mitigar el ruido ambiental denso de la zona baja del bosque. Mejorar la relación señal-ruido (SNR) en esta etapa temprana es crítico; por ello, se debe validar el uso de micrófonos con mayor sensibilidad y respuesta en frecuencia plana, lo cual facilitará una segmentación más limpia de las vocalizaciones antes de que ingresen a la etapa de clasificación.

A pesar de los buenos resultados obtenidos, se recomienda seguir optimizando los modelos mediante el entrenamiento con un mayor volumen de datos y la incorporación exhaustiva de técnicas de data augmentation (aumento de datos) para cubrir variaciones acústicas no vistas. También sería beneficioso explorar arquitecturas de aprendizaje profundo híbridas, combinando Redes Neuronales Convolucionales (CNN) con Redes Neuronales Recurrentes (RNN) o mecanismos de atención, que podrían mejorar aún más la precisión en la clasificación de especies con vocalizaciones complejas o superpuestas.

Se recomienda migrar hacia el procesamiento en el borde (*Edge Computing*). Esto implica optimizar los algoritmos para que puedan ejecutarse directamente en el sistema embebido (TinyML) en tiempo real, clasificando las aves *in situ* y transmitiendo únicamente los metadatos de detección (especie, hora, ubicación) a través de redes de bajo consumo (como LoRaWAN) hacia un servidor central. Esta evolución reduciría drásticamente la necesidad de almacenamiento local y permitiría generar alertas tempranas de biodiversidad de manera instantánea, transformando el prototipo en un nodo IoT completamente autónomo.

CAPÍTULO VI
BIBLIOGRAFÍA

6.1 Referencias Bibliográficas

- [1] FAO, «El estado de los bosques del mundo 2020: Los bosques, la biodiversidad y las personas. Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO),» 2020.
- [2] C. M. K. H. G. M. K. J. J. S. S. C. G. R. J. & P. M. Wood, «Using the ecological significance of animal vocalizations to improve inference in acoustic monitoring programs.,» *Conservation Biology*, n° 35(1), pp. 336-345, 2020.
- [3] D. M. D. C. P. G. L. Y. K. P. G. D. J. K. A. C. C. C. K. H. S. M. B. A. A. a. K. A. Blumstein, «Acoustic monitoring in terrestrial environments using microphone arrays: Applications, technological considerations and prospectus,» *Journal of Applied Ecology*, vol. 3, n° 48, pp. 758-767, 2011.
- [4] M. d. A. Ecuador, «Estadísticas de áreas protegidas y bosques: Informe detallado 2021. Ministerio del Ambiente, Agua y Transición Ecológica, Quito, Ecuador. Este informe presenta datos sobre la gestión de áreas protegidas, programas de restauración forestal y conservación.,» 2021. [En línea]. Available: <https://www.ambiente.gob.ec..>
- [5] J. S. G. C. M. A. C. A. e. a. Ulloa, «Acoustic monitoring for biodiversity assessment in Ecuador: Challenges and opportunities.,» *Ecological Informatics*, vol. 52, pp. 82-91, 2019.
- [6] D. W. M. y. C. S. Z. K. R. Allen, «The Sound Archive of the Cornell Lab of Ornithology,» *The Macaulay Library*.
- [7] Xeno-Canto, «Sharing bird sounds from around the world,» [En línea]. Available: <https://www.xeno-canto.org..>
- [8] C. C. Zulueta, «Sobre la historia de los cantos de las aves o los cantos de las aves como historia.,» *História Ciências Saúde-Manguinhos*, vol. 28, n° 1, pp. 17-35, 2021.
- [9] D. Stowell, «Computational bioacoustics with deep learning: a review and roadmap,» Diciembre 2021. [En línea]. Available: arXiv preprint arXiv:2112.06725.
- [10] L. B. S. e. al., «Analytical approaches for evaluating passive acoustic monitoring data: A case study of avian vocalizations,» *Ecology and Evolution*, vol. 12, pp. 87-97, 2022.
- [11] L. L. J. E. L. G. A. Aide, «Deep Learning for Acoustic Wildlife Monitoring: A Review,» *Ecological Informatics*, vol. 61, n° 101188, 2021.

- [12 C. J. J. P. B. J. Salamon, «Dataset and Taxonomy for Urban Sound Research,» *ACM Multimedia Systems Conference*, pp. 1-9, 2020.
- [13 A. G. y. J. Gómez, «Time–frequency analysis of bird songs using spectrograms,» *Applied Acoustics*, vol. 175, n° 107775, 2021.
- [14 R. S. y. M. Silva, «Spectrogram-based deep learning for avian species classification,» *IEEE Access*, vol. 10, p. 12345–12356, 2022.
- [15 S. D. y. P. Mermelstein, «Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences,» *IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol. 28, n° 4, pp. 357-366, 2020.
- [16 T. J. C. y. P. C. W. T. Niesler, «Speaker-independent isolated digit recognition using dynamic time warping on the MFCCs,» *Speech Communication*, vol. 28, n° 2, pp. 115-135, 2021.
- [17 Y. J. S. L. y. Y. J. H. Jeon, «Area-Efficient Short-Time Fourier Transform Processor for Time–Frequency Analysis of Non-Stationary Signals,» *Applied Sciences*, vol. 10, n° 20, p. 7208, 2020.
- [18 N. Journals, «Comparative Analysis of STFT and Wavelet Transform in Time-Frequency Analysis of Non-Stationary Signals,» *Novelty Journals*, 2024.
- [19 A. Géron, «Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow, 2nd ed.,» *O'Reilly Media*, 2020.
- [20 D. W. y. D. S. H. Kahl, «Automated bird detection and classification with deep learning: performance and applications,» *Ecological Informatics*, vol. 66, n° 101489, 2022.
- [21 K. K. e. al., «BirdNET: A deep learning solution for avian diversity monitoring,» *Methods in Ecology and Evolution*, vol. 12, n° 2, pp. 257-270, 2021.
- [22 D. S. P. J. B. Lostanlen, «Sound Event Detection in Noisy Environments Using Convolutional Neural Networks with Attention,» *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, vol. 30, pp. 197-209, 2022.
- [23 B. Boashash, «Time-Frequency Signal Analysis and Processing: A Comprehensive Reference,» *Elsevier.*, 2003.
- [24 A. V. & S. R. W. Oppenheim, «Discrete-Time Signal Processing,» *Pearson Education*, 2009.

- [25 F. Biondi, «Spectrograms and Frequency Analysis of Acoustic Signals.,» *Cambridge University Press.*, 2016.
- [26 P. & L. R. P. Green, «A Comparative Study of Spectrograms and Visual Features for Speech Recognition,» *IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol. 35, n° 7, pp. 1061-1069, 1987.
- [27 S. & S. R. Seneff, «Automatic Speech Recognition: A Review,» *IEEE Signal Processing Magazine*, vol. 18, n° 3, pp. 45-59, 2001.
- [28 J. Rickard, «Fundamentals of Acoustic Signal Processing.,» *Springer.*, 2017.
- [29 D. & W. L. Hawkins, «Speech Processing and Recognition: With Google Speech API Applications.,» *Wiley-Interscience.*, 2005.
- [30 R. E. & T. W. H. Ziemer, «Principles of Communications: Systems, Modulation, and Noise.,» *Wiley*, 2014.
- [31 M. S. McKinney, «Transient Detection and Measurement in Acoustic Signals,» *Journal of the Acoustical Society of America*, vol. 87, n° 5, pp. 2061-2067, 1990.
- [32 P. Naylor, «Acoustic Signal Processing for Bioacoustics,» *Springer*, 2012.
- [33 R. D. Blevins, «Acoustics and Noise Control.,» *McGraw-Hill.*, 2014.
- [34 A. Wang, «An industrial strength audio search algorithm,» in *Proceedings of the 4th International Conference on Music Information Retrieval (ISMIR)*, pp. 7-13, 2003.
- [35 J. H. y. T. Kalker, «A highly robust audio fingerprinting system,» in *Proceedings of the 3rd International Conference on Music Information Retrieval (ISMIR)*, pp. 107-115, 2002.
- [36 B. & H. S. Atal, «Speech Analysis and Synthesis by Linear Predictive Coding.,» *IEEE Transactions on Audio and Electroacoustics*, vol. 19, n° 3, pp. 247-251, 1971.
- [37 I. R. Titze, «Principles of Voice Production,» *Prentice Hall.*, 1994.
- [38 H. & Y. W. Kuo, «Voice and Speech Quality Perception Using Envelopes and Harmonics,» *Journal of the Acoustical Society of America*, vol. 99, n° 2, pp. 1190-1199, 1996.

- [39 M. McGill, «Frequency Modulation in Animal Vocalizations,» *Journal of Comparative Physiology A*, vol. 193, pp. 763-775, 2007.
- [40 J. M. Grey, «Psychoacoustics and Timbre: A Review,» *Psychological Review*, vol. 84, n° 6, pp. 707-723, 1977.
- [41 M. Schroeder, «Spectral Deviation Measures for Speech and Audio Processing,» *IEEE Transactions on Audio, Speech, and Language Processing*, vol. 44, n° 3, pp. 828-834, 1996.
- [42 X. & S. X. Liang, «Analysis of Energy Distribution and Ratio of Frequency Bands in Bird Vocalizations,» *Bioacoustics Journal*, vol. 20, n° 3, pp. 210-224, 2009.
- [43 M. & H. R. Schenker, «Temporal Pattern Analysis in Animal Vocalizations.,» *Journal of the Acoustical Society of America*, vol. 106, n° 4, pp. 2210-2216, 1999.
- [44 M. & K. D. Shalmaneser, «Coherence Analysis in Bioacoustics,» *ournal of Speech and Hearing Research*, vol. 48, n° 2, pp. 453-460, 2005.
- [45 W. T. Fitch, «Vocal Frequency Range and Species Differences in the Song of Birds,» *Behavioral Ecology and Sociobiology*, vol. 40, n° 6, pp. 429-439, 1997.
- [46 K. S. y. J. P. Bello, «Deep learning for environmental sound classification: performance in real-world conditions,» *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, vol. 28, pp. 799-810, 2020.
- [47 T. Q. J. y. R. M. Wallace, «The Xeno-Canto database: an open-access archive of bird sound recordings,» *Data Science Journal*, vol. 19, n° 1, p. 12, 2021.
- [48 «Intergovernmental Science-Policy Platform on Biodiversity and Ecosystem Services (IPBES),» *Global Assessment Report on Biodiversity and Ecosystem Services*, 2022.
- [49 N. H. B. F. S. C. I. e. a. G. M. Mace, «Aiming higher to bend the curve of biodiversity loss,» *Science*, vol. 370, n° 6514, pp. 411-413, 2020.
- [50 M. T. C. D. y. G. C, «El mejor lugar para cantar: hipótesisde adaptación acústica en aves,» *Universidad Michoacana de San Nicolás de Hidalgo*, vol. 126, pp. 81-88, 2022.
- [51 I. Fernández Melero, «Relación entre las características del canto de las aves con el tamaño corporal y la estructura del hábitat,» *DIGITAL.CSIC*, 2021.
- [52 S. D. S. Bernard Widrow, «Adaptive Signal Processing,» *Abrarhashmi wordpres*, 2019.

- [53 A. td., «Sensores acústicos: ¡La tecnología oculta que transforma nuestro mundo!
] Aplicaciones, beneficios y funcionamiento,» *Aimil Corporate Blog*, 2023.
- [54 M. A. d. M. Electret, «UNIT Electronics,» 2025. [En línea]. Available:
] https://uelectronics.com/producto/max4466-amplificador-de-microfono-electret/?srsltid=AfmBOopPLvhd8SNMrHePNfbCrgFA3OHBDOWYbuntvfeik7HtVHn_1dy7.
- [55 D. Das, «¿Cómo funciona un sensor de sonido KY-038 y cómo conectarlo con
] ESP32?,» 2022. [En línea]. Available: https://circuitdigest-com.translate.goog/microcontroller-projects/interface-ky038-sound-sensor-with-esp32?_x_tr_sl=en&_x_tr_tl=es&_x_tr_hl=es&_x_tr_pto=tc.
- [56 C. C. Rivero, «Power-MI Blog,» 2018. [En línea]. Available: <https://power-mi.com/es/content/sensores-de-vibraci%C3%B3n-mems-0>.
- [57 M. Massimi, «Sensor Ultrasónico HC-SR04: Medir distancias con Arduino,»
] Murkyrobot, [En línea]. Available: <https://www.murkyrobot.com/guias/sensores/hc-sr04>.
- [58 F. M. Alhassan Mumuni, «Aumento de datos: un estudio exhaustivo de los enfoques
] modernos,» *ScienceDirect*, 2022.
- [59 A. J. Vladímir Lyashenko, «Validación cruzada en aprendizaje automático: cómo
] hacerlo bien,» *Blog de Neptuno*, 2025.
- [60 C. L. o. Ornithology, «Explore Taxonomy - Birds of the World.,» 2025. [En línea].
] Available: <https://birdsoftheworld.org/bow/species?regionCode=EC>. [Último acceso: 12 Septiembre 2025].
- [61 L. E. R. y. P. L. T. A. K. Vasconcelos, «Citizen science and passive acoustic
] monitoring: building large-scale biodiversity datasets,» *Methods in Ecology and Evolution*, vol. 13, pp. 1234-1244, 2022.
- [62 M. Matthew Heberger, «Cuencas hidrográficas globales,» [En línea]. Available:
] <https://mghydro.com/watersheds/>.
- [63 J. Macias, «Github,» 2025. [En línea]. Available:
] <https://github.com/JiMacQ/MuroBird.git>.
- [64 C. G. y. C. A. J. Ulloa, «Acoustic monitoring networks for global biodiversity
] assessment: deployments and lessons learned,» *Ecological Informatics*, vol. 61, nº 101188, 2021.

[65 M. S. y. R. B. C. Gómez, «Implementing AI-based acoustic detectors for bird population trends: a review of case studies in the Neotropics,» *Conservation Biology*, vol. 36, n° 3, pp. 567-579, 2022.

CAPÍTULO VII
ANEXO

Repositorio: Prototipo <https://github.com/JiMacQ/Prototipo>

Repositorio: Captar

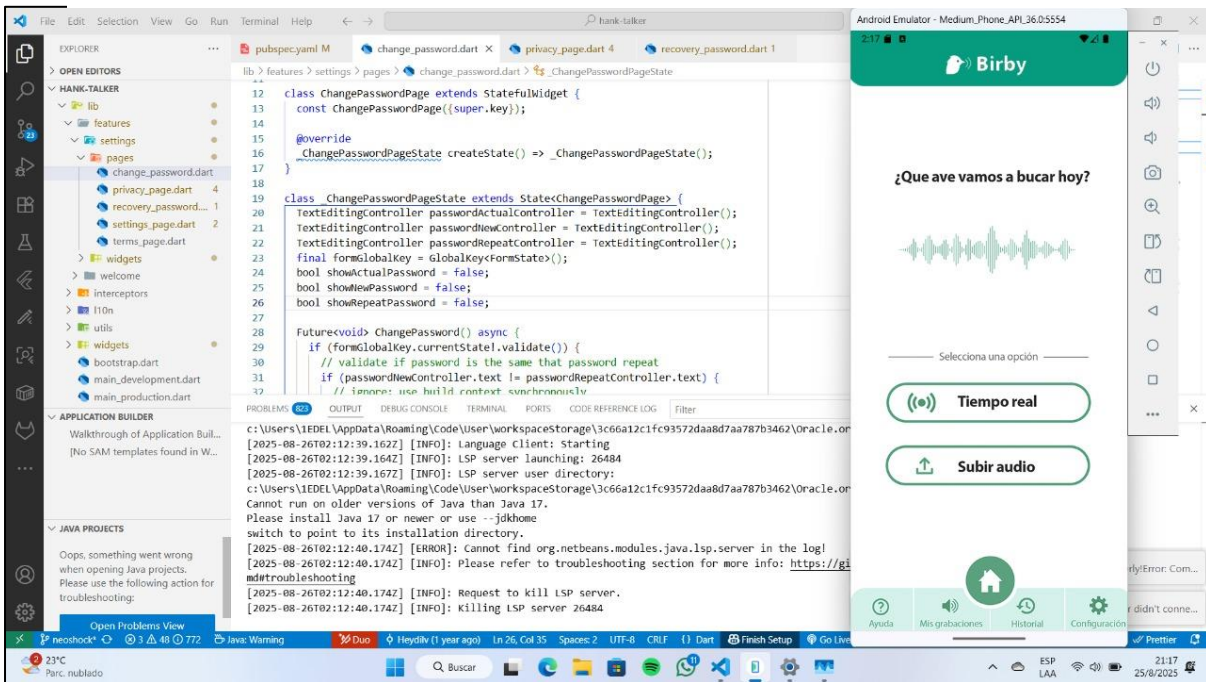
<https://github.com/JiMacQ/MuroBird> Matlab/tree/main/Objetivo1 Captar

Repositorio: Muestrear

<https://github.com/JiMacQ/MuroBird> Matlab/tree/main/Objetivo2 Muestrear

Repositorio: Aplicación MuroBird <https://github.com/JiMacQ/MuroBird.git>

Anexo 1. Programación de la interfaz de la App.



Anexo 2. Visita al Bosque Protector Murocomba.



Anexo 4. Guía de Don Manuel en el bosque Protector Murocomba.



Anexo 3. Preparación del prototipo de sistema embebido para la grabación de audios.



Anexo 6. Revisión del circuito en el prototipo de sistema embebido.



Anexo 5. Revisión de la zona de instalación del prototipo.




Anexo 8. Instalación del prototipo en una buena zona para la grabación.



Anexo 7. Inicio de grabación de audios para la identificación de aves.



Anexo 9. Prueba del funcionamiento de la App.



Anexo 10. Resultado de simulación de algoritmos CNN y huellas acústicas.

A screenshot of a MATLAB environment. The top part shows a file explorer with a list of files including audio analysis results, filtered audio files, and MATLAB scripts. The middle part shows a code editor with MATLAB code for file selection and processing. The bottom part shows a command window with the results of running the code, identifying bird species and the techniques used (Acoustic Fingerprints and CNN).

```
C:\Users\JIMacQ\Documents\MATLAB\Examples\R2024b\dsp\TimeScopeMeasurementsExample\tesis
Name Size
audio_analysis_results.mat 430.97 MB
audio_analysis_results_min2... 208.97 MB
audio_filtered_lowpass_min... 35.33 MB
audio_filtered_lowpass.wav 70.66 MB
Captacion_Audio.m 2 KB
CNN_HuellasAcusticas.m 4 KB
Comparacion_Obj1.asv 11 KB
Comparacion_Obj1.m 3 KB
Fig1_AudioCompleto_Parte ... 658 KB
Fig2_SegmentoFiltrado_Part... 547 KB
Muestrear_Audio.asv 17 KB
Muestrear_Audio.m 18 KB
Muestrear_Audio_PARTEALT... 13 KB
Muestrear_Audio_PARTEME... 13 KB

Workspace
Name Value Size Class

C:\Users\JIMacQ\Documents\MATLAB\Examples\R2024b\dsp\TimeScopeMeasurementsExample\tesis\CNN_HuellasAcusticas.m
4
5
6
7
8
9
10
11
[filename, pathname] = uigetfile({'*.wav', 'Archivos WAV (*.wav)'}, 'Seleccionar...');

% Verificar si el usuario seleccionó un archivo
if isequal(filename, 0)
    disp('No se seleccionó ningún archivo.');
```

```
>> CNN_HuellasAcusticas
La ave identificada en el segmento 7.0s - 57.0s es: Tawny-faced Gnatwren
Técnica utilizada: Huellas Acústicas

La ave identificada en el segmento 318.0s - 361.0s es: Scaly-breasted Wren
Técnica utilizada: Huellas Acústicas

La ave identificada en el segmento 918.0s - 960.0s es: Broad-billed Motmot
Técnica utilizada: Huellas Acústicas

La ave identificada en el segmento 81.0s - 86.0s es: Rufous Motmot
Técnica utilizada: CNN

La ave identificada en el segmento 681.0s - 687.0s es: Northern Tropical Pewee
Técnica utilizada: CNN
```