



**EDUCACIÓN**

SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO  
NACIONAL DE MÉXICO

# Tecnológico Nacional de México

Centro Nacional de Investigación  
y Desarrollo Tecnológico

## Tesis de Maestría

Técnicas de reconocimiento y clasificación mediante  
información acústica de especies animales

presentada por

**Ing. Carlos Daniel Solorzano Madrigal**

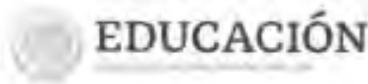
como requisito para la obtención del grado de  
**Maestra en Ciencias en Ingeniería  
Electrónica**

Director de tesis

**Dr. José Francisco Gómez Aguilar**

Cuernavaca, Morelos, México. Agosto de 2024.





Centro Nacional de Investigación y Desarrollo Tecnológico  
Subdirección Académica

Cuernavaca, Mor., 25/agosto/2024  
No. De Oficio: SAC/246/2024  
Asunto: Autorización de impresión de tesis

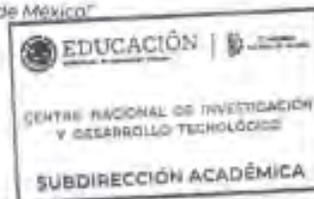
**CARLOS DANIEL SOLORZANO MADRIGAL  
CANDIDATO AL GRADO DE MAESTRO EN CIENCIAS  
EN INGENIERÍA ELECTRÓNICA  
P R E S E N T E**

Por este conducto, tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado **"Técnicas de Reconocimiento y Clasificación mediante Información Acústica de Especies Animales"**, ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.

Esperando que el logro del mismo sea acorde con sus aspiraciones profesionales, reciba un cordial saludo.

**ATENTAMENTE**

Excelencia en Educación Tecnológica®  
"Conocimiento y tecnología al servicio de México"



**CARLOS MANUEL ASTORCA ZARAGOZA  
SUBDIRECTOR ACADÉMICO**

C. C. P. Departamento de Ingeniería Electrónica  
Departamento de Servicios Escolares

CMAZ/lmz



Oficina Intermedia Insólita S/A, Cal. Palmira, E. P. 52450, Cuernavaca, México  
Tel: (5) (777) (627777), ext. 4104, e-mail: acad.cenidet@tecnomexico.mx | cenidet.com.mx



**2024**  
Felipe Carrillo  
PUERTO

# Agradecimientos

Agradezco a la existencia por permitirme estar en este momento de mi vida y poder pasar por esta experiencia.

Agradezco a mi madre, a mi hermano, a mi abuelo, a mi tía y a toda mi familia por su apoyo incondicional, por confiar en mí y por motivarme día con día para continuar con mi desarrollo personal y académico.

A mi pareja Jenifer Jiménez por su apoyo incondicional, paciencia, amor, acompañamiento, decisión y por creer en mí e impulsarme a ser mejor cada día.

Agradezco a mi asesor Dr. José Francisco Gómez Aguilar, quien me apoyo en este proceso de maestría y me ha orientado en el desarrollo de este trabajo de investigación.

A mis revisores el Dr. Juan Reyes Reyes y el Dr. Carlos Daniel García Beltrán, quienes me brindaron amablemente observaciones y comentarios en este trabajo de tesis.

A mis compañeros de Héctor Cortes y Felipe Avalos por instruirme y apoyarme en este proceso

A mis amigos Elías Ramos y Elías Alejandro Ramírez por los buenos momentos vividos en el tiempo de maestría.

Agradezco al CONACYT por el apoyo económico brindado, al Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET) y Tecnológico Nacional de México (TecNM) por abrirme las puertas de las instalaciones para realizar mis estudios de maestría y a su personal por sus amables atenciones que recibí.

# Resumen

Este documento presenta una metodología innovadora para la clasificación de señales bioacústicas, utilizando la Transformada Fraccionaria de Fourier (FRFT) y redes neuronales. La metodología propuesta fue evaluada con sonidos de anuros y cigarras, alcanzando una alta precisión de clasificación.

El monitoreo bioacústico es crucial para la conservación de ecosistemas, permitiendo la identificación y seguimiento no invasivo de especies clave. La bioacústica, que investiga los sonidos producidos por organismos vivos, enfrenta desafíos como la variabilidad estacional, el ruido ambiental y las similitudes morfológicas entre especies. La aplicación de FRFT aborda estos retos al proporcionar una representación detallada de las características temporales y frecuenciales de los sonidos, facilitando una clasificación más precisa.

La metodología integrada, que combina FRFT con redes neuronales, permite un análisis exhaustivo y una clasificación efectiva de las señales bioacústicas. Este enfoque no solo mejora la precisión en la identificación de especies, sino que también ofrece una herramienta robusta para el monitoreo y la conservación de la biodiversidad en diferentes contextos ecológicos. La tesis demuestra que la combinación de estas técnicas avanzadas supera las limitaciones tradicionales y contribuye significativamente al desarrollo de métodos no invasivos para el estudio y la preservación de los ecosistemas.

# Abstract

This document presents an innovative methodology for classifying bioacoustic signals using Fractional Fourier Transform (FRFT) and neural networks. The proposed method was evaluated with sounds from frogs (anurans) and cicadas, achieving high classification accuracy.

Bioacoustic monitoring is crucial for ecosystem conservation, enabling the non-invasive identification and tracking of key species. Bioacoustics, which studies the sounds produced by living organisms, faces challenges such as seasonal variability, environmental noise, and morphological similarities between species. The application of FRFT addresses these challenges by providing a detailed representation of the temporal and frequency characteristics of sounds, facilitating more precise classification.

The integrated methodology, combining FRFT with neural networks, allows for comprehensive analysis and effective classification of bioacoustic signals. This approach not only enhances species identification accuracy but also offers a robust tool for biodiversity monitoring and conservation across various ecological contexts. The thesis demonstrates that the combination of these advanced techniques overcomes traditional limitations and significantly contributes to the development of non-invasive methods for studying and preserving ecosystems.

# Índice

Índice	IV
Índice de figuras	VI
Índice de tablas	VIII
<b>1. Introducción</b>	<b>1</b>
1.1. Antecedentes . . . . .	1
1.2. Estado del arte . . . . .	3
1.3. Planteamiento del problema . . . . .	6
1.4. Justificación . . . . .	7
1.5. Hipótesis . . . . .	8
1.6. Objetivos . . . . .	8
1.6.1. Objetivo general . . . . .	8
1.6.2. Objetivos específicos . . . . .	8
1.7. Metas . . . . .	8
1.8. Alcance . . . . .	9
1.8.1. Metodología . . . . .	9
1.8.2. Aportación . . . . .	10
<b>2. Marco Teórico</b>	<b>11</b>
2.1. Bioacústica . . . . .	11
2.1.1. Canto de Anuros . . . . .	13
2.1.2. Canto de cigarras . . . . .	15
2.2. Cálculo Fraccionario . . . . .	18
2.2.1. Función Gamma . . . . .	18
2.2.2. Función de Mittag-Leffler . . . . .	19
2.2.3. Derivada de Riemann-Liouville . . . . .	19
2.2.4. Definición de Grünwald-Letnikov . . . . .	19
2.2.5. Definición de Liouville-Caputo . . . . .	19
2.2.6. Definición de Atangana-Baleanu-Caputo . . . . .	20
2.3. Procesamiento de señales . . . . .	20
2.3.1. Filtro pasabanda banda . . . . .	21
2.3.2. Transformadas Integrales . . . . .	21

2.3.3.	Transformada de Fourier . . . . .	22
2.3.4.	Transformada Fraccionaria de Fourier . . . . .	22
2.3.5.	Transformada wavelet . . . . .	23
2.4.	Clasificación . . . . .	23
2.4.1.	Redes neuronales artificiales . . . . .	24
<b>3.</b>	<b>Clasificación de señales bioacústicas</b>	<b>27</b>
3.1.	Clasificación de cantos de anuros . . . . .	28
3.1.1.	Base de datos . . . . .	30
3.1.2.	Preprocesamiento . . . . .	35
3.1.3.	Extracción de características . . . . .	38
3.1.4.	Entrenamiento . . . . .	51
3.1.5.	Resultados . . . . .	52
3.2.	Clasificación de sonidos de cigarras . . . . .	54
3.2.1.	Zumbido de cigarras . . . . .	55
3.2.2.	Descripción de la base de datos . . . . .	55
3.2.3.	Preprocesamiento y Extracción de Características . . . . .	58
3.2.4.	Clasificación . . . . .	63
<b>4.</b>	<b>Conclusiones</b>	<b>65</b>
<b>5.</b>	<b>Trabajos futuros</b>	<b>67</b>
	<b>Bibliografía</b>	<b>68</b>
	<b>A. Producto de investigacion</b>	<b>79</b>
	<b>B. Pseudocódigos</b>	<b>81</b>

# Índice de figuras

2.1. Descomposición wavelet 3 niveles. . . . .	24
2.2. Neurona de McCulloch-Pitts . . . . .	25
3.1. Esquema de metodología general de solución . . . . .	27
3.2. Diagrama de taxonomía de anuros . . . . .	29
3.3. Familia Bufonidae. . . . .	31
3.4. Familia Hylidae. . . . .	31
3.5. Familia Centrolenidae. . . . .	32
3.6. Familia Craugastoridae. . . . .	32
3.7. Familia Eleutherodactylidae. . . . .	33
3.8. Familia Leptodactylidae. . . . .	33
3.9. Familia Ranidae. . . . .	34
3.10. Familia Rhynophrinidae. . . . .	34
3.11. Comparación de una señal con ruido ambiental y su filtrado. . . . .	37
3.12. Craugastor SP1. . . . .	39
3.13. Craugastor SP2. . . . .	39
3.14. Craugastor SP3. . . . .	39
3.15. Craugastor SP4. . . . .	39
3.16. Craugastor SP5. . . . .	39
3.17. Comparación de los espectrogramas de especies de anuros. . . . .	40
3.18. Espectrograma de canto Craugastor Sp1. . . . .	40
3.19. Espectrograma de canto Craugastor Sp2. . . . .	41
3.20. Espectrograma de canto Craugastor Sp3. . . . .	41
3.21. Espectrograma de canto Craugastor Sp4. . . . .	42
3.22. Espectrograma de canto Craugastor Sp5. . . . .	42
3.23. Visualización de diferentes funciones wavelet madre. . . . .	43
3.24. Descomposición Wavelet nivel 1 de cantos anuros con ventana db4. . . . .	44
3.25. Descomposición Wavelet nivel 1 de cantos anuros con ventana sym4. . . . .	44
3.26. Descomposición Wavelet nivel 1 de cantos anuros con ventana db8. . . . .	45
3.27. Descomposición Wavelet nivel 1 de cantos anuros con ventana sym8. . . . .	45
3.28. Descomposición Wavelet nivel 2 de cantos anuros con ventana db4. . . . .	46
3.29. Descomposición Wavelet nivel 2 de cantos anuros con ventana sym4. . . . .	46
3.30. Descomposición Wavelet nivel 2 de cantos anuros con ventana db8. . . . .	47

3.31. Descomposición Wavelet nivel 2 de cantos anuros con ventana sym8. . . . .	47
3.32. Descomposición Wavelet nivel 3 de cantos anuros con ventana db4. . . . .	48
3.33. Descomposición Wavelet nivel 3 de cantos anuros con ventana sym4. . . . .	48
3.34. Descomposición Wavelet nivel 3 de cantos anuros con ventana db8. . . . .	49
3.35. Descomposición Wavelet nivel 3 de cantos anuros con ventana sym8. . . . .	49
3.36. Características FRFT nivel de descomposición Wavelet nivel 2 cantos anuros. . .	50
3.37. Características FRFT nivel de descomposición Wavelet nivel 3 cantos anuros. . .	50
3.38. Comparativa de las características empleadas con el caso clásico y la señal original.	53
3.39. Matriz de confusión por el clasificador para la etapa de prueba. . . . .	54
3.40. Señales de sonidos de cigarras. . . . .	57
3.41. Comparación de los espectrogramas de las clases de cigarras . . . . .	58
3.42. Descomposición Wavelet nivel 1. . . . .	59
3.43. Descomposición Wavelet nivel 2. . . . .	59
3.44. Descomposición Wavelet nivel 3. . . . .	60
3.45. Descomposición Wavelet nivel 4. . . . .	60
3.46. Descomposición Wavelet nivel 5. . . . .	61
3.47. Características de cigarras de nivel descomposición 2 en dominio de Fourier frac-	
cionario. . . . .	62
3.48. Características de cigarras de nivel descomposición 3 en dominio de Fourier frac-	
cionario. . . . .	62
3.49. Matriz de confusión obtenida por la red neuronal entrenada para la clasificación	
de cigarras en base a señales acústicas. . . . .	64

# Índice de tablas

2.1. Generalidades en bioacústica . . . . .	12
2.2. Herramientas recomendadas en la literatura. . . . .	13
3.1. Rangos de frecuencia de los sonidos de anuros considerados. . . . .	35
3.2. Numero de neuronas y funciones de activación utilizadas por capa para la red neuronal entrenada. . . . .	51
3.3. Comparación de la metodología empleada con su equivalente de orden entero y la clasificación con los datos en el dominio temporal. . . . .	54
3.4. Características de señales acústicas de las cigarras. . . . .	56
3.5. Hiperparámetros de la RNA para la clasificación de sonidos de cigarras. . . . .	63
3.6. Comparación de la metodología empleada con su equivalente de orden entero. . .	64

# Capítulo 1

## Introducción

La conservación de los ecosistemas es de vital importancia para mantener la biodiversidad y el equilibrio ecológico. Estudios recientes han demostrado cómo el monitoreo bioacústico es esencial en esta tarea al permitir la identificación y seguimiento de especies clave, de igual manera se demuestra que la bioacústica desempeña un rol crucial en la conservación de ecosistemas al permitir un monitoreo no invasivo y preciso de la biodiversidad.

La bioacústica es el estudio de los sonidos producidos por los organismos vivos y su papel en la comunicación, el comportamiento y la ecología de las especies [1]. La bioacústica también enfrenta desafíos como variabilidad estacional, ruido ambiental y similitudes morfológicas entre especies.

La bioacústica desempeña un papel clave en la conservación y comprensión de los ecosistemas naturales. Superar estos retos es esencial para el uso de la bioacústica como herramienta en la conservación de ecosistemas y la monitorización de la biodiversidad. La mejora continua de los métodos de procesamiento de señales es necesaria para abordar la variabilidad de los datos y aumentar la precisión en la identificación de especies. La bioacústica es invaluable en la preservación de la vida silvestre y la conservación de ecosistemas de una manera no invasiva.

El uso de la Transformada de Fourier Fraccionaria (FRFT) en señales bioacústicas ofrece una herramienta eficaz para el análisis de vocalizaciones de ranas, mamíferos y aves. La FRFT ofrece ventajas significativas en el análisis de señales bioacústicas al proporcionar una representación que involucra las características temporales y frecuenciales de los sonidos, lo que facilita la clasificación de especies. Por otro lado, las redes neuronales permiten una clasificación automática precisa de señales bioacústicas al aprender patrones complejos, lo que aumenta la precisión en la identificación de especies en una amplia variedad de contextos. Ambos enfoques son herramientas poderosas para la conservación y el monitoreo de la biodiversidad en el campo de la bioacústica.

### 1.1. Antecedentes

En las últimas décadas, el análisis y clasificación de señales provenientes de organismos vivos ha experimentado un crecimiento exponencial. Actualmente, existen técnicas avanzadas que permiten reconocer palabras y realizar el reconocimiento de voz de diversos usuarios, principalmente en aplicaciones comerciales. Sin embargo, también surge la necesidad de desarrollar técnicas de

reconocimiento acústico enfocadas en el análisis de sonidos emitidos por la fauna, especialmente aquellos provenientes del aparato fonador.

La diversidad de sonidos con propiedades distintas en el dominio temporal demanda la clasificación de dichos sonidos, definiendo sus características y describiendo su origen. Este desafío impulsa el diseño de algoritmos más robustos basados en las propiedades inherentes de las señales.

Un ejemplo de aplicación de estas metodologías se presenta en el trabajo de Cortes Campos en el CENIDET en 2020 [2]. En este estudio, se propone una metodología para el diagnóstico de fallas en máquinas eléctricas, utilizando transformadas integrales de orden fraccionario, como la transformada de Fourier de orden fraccionario. La metodología se fundamenta en el comportamiento de las señales, empleando la forma discretizada de la transformada de Fourier mediante la descomposición en valores y vectores propios. Además, se diseñó una red neuronal del tipo perceptrón para llevar a cabo la clasificación requerida en la metodología. Los resultados obtenidos demuestran que el uso de la transformada de Fourier fraccionaria posibilita una detección altamente precisa para la extracción de características.

Nicolás Toro abordó el reconocimiento de cuatro especies de ranas a través de sus cantos en su trabajo [3], utilizando herramientas de procesamiento digital de señales. El proceso comprende varias etapas, comenzando con la extracción de datos y la aplicación de filtros sobre los mismos. Estos datos se emplean como entrada para una red neuronal de tipo *backpropagation* implementada en MATLAB, con el objetivo de clasificar las señales. Los resultados muestran un elevado porcentaje de aciertos en la clasificación de las cuatro especies estudiadas.

En el año 2013, la revista de ciencia e ingeniería de la Universidad EAFIT publicó un artículo [4] que revisa los conceptos básicos para el monitoreo bioacústico automatizado. En este trabajo, se analizan, comparan y categorizan diversas técnicas de procesamiento digital de señales. El enfoque principal resalta la importancia y la necesidad de implementar esta tecnología, abordando métodos de representación y clasificación, así como proporcionando una lista de software, tanto comercial como libre, utilizado para el análisis de reconocimiento bioacústico.

En el año 2017, Rodríguez presenta un estudio [5] que se centra en la parametrización de ecuaciones para simular el canto de las aves. Este trabajo realiza una revisión exhaustiva de ecuaciones utilizadas para la reproducción y análisis de los cantos de aves, con el objetivo principal de emular las señales emitidas por estas aves. El autor propone modelos, realiza la matización de ecuaciones diferenciales y las integra mediante métodos numéricos, utilizando series de Fourier para representar las señales en forma exponencial compleja.

La metodología adoptada se basa en la integración de la ecuación de Van der Pol, seleccionada por su capacidad para proporcionar datos que describen la dinámica del sistema y ofrecen soluciones que reproducen la señal. Los resultados obtenidos por el autor muestran un éxito destacado en la síntesis de la señal, ya que este enfoque proporciona la ventaja de refinar los datos utilizados en la clasificación y simulación de las señales.

## 1.2. Estado del arte

En el trabajo “Monitoreo bioacústico de las poblaciones de anuros en la reserva de la biosfera Nahá, Chiapas, México” [6] el autor realiza un seguimiento bioacústico recopilando por medio de dos grabadoras 370 horas de grabación de las que pudo identificar doce especies, cuatro identificadas a nivel de especie y cinco de ellas identificadas a nivel de género. Encontró una gran similitud entre *Craugastor rhodopis* y dos especies que podrían estar conectadas con similitud morfológica. Calculó la frecuencia temporal del canto de las especies y creo gráficas que muestran la variación estacional de las especies. Entre las familias reportadas se mencionan Crauastoridae, Centrolenidae, Hylidae y Ranidae.

En el trabajo “Patrones fenológicos del canto del área de protección de flora y fauna Nahá, Chiapas, México” [7] el autor muestra la ecología del paisaje acústico como una disciplina que puede ser capaz de identificar las variaciones y consistencias en los niveles de actividad en la zona protegida antes mencionada. Se evaluaron seis índices acústicos y se aplicaron modelos lineales generalizados, estudiando los cambios con respecto a sitio, temporada y año. Se obtuvieron un total de 3,363 grabaciones de las cuales se seleccionaron 8 que representan el nicho acústico de la reserva Nahá y se construyó un espectrograma para cada grabación encontrando diferencias acústicas entre cada temporada.

En el estudio de *Zaguri et al.* [8] se empleó el aprendizaje profundo para la detección de eventos bioacústicos con el fin de monitorear la biodiversidad. Los investigadores utilizaron redes neuronales convolucionales para el reconocimiento automático de diferentes tipos de sonidos. El enfoque propuesto logró una alta precisión de detección de eventos en una amplia gama de especies y contextos.

El trabajo de Zamanian [9] presenta una metodología para la clasificación de señales bioacústicas de insectos basado en características en los dominios del tiempo y la frecuencia. La selección de las características se llevo a cabo mediante la implementación de un algoritmo genético. Se recopiló una base de datos de cinco especies de cigarras en Irán, la cual fue posteriormente procesada con la finalidad de suprimir el ruido ambiental presente en el ecosistema. Posteriormente se realizó la segmentación de los datos en muestras de 400ms. El clasificador seleccionado logró una precisión del 98.10 % empleando las características espectrales optimizadas y eliminando los valores atípicos en la base de datos.

En el trabajo de Marshall [10] se realizaron una serie de experimentos para la clasificación de especies de cigarras utilizando diferentes variantes de conjuntos de datos procesados mediante el algoritmo Härmä, el cual es una técnica utilizada para segmentar señales de audio en unidades más pequeñas como sílabas. Centrándose en conjuntos de datos de Longitud Completa y segmentados se empleó una arquitectura de Red Neuronal Convolutiva (CNN), inicializada con capas de abandono configuradas en 0.2 y entrenada con el optimizador Adam a lo largo de 40 épocas. Las pruebas iniciales utilizando señales procesadas y representaciones espectrograma alcanzaron una precisión del 77.78 %. Al aplicar el algoritmo Härmä, se obtuvieron los siguientes resultados: el Conjunto de Datos de Longitud Completa logró una precisión inicial del 66.67 %, mejorando al 77.78 % con ajustes en el abandono, mientras que el Conjunto de Datos Cortados alcanzó un 89.05 %, posteriormente mejorado al 92.70 % tras ajustes adicionales. La incorporación del umbral binario con Härmä mostró tendencias similares con precisiones que alcanzaron

el 88.32% y el 93.02% para conjuntos de datos de longitud completa y segmentados, respectivamente, mejorados mediante ajustes en el abandono. El algoritmo Harman mejorado superó consistentemente a otros métodos, logrando una precisión perfecta del 100% con el Conjunto de Datos de Longitud Completa y del 93.02% con el Conjunto de Datos.

En el trabajo de Brown [11] se presenta un enfoque novedoso para la clasificación de lluvia y coros de cigarras en grabaciones de audio mediante modelos de aprendizaje automático. Se exploraron 559 combinaciones para la clasificación de lluvia, encontrando que configuraciones con MLP, activación ReLU, y optimizador Adam, junto con filtros de alta frecuencia, sin el filtro MMSE STSA, y utilizando todos los atributos o todos excepto las deltas de MFCC, obtuvieron los mejores resultados con AUC entre 0.9900–0.9911. Se compararon estas configuraciones con otras usando pruebas t de dos colas no pareadas, mostrando diferencias estadísticamente insignificantes. El modelo MLP seleccionado se aplicó a un conjunto de datos más grande, clasificando 5762 archivos de 10 segundos con tiempos de ejecución eficientes y alta precisión de clasificación. Además, se comparó con enfoques existentes como los árboles de decisión C4.5 y el umbral PSD/SNR, demostrando superioridad significativa en AUC y efectividad.

En el trabajo de *Niu et al.* [12] se aplicó la Transformada de Fourier fraccionaria para extraer características fractales de sonidos de aves. Se utilizó un perceptrón multicapa para la clasificación de 12 especies de aves, logrando una precisión de clasificación del 89.4%.

El trabajo realizado por *Jin et al.* [13] se utilizó una representación tiempo - frecuencia de las llamadas de ranas y redes neuronales profundas para la clasificación de especies. Se aplicó una metodología que involucró la transformada de Fourier y la representación tiempo - frecuencia de las señales de llamadas de ranas y se utilizó una red neuronal profunda, específicamente una red neuronal convolucional (CNN), para la clasificación. El objetivo fue lograr una alta precisión en la clasificación de especies de ranas basada en sus llamadas. Los resultados mostraron una tasa de clasificación promedio del 93.4% en el conjunto de datos de prueba, demostrando la efectividad del enfoque propuesto.

En el estudio presentado por *Bonada et al.* [14] se aplicó el aprendizaje profundo para la identificación de especies de murciélagos a partir de grabaciones de audio con reducción de ruido. Se utilizó una combinación de técnicas de procesamiento de señales y redes neuronales convolucionales para el reconocimiento automático. Los resultados demostraron una alta precisión en la identificación de diferentes especies de murciélagos, lo que destaca la eficacia de los enfoques basados en el aprendizaje profundo en este campo.

El estudio de *Anjum et al.* [15] aplicó técnicas de aprendizaje automático para la clasificación de llamadas de ranas. Se utilizó una metodología que involucró la extracción de características de los sonidos y la clasificación utilizando algoritmos de aprendizaje automático, como máquinas de vectores de soporte (SVM) y bosques aleatorios (RF). El objetivo fue lograr una clasificación precisa de las llamadas de ranas para identificar diferentes especies. Los resultados mostraron una precisión de clasificación promedio del 89.7%, demostrando la eficacia de los enfoques de aprendizaje automático en la clasificación de llamadas de ranas.

El estudio de *Kaim et al.* [16], se utilizó el aprendizaje profundo para la detección automática de aves en grabaciones de audio. Se aplicaron redes neuronales convolucionales para la clasificación de señales acústicas. Los resultados mostraron un alto rendimiento en la detección y clasificación de diferentes especies de aves, lo que demuestra el potencial de las técnicas de aprendizaje

profundo en la monitorización de la avifauna.

El trabajo de *Bravo et al.* [17], se utilizó bioacústica y técnicas de aprendizaje automático para la clasificación de vocalizaciones de anuros sudamericanos. Se aplicó una metodología que involucró la extracción de características acústicas de las vocalizaciones y la clasificación utilizando algoritmos de aprendizaje automático, como máquinas de vectores de soporte (SVM) y bosques aleatorios (RF). El objetivo fue lograr una clasificación precisa de las vocalizaciones de anuros para identificar diferentes especies. Los resultados mostraron una precisión de clasificación promedio del 92.1%, demostrando la efectividad del enfoque propuesto en la clasificación de vocalizaciones de anuros.

En el estudio de *Singh et al.* [18], se propuso una representación innovadora de tiempo - frecuencia para la clasificación automática de vocalizaciones de mamíferos, empleando técnicas de aprendizaje profundo. Se entrenó una red neuronal convolucional utilizando datos de vocalizaciones y se evaluó su rendimiento en la clasificación de diferentes especies o tipos de canto. La representación de tiempo - frecuencia utilizada permitió capturar de manera efectiva las características distintivas de las vocalizaciones, lo que condujo a una mejora significativa en la precisión de la clasificación en comparación con enfoques anteriores. Este enfoque basado en aprendizaje profundo demuestra el potencial de las técnicas modernas de inteligencia artificial para el análisis y clasificación de vocalizaciones de mamíferos.

*Gómez-Echevarría et al.* [19] en el año 2020 presentó una revisión de la literatura sobre la aplicación de la FRFT en el campo biomédico, enumerando aplicaciones que incluyen la detección de señales, filtrado y extracción de características. Se concluyó que la FRFT se puede usar para problemas de extracción de características, donde el orden fraccionario ayuda a determinar cambios de frecuencia en tiempo que permiten caracterizar la dinámica no estacionaria de la misma .

En el estudio presentado por *Zhang et al.* [20] se utilizó la FRFT para obtener el espectro de frecuencia de sonidos de aves. Se aplicó una red neuronal convolucional para clasificar las especies de aves, obteniendo una precisión de clasificación promedio de 94.5% en un conjunto de datos de prueba que incluía 10 especies de aves comunes.

Emplearon en la investigación de *Li et al.* [21] la Transformada de Fourier para calcular los coeficientes cepstrales de frecuencia de Mel (MFCC) a partir de sonidos de ballenas. Se utilizó un modelo de aprendizaje profundo para clasificar las vocalizaciones de ballenas, logrando una precisión de clasificación del 94.6%.

En el estudio de *Laje et al.* [22] se aplicó la Transformada de Fourier fraccionaria para analizar las señales bioacústicas emitidas por ranas en el contexto de la reproducción y selección de pareja. Se utilizó la Transformada de Fourier fraccionaria para extraer características temporales y espectrales de los cantos de las ranas. Los resultados mostraron que el uso de la Transformada de Fourier fraccionaria permitió detectar cambios en la estructura temporal y frecuencial de los cantos, lo que contribuyó a una mejor comprensión de los procesos de comunicación acústica en estas especies.

El trabajo de *Sarria-Paja et al.* [23], se aplicó la Transformada de Fourier fraccionaria para analizar señales de vocalización de murciélagos. Se utilizó la Transformada de Fourier fraccionaria para extraer características espectrales y temporales de las señales de ultrasonido emitidas por los murciélagos. Los resultados mostraron que la Transformada de Fourier fraccionaria permitió

identificar patrones distintivos en las señales de diferentes especies de murciélagos y facilitó su clasificación. Además se encontró que el uso de la Transformada de Fourier fraccionaria mejoró la resolución de tiempo - frecuencia en comparación con otros métodos de análisis.

En la investigación de *Beltran et al.* [24], se empleó la Transformada de Fourier fraccionaria para el análisis de señales de canto de aves. Se utilizó la Transformada de Fourier fraccionaria para extraer características espectrales y temporales de los cantos de diferentes especies de aves. Los resultados revelaron que la Transformada de Fourier fraccionaria permitió una representación más precisa de los cantos de aves, facilitando la identificación de patrones y diferencias sutiles entre especies. Además, se demostró que esta herramienta de análisis fue útil para la clasificación automática de especies basada en las características extraídas.

En el estudio de *Das et al.* [25], se aplicó la Transformada de Fourier fraccionaria para la extracción de características en señales de vocalizaciones de anfibios. Los investigadores utilizaron esta herramienta para analizar las características espectrales y temporales de los cantos de diferentes especies de anfibios. Los resultados obtenidos mediante la Transformada de Fourier fraccionaria fueron comparados con otras técnicas de análisis, como la Transformada de Fourier convencional y la Transformada Wavelet, para evaluar su eficacia en la identificación y clasificación de especies. Los resultados mostraron que la Transformada de Fourier fraccionaria permitió una mejor resolución en las características temporales y frecuenciales de los cantos, lo que facilitó la discriminación y clasificación precisa de las especies de anfibios.

En el trabajo de *Gao et al.* [26] se aplicó la Transformada de Fourier para obtener el espectro de frecuencia de sonidos de langostas, se emplearon técnicas de aprendizaje profundo y aumento de datos para su clasificación, obteniendo una precisión de 88.1 % en la identificación por especie.

En el estudio de *Xia et al.* [27] se emplearon bancos de filtros adaptativos y aprendizaje profundo para la clasificación automática de sonidos de peces. Se utilizó un enfoque que combina el diseño de bancos de filtros adaptativos para extraer características relevantes de los sonidos de peces y un modelo de aprendizaje profundo, específicamente una red neuronal convolucional (CNN), para la clasificación. El objetivo era lograr una alta precisión en la clasificación automática de sonidos de peces en entornos acuáticos. Los resultados demostraron una tasa de clasificación promedio del 92.5 % en el conjunto de datos de prueba, lo que indica la efectividad del enfoque propuesto para la clasificación precisa de sonidos de peces.

En el artículo “Eliminación de ruido de señales bioacústicas: una revisión” [28] los autores discuten los desafíos y las oportunidades en la eliminación de ruido en grabaciones bioacústicas, destacando la diversidad de métodos existentes y la necesidad de mejorar la precisión y eficiencia de estos métodos, especialmente a través de técnicas de aprendizaje profundo. Además, resaltan la dificultad de evaluar estos métodos debido a la falta de señales limpias.

### 1.3. Planteamiento del problema

La bioacústica se enfoca en comprender las características de las expresiones fonéticas a través del análisis de señales sonoras. Uno de los principales desafíos en la bioacústica radica en la distinción precisa de señales similares. En algunas aplicaciones la transformada de Fourier ha sido utilizada, sin embargo esta metodología a menudo no es suficiente para distinguir señales

con un alto grado de similitud.

Las transformadas integrales de orden fraccionario presentan una herramienta para abordar problemas donde las transformadas de orden entero no resultan suficientes, mejorando la distinción y clasificación de sonidos bioacústicos.

Debido a la importancia del monitoreo de especies para su preservación, se pretende mejorar la clasificación de señales bioacústicas mediante transformadas integrales de orden generalizado y redes neuronales especializadas, permitiendo la distinción precisa de sonidos similares o superpuestos.

## 1.4. Justificación

La bioacústica es una disciplina que se enfoca en el estudio de señales de audio producidas por seres vivos. Estas señales son vitales para comprender el comportamiento de diversas especies animales y para preservar y conservar la biodiversidad de nuestro entorno. La importancia de esta área de investigación radica en varios aspectos clave:

- **Comprender el comportamiento animal**  
Las señales acústicas desempeñan un papel fundamental en la comunicación y el comportamiento de las especies animales. Al estudiar y comprender estas señales, podemos obtener información valiosa sobre su ecología, reproducción, migración e interacciones sociales.
- **Conservación de especies**  
En un mundo en constante cambio y amenazas ambientales es esencial conocer a fondo el comportamiento de las especies para poder implementar estrategias efectivas de conservación. La bioacústica nos permite monitorear y proteger poblaciones en peligro de extinción al comprender sus patrones de vocalización y sus necesidades.
- **Ecología y entorno**  
La bioacústica brinda una ventana única para entender el entorno en el que vivimos. Los sonidos emitidos por animales son indicadores de la salud y la dinámica de los ecosistemas, lo que puede ser útil para evaluar la calidad del medio ambiente y la biodiversidad de una región.

Uno de los principales desafíos en la identificación de especies por medio de señales bioacústicas consiste en que muchas veces las señales pueden ser muy similares entre diferentes especies o pueden representar situaciones o comportamientos diferentes. Esto puede llevar a la interpretación errónea de los sonidos y, en casos extremos, a la confusión de especies que emiten señales muy parecidas entre sí. Para superar este desafío, es esencial desarrollar técnicas de clasificación más robustas.

Una de las herramientas que pueden mejorar la precisión de la clasificación de señales acústicas son los filtros de orden fraccionario. Estos filtros tienen la ventaja de adaptarse mejor a señales complejas y variables, lo que es común en el ámbito de la bioacústica. Al emplear filtros de orden fraccionario en la clasificación de señales, se puede lograr una mayor precisión en la

identificación de especies y comportamientos, reduciendo así la clasificación errónea y la confusión en la caracterización de los sonidos de animales.

La bioacústica desempeña un papel esencial en la comprensión y preservación de la vida silvestre y el entorno. Al abordar los desafíos previamente mencionados es crucial desarrollar técnicas de clasificación más sólidas, como el uso de filtros de orden fraccionario, para mejorar la precisión en la identificación de especies y comportamientos, lo que contribuirá de manera significativa a la conservación de la biodiversidad y la comprensión de nuestro entorno natural.

## 1.5. Hipótesis

La clasificación de sonidos bioacústicos al utilizar transformaciones integrales de orden generalizadas proporcionan patrones que dan características más claras para clasificación y comparación de las señales.

## 1.6. Objetivos

### 1.6.1. Objetivo general

Desarrollar técnicas de reconocimiento acústico mediante filtros y redes neuronales de orden fraccionario para el reconocimiento automatizado de especies animales.

### 1.6.2. Objetivos específicos

- Diferenciar los sonidos bioacústicos mediante las características de la señal.
- Aplicar técnicas de reconocimiento de audio como herramientas para sistemas de reconocimiento de sonidos enfocados en bioacústica
- Realizar una clasificación mediante el uso de redes neuronales que permitan clasificar las diferencias entre las características de las señales.

## 1.7. Metas

- Aplicar técnicas de reconocimiento de audio como herramientas para sistemas de reconocimiento de sonidos enfocados en bioacústica.
- Diseñar filtros de orden fraccionario con el objetivo de filtrar el ruido ambiental.
- Mediante el uso de redes neuronales, realizar la identificación y clasificación acústica.

## 1.8. Alcance

- Estudio de conceptos principales de transformadas integrales y cálculo fraccionario.
- Revisión y uso de las propiedades de las transformadas integrales de orden generalizado aplicadas al uso de identificación de señales.
- Identificar técnicas de reconocimiento que permitan la exclusión de sonido biacústico utilizando las propiedades de las señales.
- Estudiar el uso de redes neuronales que permitan la clasificación de los sonidos basándose en las características de la señal.

### 1.8.1. Metodología

A continuación se muestran una serie de pasos para lograr este propósito.

- Estudiar transformadas integrales.  
Revisando literatura acerca de transformadas integrales identificando las técnicas clásicas existentes.
- Estudiar cálculo fraccionario.  
Efectuando una revisión bibliográfica acerca del cálculo fraccionario para comprender sus bases y aplicarlo al análisis de señales.
- Aplicar una técnica que permita la diferenciación de señales.  
Con el uso de transformadas integrales de orden generalizado se aplicará una metodología que permita extraer las propiedades de las señales con una mayor número de características.
- Proponer metodología.  
Desarrollar una metodología que permita la clasificación de sonidos bioacústicos. Empleando redes neuronales artificiales, realizar una clasificación con base en las características de la señal.
- Programación del método.  
Programar la metodología empleando el uso de un software que permita el desarrollo de la técnica propuesta.
- Comparación de resultados.  
Se efectuará una comparación de la literatura existente con los resultados obtenidos, mostrando las ventajas y desventajas de la aplicación de integrales de orden generalizado aplicado en el análisis señales.

### 1.8.2. Aportación

- Desarrollar una metodología con base en transformadas integrales de orden generalizado para la identificación de señales.
- Desarrollar técnicas de reconocimiento que permitan diferenciar el sonido bioacústico mediante las propiedades de las señales utilizando filtros de orden fraccionario.
- Diseñar redes neuronales que permitan la clasificación de los sonidos bioacústicos basándose en las características de la señal.

# Capítulo 2

## Marco Teórico

### 2.1. Bioacústica

La acústica es la rama de la física que se encarga del estudio del sonido, es decir, de las ondas mecánicas que se propagan a través de la materia. Cuando se produce un evento sonoro, implica la existencia de una cadena de efectos, desde una fuente sonora que genera vibraciones de amplitud en el aire circundante hasta la percepción de estas vibraciones por parte de un oyente [29].

En el contexto de la bioacústica, se busca explicar la vocalización de los animales mediante modelos que aproximen la producción acústica. La diversidad de sonidos emitidos por diferentes especies generalmente se atribuye a procesos de aprendizaje específicos de cada población [30].

La bioacústica se enfoca en el estudio de los sonidos producidos por organismos vivos y su papel en la comunicación, el comportamiento y la ecología de las especies [1]. Esta disciplina se centra en comprender la producción, transmisión y recepción de señales acústicas en el contexto biológico. Los sonidos generados por animales, como vocalizaciones, llamadas y cantos, desempeñan roles fundamentales en su supervivencia, reproducción, defensa territorial y comunicación social [31]. En bioacústica, los sonidos son generados por diversas fuentes biológicas, como aves, mamíferos marinos, insectos y anfibios. Estos organismos utilizan estructuras especializadas, como cuerdas vocales, órganos sonoros o mecanismos de percusión, para producir sonidos [31]. La generación de sonidos en bioacústica está determinada por factores anatómicos, fisiológicos y comportamentales específicos de cada especie.

La bioacústica juega un papel crucial en la comprensión de la ecología y el comportamiento de las especies. Los sonidos emitidos por los organismos pueden transmitir información valiosa sobre la ubicación, identificación y estado fisiológico de los individuos [32]. Además, la bioacústica permite investigar procesos como la comunicación, la selección de pareja, la territorialidad y la migración de las especies. Asimismo, se utiliza para evaluar la salud de los ecosistemas a través de la monitorización acústica.

La aplicación de la ingeniería en bioacústica es de gran importancia, ya que proporciona herramientas y métodos para capturar y analizar datos acústicos a gran escala. Esto permite llevar a cabo estudios detallados sobre la diversidad biológica, la ecología y la conservación de especies [1].

La ingeniería desempeña un papel fundamental en la bioacústica, contribuyendo al diseño de

## 2.1. BIOACÚSTICA

---

dispositivos de grabación y sensores acústicos, así como al desarrollo de algoritmos y modelos computacionales para el análisis de datos bioacústicos.

En el ámbito de la detección de especies, la bioacústica ha demostrado ser una herramienta eficaz para la identificación y seguimiento de animales en diversos entornos. Por ejemplo, en el estudio de aves, las vocalizaciones se utilizan para determinar la presencia y abundancia de especies, así como para evaluar la calidad del hábitat [33]. Estos enfoques se han aplicado con éxito en una variedad de ecosistemas, desde selvas tropicales hasta paisajes urbanos, destacando la utilidad de la bioacústica en la detección y seguimiento de especies.

Además, la bioacústica ha encontrado aplicaciones significativas en la evaluación de ecosistemas y la conservación de la naturaleza. Los estudios de paisaje acústico, que analizan la composición y estructura de los sonidos ambientales, permiten evaluar la calidad y salud de los ecosistemas. Estos análisis han revelado la importancia de los paisajes sonoros en la conservación de especies y la detección de cambios en los ecosistemas [32].

Tabla 2.1. Generalidades en bioacústica

Concepto	Definición	Cita
Bioacustica	Estudio de la comunicación acústica entre los animales, esta comprende desde las características fisiológicas y anatómicas que dan origen a las vocalizaciones, hasta el comportamiento asociado a la recepción e interpretación de los sonidos y el análisis de las propiedades de las vocalizaciones.	[34]
Fenología	Fenología es el estudio de la distribución temporal de eventos biológicos, estacionales y recurrentes del ciclo de vida de los organismos, enfocados especialmente en sus relaciones con el tiempo meteorológico y el clima durante un año.	[35]
Simpatria	Dos o más especies o poblaciones que viven en la misma área geográfica y son capaces de encontrarse entre ellos.	[36]
Fotoperíodo	Cantidad de luz que recibe el espécimen por ciclo.	[37]

En la tabla 2.2 se muestra una comparación de softwares que algunos autores recomiendan los cuales contienen herramientas para el procesamiento de señales de audio, estas son utilizadas para analizar y reconocer señales bioacústicas.

Tabla 2.2. Herramientas recomendadas en la literatura.

Concepto	Definición
Avisoft	Proporciona herramientas de análisis, edición y clasificación de sonido.
PAMGUARD	Software de código abierto diseñado para monitorización de entornos marinos
Raven	Software especializado en la visualización y medición de sonidos de animales
Song Scope	Herramienta diseñada para revisar grabaciones realizadas por equipos convencionales de grabación bioacustica
SoundID	Aplicación de reconocimiento de sonido, originalmente para buscar loros.
XBAT	Caja de herramientas de bioacústica desarrollada en MATLAB.
SonoBat	Software para mostrar y analizar espectrogramas de llamadas de ecolocalización de murciélagos.

### 2.1.1. Canto de Anuros

Los anuros, que comprenden ranas y sapos, son un orden de anfibios que se caracterizan por su notable capacidad para producir sonidos vocales, conocidos comúnmente como cantos. Estos cantos son una herramienta esencial de comunicación, especialmente en el contexto de la reproducción. Los machos de la mayoría de las especies utilizan sus cantos para atraer a las hembras y establecer y defender territorios contra otros machos. Los cantos varían considerablemente entre especies y dentro de una misma especie, influenciados por factores ambientales como la temperatura, la humedad y la hora del día[40].

El aparato vocal de los anuros está altamente especializado para la producción de sonidos. Las estructuras involucradas incluyen los sacos vocales, que actúan como amplificadores de las vibraciones generadas por las cuerdas vocales. La variedad de cantos puede clasificarse en varias categorías, tales como cantos de anuncio, cantos de cortejo y cantos territoriales, cada uno con características acústicas específicas y funciones ecológicas distintas [37].

#### Tipos de cantos

- **Cantos de anuncio:** Utilizados principalmente para atraer hembras, estos cantos suelen ser repetitivos y de gran amplitud, diseñados para ser escuchados a largas distancias.
- **Cantos de cortejo:** Más suaves y variados, estos cantos se emplean en interacciones cercanas con hembras potenciales.
- **Cantos territoriales:** Emitidos para advertir a otros machos de la presencia de un individuo en un territorio específico, ayudando a minimizar confrontaciones directas.

### Procesamiento de canto de anuros

El procesamiento de los cantos de anuros implica una serie de técnicas de análisis de señales destinadas a extraer características relevantes que permitan la identificación y clasificación de las especies. A continuación, se describen las etapas clave de este proceso[41]:

- **Adquisición de Señales:** Las señales acústicas se capturan utilizando grabadoras de campo equipadas con micrófonos sensibles. Estas grabaciones a menudo incluyen ruido de fondo, lo que requiere un preprocesamiento adecuado.
- **Preprocesamiento de Señales:** Consiste en la eliminación del ruido ambiental y la normalización de las señales. Se aplican técnicas como el filtrado de banda y la reducción de ruido para mejorar la calidad de las señales antes del análisis.
- **Extracción de Características:** Se extraen características acústicas relevantes, tales como frecuencia dominante, duración de pulsos, tasa de repetición, espectrogramas y envolventes temporales. Estas características son fundamentales para la posterior clasificación de las especies.
- **Clasificación:** Utilizando algoritmos de aprendizaje automático, como máquinas de soporte vectorial (SVM), redes neuronales y análisis discriminante lineal (LDA), se asignan las señales a diferentes categorías correspondientes a distintas especies de anuros. Este paso es crucial para la automatización del reconocimiento de especies en estudios bioacústicos.

### Especies e importancia

La identificación y el estudio de las especies de anuros tienen una relevancia significativa en varios contextos [39]:

1. **Conservación de la Biodiversidad:** Los anuros son considerados indicadores clave de la salud ambiental debido a su sensibilidad a cambios en los ecosistemas acuáticos y terrestres. El monitoreo acústico permite realizar censos poblacionales efectivos, facilitando la detección de cambios en la biodiversidad y la implementación de estrategias de conservación.
2. **Ecología y Comportamiento:** El análisis de los cantos de anuros proporciona información valiosa sobre sus comportamientos reproductivos, estructuras poblacionales e interacciones ecológicas. Los patrones de canto revelan estrategias de apareamiento y dinámicas de competencia entre machos, contribuyendo al entendimiento de sus roles ecológicos.
3. **Impacto del Cambio Climático:** Los anuros son altamente susceptibles a cambios ambientales, lo que los convierte en bioindicadores eficientes del impacto del cambio climático. Alteraciones en los patrones de canto pueden reflejar cambios en la temperatura y la humedad, afectando la fenología y la distribución de estas especies.

El estudio de los anuros a través del análisis de sus cantos no solo contribuye al conocimiento científico sobre la biología y ecología de estos animales, sino que también tiene implicaciones

prácticas en la conservación de especies y la gestión de ecosistemas. La integración de técnicas avanzadas de procesamiento de señales y aprendizaje automático permite desarrollar herramientas efectivas para el monitoreo y conservación de la biodiversidad. Además, estos estudios proporcionan datos esenciales para evaluar los efectos del cambio climático y otras perturbaciones antropogénicas sobre los ecosistemas naturales [43].

### 2.1.2. Canto de cigarras

Las cigarras son insectos pertenecientes al orden Hemiptera y a la familia Cicadidae. Son conocidas por su capacidad para producir sonidos fuertes y distintivos, los cuales desempeñan un papel crucial en su comportamiento reproductivo y social. Los machos emiten cantos para atraer a las hembras y para marcar territorio frente a otros machos. La producción de estos sonidos se realiza mediante un órgano especializado llamado timbal, situado en el abdomen, que genera vibraciones amplificadas por una caja de resonancia [47].

El canto de las cigarras es específico de cada especie y puede variar en frecuencia, duración, ritmo y patrones temporales. Esta variabilidad no solo facilita la comunicación entre individuos de la misma especie, sino que también actúa como un mecanismo de aislamiento reproductivo, evitando la hibridación entre especies diferentes. El estudio de los cantos de cigarras ofrece una ventana invaluable para entender los mecanismos de comunicación animal y la ecología acústica [10].

#### Tipos de cantos

Los cantos de las cigarras pueden clasificarse en diferentes tipos, cada uno con funciones ecológicas y comportamentales específicas[44]:

- **Cantos de Llamado:** Emitidos por los machos para atraer a las hembras. Estos cantos suelen ser fuertes y repetitivos, optimizados para ser escuchados a largas distancias. La intensidad y la frecuencia de los cantos pueden variar según la especie y las condiciones ambientales.
- **Cantos de Alarma:** Emitidos en situaciones de amenaza para alertar a otros individuos sobre la presencia de depredadores. Estos cantos son generalmente más cortos y abruptos, diseñados para provocar una respuesta rápida en otros individuos.
- **Cantos de Cortejo:** Utilizados en interacciones cercanas con hembras, estos cantos son más suaves y variables, ayudando a las hembras a evaluar la calidad del macho. La variabilidad en estos cantos puede proporcionar información sobre la condición física y genética del emisor.

#### Procesamiento de canto de cigarras

En el contexto del procesamiento de señales bioacústicas, el estudio del canto de las cigarras ofrece múltiples oportunidades para el desarrollo y aplicación de técnicas avanzadas de análisis de señales. La bioacústica se ocupa del registro, análisis e interpretación de los sonidos producidos

por los organismos vivos, y las cigarras, con sus patrones de canto únicos y estructurados, presentan un caso de estudio ideal para explorar y validar métodos de procesamiento de señales. Estas técnicas incluyen, pero no se limitan a, la transformación de Fourier, el análisis de la envolvente, la descomposición en modos empíricos y métodos de aprendizaje automático.

El análisis y procesamiento de los cantos de cigarras implica varias etapas técnicas que permiten extraer características acústicas relevantes para la identificación y clasificación de especies. A continuación se detallan los pasos principales en este proceso[45]:

- **Adquisición de Señales:** Las señales acústicas se graban en el campo utilizando equipos de grabación de alta fidelidad. Estas grabaciones a menudo contienen ruido ambiental, lo que hace necesario realizar un preprocesamiento adecuado para obtener señales limpias.
- **Preprocesamiento de Señales:** Consiste en la eliminación del ruido ambiental y la normalización de las señales acústicas. Se aplican técnicas de filtrado de banda y reducción de ruido para mejorar la calidad de las señales y facilitar su análisis. Este paso es crucial para asegurar que las características extraídas reflejen fielmente las propiedades del canto de las cigarras.
- **Extracción de Características:** Se extraen características acústicas significativas como la frecuencia dominante, los espectrogramas, la duración de los pulsos, las tasas de repetición y las envolventes temporales. Estas características son esenciales para diferenciar entre especies de cigarras. La frecuencia dominante y los patrones temporales son particularmente útiles para la clasificación.
- **Clasificación:** Utilizando algoritmos de aprendizaje automático, como máquinas de soporte vectorial (SVM), redes neuronales y análisis discriminante lineal (LDA), se clasifican las señales acústicas en distintas categorías correspondientes a diferentes especies. Este proceso es fundamental para automatizar el reconocimiento de especies en estudios bioacústicos. La precisión de estos modelos puede mejorarse mediante el uso de técnicas avanzadas de deep learning y la integración de múltiples características acústicas.

### Especies e importancia

La identificación y el estudio de las especies de cigarras tienen una relevancia significativa por varias razones[46]:

- **Conservación de la Biodiversidad:** Las cigarras son importantes indicadores de la salud de los ecosistemas. Su presencia y diversidad reflejan la condición del hábitat, permitiendo a los científicos evaluar el impacto de cambios ambientales y desarrollar estrategias de conservación. El monitoreo acústico es una herramienta poderosa para realizar censos poblacionales y detectar cambios en la biodiversidad.
- **Ecología y Comportamiento:** El estudio de los cantos de cigarras proporciona información valiosa sobre su comportamiento reproductivo, estructura poblacional y dinámicas de interacción entre especies. Los patrones de canto revelan estrategias de apareamiento y

defensa territorial, contribuyendo al entendimiento de sus roles ecológicos y su impacto en las comunidades biológicas.

- **Impacto del Cambio Climático:** Las cigarras son altamente sensibles a cambios en su entorno, lo que las convierte en bioindicadores eficientes del impacto del cambio climático. Alteraciones en los patrones de canto pueden reflejar cambios en la temperatura y la humedad, afectando la sincronización de sus ciclos de vida y, por ende, la dinámica poblacional. El estudio de estos cambios puede proporcionar información crítica para la gestión de ecosistemas y la conservación de especies.

A continuación se listan algunas de las especies relevantes de cigarras [48]:

- *Magicicada septendecim*: Esta especie, conocida como la cigarra periódica de 17 años, es famosa por sus emergencias masivas en intervalos específicos. Su canto es fuerte y resonante, utilizado para atraer a las hembras en grandes cantidades. Estudiar esta especie ayuda a entender los mecanismos de sincronización y los impactos ecológicos de las emergencias periódicas. Las emergencias de *Magicicada* tienen un impacto significativo en los ecosistemas, afectando tanto a la flora como a la fauna local.
- *Amphipsalta cingulata*: Comúnmente encontrada en Nueva Zelanda, esta cigarra emite un canto regular y melodioso. Es un modelo importante para estudiar la diversidad acústica en ambientes insulares y las adaptaciones ecológicas específicas de estas regiones. La biología y ecología de *Amphipsalta cingulata* proporcionan insights sobre cómo las cigarras se adaptan a entornos insulares con recursos limitados y fluctuaciones ambientales.
- *Tibicen linnei*: Conocida como la cigarra linneana, es común en América del Norte. Su canto es continuo y de alta frecuencia, utilizado principalmente en estudios de comportamiento territorial y comunicación intraespecífica. Esta especie es fundamental para entender cómo las cigarras utilizan el canto para establecer y defender territorios, así como para atraer a las hembras.

El estudio de las cigarras y sus cantos no solo enriquece el conocimiento sobre la biología y ecología de estos insectos, sino que también tiene importantes implicaciones prácticas en la conservación de la biodiversidad y la gestión de ecosistemas. La integración de técnicas avanzadas de procesamiento de señales y aprendizaje automático permite desarrollar herramientas efectivas para el monitoreo y conservación de estas especies. Además, estos estudios proporcionan datos esenciales para evaluar los efectos del cambio climático y otras perturbaciones ambientales sobre los ecosistemas naturales [49].

El conocimiento detallado sobre los cantos de cigarras y su variabilidad entre especies es crucial para desarrollar estrategias de conservación específicas y efectivas. La capacidad de identificar y monitorear especies a través de sus cantos facilita la detección temprana de cambios en las poblaciones, permitiendo una intervención rápida y efectiva. Asimismo, los estudios bioacústicos de cigarras pueden informar sobre la conectividad ecológica entre hábitats, la calidad del hábitat y los efectos de la fragmentación del paisaje [46].

## 2.2. Cálculo Fraccionario

El cálculo fraccionario se encarga de estudiar el uso de operadores de integración y derivación, donde se emplea que estos operadores tomen valores no enteros, así como órdenes fraccionarios, o números imaginarios [50]. La siguiente es la expresión (2.1) es la definición de una función de orden fraccionario

$${}_{\tau_0}^M D_{\tau_1}^\alpha f(t). \quad (2.1)$$

Donde  $M$  Representa el sentido de la derivada fraccionaria. Donde  $\tau_0$  indica el límite inferior, mientras que  $\tau_1$  representa el límite superior de la integral asociada, a sí mismo  $\alpha$  simboliza el orden de la derivada.

El cálculo fraccionario a diferencia del cálculo clásico no cuenta con una sola función que la defina, ya que está compuesta de diferentes expresiones matemáticas que cumplan con las propiedades necesarias para ser definidas como derivadas fraccionarias.

- Al definir el orden de la derivada como  $\alpha = 1$  se obtiene el caso clásico
- La característica de contener efecto de memoria.

El cálculo fraccionario cubre la necesidad de obtener soluciones a ecuaciones diferenciales de orden diferente de 1.

El cálculo fraccionario usualmente utiliza funciones generalizadoras como la función Gama o la función de Mittag-Leffler.

### 2.2.1. Función Gamma

La función Gama extiende la definición de un factorial, incluyendo números imaginarios a si como negativos no enteros, ya que en la práctica tradicional  $\alpha$  toma un valor entero.

La función Gama está definida por (2.2):

$$\Gamma = \int_0^\alpha e^{-t} t^{z-1} dt. \quad (2.2)$$

La propiedad que relaciona con los números factoriales está dada por (2.3):

$$\Gamma(x+1) = x\Gamma(x) = x!. \quad (2.3)$$

Donde  $x$  representa números reales, excluyendo de esto a los números enteros negativos.

### 2.2.2. Función de Mittag-Leffler

Permite la generalización de los exponenciales mediante una serie finita

$$E_{\alpha,\beta}(z) = \left( \sum_{n=0}^{\infty} \frac{z^n}{\Gamma(\alpha n + \beta)} \right). \quad (2.4)$$

Existen diversas definiciones de derivadas fraccionarias tales como:

### 2.2.3. Derivada de Riemann-Liouville

$${}_{0}^{RL} D_t^m f(t) = \frac{1}{\Gamma(n-m)} \frac{d^n}{dt^n} \int_0^t (t-\tau)^{n-m-1} f(\tau) d\tau, \quad m \in [n-1, n]. \quad (2.5)$$

Donde:

- $f(\tau)$  Representa la función.
- $(t-\tau)^{n-m-1}$  Simboliza el kernel de convolución.

El Kernel es quien permite la descripción de la memoria del sistema [51].

### 2.2.4. Definición de Grünwald-Letnikov

Esta es la discretización de la definición de la derivada de Riemann-Liouville representada como (2.6):

$${}^{GL} D^\alpha f(t) = \lim_{h \rightarrow 0} \frac{1}{h^\alpha} \sum_{m=0}^{\frac{t-\alpha}{h}} (-1)^m \frac{\Gamma(\alpha+1)}{m! \Gamma(\alpha-m+1)} f(t-mh). \quad (2.6)$$

### 2.2.5. Definición de Liouville-Caputo

En esta, a diferencia de la definición de Riemann-Liouville el operador se ubica fuera de la integral, mientras que en la definición de Liouville-Caputo el operador se encuentra dentro de la integral y se define como (2.7):

$$\left( {}^C D_b^{\alpha(t)} x \right) (t) = \frac{1}{\Gamma(n-\alpha(t))} \int_a^b \frac{d^n}{dt^n} \frac{x(\tau)}{(t-\tau)^{\alpha(t)-n+1}} d\tau. \quad (2.7)$$

### 2.2.6. Definición de Atangana-Baleanu-Caputo

La derivada fraccionaria en el sentido de Atangana-Baleanu-Caputo [52] está definida por la expresión siguiente (2.8):

$$({}^{ABC}D_b^{\alpha(t)}x)(t) = \frac{B(\alpha(t))}{1-\alpha(t)} \int_a^b \frac{d}{dt}(x(\tau)) E_{\alpha(t)} \left[ -\frac{\alpha(t)}{1-\alpha(t)}(t-\tau)^{\alpha(t)} \right] d\tau. \quad (2.8)$$

Los operadores de orden fraccionario permiten describir comportamientos físicos con memoria, así como fenómenos de fractalidad, por lo que presenta una ventaja considerable ante los operadores clásicos.

## 2.3. Procesamiento de señales

Una señal porta información sobre el estado o comportamiento de un sistema físico. Las señales son representadas como funciones de una o más variables independientes. Oppenheim recomienda referirse a la variable independiente como el tiempo de la representación matemática de la señal, donde esta variable independiente puede ser continua o discreta [53]. Las señales producidas por aparatos fonadores pueden ser representadas matemáticamente como función del tiempo, por otro lado, las imágenes puede ser representadas por la brillantez como una función de dos variables especiales. Estudio será enfocado a señales con una sola variable independiente [54].

**Señal en tiempo continuo:** Esta señal está definida en una escala temporal continua, esta señal es denominada comúnmente como señal analógica.

**Señal en tiempo discreto:** Se encuentran definidas en escalas de tiempo discretas

Están definidas por instantes discretos del tiempo, por ello la variable temporal toma valores discretos, esto significa que los instantes discretos del tiempo son representados como secuencias de números. En este caso La variable independiente es continua, por tanto, estas señales se definen en una sucesión continua de valores de la variable independiente. La variable independiente continua es expresada formalmente con el símbolo  $t$ . Las Señales Discretas solo están definidas en tiempos discretos en este tipo de señales la variable independiente solo usa conjuntos discretos de valores, en este caso la señal discreta de representación de la variable independiente será  $n$ . Sin importar el origen de la señal  $x[n]$  los valores están definidos solamente por números enteros. Las señales en tiempo discreto se representan matemáticamente como una secuencia de números. Además de ser continua o discreta la variable independiente, la amplitud de la señal puede ser de igual manera continua o discreta. Una señal discreta en el tiempo y en la amplitud es denominada señal digital. El procesamiento de señales es un campo fundamental en la ingeniería y la ciencia que se ocupa de manipular, analizar y extraer información útil de las señales. Las señales se definen como funciones de una o más variables independientes y pueden representar diversos fenómenos físicos y sistemas. Según Oppenheim y Schaffer [54], las señales pueden ser continuas o discretas en el tiempo, y su representación matemática puede ser analógica o digital.

El procesamiento de señales digitales se ha vuelto esencial en numerosas aplicaciones, desde las comunicaciones hasta la medicina y la imagenología. El libro "Digital Signal Processing: Principles, Algorithms, and Applications" de Proakis y Manolakis [55] aborda los principios fun-

damentales del procesamiento de señales digitales, incluyendo el análisis y la transformación de señales, el diseño de filtros digitales y algoritmos de procesamiento.

El tratamiento de señales se clasifica de forma similar a las señales. Los sistemas en tiempo continuo son aquellos en los que tanto en la entrada como en la salida son señales en tiempo continuo, Los sistemas en tiempo discreto de igual manera son definidos por su entrada y su salida.

### 2.3.1. Filtro pasabanda banda

Al aplicar un filtro de banda condensada a una señal, se eliminan o reducen las componentes de frecuencia fuera de la banda de interés, lo que facilita el análisis de la información relevante en esa banda. El diseño de estos filtros implica seleccionar cuidadosamente la frecuencia central y el ancho de banda para garantizar una respuesta precisa a las frecuencias deseadas.[104]. un filtro pasabanda es un dispositivo que se utiliza para resaltar o aislar una banda específica de frecuencias dentro de una señal y atenuar o eliminar las frecuencias fuera de ese rango, y su comportamiento se puede entender en términos de la densidad espectral de potencia de la señal de entrada y la respuesta en frecuencia del filtro. Un filtro pasa-banda es un tipo de filtro en el procesamiento de señales que permite que las componentes de frecuencia de una señal que se encuentran dentro de un cierto rango de frecuencias pasen a través del filtro, mientras atenúa o elimina las componentes de frecuencia que están fuera de ese rango. En otras palabras, un filtro pasa-banda se utiliza para seleccionar o pasar un cierto rango de frecuencias de una señal y rechazar las frecuencias que están por encima y por debajo de ese rango.

Se establece una relación entre la densidad espectral de potencia de la señal de entrada  $\Phi_{xx}[0]$  y la densidad espectral de potencia de la señal de salida  $\Phi_{yy}[0]$  cuando la función de transferencia del filtro es un filtro pasa banda ideal. La ecuación (193) describe cómo se puede calcular la densidad espectral de potencia de la señal de salida en términos de la densidad espectral de potencia de la señal de entrada y la respuesta en frecuencia del filtro. Donde  $\omega_a$  y  $\omega_b$  representan las frecuencias de corte inferior y superior del filtro, respectivamente. El área bajo la curva de la densidad espectral de potencia de la señal de entrada en la banda de frecuencia entre  $\omega_a$  y  $\omega_b$  se considera el valor cuadrático medio de la entrada en esa banda de frecuencia. Esto significa que el filtro pasa-banda permite que las componentes de frecuencia de la señal que caen dentro de este rango de frecuencias seleccionado pasen a través del filtro, y la potencia de estas componentes se refleja en la densidad espectral de potencia de la señal de salida

### 2.3.2. Transformadas Integrales

Las transformadas integrales son operadores matemáticos que relacionan una función con un conjunto de parámetros mediante la integración. En el contexto de este artículo, consideramos la transformada integral definida como se muestra en la Ecuación (2.9)

$$F(u) = \int_{a_1}^{a_2} K(n) \cdot f(t) dt. \quad (2.9)$$

Donde:

$f(t)$  representa la función a transformar.

$K(n)$  es el kernel de transformación.

$a_1, a_2$  definen los límites de la integral.

### 2.3.3. Transformada de Fourier

La ejemplificación más básica de la serie de Fourier es que toda función periódica con un periodo  $T$  puede expresarse como una adición trigonométrica de senos y cosenos de periodo  $T$  [56]. La transformada de Fourier es una herramienta fundamental en el análisis de señales. Permite representar una función en el dominio de la frecuencia y se define en la Ecuación (2.10)

$$F(\omega) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-i\omega t} f(t) dt. \quad (2.10)$$

Donde  $f(t)$  es la señal de entrada y  $\omega$  es la frecuencia angular [57].

Para una función  $F(\omega)$  en el dominio de la frecuencia la transformada inversa de Fourier se muestra en la Ecuación (2.11)

$$f(t) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{i\omega t} F(\omega) d\omega. \quad (2.11)$$

La transformada inversa de Fourier se utiliza para recuperar la señal original a partir de su representación en el dominio de la frecuencia [57]. La transformada inversa de Fourier es una herramienta que permite la investigación de estructuras periódicas en espectros de frecuencia, principalmente es aplicada en el análisis de sonidos acústicos, esto sirve como herramienta para investigar las propiedades periódicas en espectros de frecuencia.

### 2.3.4. Transformada Fraccionaria de Fourier

La FRFT es una generalización de la transformada de Fourier que permite rotar el ángulo en el plano tiempo-frecuencia. La transformada fraccionaria de Fourier la definió por primera vez Víctor Namias en el año 1980 [58]. Transformada fraccionaria de Fourier se define en la Ecuación (2.12)

$$f_a(u) = \int_{-\infty}^{\infty} K_a(u, u') f(u') du', \quad \text{donde} \quad (2.12)$$

$$K_a(u, u') = A_\alpha \exp[i\pi(\cot \alpha u^2 - 2 \csc \alpha uu' + \cot \alpha u'^2)],$$

y

$$A_\alpha = \exp \sqrt{1 - i \cot \alpha}, \quad \alpha = \frac{a\pi}{2}. \quad (2.13)$$

Donde  $a \neq 2j$ , cuando  $\alpha = 4j$  la transformación es definida como  $K\alpha(u, u') = \delta(u - u')$  y cuando  $a = 4j + 2$  la transformada se define como  $K\alpha(u, u') = \delta(u + u')$  se puede demostrar que el kernel para  $a \neq 2j$  se acercan estas funciones delta cuando se aproxima el kernel a un números enteros par.

## 2.4. CLASIFICACIÓN

---

La elección del valor de  $\alpha$  afectará cómo se analiza la señal en términos de su contenido espectral y temporal. Está transformada es útil en aplicaciones donde se necesitan representaciones de señales que no se ajustan bien a las propiedades de la transformada de Fourier tradicional. La FRFT es de gran importancia en el análisis de señales en tiempo-frecuencia [59], con diversas aplicaciones en campos como comunicación, cifrado, procesamiento de imágenes y reconocimiento de patrones.

La matriz de transformación de discreta de la FRFT se define en la ec. 2.14

$$\mathbf{F}^\alpha[m, n] = \sum_{k=0}^{N-1} u_k[m] e^{-j\frac{\pi}{2}k\alpha} u_k[n]. \quad (2.14)$$

En donde  $u_k[m]$  y  $u_k[n]$  denotan las funciones de hermite-gauss.

### 2.3.5. Transformada wavelet

La transformada wavelet descompone señales en componentes escaladas y desplazadas de una función previamente definida conocida como wavelet madre. La Ecuación (2.15) presenta de manera general la función wavelet madre con escalamiento  $a$  y desplazamiento  $b$

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \cdot \psi\left(\frac{t-b}{a}\right). \quad (2.15)$$

La Ecuación (2.16) presenta la transformada wavelet

$$WT(f(t)) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \psi\left(\frac{t-b}{a}\right). \quad (2.16)$$

La transformada Wavelet, descompone señales en componentes de tiempo y frecuencia, aportando detalles tanto en el dominio temporal como en el espectral, en contraste con la transformada de Fourier. La selección de la función wavelet madre dependerá de la morfología de la señal a analizar.

La aplicación de la transformada wavelet como filtros para la descomposición de una señal se lleva a cabo a través de la definición de la función wavelet madre como

$$\Phi(t) = \sum_{k=-1}^{N-2} (-1)^k \cdot c_{k+1} \psi(2t+k), \quad (2.17)$$

en donde  $c_k$  corresponde a los coeficientes wavelet, los cuales pueden ser usados como filtros, al odernarse en dos tipos de patrones de forma matricial, en la Fig. 2.1 se muestra el diagrama de la descomposición wavelet.

## 2.4. Clasificación

Un clasificador, en el contexto del aprendizaje automático y la inteligencia artificial, es un tipo de modelo o algoritmo que se utiliza para asignar una etiqueta, categoría o clase a un conjunto de

---

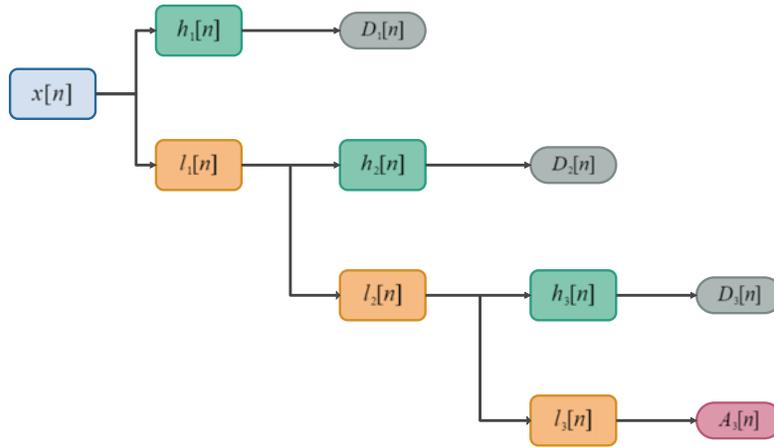


Fig. 2.1. Descomposición wavelet 3 niveles.

datos o elementos. La tarea principal de un clasificador es analizar las características o atributos de entrada de los datos y predecir la etiqueta o clase a la que pertenecen.

La clasificación es un proceso fundamental en el campo del reconocimiento de patrones que implica asignar objetos o eventos a categorías predefinidas en función de sus características. Este proceso tiene aplicaciones amplias en campos como biología, medicina e informática. En la clasificación los pasos clave son: la extracción de características de los objetos, la elección de algoritmos de clasificación apropiados, el entrenamiento del modelo utilizando datos etiquetados y la validación del modelo. Finalmente, el modelo se utiliza para hacer predicciones en nuevos datos no etiquetados [60].

Un clasificador es una herramienta que permite automatizar la tarea de categorizar o etiquetar datos en función de patrones, reglas o características específicas. Los clasificadores son esenciales en el campo del aprendizaje automático y desempeñan un papel fundamental en la automatización de procesos y la toma de decisiones basada en datos.

### 2.4.1. Redes neuronales artificiales

Las redes neuronales artificiales (RNA) se basan en modelos simplificados de las redes neuronales biológicas, buscando capturar su capacidad de resolver problemáticas como el reconocimiento de patrones, una RNA es definida también como un procesador paralelo distribuido e interconectado que almacena conocimiento experimental [61].

En la figura 2.2 se muestra el modelo de una neurona propuesto por McCulloch-Pitts.

Modelo Artificial de una red neuronal propuesto por McCulloch and Pitts, es un modelo matemático no lineal de aproximación inspirada en el modelo de la distribución de datos de una neurona biológica [62].

El modelo es representado por la ecuación siguiente (2.18)

$$y(\varphi) = \left( \sum_{i=1}^n x_i w_{i+\theta} \right). \quad (2.18)$$

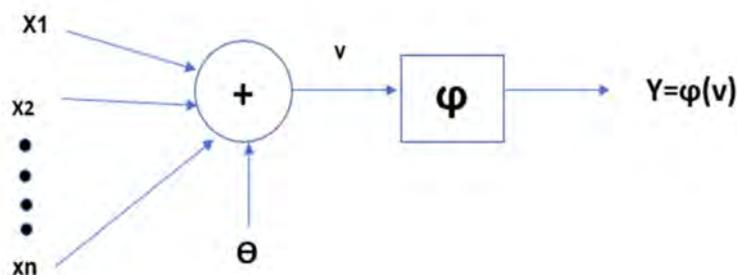


Fig. 2.2. Neurona de McCulloch-Pitts

La notación de la neurona está dada por la siguiente nomenclatura: [63]

- $x_i$  =es la i-ésima entrada en la cual se puede recibir información,
- $w_i$  es el i-ésimo peso sináptico, este se encarga de atender las entradas donde si su valor es  $w_i > 0$ , Es una sinapsis excitatoria y si  $w \leq 0$  es una sinapsis inhibitoria.
- $\theta$  =es el umbral de activación (umbral).
- $\varphi$  =es la función de activación, efectúa el procesamiento de las sumas de las señales de entrada.
- $y$  =es la salida de la neurona.
- $v$  =es igual al argumento de la función de activación.

Las redes neuronales presentan diversas ventajas [64], listadas a continuación:

- **Modelado con relación entrada-salida:** La capacidad de aprender con base en un conjunto de pares de datos denominados entrada-salida, estos permiten la optimización de los pesos de la red generando un mapeo entrada-salida y así analizar circunstancias no antes reproducidos por el conjunto de datos primario.
- **Aprendizaje adaptativo:** Estos sistemas presentan la capacidad de aprendizaje, de ejecución de tareas, partir de cierto entrenamiento, ya que con la cualidad de auto-ajuste de las neuronas, en el entrenamiento los pesos relacionados con las neuronas se ajustan, de manera que la RNA replica los resultados con el fin que fue diseñada, no es necesario conocer la información de los procesos internos, ya que la RNA cuenta con auto-organización y distribución de pesos mediante los datos ofrecidos en el entrenamiento.
- **Identificación de fallos:** Las RNA llegan a reconocer alteraciones dentro de los patrones, con base en información correcta para ser comparada con las fallas.
- **No linealidad:** las neuronas generalmente son elementos no lineales, por lo que al estar interconectadas se genera una estructura de datos donde la no linealidad queda distribuida por la red, por lo que complica la aplicación de técnicas de sistemas lineales.

- **Operación en tiempo real:** Una vez entrenada la RNA su respuesta ante nuevas variables en la entrada es rápida.
- **Fácil adaptación dentro de la tecnología existente.**

La Ecuación (2.19) representa una capa de una red neuronal, donde  $X$  y  $Y$  son la entrada y la salida de la capa respectivamente.  $W$  representa los pesos sinápticos que ponderan la entrada.  $\theta$  es el bias de las neuronas y  $\varphi$  la función de activación.

$$Y_i = \varphi(W_i X_i + \theta). \quad (2.19)$$

En el contexto de la clasificación automática, las RNA pueden ser empleadas como clasificadores. Un clasificador analiza las características de los datos y predice su etiqueta. Estas herramientas automatizan la categorización basada en patrones, reglas o características específicas, siendo fundamentales en la automatización de procesos y la toma de decisiones basada en datos. Los clasificadores son claves en la organización y comprensión de grandes conjuntos de información. El reconocimiento de patrones se encarga de extraer información a fin de mostrar las propiedades entre conjuntos de eventos, los patrones son obtenidos a partir de procesos de extracción y separación de características donde cada caso queda descrito por sus propiedades, una vez hecho esto son asignadas en categorías o clases (conjunto de entidades que comparten características con respecto de las demás a cada muestra obtenida.) la clasificación es utilizada para asignar eventos o elementos en un grupo o clase basándose en sus características [65].

# Capítulo 3

## Clasificación de señales bioacústicas

La bioacústica es un campo de estudio que investiga las características de las expresiones fonéticas a través del análisis de señales sonoras. Una de sus tareas principales es la diferenciación precisa de señales acústicas similares, lo que puede ser un desafío dado que las señales pueden tener características muy parecidas[66].

Para enfrentar este desafío, se emplean herramientas matemáticas como la transformada de Fourier para analizar las señales sonoras, aunque esta técnica puede tener dificultades para distinguir entre señales altamente similares. Para mejorar esta diferenciación, se han adoptado transformadas integrales de orden fraccionario, que ofrecen una mayor precisión en la identificación y clasificación de sonidos bioacústicos[67].

Además, se desarrolla una metodología que se basa en el comportamiento de las señales, utilizando técnicas de extracción de características y redes neuronales especializadas. Estas herramientas permiten clasificar sonidos de acuerdo con su origen fonético de manera más precisa.

El estudio también utiliza transformadas integrales de orden generalizado para facilitar la clasificación de señales bioacústicas. Esta metodología proporciona una representación más detallada de las señales, permitiendo identificar patrones específicos en los sonidos[68].

El objetivo final de este tipo de investigación es mejorar la clasificación de señales bioacústicas mediante transformadas integrales de orden generalizado y redes neuronales especializadas. Esto permite distinguir con precisión sonidos, incluso cuando son similares o están superpuestos. Estos avances prometen tener un impacto positivo en la comprensión de especies y ecosistemas, contribuyendo así al estudio y conservación del entorno natural a través del análisis de sonidos bioacústicos.



Fig. 3.1. Esquema de metodología general de solución

### 3.1. Clasificación de cantos de anuros

Conservar los ecosistemas es crucial para garantizar la variedad y abundancia de formas de vida en nuestro entorno, lo que a su vez nos brinda la posibilidad de asegurar la sostenibilidad de los recursos naturales en el largo plazo. Mantener la biodiversidad de los ecosistemas es esencial para mantener el equilibrio ecológico, prevenir la extinción de especies y preservar los servicios vitales que estos ecosistemas nos proporcionan, tales como la producción de alimentos, la regulación del clima y la purificación del agua. Asimismo, la conservación de la biodiversidad contribuye a la resiliencia de los ecosistemas frente a los cambios ambientales y climáticos, lo que resulta fundamental para la supervivencia y el bienestar tanto de las comunidades humanas como de las demás formas de vida en el planeta. Por lo tanto, proteger los ecosistemas es una inversión en nuestro futuro y en el mantenimiento del equilibrio de la vida en la Tierra [69].

Un método de monitoreo no invasivo de especies para su conservación y estudio es la bioacústica, el cual es un enfoque que aprovecha los sonidos naturales emitidos por los animales para obtener información de su presencia, distribución, comportamiento y salud. Al utilizar grabaciones de sonidos en diferentes hábitats, los investigadores pueden identificar y clasificar especies, rastrear sus movimientos y evaluar la salud de las poblaciones sin perturbar su entorno natural. La bioacústica ofrece ventajas significativas sobre otros métodos de monitoreo, ya que es no invasiva, económica y eficiente, y puede aplicarse en una variedad de entornos, desde bosques densos hasta océanos profundos. Además, el uso de tecnologías avanzadas, como el análisis computarizado de sonidos y la inteligencia artificial amplía aún más las capacidades de la bioacústica en la detección y seguimiento de especies [70].

En el caso particular de anfibios, el conocimiento de su ecología es esencial para desarrollar estrategias efectivas destinadas a preservar sus poblaciones. Esta comprensión profunda de cómo interactúan y dependen los anfibios de su entorno nos permite trazar planes de acción específicos que aborden las amenazas que enfrentan. A nivel global, existe una extensa documentación que evidencia la disminución preocupante de las poblaciones de diferentes especies de anfibios. Este declive generalizado nos alerta sobre la urgencia de actuar para proteger estas criaturas y los ecosistemas en los que habitan [71].

En los anuros, que son un orden de anfibios que incluye a las ranas y sapos, el canto juega un papel crucial en sus interacciones sociales y reproductivas. Estos animales utilizan sus llamadas vocales como una forma de comunicación para atraer a potenciales parejas, establecer territorios y advertir a competidores. El canto no solo transmite información sobre la identidad y la calidad genética del emisor, sino que también proporciona pistas sobre su estado físico y su posición en el entorno. La Figura 3.2 presenta el diagrama taxonómico de algunas especies de anuros, cuya preservación es relevante como medida de protección al medio ambiente.

### 3.1. CLASIFICACIÓN DE CANTOS DE ANUROS

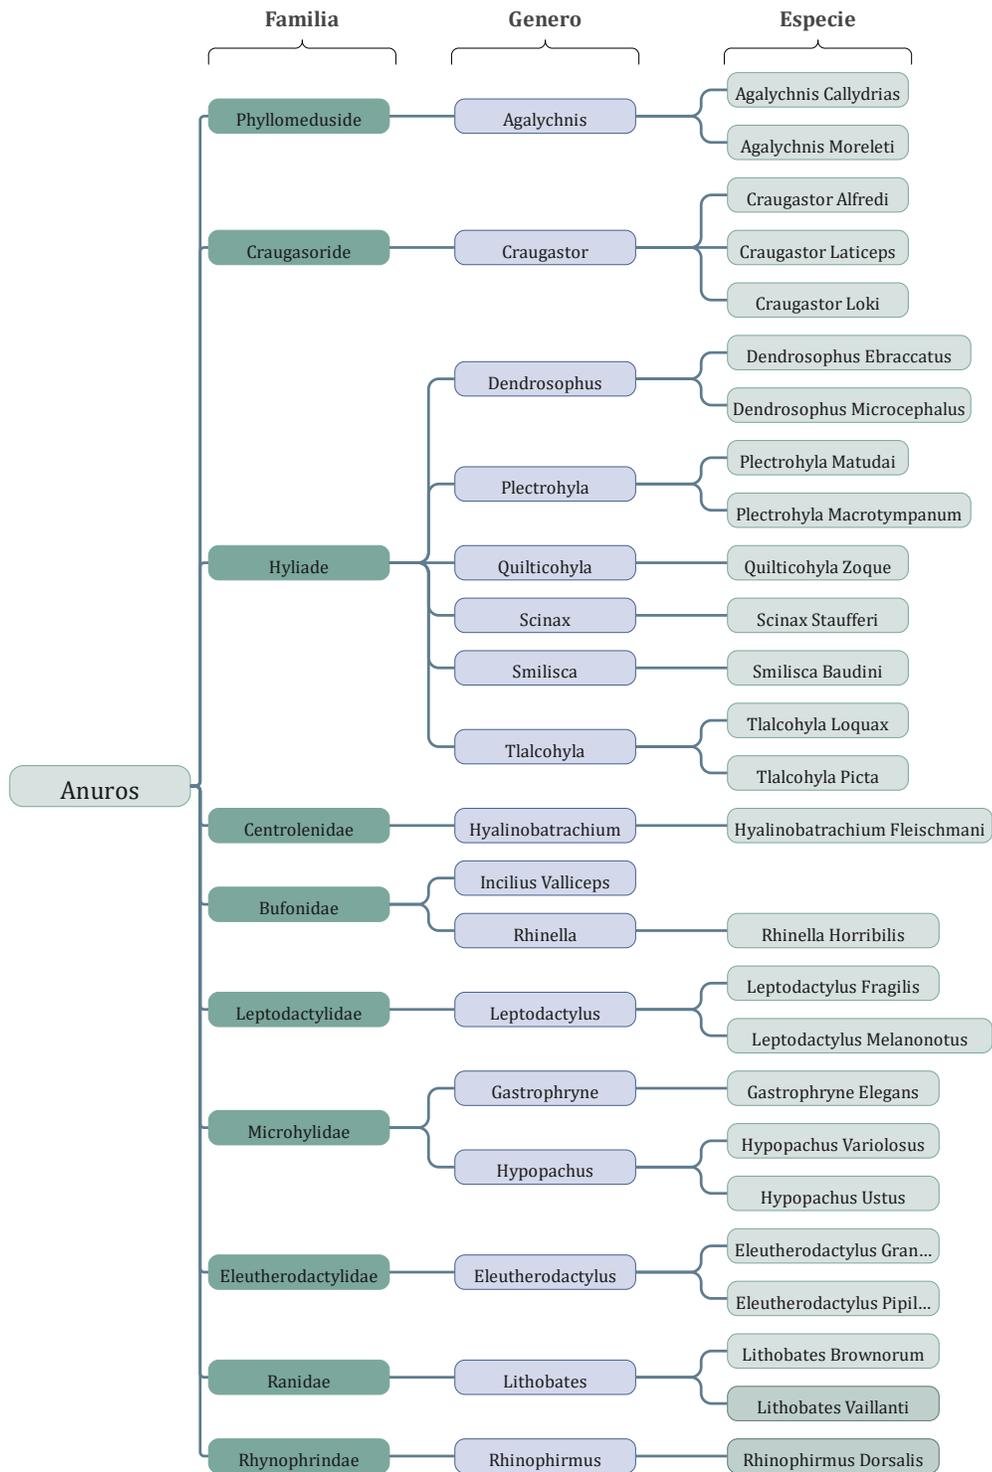


Fig. 3.2. Diagrama de taxonomía de anuros

### 3.1. CLASIFICACIÓN DE CANTOS DE ANUROS

---

En esta sección, se describe el proceso de entrenamiento de un modelo de clasificación que utiliza características derivadas de transformadas integrales de orden fraccionario. El propósito de este modelo es distinguir entre diferentes especies de anuros basándose en sus llamadas vocales. El objetivo final es desarrollar un sistema preciso y eficaz que pueda identificar automáticamente las especies de anuros basándose en sus vocalizaciones. Este enfoque puede tener aplicaciones importantes en la investigación y conservación de la vida silvestre, así como en el monitoreo de poblaciones de anfibios en entornos naturales.

#### 3.1.1. Base de datos

En los anuros, el canto desempeña un papel crucial en la reproducción y la selección sexual, ya que transmite información sobre las características físicas y la ubicación de las especies. El sonido producido proviene del sistema muscular, el cual está compuesto por el aparato laríngeo, los músculos del tronco y el saco bucal, este último encontrado únicamente en los machos.

La laringe de los anuros consiste en una estructura cartilaginosa que contiene las cuerdas vocales. Estas cuerdas son capaces de vibrar y producir sonidos cuando el aire pasa a través de ellas [38]. La morfología y las características físicas de las cuerdas vocales varían entre especies, lo que da lugar a una amplia diversidad de vocalizaciones, que permiten diferenciar entre ellas. Además de la laringe y las cuerdas vocales, otros órganos y estructuras pueden estar involucrados en la producción del canto. Por ejemplo algunos machos de anuros poseen sacos vocales o resonadores que amplifican y modulan el sonido producido [42]. La capacidad de inflar o desinflar estos sacos vocales permite a los anuros ajustar las propiedades acústicas de sus vocalizaciones, lo que puede ser crucial para la comunicación y la interacción social.

Es posible clasificar las vocalizaciones de los anuros de acuerdo a su taxonomía o bien, por el contexto de comportamiento. Las vocalizaciones del canto de los anuros se clasifican por taxonomía o por un contexto de comportamiento. Existen cantos de anuncio, atracción sexual, advertir o anunciar receptividad sexual, este tipo de sonidos son emitidos por especies territoriales de corto rango alarmas y peligro. La variación de los cantos debido al contexto dentro de ejemplares de la misma especie presenta un grado de dificultad adicional al momento de identificarlas.

En este trabajo, se consideró la base de datos proveniente del estudio "Monitoreo bioacústico en la reserva de la biosfera Naha en Chiapas"[72], en donde se utilizaron dos grabadoras para registrar el canto de anuros, para obtener un total de 370 horas de grabación. Las grabaciones fueron obtenidas con una frecuencia de muestreo de 48 KHz. En los sonidos obtenidos se identificaron un total de 12 especies, de las cuales 5 se identificaron únicamente a nivel de género. Para analizar las grabaciones se generaron espectrogramas de las señales por medio del programa Raven Pro 1.4.

3.1. CLASIFICACIÓN DE CANTOS DE ANUROS

---



Fig. 3.3. Familia Bufonidae.



Fig. 3.4. Familia Hylidae.

3.1. CLASIFICACIÓN DE CANTOS DE ANUROS

---



Fig. 3.5. Familia Centrolenidae.



Fig. 3.6. Familia Craugastoridae.



Fig. 3.7. Familia Eleutherodactylidae.

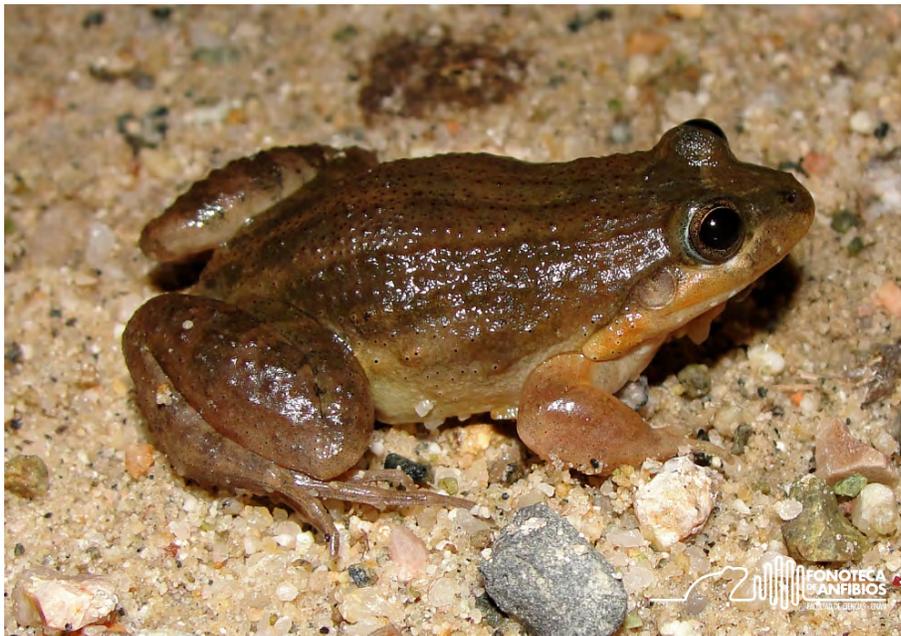


Fig. 3.8. Familia Leptodactylidae.

3.1. CLASIFICACIÓN DE CANTOS DE ANUROS

---



Fig. 3.9. Familia Ranidae.



Fig. 3.10. Familia Rhynophrynidae.

### 3.1.2. Preprocesamiento

Las señales fueron registradas en un entorno natural no controlado, lo que significa que estaban sujetas a la presencia de ruido ambiental característico del ecosistema de donde provienen. Este ruido puede ser producto de una variedad de fuentes, como el viento, otros animales, actividades humanas cercanas o incluso fenómenos naturales como la lluvia o el tráfico de agua. La presencia de este ruido de fondo puede afectar la calidad de las grabaciones y dificultar la identificación precisa de las vocalizaciones de los anuros. Para abordar este desafío, se realizó un análisis exhaustivo de las frecuencias asociadas con las especies de anuros consideradas, utilizando información recopilada de investigaciones previas. La Tabla 3.1 proporciona detalles sobre los rangos de frecuencia asociados con cada especie considerada.

Tabla 3.1. Rangos de frecuencia de los sonidos de anuros considerados.

Clase	Especie y cita	Rango [kHz]
1	Agalychnis callydrias [129]	1.5 – 2.5
2	Agalychnis moreleti[130]	1.0 – 1.4
3	Anotheca spinosa [131]	0.5 – 2.5
4	Craugastor Sp1 [40]	1.0 – 2.1
5	Craugastor Sp2[40]	1.0 – 2.1
6	Craugastor Sp3[40]	1.0 – 2.1
7	Craugastor Sp4[40]	1.0 – 2.1
8	Craugastor Sp5 [40]	1.0 – 2.1
9	Dendrosophus ebraccatus[133]	2.5 – 3.5
10	Hyalinobatrachium fleishmani [136]	3.8 – 7.6
11	Hypopachus variolosus [67]	0.9 – 1.3
12	Lithobates brownorum [115]	1.1 – 2.4
13	Rhinella horribilis [41]	0.6 – 5.8
14	Rhinophirinus dorsalis [69]	1.1 – 1.9
15	Tlalocohyla loquax [120]	0.9 – 1.5

Un filtro pasabanda se utiliza para resaltar o aislar una banda específica de frecuencias dentro de una señal y atenuar o eliminar las frecuencias fuera de ese rango, y su comportamiento se puede entender en términos de la densidad espectral de potencia de la señal de entrada y la respuesta en frecuencia del filtro [73]. La Ecuación (3.1) establece la base para comprender el concepto de espectro de densidad de potencia.

$$\phi_{yy}(e^{j\omega}) = |H(e^{j\omega})|^2 \phi_{xx}(e^{j\omega}). \quad (3.1)$$

Aquí,  $\phi_{yy}(e^{j\omega})$  es la densidad espectral de potencia de la señal de salida  $y[n]$ ,  $|H(e^{j\omega})|^2$  es la respuesta en frecuencia del filtro, y  $\phi_{xx}(e^{j\omega})$  es la densidad espectral de potencia de la señal de entrada  $x[n]$ . Esta ecuación muestra que la densidad espectral de potencia de la señal de salida es el producto de la densidad espectral de potencia de la señal de entrada y el cuadrado del módulo de la respuesta en frecuencia del filtro. La potencia total de la señal de salida está dada por la Ecuación (3.2):

$$\varepsilon y^2[n] = \phi_{yy}[0] = \frac{1}{2\pi} \int_{-\pi}^{\pi} \phi_{yy}(e^{j\omega}) d\omega. \quad (3.2)$$

Sustituyendo la Ecuación (3.1) en (3.2), obtenemos:

$$\varepsilon y^2[n] = \phi_{yy}[0] = \frac{1}{2\pi} \int_{-\pi}^{\pi} |H(e^{j\omega})|^2 \phi_{xx}(e^{j\omega}) d\omega. \quad (3.3)$$

Esta expresión relaciona la potencia media de la señal de salida,  $Ey^2[n]$  o  $\varepsilon_{yy}[0]$ , con la respuesta en frecuencia del filtro  $|H(e^{j\omega})|^2$  y la densidad espectral de potencia de la señal de entrada  $\phi_{xx}(e^{j\omega})$ . La integral se evalúa sobre todas las frecuencias posibles, es decir de  $-\pi$  a  $\pi$ . Para un filtro pasabanda ideal,  $|H(e^{j\omega})|^2$  es una función par de  $\omega$ . Dado que  $\phi_{xx}[m]$  es una secuencia real y par, su transformada de Fourier también es real y par:

$$\phi_{xx}(e^{j\omega}) = \phi_{xx}(e^{-j\omega}). \quad (3.4)$$

La potencia promedio en la salida se puede expresar como:

$$\phi_{yy}[0] = \frac{1}{2\pi} \int_{\omega_a}^{\omega_b} \phi_{xx}(e^{j\omega}) d\omega + \frac{1}{2\pi} \int_{-\omega_b}^{-\omega_a} \phi_{xx}(e^{j\omega}) d\omega. \quad (3.5)$$

Aquí, el área bajo  $\phi_{xx}(e^{j\omega})$  para  $\omega_a \leq |\omega| \leq \omega_b$  representa la potencia de la señal de entrada en esa banda de frecuencia. La potencia de salida debe ser no negativa:

$$\lim_{(\omega_b - \omega_a) \rightarrow 0} \phi_{yy}[0] \geq 0. \quad (3.6)$$

Este resultado, junto con la Ecuación (3.5) y el hecho de que la banda  $\omega_a \leq \omega \leq \omega_b$  puede ser arbitrariamente pequeña, implica que:

$$\phi_{xx}(e^{j\omega}) \geq 0, \forall \omega. \quad (3.7)$$

Esto nos lleva a concluir que la función de densidad de potencia de una señal real es siempre real, par y no negativa. Las frecuencias de corte del filtro,  $\omega_a$  y  $\omega_b$ , determinan el rango de frecuencias que pasan a través del filtro pasabanda, y el área bajo la curva de la densidad espectral de potencia de la señal de entrada entre  $\omega_a$  y  $\omega_b$  representa la potencia de las frecuencias que se transfieren a la señal de salida.

El filtro pasabanda utilizado fue diseñado con una atenuación de  $60dB$  para frecuencias fuera de los rangos especificados en la Tabla 3.1. Se empleó un filtrado de fase cero con la finalidad de no alterar la fase de las señales procesadas.

El filtrado de fase cero se refiere al proceso de filtrado en el cual no se altera la fase de la señal, esto quiere decir que solo se modifica la amplitud de los datos, sin introducir desfasamiento. Una manera de lograr un filtrado de fase cero es aplicando un filtro dos veces; primero hacia adelante y luego hacia atrás, como se muestra en la Ecuación (3.8)

$$y[n] = x[n] * h[n] * h[-n]. \quad (3.8)$$

### 3.1. CLASIFICACIÓN DE CANTOS DE ANUROS

---

Donde  $y[n]$  es la señal filtrada,  $x[n]$  se refiere a la señal de entrada y  $h[n]$  es la respuesta del filtro al impulso finito. En este caso  $*$  denota la operación de convolución.

Dado que el filtro se aplica en ambas direcciones (hacia adelante y hacia atrás), cualquier desfase introducido por la primera aplicación del filtro es cancelado por la segunda. Esto resulta en una respuesta en frecuencia cuya fase es cero, es decir, todas las componentes de frecuencia permanecen en fase.

La Figura 3.11 presenta la comparación entre una señal tomada de la base de datos previamente mencionada con la misma señal filtrada. Como puede verse, el filtrado del ruido ambiental permite distinguir de manera mas clara los periodos de actividad en las bandas de frecuencia de interés.

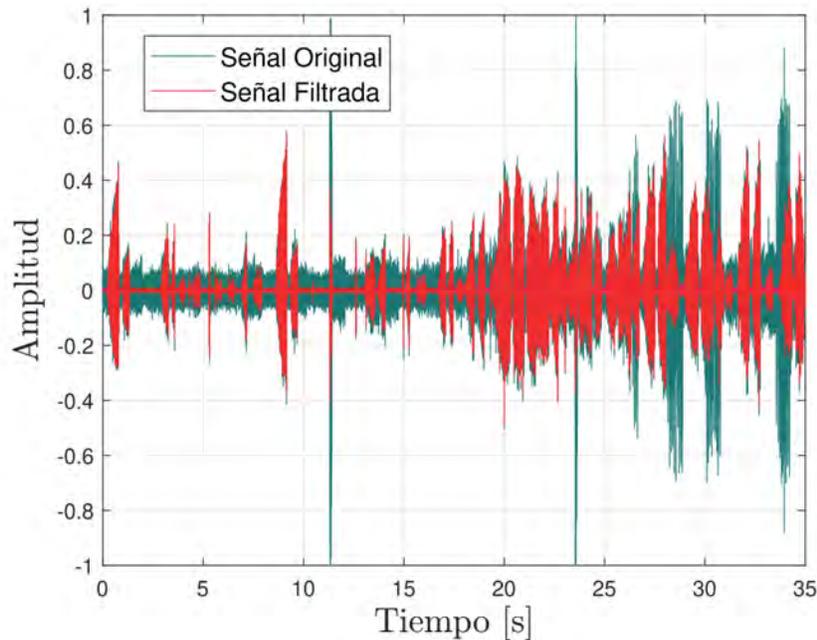


Fig. 3.11. Comparación de una señal con ruido ambiental y su filtrado.

Debido a que en algunos casos las tiras de audio presentaban mas de un sonido por archivo se realizó la segmentación de estas señales para asegurar tener una sola instancia de canto por señal. De manera general, los cantos de anuros obtenidos podrían categorizarse en dos: cantos continuos y cantos intermitentes. Para la segmentación de archivos con cantos intermitentes se realizó un monitoreo de amplitud en la señal, es decir, se detectaron los momentos en donde la intensidad del sonido aumentaba y se tomaron como el inicio del canto del anuro. En el caso de los cantos continuos se realizó una segmentación basada en ventanas de duración predefinida. Para el posterior entrenamiento de la red neuronal se realizó un balanceo de los datos mediante un enfoque discriminativo, donde se igualó la cantidad de ventanas disponible para cada especie en el conjunto de datos, garantizando así que todas las especies se encuentren representadas de manera equitativa en la base de datos. Esto es importante para evitar el sobre entrenamiento de la red neuronal con respecto a una clase específica y mantener la generalidad del modelo.

#### 3.1.3. Extracción de características

Una vez filtrado el ruido de las señales es necesario encontrar valores cuantitativos que permitan a la red neuronal distinguir entre las clases previamente definidas, en este caso las especies de anuros. Para esto se realizó un análisis exploratorio de algunas variables temporales, listadas a continuación:

- Pulsos por nota.
- Tasa de pulsos.
- Duración del pulso de máxima amplitud.
- Tiempo de caída del pulso de máxima amplitud.

En el caso específico del género *Craugastor*, las vocalizaciones producidas por diferentes especies resultan muy similares debido a la similitud en la estructura de aparato fonador. La tabla 3.1 presenta algunas de las especies de anuros pertenecientes al genero *Carugastor*. Si bien todas las especies son similares a simple vista, también es posible discernir diferencias notables como por ejemplo su color o patrones en la piel del animal. Sin embargo, en el caso de las señales acústicas obtenidas, los sonidos pueden ser complicados de diferenciar debido a que tienen características similares.

En el caso del género *Craugastor*, la vocalización presentó desafíos en la identificación debido a la similitud en la estructura. La falta de vocalizaciones asociadas entre especies llevó a considerarlas como diferentes, destacando la importancia de las vocalizaciones en la diferenciación y clasificación de especies dentro de este género.

El trabajo que se realizó en este estudio consiste en el análisis de las cuatro variables que más variaciones presentaban, como:

Con estas variables se realizó un análisis multivariado de varianza para comprobar las existencias significativas [6].

En las grabaciones las vocalizaciones resultaron ser muy parecidas (todas consisten en una sola nota de larga duración emitida entre 3 y 5 kHz) mostrando que su variación principal se dio en la frecuencia [43].

A continuación observamos los cantos de las siguientes especies de anuros utilizando la STFT.

### 3.1. CLASIFICACIÓN DE CANTOS DE ANUROS

---



Fig. 3.12. Craugastor SP1.



Fig. 3.13. Craugastor SP2.



Fig. 3.14. Craugastor SP3.



Fig. 3.15. Craugastor SP4.



Fig. 3.16. Craugastor SP5.

La Figura 3.17 muestra la comparación de los espectrogramas de las señales acústicas de las especies de anuros, se puede apreciar que comparten bandas de frecuencia, lo cual dificulta identificar la especie en particular.

### 3.1. CLASIFICACIÓN DE CANTOS DE ANUROS

---

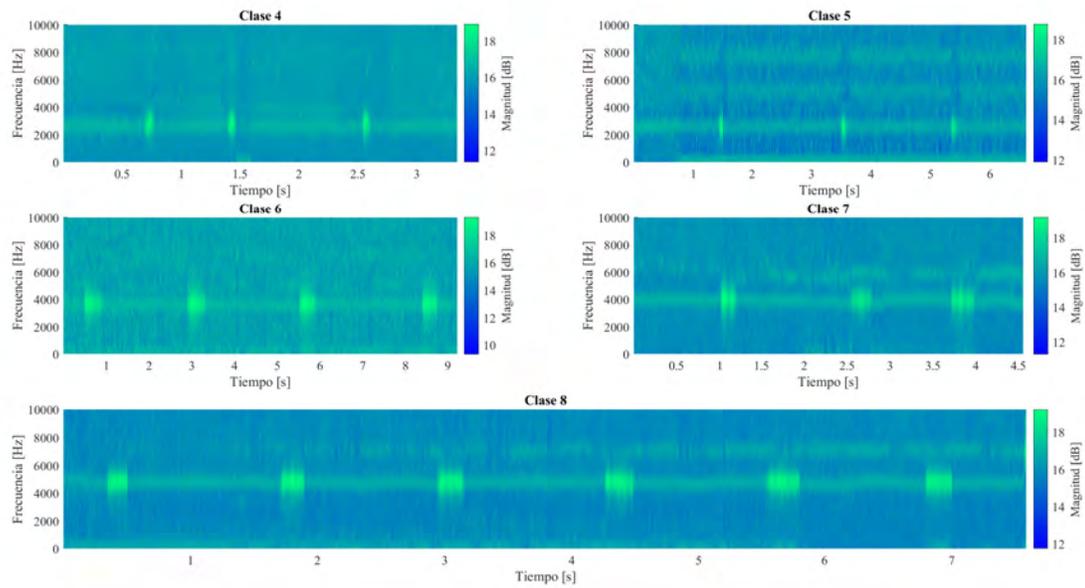


Fig. 3.17. Comparación de los espectrogramas de especies de anuros.

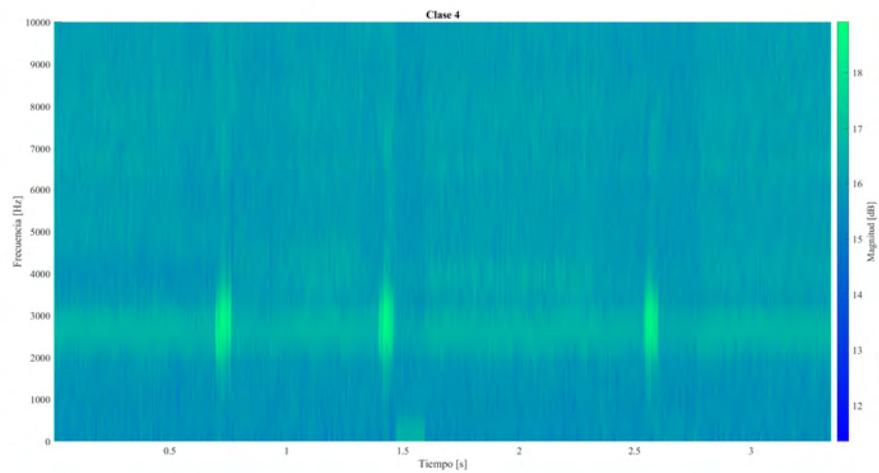


Fig. 3.18. Espectrograma de canto Craugastor Sp1.

### 3.1. CLASIFICACIÓN DE CANTOS DE ANUROS

---

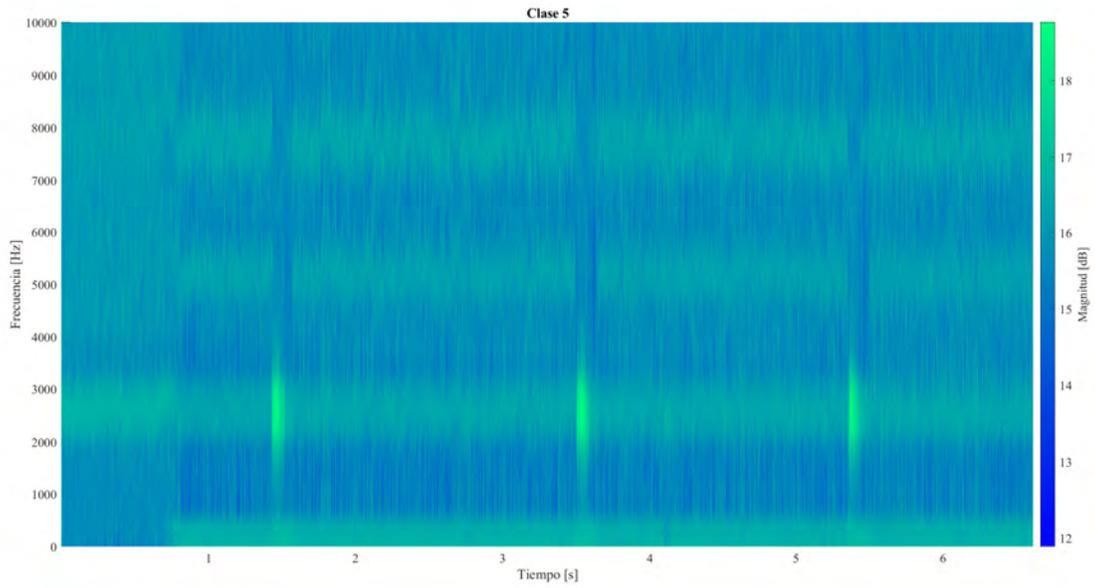


Fig. 3.19. Espectrograma de canto Craugastor Sp2.

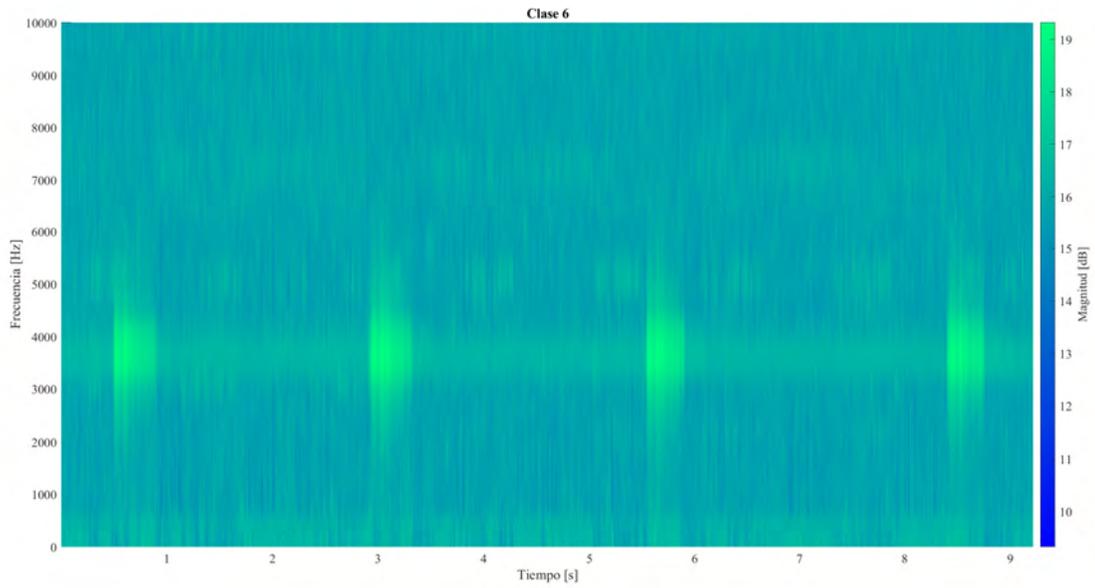


Fig. 3.20. Espectrograma de canto Craugastor Sp3.

### 3.1. CLASIFICACIÓN DE CANTOS DE ANUROS

---

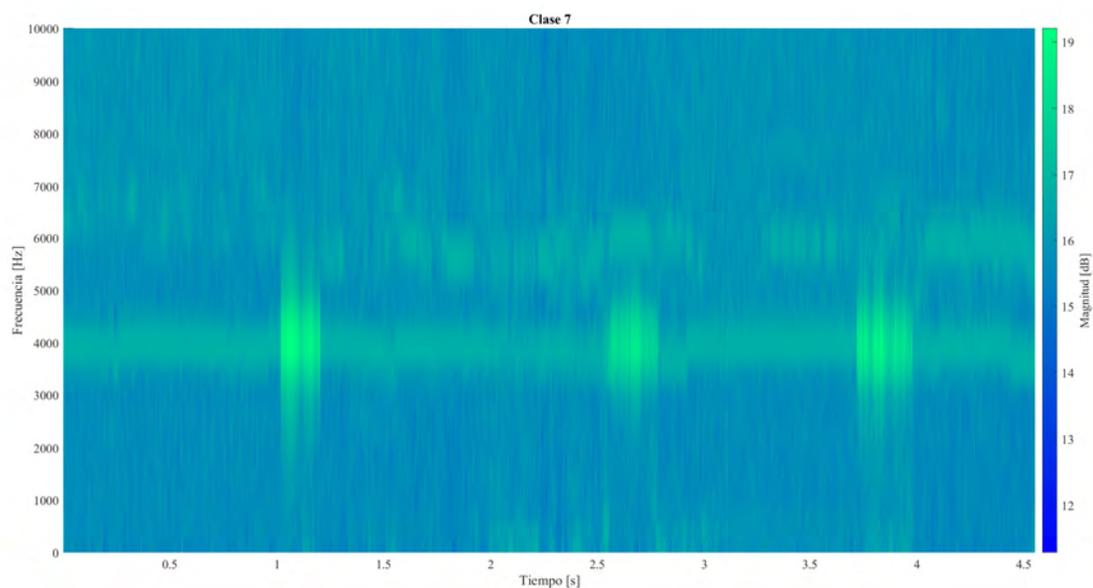


Fig. 3.21. Espectrograma de canto Craugastor Sp4.

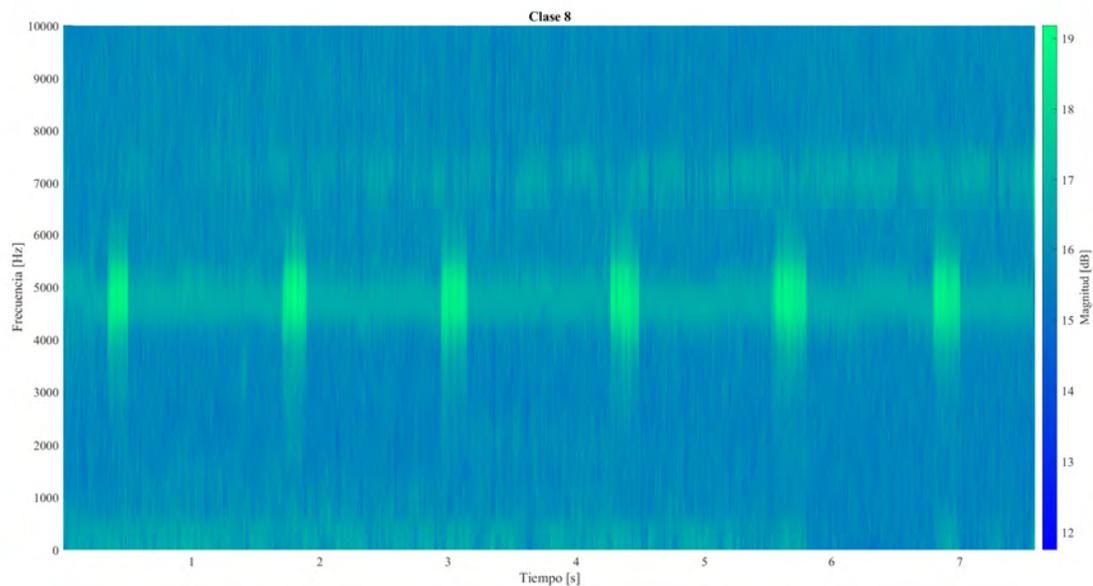


Fig. 3.22. Espectrograma de canto Craugastor Sp5.

En una descomposición wavelet a 5 niveles, una señal o se divide en componentes de baja y alta frecuencia en cinco etapas. Cada etapa produce más detalles en las frecuencias. Esto se

### 3.1. CLASIFICACIÓN DE CANTOS DE ANUROS

---

utiliza para el análisis y compresión eficiente de la seña. Cada nivel agrega detalles más finos a la descomposición.

Se consideraron funciones wavelet madre de la familia Symlet y Daubechies, las cuales debido a su forma presentan una opción para el análisis de señales de audio.

La Figura 3.23 muestra algunas funciones wavelet que fueron consideradas para la descomposición de las señales de audio previamente filtradas.

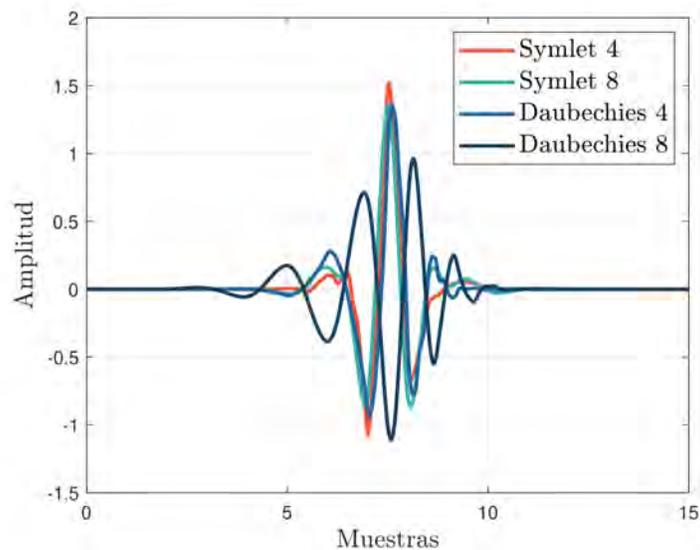


Fig. 3.23. Visualización de diferentes funciones wavelet madre.

En la etapa de extracción de características, se empleó una descomposición wavelet de 5 niveles.

### 3.1. CLASIFICACIÓN DE CANTOS DE ANUROS

---

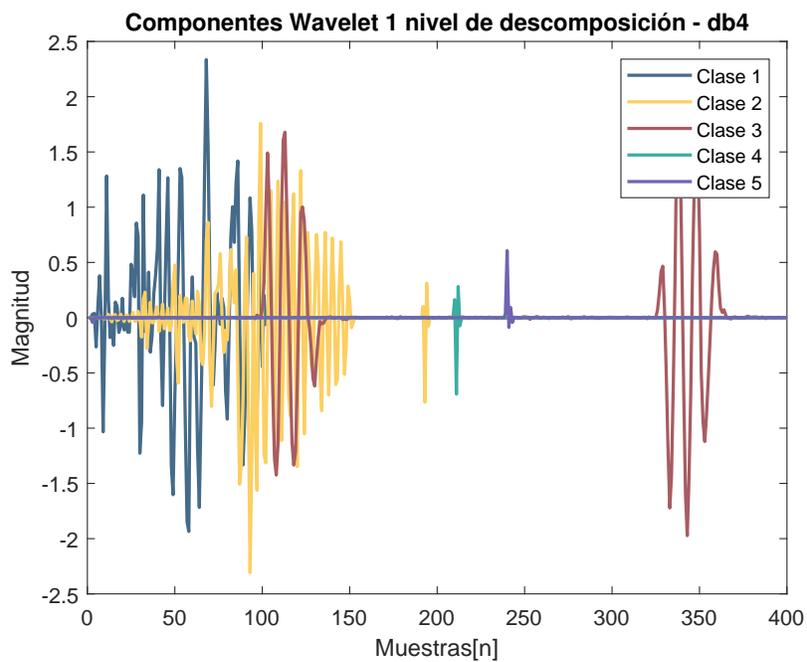


Fig. 3.24. Descomposición Wavelet nivel 1 de cantos anuros con ventana db4.

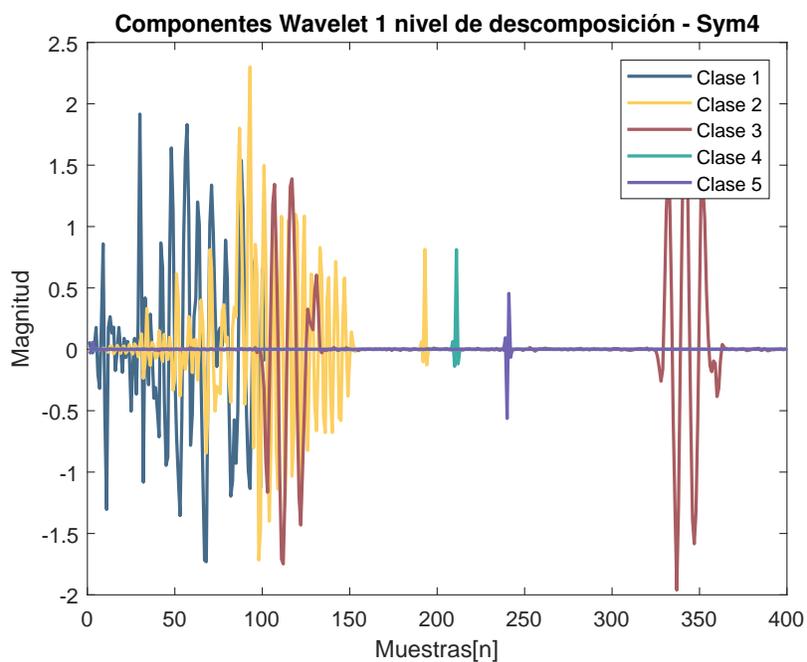


Fig. 3.25. Descomposición Wavelet nivel 1 de cantos anuros con ventana sym4.

### 3.1. CLASIFICACIÓN DE CANTOS DE ANUROS

---

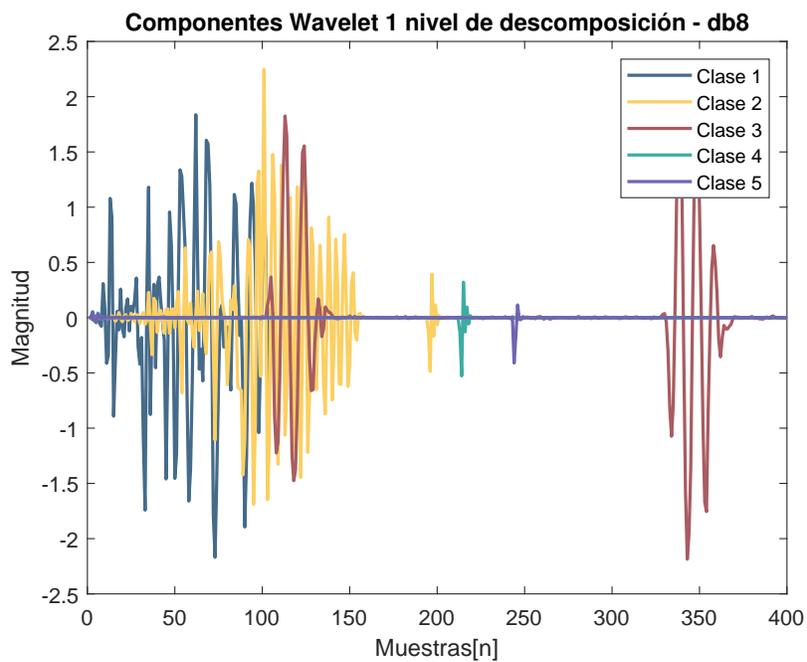


Fig. 3.26. Descomposición Wavelet nivel 1 de cantos anuros con ventana db8.

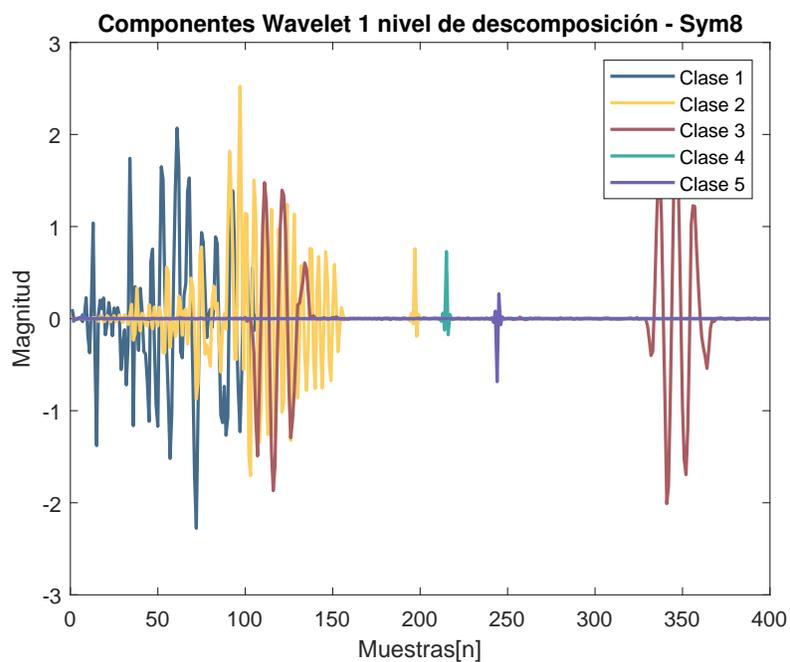


Fig. 3.27. Descomposición Wavelet nivel 1 de cantos anuros con ventana sym8.

### 3.1. CLASIFICACIÓN DE CANTOS DE ANUROS

---

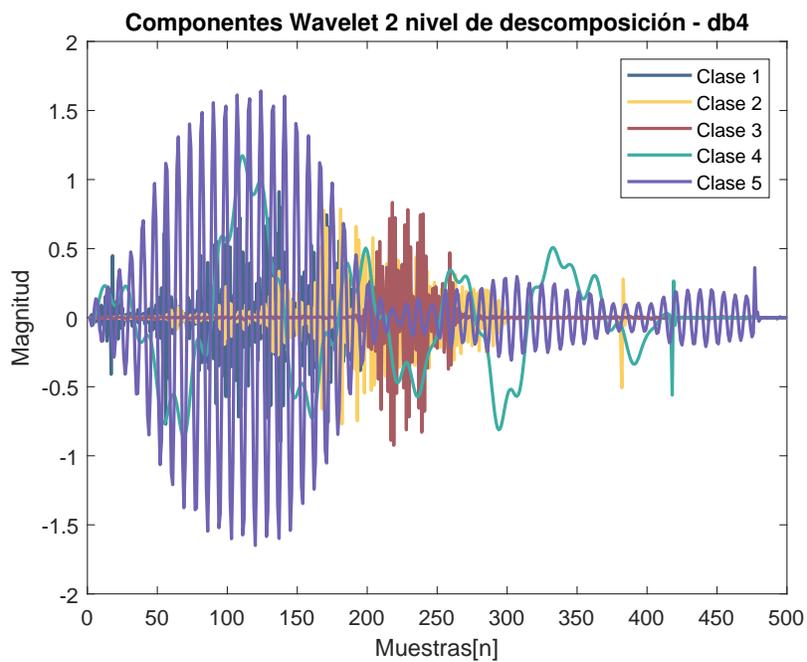


Fig. 3.28. Descomposición Wavelet nivel 2 de cantos anuros con ventana db4.

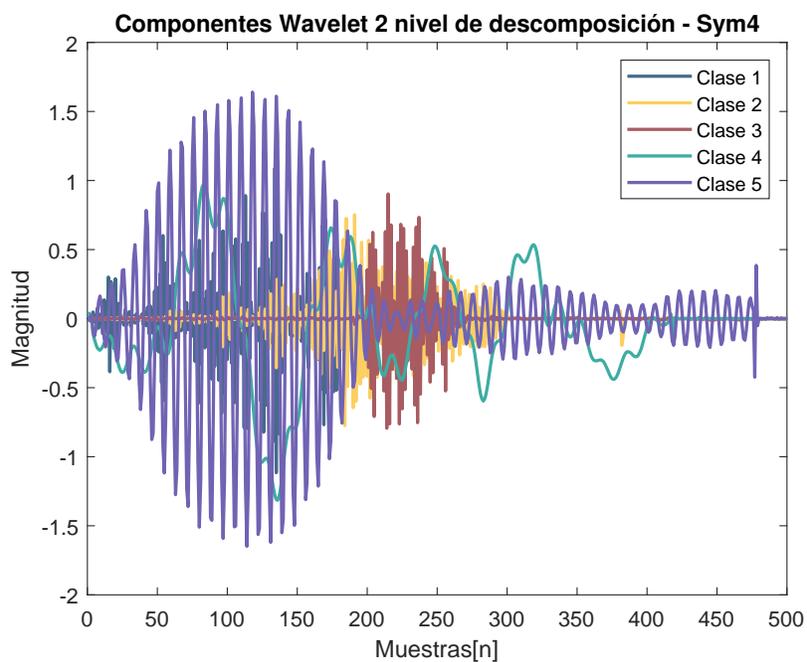


Fig. 3.29. Descomposición Wavelet nivel 2 de cantos anuros con ventana sym4.

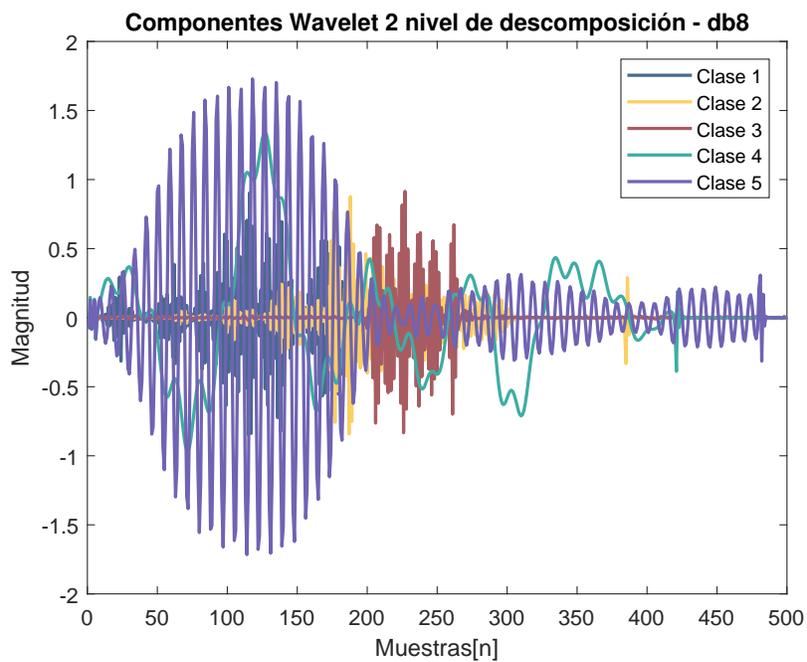


Fig. 3.30. Descomposición Wavelet nivel 2 de cantos anuros con ventana db8.

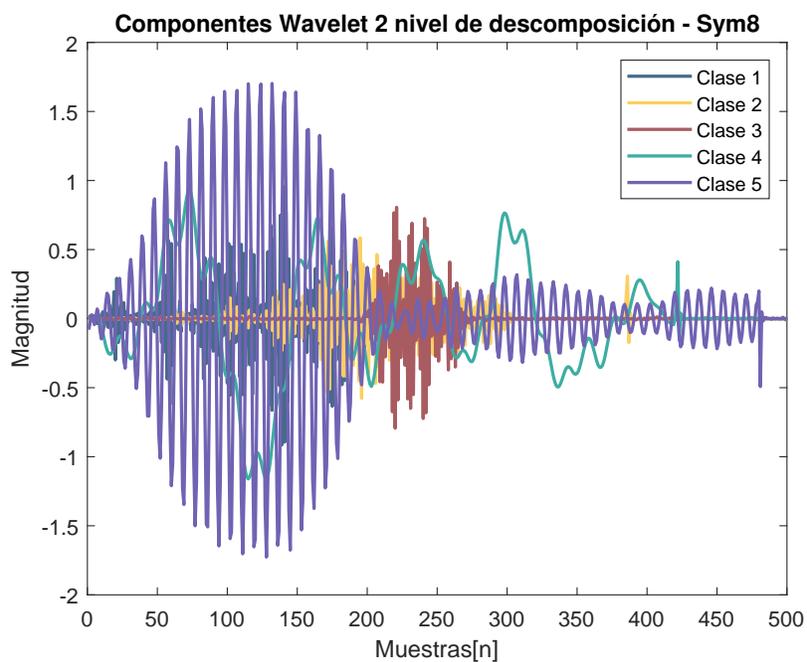


Fig. 3.31. Descomposición Wavelet nivel 2 de cantos anuros con ventana sym8.

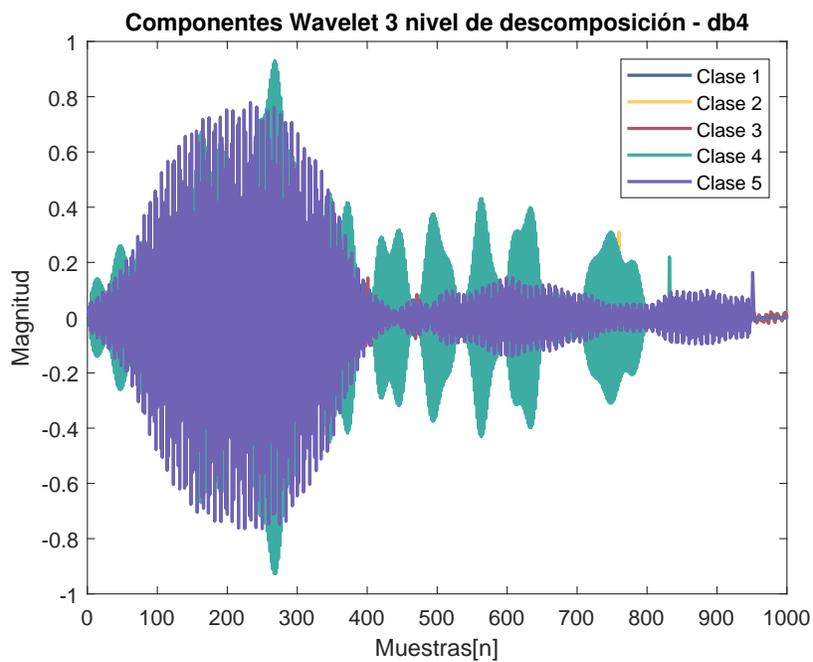


Fig. 3.32. Descomposición Wavelet nivel 3 de cantos anuros con ventana db4.

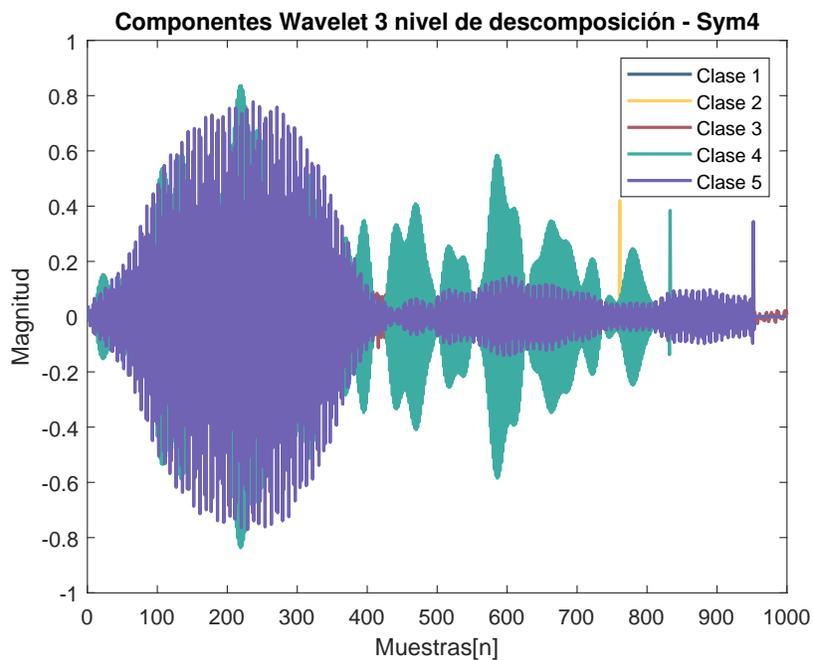


Fig. 3.33. Descomposición Wavelet nivel 3 de cantos anuros con ventana sym4.

### 3.1. CLASIFICACIÓN DE CANTOS DE ANUROS

---

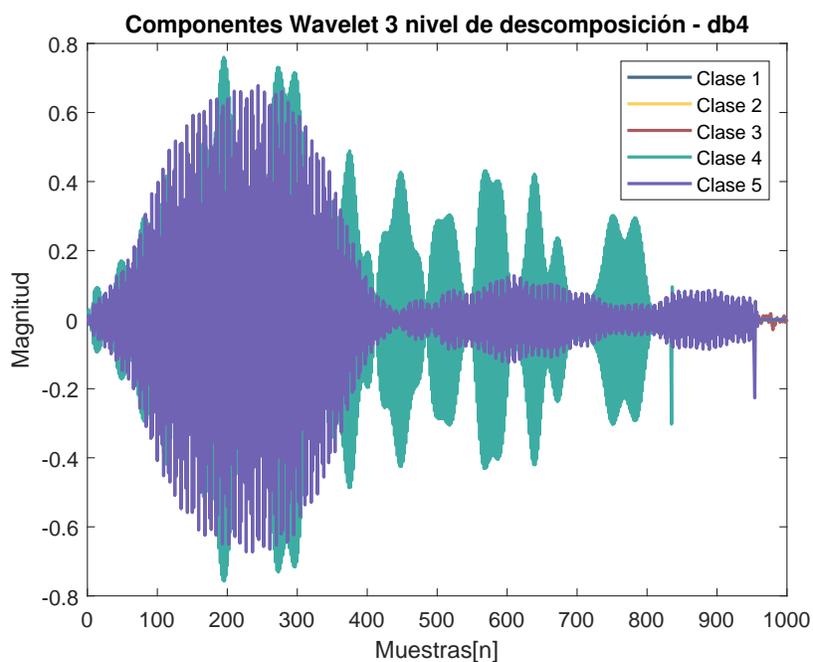


Fig. 3.34. Descomposición Wavelet nivel 3 de cantos anuros con ventana db8.

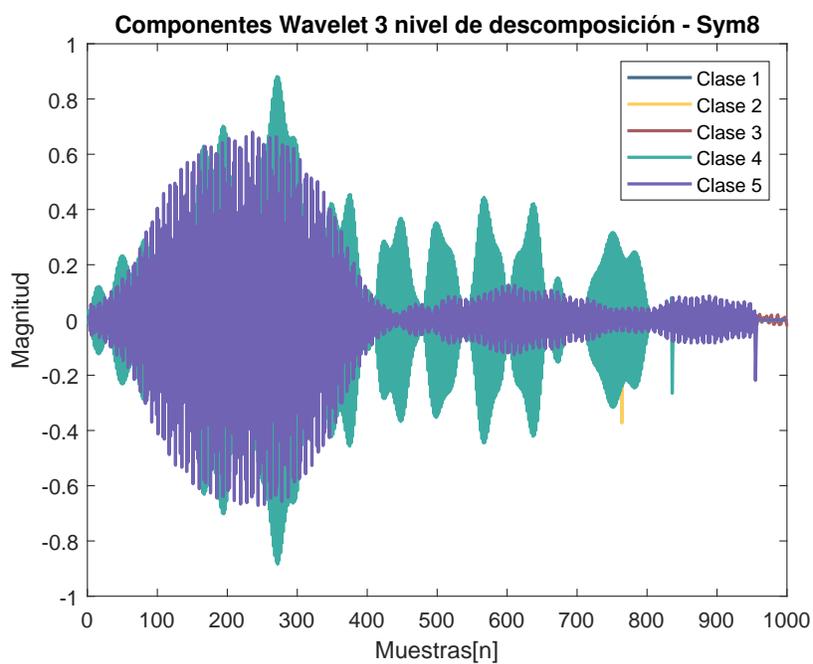


Fig. 3.35. Descomposición Wavelet nivel 3 de cantos anuros con ventana sym8.

Se tomaron los dos niveles de descomposición, los cuales corresponden a las componentes de

---

### 3.1. CLASIFICACIÓN DE CANTOS DE ANUROS

alta frecuencia en los niveles 4 y 5. Se aplicó la FRFT a los niveles considerados de manera individual, por lo que se utilizaron dos órdenes de transformación  $\alpha$  y  $\beta$ .

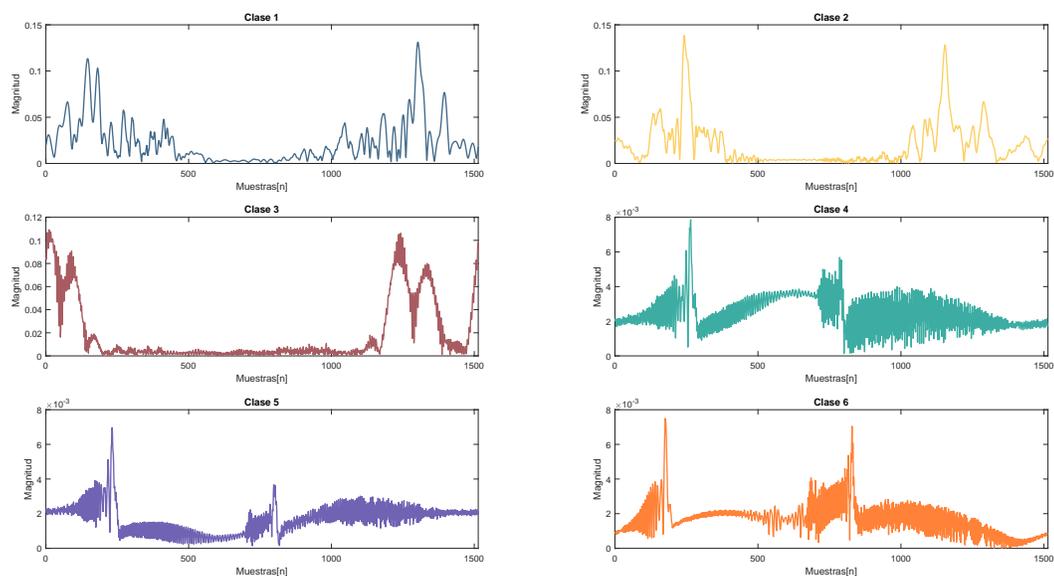


Fig. 3.36. Características FRFT nivel de descomposición Wavelet nivel 2 cantos anuros.

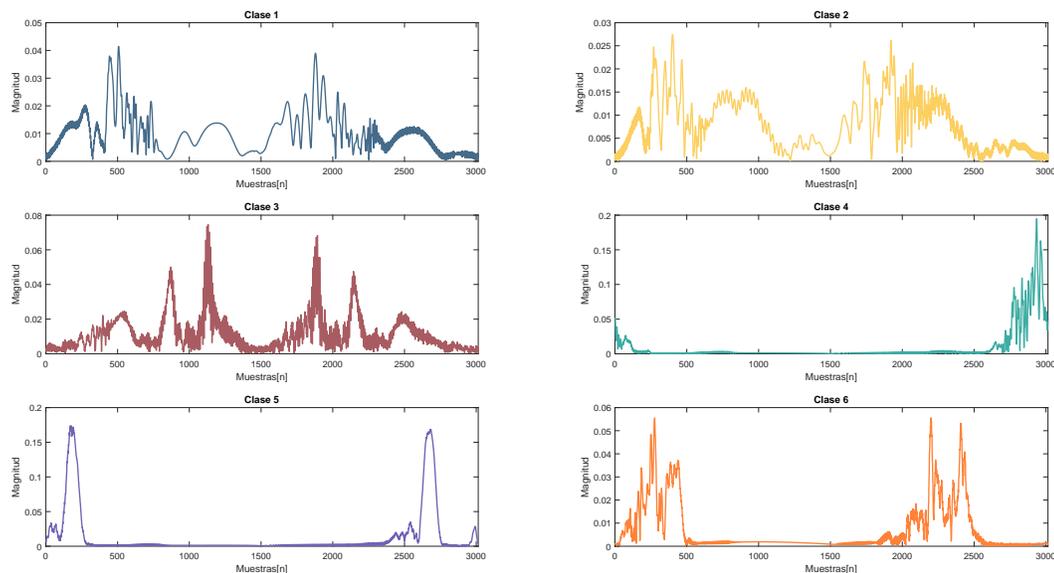


Fig. 3.37. Características FRFT nivel de descomposición Wavelet nivel 3 cantos anuros.

### 3.1.4. Entrenamiento

Se seleccionó como modelo de clasificación una RNA. Las redes neuronales de perceptrón multicapa se componen al menos de tres capas: una capa de entrada, una o más capas ocultas y una capa de salida. Estas redes se utilizan para problemas de aprendizaje automático, clasificación, regresión, entre otros. En el caso específico del aprendizaje automático son populares las siguientes funciones de activación

- Sigmoidal:  $Y = V \phi (WX + W_h)$ .
- ReLu:  $R(z) = \max(0, z)$ .
- Softmax:  $z_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}$ .

Los parámetros de la red a entrenar se muestran en la Tabla 3.2, se propone una arquitectura de cinco capas las primeras cuatro capas utilizan la función relu, en la capa final se emplea la función de activación softmax, el numero de neuronas en la capa de salida corresponde al número de clases en la clasificación.

Tabla 3.2. Numero de neuronas y funciones de activación utilizadas por capa para la red neuronal entrenada.

Capa	Número de Neuronas	Función de Activación
1	2048	relu
2	1024	relu
3	512	relu
4	256	relu
5	15	softmax

Para el entrenamiento de la red neuronal se empleó el método ADAM (Estimación de Momento Adaptativo) el cual es un método de gradiente estocástico popular utilizado en aplicaciones de aprendizaje automático. De manera general, el algoritmo permite actualizar las tasas de aprendizaje de cada parámetro de manera individual. La aleatoriedad involucrada en el algoritmo por el gradiente estocástico evita que el algoritmo se detenga en mínimos locales. Se presenta en el Algoritmo 1 el pseudocódigo del método ADAM

---

**Pseudocódigo 1** Entrenamiento con método de Adam.

---

0: **Considerando:**  $\alpha \in \mathbb{R}^+$ ,  $\epsilon \in \mathbb{R}$ .  $\beta_1, \beta_2 \in (0,1)$ ,  $w_0 \in \mathbb{R}^n$  y la función  $f(w) \in C^2(\mathbb{R}^n, \mathbb{R})$

0: 1:  $m_0 = 0, v_0 = 0, t = 0$

0: 2: **while w no converge do**

0: 3:  $m_{t+1} = \beta_1 m_t + (1 - \beta_1) \nabla_w f(w_t)$

0: 4:  $v_{t+1} = \beta_2 v_t + (1 - \beta_2) \nabla_w f(w_t) \otimes \nabla_w f(w_t)$

0: 5:  $w_{t+1} = w_t - \alpha \frac{\sqrt{1 - \beta_2^{t+1}}}{(1 - \beta_1^{t+1})} m_{t+1} \oslash \sqrt{v_{t+1} \oplus \epsilon}$

0: 6:  $t = t + 1$

0: 7: **end while** =0

---

### 3.1. CLASIFICACIÓN DE CANTOS DE ANUROS

---

Para el entrenamiento del clasificador se empleó el 70 % de los datos disponibles, reservando el 30 % restante para la etapa de validación. La evaluación de los resultados de entrenamiento y validación fue realizada por medio de diversos índices de desempeño. La Ecuación (3.9) presenta la función de exactitud, en donde  $VP$  representa los verdaderos positivos,  $VN$  los verdaderos negativos y  $N$  el número total de señales empleadas

$$Acc = \frac{VP + VN}{N}. \quad (3.9)$$

La Ecuación (3.10) representa la precisión y relaciona los positivos con los falsos positivos, denotados como  $FP$

$$P(M) = \frac{VP}{VP + FP}. \quad (3.10)$$

Por su parte, la exhaustividad relaciona los positivos con los falsos negativos, ( $FN$ ) como se muestra en la Ecuación (3.11)

$$Ex(M) = \frac{VP}{VP + FN}. \quad (3.11)$$

Para la selección de los órdenes de transformación de la FRFT ( $\alpha, \beta$ ) se empleó un algoritmo de optimización metaheurística. El algoritmo PSO (Optimización por Enjambre de Partículas) es una técnica que utiliza partículas virtuales para encontrar soluciones óptimas en problemas de optimización. Estas partículas se mueven en un espacio multidimensional definido en el espacio de la solución y ajustan sus posiciones para mejorar gradualmente la solución.

Considerando un enjambre de  $N$  partículas, la posición en el espacio de la solución de cada una de ellas puede ser expresada como  $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$ . El cambio de posición de cada partícula se define como  $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ , la mejor posición histórica de cada partícula se representa como  $P_i = (p_{i1}, p_{i2}, \dots, p_{iD})$ , y finalmente  $P_g = (p_{g1}, p_{g2}, \dots, p_{gD})$  presenta la mejor posición obtenida de manera histórica por el enjambre. La actualización de la posición de cada partícula puede describirse con las Ecuaciones (3.12) y (3.13)

$$v_i^{k+1} = wv_i^k + c_1r_1(p_i^k - x_i^k) + c_2r_2(p_g^k - x_i^k), \quad (3.12)$$

$$x_i^{k+1} = x_i^k + v_i^{k+1}, \quad (3.13)$$

donde  $c_1$ ,  $c_2$  y  $w$  representan constantes del algoritmo y  $r_1, r_2$  son números aleatorios entre 0 y 1.

#### 3.1.5. Resultados

La Figura 3.38, presenta una comparación entre la señal original con las características obtenidas, empleando los niveles de descomposición wavelet previamente descritos y la FRFT para órdenes  $[\alpha, \beta] = [1, 1]$  y  $[\alpha, \beta] = [1.2577, 1.4678]$ , estos últimos correspondientes a los obtenidos por el algoritmo PSO.

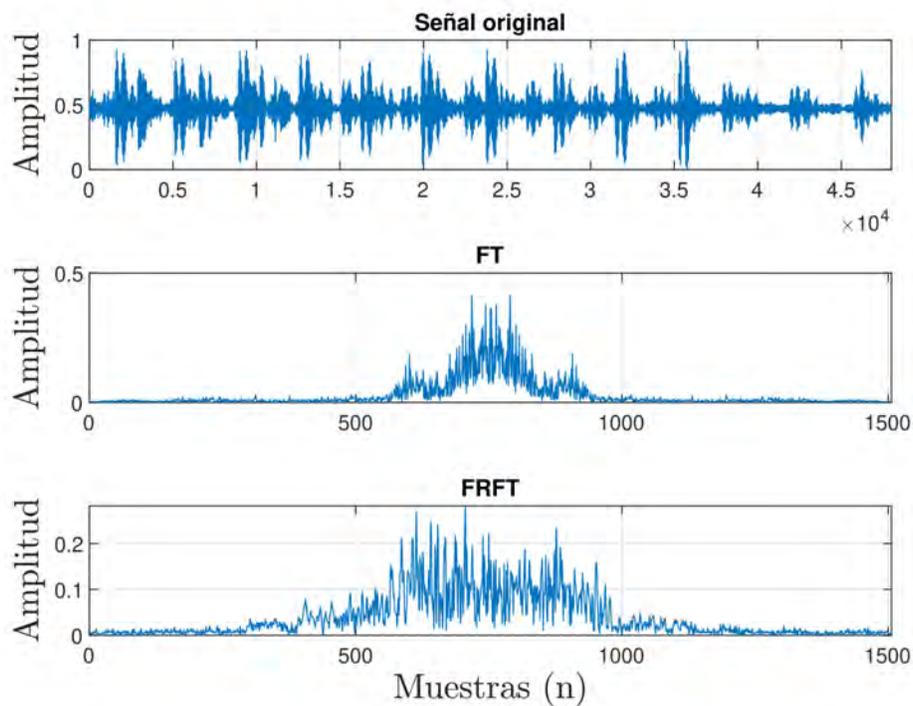


Fig. 3.38. Comparativa de las características empleadas con el caso clásico y la señal original.

La Figura 3.39, muestra los resultados obtenidos por el clasificador para la etapa de entrenamiento. Las predicciones correctas en la figura se muestran sobre la diagonal principal. Los resultados se encuentran normalizados por clase.

### 3.2. CLASIFICACIÓN DE SONIDOS DE CIGARRAS

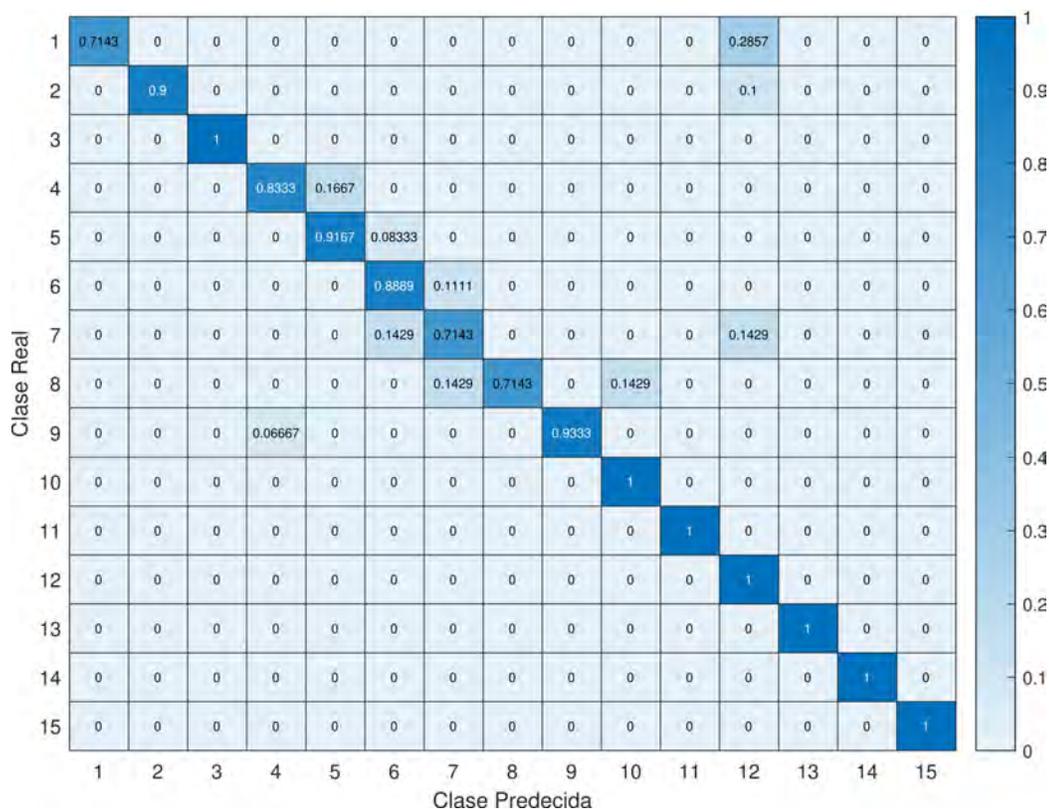


Fig. 3.39. Matriz de confusión por el clasificador para la etapa de prueba.

La Tabla 3.3 muestra una comparativa entre los índices presentados en las Ecuaciones (3.9), (3.10) y (3.11) de la metodología utilizada para la extracción de características con su equivalente de orden entero y la clasificación utilizando las señales en el dominio temporal.

Tabla 3.3. Comparación de la metodología empleada con su equivalente de orden entero y la clasificación con los datos en el dominio temporal.

	Señal original	Clásico	FRFT
Acc	29.41 %	53.59 %	91.27 %
P	39.92 %	54.47 %	91.27 %
Ex	14.38 %	53.59 %	91.27 %
$[\alpha, \beta]$	$[NA, NA]$	$[1, 1]$	$[1.2577, 1.4678]$

### 3.2. Clasificación de sonidos de cigarras

La identificación de especies de cigarras basada en sonido es crucial debido a la observación de cambios en el patrón de emergencia de cigarras periódicas de 17 años. Se sospecha que estos cambios están relacionados con el cambio climático, pero la falta de datos suficientes dificulta la confirmación de esta hipótesis. Para abordar esto, se ha propuesto en la literatura sistemas

de reconocimiento de especies de cigarras mediante señales acústicas, utilizando un modelo de aprendizaje automático. Este enfoque no solo puede contribuir a entender las relaciones entre el comportamiento de las cigarras y el entorno, sino que también permite monitorear las especies de cigarras de manera más eficaz. El uso de una red neuronal convolucional (CNN) para la clasificación ha demostrado alta precisión en los experimentos realizados con grabaciones de sonido pre procesadas. En última instancia, esta tecnología podría tener aplicaciones valiosas en la detección temprana de cambios en el comportamiento de las cigarras, proporcionando información valiosa para comprender y abordar posibles efectos del cambio climático en estos insectos [48].

### 3.2.1. Zumbido de cigarras

Las cigarras son conocidas por el sonido distintivo que producen, que es generado principalmente por los machos. Este sonido, que a menudo se describe como un zumbido o canto, es utilizado en la comunicación entre individuos de la misma especie, específicamente durante la temporada de apareamiento [46]. Cada especie de cigarra tiene su propio patrón de canto, lo que facilita el reconocimiento entre individuos de la misma especie y contribuye a la segregación reproductiva. La importancia de la bioacústica de las cigarras radica en varios aspectos:

- **Comunicación y Apareamiento:** El canto de las cigarras es esencial para atraer a las hembras durante la temporada de apareamiento. Las hembras eligen a los machos en función de la calidad y la consistencia de su canto, lo que contribuye al éxito reproductivo de la especie.
- **Reconocimiento de Especies:** Cada especie de cigarra tiene su propio patrón de canto único. Este reconocimiento acústico es crucial para garantizar que las cigarras se reproduzcan solo con individuos de su misma especie, evitando la hibridación y manteniendo la integridad genética de las poblaciones.
- **Defensa Territorial:** Los machos también utilizan su canto para establecer y defender territorios contra otros machos. El canto puede ser una forma de comunicación agresiva que ayuda a mantener la distancia entre individuos competidores.

Usualmente el canto de apareamiento de las cigarras es descrito como una serie de ticks seguidos inmediatamente por un zumbido agudo.

### 3.2.2. Descripción de la base de datos

La base de datos utilizada para la clasificación de especies de cigarras se compone de dos conjuntos de datos públicos, los cuales fueron seleccionados cuidadosamente para proporcionar una variedad de señales acústicas representativas de distintas especies.

El primer conjunto de datos [44] contiene señales acústicas de cigarras del género *Magicicada*. Estas cigarras, también conocidas como cigarras periódicas, son notables por su ciclo de vida inusualmente largo y sincronizado. Especies de *Magicicada* emergen en ciclos de 13 o 17 años, con casi todos los individuos de una población local sincronizados en su desarrollo y emergiendo en el mismo año. Este fenómeno es un ejemplo fascinante de sincronización natural y ha sido

### 3.2. CLASIFICACIÓN DE SONIDOS DE CIGARRAS

---

objeto de numerosos estudios biológicos. El dataset incluye principalmente especies con un ciclo de 17 años, como *Magicicada septendecim*, *Magicicada cassini*, y *Magicicada septendecula*. Estas especies se encuentran principalmente en el este de los Estados Unidos y son conocidas por su canto característico, utilizado tanto para la atracción de parejas como para la defensa territorial. El segundo conjunto de datos [45] proviene de especies de cigarras propias de la región de Nueva Zelanda, como las del género *Amphipsalta*, comúnmente conocidas como *kikihiki* en el idioma maorí. Estas cigarras son endémicas de Nueva Zelanda y presentan una gran diversidad en sus cantos, que varían significativamente entre especies. Algunas de las especies incluidas en este dataset son *Amphipsalta cingulata*, *Amphipsalta zelandica*, y *Amphipsalta strepitans*. A diferencia de las cigarras periódicas, estas especies emergen anualmente, lo que ofrece un contraste interesante en términos de patrones de vida y comportamiento acústico.

Aunque las especies de *Magicicada* y *Amphipsalta* no comparten ubicación geográfica, se decidió combinar ambos conjuntos de datos para aumentar la complejidad del problema de clasificación y evaluar la robustez de los modelos desarrollados. La inclusión de señales acústicas de diferentes regiones y especies con distintos patrones de canto presenta un desafío significativo, ya que los modelos deben ser capaces de distinguir entre características acústicas que no solo varían entre especies, sino también entre geografías y contextos ecológicos [48].

En ambos casos, las señales acústicas fueron previamente filtradas para suprimir el ruido ambiental, asegurando así que los datos utilizados para el entrenamiento y evaluación de los modelos fueran de alta calidad. Este preprocesamiento incluyó técnicas de eliminación de ruido y normalización de las señales para facilitar la comparación y clasificación. Las frecuencias del canto de las especies de cigarras consideradas se muestran en la Tabla 3.4, donde se detallan las características acústicas más relevantes de cada especie.

La combinación de estos dos conjuntos de datos no solo permite un análisis más exhaustivo de las capacidades de clasificación de los modelos, sino que también proporciona una base de datos más rica y variada para futuros estudios en bioacústica y ecología. El estudio de las señales acústicas de cigarras ofrece insights valiosos sobre la comunicación animal y los procesos evolutivos que dan forma a estos patrones de comportamiento [49].

Tabla 3.4. Características de señales acústicas de las cigarras.

Clase	Especie	Frecuencia [ $kHz$ ]
1	Cassini <i>Magicicada</i>	4.3
2	Septendecula <i>Magicicada</i>	4.5
3	Cingulata <i>Amphipsalta</i>	1.7
4	Zelandica <i>Amphipsalta</i>	1.9
5	Muta <i>Kikihia</i>	3.5
6	Ochrina <i>Kikihia</i>	1.2

### 3.2. CLASIFICACIÓN DE SONIDOS DE CIGARRAS

---

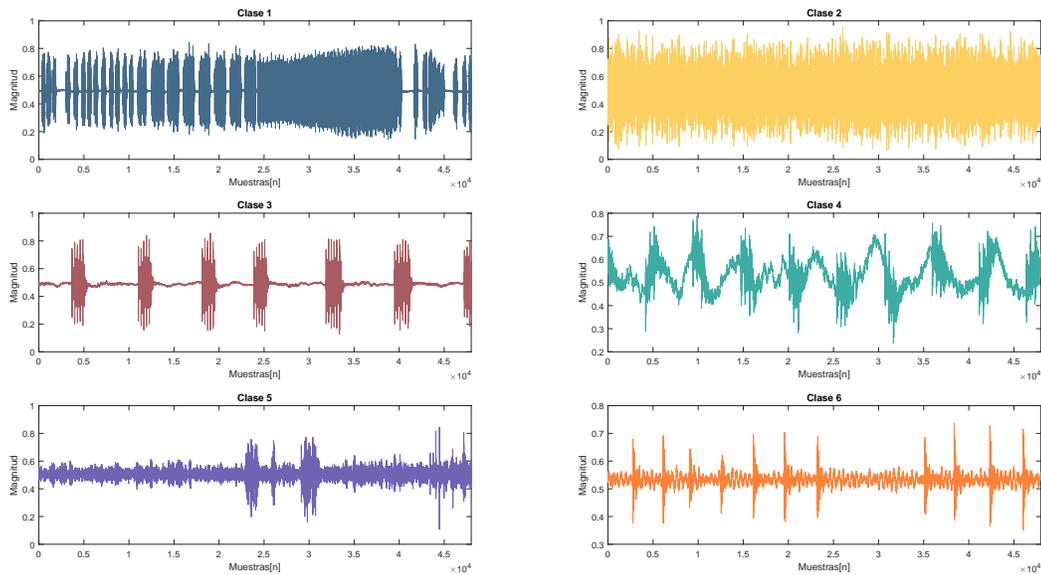


Fig. 3.40. Señales de sonidos de cigarras.

En la Figura 3.40 se muestran las señales de los sonidos de las 6 clases distintas de cigarras que componen la base de datos. A continuación se describen las características observables en cada clase de señal:

La señal de la clase 1 muestra una serie de picos altos y anchos que indican una estructura de pulsos repetitivos con intervalos relativamente cortos entre ellos. La señal presenta una amplitud constante y un patrón regular, lo cual es característico de algunas especies de cigarras periódicas. La señal de la clase 2 se caracteriza por una apariencia más densa y ruido de fondo uniforme. La magnitud varía de manera caótica a lo largo del tiempo, sin un patrón repetitivo claro. Esto sugiere la presencia de un canto continuo y posiblemente complejo.

La señal de la clase 3 exhibe picos bien definidos con intervalos más largos entre ellos en comparación con la clase 1. La señal tiene una estructura más espaciada y los picos son más agudos, indicando un ritmo distinto en el canto de esta especie.

La señal de la clase 4 muestra un patrón ondulante con picos de amplitud que varían regularmente. Este tipo de señal sugiere una modulación en la frecuencia del canto, característica de ciertas especies que utilizan variaciones tonales en su comunicación.

La señal de la clase 5 presenta una serie de picos con una amplitud variable y una estructura menos regular que la de las clases anteriores. La señal parece ser más ruidosa y menos estructurada, lo cual podría ser indicativo de un entorno acústico más complejo o de una especie con un canto menos predecible.

La señal de la clase 6 tiene picos pronunciados y espaciados de manera regular. La magnitud de los picos es consistente, lo que sugiere un patrón repetitivo claro y una estructura de canto bien definida.

Cada una de estas señales ha sido filtrada previamente para eliminar el ruido ambiental, ga-

### 3.2. CLASIFICACIÓN DE SONIDOS DE CIGARRAS

---

manteniendo así la calidad de los datos utilizados en el análisis. La diversidad en los patrones de las señales acústicas refleja la variedad de estrategias de comunicación utilizadas por diferentes especies de cigarras, y resalta la complejidad del problema de clasificación abordado en este estudio. La capacidad de distinguir entre estas señales es crucial para el desarrollo de modelos efectivos de clasificación de especies en estudios bioacústicos.

La Figura 3.41 muestra la comparación de los espectrogramas tiempo frecuencia de las señales acústicas mostradas en la Figura 3.40, en estas se puede observar que las que el rango de frecuencias en las cuales se encuentra la energía de las señales es similar entre algunas clases, como es el caso de la clase 1 con la clase 2 y la clase 3 con la clase 4, esto puede complicar el análisis de las señales.

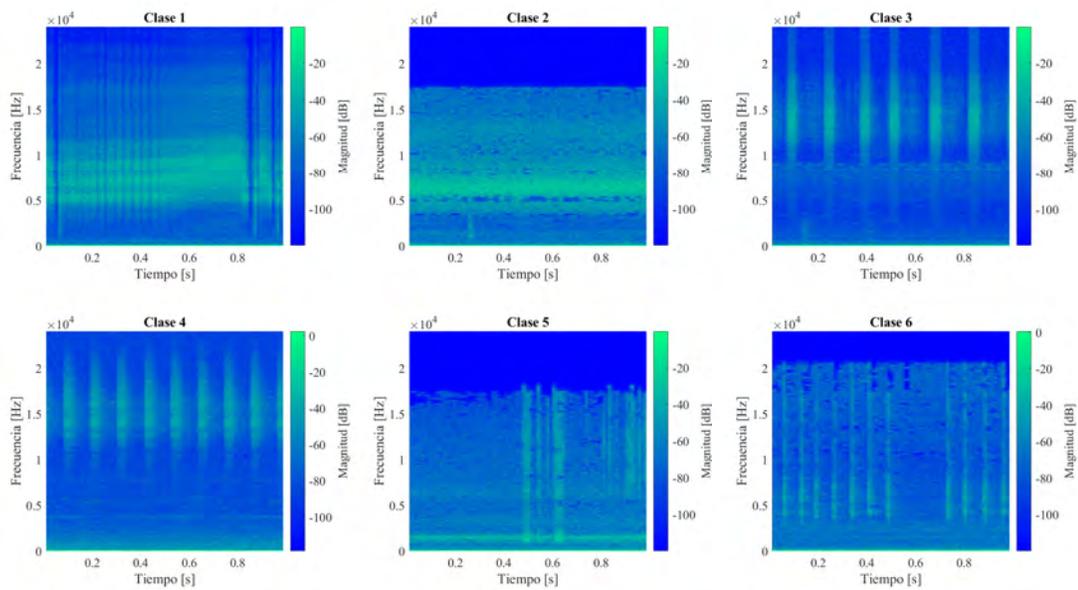


Fig. 3.41. Comparación de los espectrogramas de las clases de cigarras

#### 3.2.3. Preprocesamiento y Extracción de Características

Las señales acústicas fueron ventaneadas empleando ventanas de un segundo de duración, con un solapamiento de ventana de 0.25s. Para este caso, las señales no fueron filtradas debido a que se encontraban suficientemente procesadas.

La extracción de características fue realizada siguiendo la misma metodología que en el caso anterior. En este caso se tomaron los niveles de descomposición 2 y 3 de la descomposición wavelet obtenida de cada señal acústica. De manera similar, estos fueron obtenidos a partir de emplear las funciones wavelet madre mostradas en la Figura 3.23,

### 3.2. CLASIFICACIÓN DE SONIDOS DE CIGARRAS

---

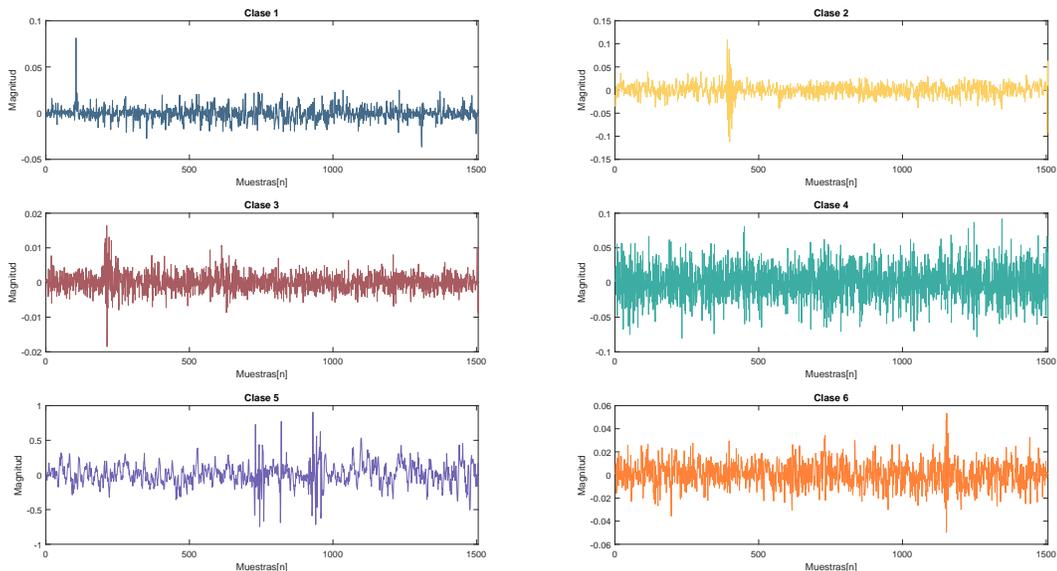


Fig. 3.42. Descomposición Wavelet nivel 1.

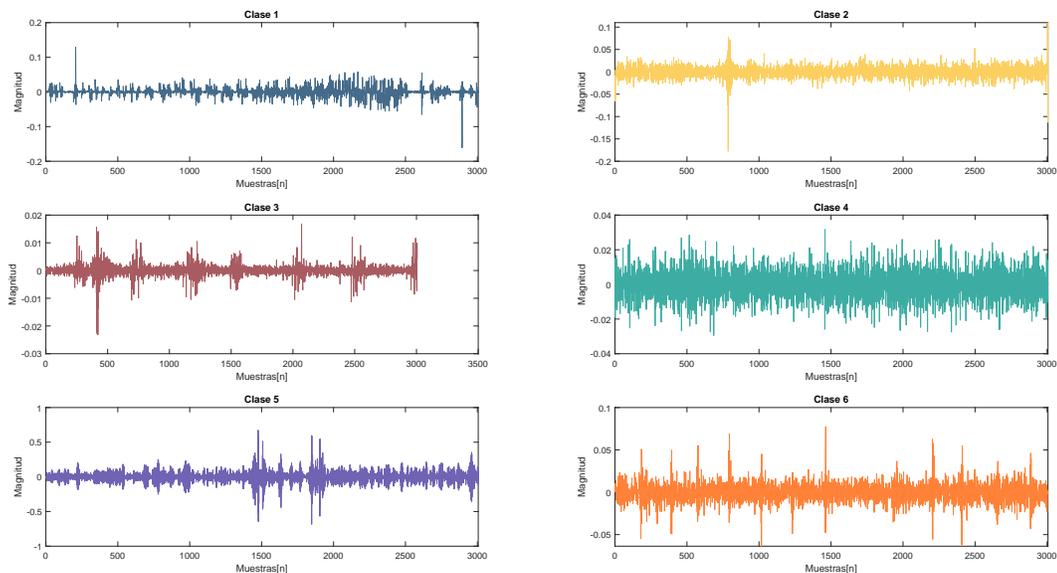


Fig. 3.43. Descomposición Wavelet nivel 2.

### 3.2. CLASIFICACIÓN DE SONIDOS DE CIGARRAS

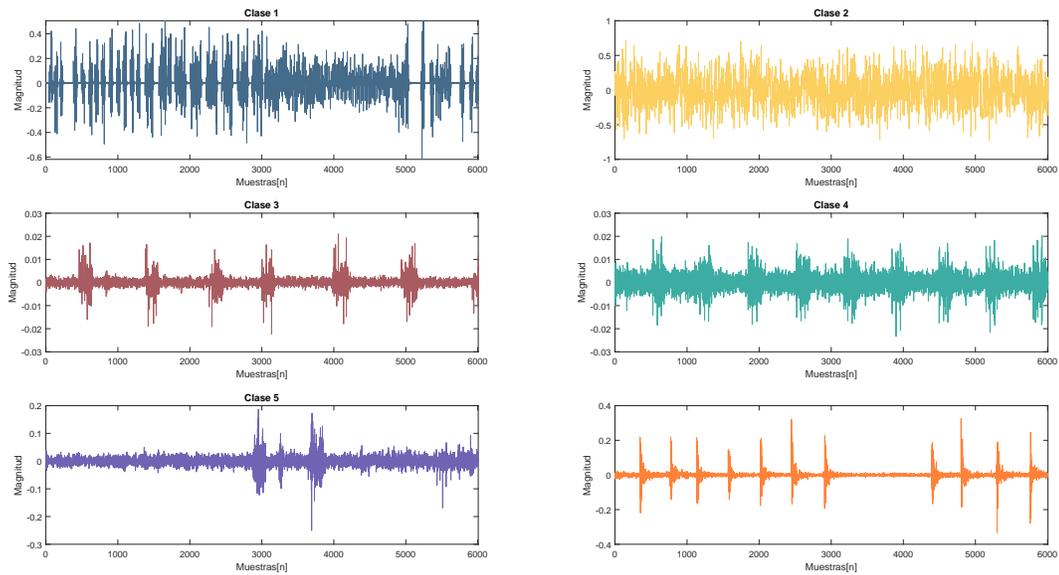


Fig. 3.44. Descomposición Wavelet nivel 3.

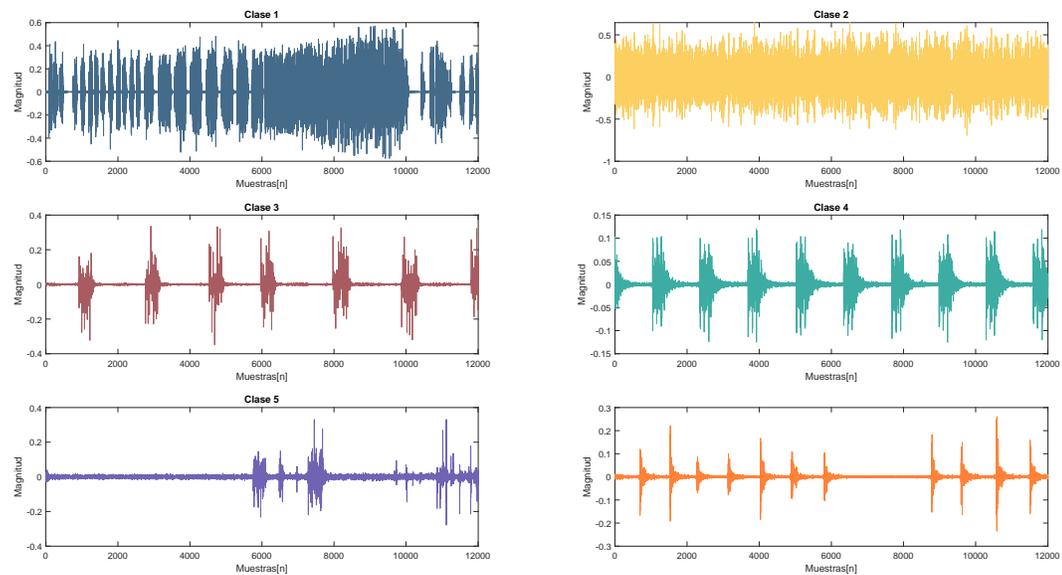


Fig. 3.45. Descomposición Wavelet nivel 4.

### 3.2. CLASIFICACIÓN DE SONIDOS DE CIGARRAS

---

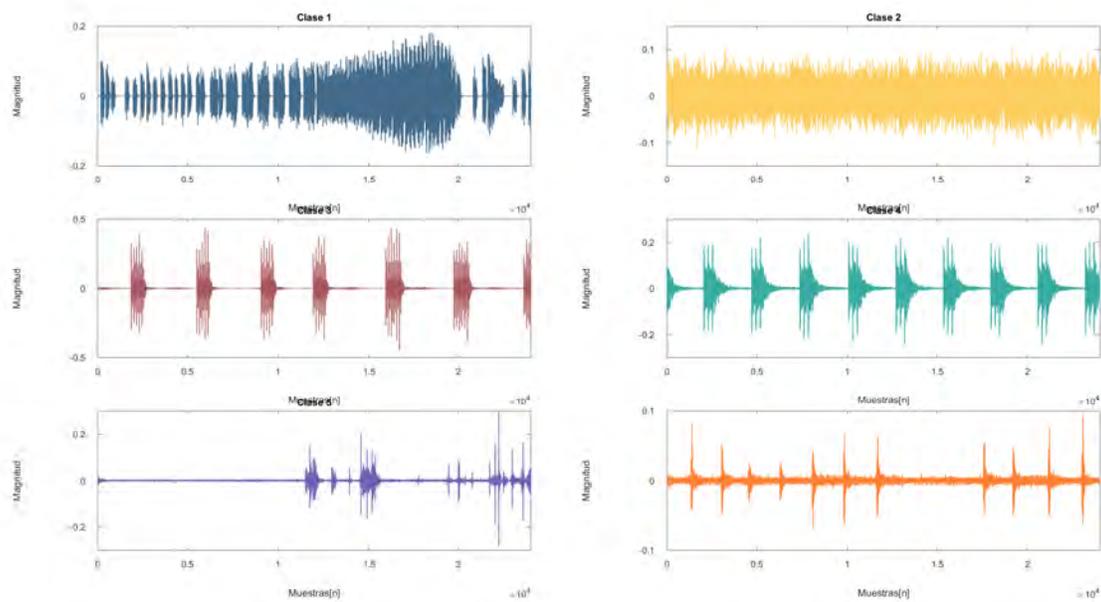


Fig. 3.46. Descomposición Wavelet nivel 5.

La selección de los órdenes de la FRFT empleada en los niveles de descomposición se realizó con base en la optimización con base en la exactitud (Ecuación (3.9)) mediante el algoritmo de enjambre de partículas (Ecuaciones (3.12) y (3.13)), obteniendo los órdenes de transformación  $[\alpha, \beta] = [1.2577, 1.4677]$ .

### 3.2. CLASIFICACIÓN DE SONIDOS DE CIGARRAS

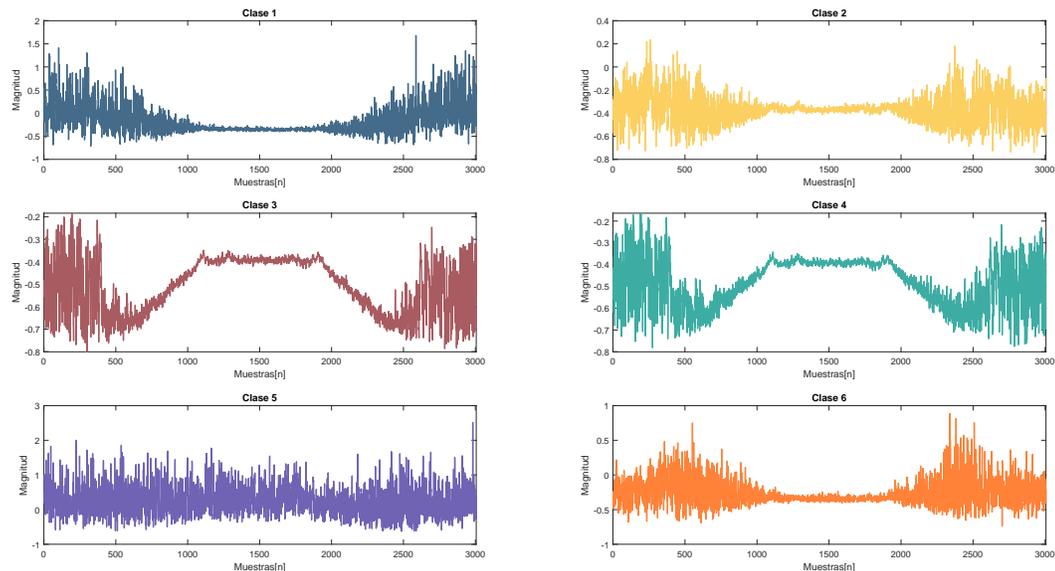


Fig. 3.47. Características de cigarras de nivel descomposición 2 en dominio de Fourier fraccionario.

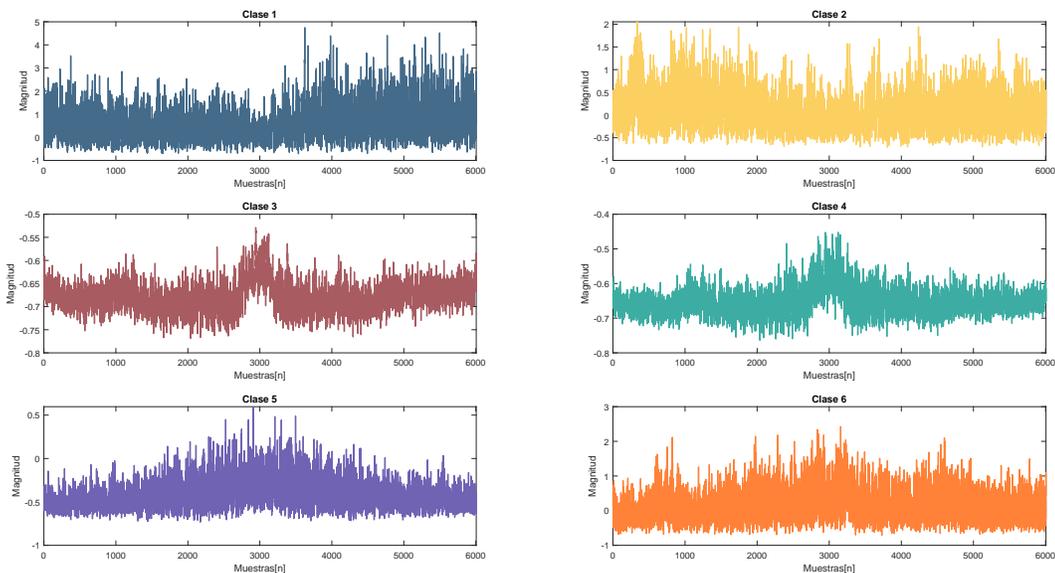


Fig. 3.48. Características de cigarras de nivel descomposición 3 en dominio de Fourier fraccionario.

### 3.2.4. Clasificación

La estructura de la red neuronal utilizada para la clasificación de señales acústicas provenientes de cigarras se muestra en la Tabla 3.5, una vez más el método ADAM fue empleado para el entrenamiento de la red neuronal.

Tabla 3.5. Hiperparámetros de la RNA para la clasificación de sonidos de cigarras.

Capa	Número de Neuronas	Función de Activación
1	512	relu
2	256	relu
3	6	softmax

### 3.2. CLASIFICACIÓN DE SONIDOS DE CIGARRAS

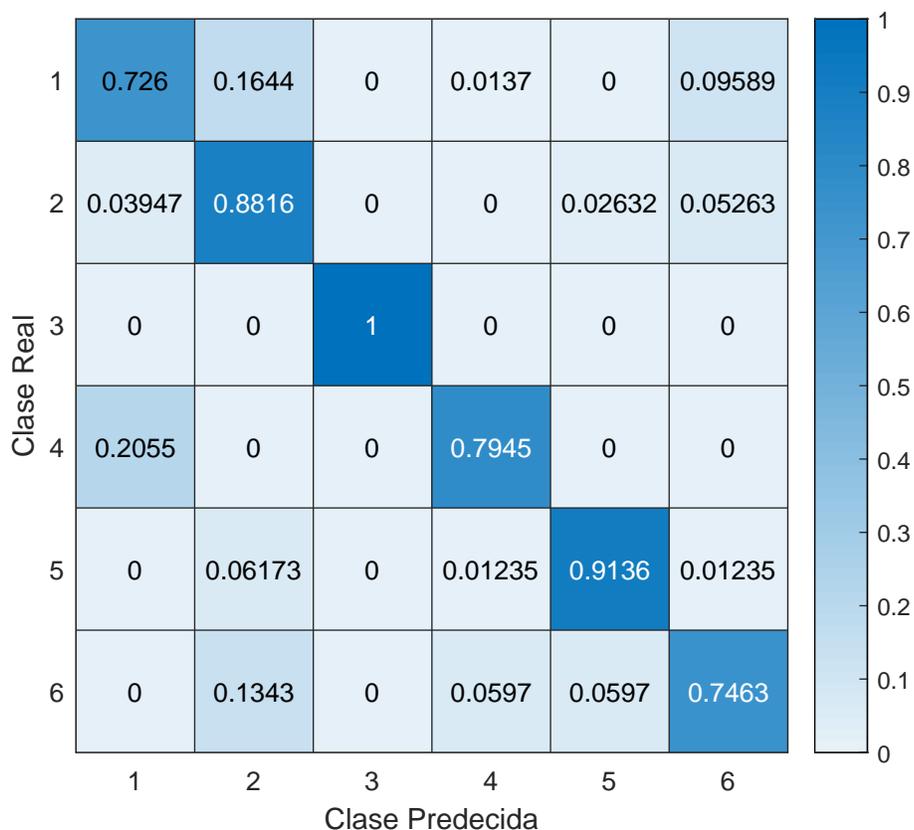


Fig. 3.49. Matriz de confusión obtenida por la red neuronal entrenada para la clasificación de cigarras en base a señales acústicas.

La Tabla 3.6 muestra la comparación de los resultados obtenidos con la metodología equivalente de orden entero, en donde se evidencia la mejora obtenida al aplicar la FRFT para la extracción de características.

Tabla 3.6. Comparación de la metodología empleada con su equivalente de orden entero.

	Clásico	FRFT
Acc	80.67 %	85.78 %
P	80.62 %	85.97 %
Ex	80.44 %	85.78 %
$[\alpha, \beta]$	[1, 1]	[1.2577, 1.4677]

# Capítulo 4

## Conclusiones

Este documento presenta una metodología innovadora para la clasificación de señales bioacústicas utilizando la Transformada Fraccionaria de Fourier (FRFT) y redes neuronales artificiales (RNAs). La metodología fue evaluada con sonidos de anuros y cigarras, alcanzando una alta precisión de clasificación.

En la etapa de preprocesamiento, los datos fueron filtrados para eliminar componentes de ruido ambiental y posteriormente segmentados según la amplitud de la señal. En la etapa de extracción de características, se empleó la Transformada Wavelet para descomponer la señal, seguida de la FRFT para la transformación de dos niveles de descomposición correspondientes a las frecuencias altas de la señal.

La elección de utilizar la Transformada Fraccionaria de Fourier (FRFT) se basó en su capacidad para mejorar el análisis de señales de audio en comparación con los métodos clásicos, lo que resultó en una mayor precisión en la clasificación. Esta precisión se refleja en la capacidad de discriminar especies cuyos cantos se encuentran en los mismos rangos de frecuencia, como es el caso de las clases 13 y 3, que presentan un amplio rango de frecuencias coincidente con el de otras especies. Este tipo de coincidencias es común entre especies que pertenecen a la misma familia, como se observa en las clases 4 a 8, las cuales comparten rangos de frecuencia debido a su relación genética. Para el caso de las cigarras, las clases que presentan rangos similares en el caso de la clase 1 con la clase 2 y la clase 3 con la clase 4.

Para la etapa de entrenamiento, se utilizó una red neuronal tipo perceptrón con dos funciones de activación: softmax y ReLU. El entrenamiento se llevó a cabo utilizando el método ADAM. Este enfoque integrado proporciona un sistema robusto y preciso para la clasificación de sonidos bioacústicos, superando las limitaciones de los métodos de orden entero.

La tecnología propuesta ofrece una herramienta no invasiva para la conservación de especies y el monitoreo de ecosistemas, permitiendo la observación precisa de la fauna sin perturbarla. Esto es crucial para la protección de especies en peligro de extinción y para una mejor comprensión de la biodiversidad en su entorno natural.

---

Este trabajo no se limita a la clasificación de especies de anuros, sino que también destaca la versatilidad y el potencial de la metodología propuesta en el estudio de la bioacústica de diversas especies animales. La aplicación de esta técnica en el monitoreo de aves, ballenas, cigarras y otros organismos ofrece oportunidades emocionantes para la comprensión y conservación de la biodiversidad.

# Capítulo 5

## Trabajos futuros

- Aplicación en el monitoreo de ecosistemas Acuáticos: Extender la metodología para la clasificación de señales bioacústicas en ecosistemas acuáticos, como ríos y océanos. Esto podría incluir la identificación de especies marinas, como cetáceos y peces, para ayudar en la conservación y monitoreo de la salud de los ecosistemas acuáticos.
- Implementación en tiempo real: desarrollar un sistema en tiempo real para el monitoreo continuo de ecosistemas, permitiendo la identificación instantánea de especies a partir de sus señales acústicas.
- Ampliación de la base de datos bioacústica: Crear una base de datos más extensa que incluya una mayor variedad de especies y ambientes. Esto permitiría una evaluación más robusta de la metodología y su adaptación para el estudio de la biodiversidad en diferentes regiones geográficas y ecosistemas, aumentando su aplicabilidad global.
- Desarrollo de un sistema de alerta temprana para especies invasoras: Implementar la metodología en un sistema automatizado de detección de especies invasoras a través de sus señales acústicas. Este sistema podría ser utilizado en áreas protegidas para identificar y mitigar rápidamente la presencia de especies no nativas que amenazan la biodiversidad local.

# Bibliografía

- [1] N. Pieretti, A. Farina, and D. Morri, “A new methodology to infer the singing activity of an avian community: The acoustic complexity index (aci),” Ecological indicators, vol. 11, no. 3, pp. 868–873, 2011.
- [2] H. M. Cortes Campos et al., “Metodología para el diagnóstico de fallas en máquinas eléctricas empleando transformadas integrales de orden generalizado,” 2020.
- [3] N. Toro, S. F. G. Gómez, and T. S. Jiménez, “Reconocimiento de especies de anuros por sus cantos, en archivos de audio, mediante técnicas de procesamiento digital de señales,” Scientia et technica, vol. 3, no. 32, 2006.
- [4] P. C. Caycedo-Rosales, J. F. Ruiz-Muñoz, and M. Orozco-Alzate, “Reconocimiento automatizado de señales bioacústicas: Una revisión de métodos y aplicaciones,” Ingeniería y Ciencia, vol. 9, no. 18, pp. 171–195, 2013.
- [5] P. Rodríguez Beltrán et al., “Bioacústica física: La parametrización de las ecuaciones para simular el canto de los pájaros.” 2017.
- [6] Ó. Alberto, “Monitoreo bioacústico de las poblaciones de anuros de la reserva de la biosfera nahá, chiapas, méxico,” Ph.D. dissertation, UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO, 2015.
- [7] S. Ordóñez Flores, “Patrones temporales en el paisaje acústico del área de protección de flora y fauna nahá, chiapas, méxico,” Ph.D. dissertation, UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO, 2019.
- [8] M. Zaguri, S. Kandel, S. A. Rinehart, V. R. Torsekar, and D. Hawlena, “Protein quantification in ecological studies: a literature review and empirical comparisons of standard methodologies,” Methods in Ecology and Evolution, vol. 12, no. 7, pp. 1240–1251, 2021.
- [9] F. Grün, H. Watanabe, Z. Zamanian, L. Maeda, K. Arima, R. Chubacha, D. M. Gardiner, J. Kanno, T. Iguchi, and B. Blumberg, “Endocrine disrupting organotin compounds are potent inducers of adipogenesis in vertebrates,” Molecular Endocrinology, vol. 20, no. 9, pp. 2141–2155, 2006.
- [10] J. R. Cooley and D. C. Marshall, “Sexual signaling in periodical cicadas, *magicicada* spp.(hemiptera: Cicadidae),” Behaviour, pp. 827–855, 2001.

- [11] Universidad de Connecticut. (22 de Agosto de 2019) [https://cicadas.uconn.edu/m\\_cassini/](https://cicadas.uconn.edu/m_cassini/).
- [12] Y. Niu et al., “Bird sound classification using fractal features and multilayer perceptron,” Ecological Informatics, vol. 55, p. 101023, 2020.
- [13] L. Jin et al., “Frog call classification using deep neural networks with time-frequency representation,” Applied Acoustics, vol. 171, p. 107628, 2020.
- [14] N. Bonada et al., “Biological impacts of underwater noise: suggestions for research and management,” Frontiers in Ecology and the Environment, vol. 16, no. 6, pp. 330–338, 2018.
- [15] R. Anjum, A. Paul, and S. Ray, “Frog call classification using machine learning techniques,” Ecological Informatics, vol. 59, p. 101139, 2020.
- [16] A. Kaim, M. E. Watts, and H. P. Possingham, “On which targets should we compromise in conservation prioritization problems?” Methods in Ecology and Evolution, vol. 8, no. 12, pp. 1858–1865, 2017.
- [17] M. Bravo et al., “Vocalization classification of south american anurans using bioacoustics and machine learning,” Applied Acoustics, vol. 121, pp. 158–167, 2017.
- [18] S. P. Singh, A. Agarwal, and A. Gupta, “Deep learning-based automatic classification of mammal vocalizations using a novel time-frequency representation,” Applied Acoustics, vol. 179, p. 108060, 2021.
- [19] A. Gómez-Echavarría, J. P. Ugarte, and C. Tobón, “The fractional fourier transform as a biomedical signal and image processing tool: A review,” Biocybernetics and Biomedical Engineering, vol. 40, no. 3, pp. 1081–1093, 2020. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0208521620300711>
- [20] H. Zhang et al., “Acoustic classification of bird species using fourier spectrum and convolutional neural network,” Ecological Informatics, vol. 61, p. 101218, 2021.
- [21] Z. Li et al., “Whale sound classification using mel-frequency cepstral coefficients and deep learning,” The Journal of the Acoustical Society of America, vol. 147, no. 2, pp. EL146–EL151, 2020.
- [22] R. Laje, A. Cobo-Cuan, F. Ronco, and D. Castro, “Application of fractional fourier transform to study the acoustic communication in anurans,” Ecological Informatics, vol. 47, pp. 75–82, 2018.
- [23] M. Sarria-Paja et al., “Fractal fourier analysis for classification of bat echolocation calls,” Ecological Informatics, vol. 52, pp. 119–128, 2019.
- [24] J. Beltran et al., “Fractal dimension estimation of bird songs using the fractional fourier transform,” Applied Acoustics, vol. 165, p. 107334, 2020.

- [25] A. Das *et al.*, “Comparative analysis of vocalization of anuran species using fractional fourier transform and other signal processing techniques,” *Ecological Informatics*, vol. 51, pp. 78–89, 2019.
- [26] L. Gao *et al.*, “Acoustic monitoring of grasshopper species using deep learning and data augmentation,” *Ecological Informatics*, vol. 50, pp. 40–48, 2019.
- [27] X. Xia, Z. Yang, H. Lin, and Y. Li, “Automatic classification of fish sounds using adaptive filter banks and deep learning,” *Applied Acoustics*, vol. 180, p. 107985, 2021.
- [28] J. Xie, J. G. Colonna, and J. Zhang, “Bioacoustic signal denoising: a review,” *Artificial Intelligence Review*, vol. 54, pp. 3575–3597, 2021.
- [29] F. Miyara, *Acústica y sistemas de sonido*. Universidad Nacional de Rosario, 2003.
- [30] P. Munding, “Microgeographic and macrogeographic variation in acquired vocalizations in birds. in ‘acoustic communication in birds. vol. 2: Song learning and its consequences’.(eds de kroodsma and eh miller.) pp. 147–208,” 1982.
- [31] P. Marler, “Bird calls: their potential for behavioral neurobiology,” *Annals of the New York Academy of Sciences*, vol. 1016, no. 1, pp. 31–44, 2004.
- [32] B. C. Pijanowski, L. J. Villanueva-Rivera, S. L. Dumyahn, A. Farina, B. L. Krause, B. M. Napoletano, S. H. Gage, and N. Pieretti, “Soundscape ecology: the science of sound in the landscape,” *BioScience*, vol. 61, no. 3, pp. 203–216, 2011.
- [33] P. Laiolo, “Homogenisation of birdsong along a natural–urban gradient in argentina,” *Ethology Ecology & Evolution*, vol. 23, no. 3, pp. 274–287, 2011.
- [34] L. F. Baptista and J. E. M. Gómez, “La investigación bioacústica de las aves del archipiélago de revillagigedo: un reporte de avance,” *Huitzil. Revista Mexicana de Ornitología*, vol. 3, no. 2, pp. 33–41, 2002.
- [35] A. paterno Fuentes, “1.-datos del alumno,” Ph.D. dissertation, UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO, 2019.
- [36] H. Bennet-Clark, “Efectos de tamaño y escala como limitaciones en la comunicación sonora de los insectos,” *Transacciones filosóficas de la Royal Society de Londres. Serie B: Ciencias Biológicas*, vol. 353, no. 1367, pp. 407–419, 1998.
- [37] J. A. Valetti, N. E. Salas, and A. L. Martino, “Bioacústica del canto de advertencia de *ceratophrys cranwelli* (anura: Ceratophryidae),” *Revista de Biología Tropical*, vol. 61, no. 1, pp. 273–280, 2013.
- [38] H. C. Gerhardt, “The evolution of vocalization in frogs and toads,” *Annual review of ecology and systematics*, vol. 25, no. 1, pp. 293–324, 1994.

- [39] O. F. R. Bustos, J. M. Serrano, and F. M. Huerta, “El canto de anuncio del anuro más pequeño de México, la rana pigmea *Craugastor pygmaeus* (Anura: Craugastoridae),” Revista Latinoamericana de Herpetología, vol. 4, no. 2, pp. 108–115, 2021.
- [40] J. O. Cossel Jr, J. E. Twining, K. L. Di Stefano, A. O'Brien, A. S. Reich, and J. Sandoval-Alanis, “Vocalizations of five species of frogs in the *Craugastor podiciferus* species group (Anura: Craugastoridae) from Costa Rica,” Herpetological Conservation and Biology, vol. 14, no. 1, pp. 235–249, 2019.
- [41] M. A. Ulloa Rengifo, “Descripción y análisis del canto de anuncio de *Rhinella horribilis* (Amphibia: Bufonidae) en la vereda el Tabacal, la Vega, Cundinamarca.” 2021.
- [42] A. R. d. Santana, “Variação inter e intraespecífica do canto de anúncio de *Dendropsophus elegans* (Wied-Neuwied, 1824) (Anura: Hylidae) em um fragmento de mata atlântica no nordeste brasileiro.” B.S. thesis, Brasil, 2019.
- [43] T. V. Z. Torres, D. L. Fuentes-de-la Rosa, and S. Ordoñez-Flores, “La colección de sonidos de anuros del Museo de Zoología Alfonso L. Herrera de la Facultad de Ciencias,” Revista Latinoamericana de Herpetología, vol. 3, no. 1, pp. 132–140, 2020.
- [44] W. T. Tey, T. Connie, K. Y. Choo, and M. K. O. Goh, “Cicada species recognition based on acoustic signals,” Algorithms, vol. 15, no. 10, p. 358, 2022.
- [45] M. Hasenbank, “Kihikihi,” 2023, June 7, <https://www.kaggle.com/datasets/marchasenbank/kihikihi>.
- [46] C. Fleming, “Acoustic behaviour as a generic character in New Zealand cicadas (Hemiptera: Homoptera),” Journal of the Royal Society of New Zealand, vol. 5, no. 1, pp. 47–64, 1975.
- [47] iNaturalist. (20 de Mayo de 2023) <https://www.inaturalist.org/taxa/1248682-Magicicada-sep>
- [48] D. C. Marshall, K. B. Hill, J. R. Cooley, and C. Simon, “Hybridization, mitochondrial DNA phylogeography, and prediction of the early stages of reproductive isolation: lessons from New Zealand cicadas (genus *Kihikihia*),” Systematic Biology, vol. 60, no. 4, pp. 482–502, 2011.
- [49] J. Bator, D. C. Marshall, K. B. Hill, J. R. Cooley, A. Leston, and C. Simon, “Phylogeography of the endemic red-tailed cicadas of New Zealand (Hemiptera: Cicadidae: Rhodopsalta), and molecular, morphological and bioacoustical confirmation of the existence of Hudson’s *Rhodopsalta microdora*,” Zoological Journal of the Linnean Society, vol. 195, no. 4, pp. 1219–1244, 2022.
- [50] I. Petráš, Fractional-order nonlinear systems: modeling, analysis and simulation. Springer Science & Business Media, 2011.
- [51] J. J. Trujillo, E. Scalas, K. Diethelm, and D. Baleanu, Fractional calculus: models and numerical methods. World Scientific, 2016, vol. 5.

- [52] I. Podlubny, Fractional differential equations: an introduction to fractional derivatives, fractional differential equations, to methods of their solution and some of their applications. Elsevier, 1998.
- [53] A. V. Oppenheim, J. R. Buck, and R. W. Schafer, Discrete-time signal processing. Vol. 2. Upper Saddle River, NJ: Prentice Hall, 2001.
- [54] A. V. Oppenheim, J. Buck, M. Daniel, A. S. Willsky, S. H. Nawab, and A. Singer, Signals & systems. Pearson Educación, 1997.
- [55] J. G. Proakis and D. G. Manolakis, Digital Signal Processing: Pearson New International Edition. Pearson Higher Ed, 2013.
- [56] G. González, “Series de fourier, transformadas de fourier y aplicaciones,” Divulgaciones matemáticas, vol. 5, no. 1/2, pp. 43–60, 1997.
- [57] M. P. Norton and D. G. Karczub, Fundamentals of noise and vibration analysis for engineers. Cambridge university press, 2003.
- [58] V. Namias, “The fractional order fourier transform and its application to quantum mechanics,” IMA Journal of Applied Mathematics, vol. 25, no. 3, pp. 241–265, 1980.
- [59] H. M. Ozaktas and O. Aytür, “Fractional fourier domains,” Signal Processing, vol. 46, no. 1, pp. 119–124, 1995.
- [60] T. Hastie, R. Tibshirani, and J. Friedman, The Elements of Statistical Learning: Data Mining, Inference, and Prediction. Springer, 2009.
- [61] M. Kubat, “Neural networks: a comprehensive foundation by simon haykin, macmillan, 1994, isbn 0-02-352781-7.” The Knowledge Engineering Review, vol. 13, no. 4, pp. 409–412, 1999.
- [62] F. B. Fitch, “Warren s. mcculloch and walter pitts. a logical calculus of the ideas immanent in nervous activity. bulletin of mathematical biophysics, vol. 5 (1943), pp. 115–133.” The Journal of Symbolic Logic, vol. 9, no. 2, pp. 49–50, 1944.
- [63] E. N. Sanchez and A. Y. Alanis, “Redes neuronales: conceptos fundamentales y aplicaciones a control automático,” Cinvestav Unidad Guadalajara. Editorial Prentice Hall, 2006.
- [64] A. J. Maren, C. T. Harston, and R. M. Pap, Handbook of neural computing applications. Academic Press, 2014.
- [65] G.-F. Lara Martínez, “Caracterización y modelado de la producción de sonidos de las ballenas beluga (*delphinapterus leucas*) basado en modelos de análisis/síntesis de voz,” Ph.D. dissertation, Universitat Politècnica de València, 2016.

- [66] C. L. Barrio-Amorós, C. Grünwald, H. Franz-Chavez, A. Mendoza, and B. T. La Forest, “Notes on natural history and call description of the critically endangered *plectrohyla avia* (anura: Hylidae) from chiapas, mexico,” Amphibian & Reptile Conservation, vol. 10, no. 2, pp. 11–17, 2016.
- [67] Canseco, J. L. Aguilar-López, R. Luría-Manzano, E. Pineda, and I. W. Caviedes-Solís, “A new species of treefrog of the genus *ptychohyla* (anura: Hylidae) from southern mexico,” Zootaxa, vol. 4317, no. 2, pp. 279–290, 2017.
- [68] J. Faivovich, M. O. Pereyra, M. C. Luna, A. Hertz, B. L. Blotto, C. R. Vásquez-Almazán, J. R. McCranie, D. A. Sánchez, D. Baêta, K. Araujo-Vieira et al., “On the monophyly and relationships of several genera of hylini (anura: Hylidae: Hylinae), with comments on recent taxonomic changes in hylids,” South American Journal of Herpetology, vol. 13, no. 1, pp. 1–32, 2018.
- [69] L. A. Sandoval, G. Barrantes Montero, D. Ocampo Vargas, and C. Sánchez Quirós, “Sexual size dimorphism and acoustical features of the pre-advertisement and advertisement calls of *rhinophrynus dorsalis duméril & bibron*, 1841 (anura: Rhinophrynidae),” 2015.
- [70] A. M. Mendoza, R. Hernandez-Austria, A. López-Velázquez, and G. Parra-Olea, “Description of two calls of *eleutherodactylus rubrimaculatus* (anura: Eleutherodactylidae) in chiapas, mexico,” Zootaxa, vol. 4732, no. 4, pp. 589–592, 2020.
- [71] J. R. Barber, K. R. Crooks, and K. M. Fristrup, “The costs of chronic noise exposure for terrestrial organisms,” Trends in ecology & evolution, vol. 25, no. 3, pp. 180–189, 2010.
- [72] Ó. Alberto, “Monitoreo bioacústico de las poblaciones de anuros de la reserva de la biosfera nahá, chiapas, méxico,” Ph.D. dissertation, UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO, 2015.
- [73] A. V. Oppenheim and R. W. Schaffer, Discrete-Time Signal Processing. Prentice Hall, 1999.
- [74] Y. Zhang, S. Wang, J.-F. Yang, Z. Zhang, P. Phillips, P. Sun, and J. Yan, “A comprehensive survey on fractional fourier transform,” Fundamenta Informaticae, vol. 151, no. 1-4, pp. 1–48, 2017.
- [75] T. Lv, L. Wang, H. Xie, X. Zhang, and Y. Zhang, “Evolutionary overview of water resource management (1990–2019) based on a bibliometric analysis in web of science,” Ecological informatics, vol. 61, p. 101218, 2021.
- [76] J. Ross and D. K. Mellinger, “Detection, classification, and density estimation of marine mammals using passive acoustic sensors: A review,” The Journal of the Acoustical Society of America, vol. 145, no. 4, pp. 2348–2372, 2019.
- [77] J. Schmidhuber, “Deep learning in neural networks: An overview,” Neural networks, vol. 61, pp. 85–117, 2015.

- [78] G. Hinton, L. Deng, D. Yu, G. E. Dahl, A.-r. Mohamed, N. Jaitly, A. Senior, V. Vanhoucke, P. Nguyen, T. N. Sainath *et al.*, “Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups,” *IEEE Signal processing magazine*, vol. 29, no. 6, pp. 82–97, 2012.
- [79] S. E. Molina, L. Matos, and C. Torres, “Adapted filters in the domain of the fractional fourier transform,” in *2012 XVII Symposium of Image, Signal Processing, and Artificial Vision (STSIVA)*. IEEE, 2012, pp. 312–316.
- [80] C. Duncan, J. R. Thompson, and N. Pettorelli, “The quest for a mechanistic understanding of biodiversity–ecosystem services relationships,” *Proceedings of the Royal Society B: Biological Sciences*, vol. 282, no. 1817, p. 20151348, 2015.
- [81] S. Kong, M. Saif, and G. Cui, “Estimation and fault diagnosis of lithium-ion batteries: A fractional-order system approach,” *Mathematical Problems in Engineering*, vol. 2018, 2018.
- [82] J. Luo, D. Yu, and M. Liang, “Application of multi-scale chirplet path pursuit and fractional fourier transform for gear fault detection in speed up and speed-down processes,” *Journal of sound and vibration*, vol. 331, no. 22, pp. 4971–4986, 2012.
- [83] H.-C. Chen and H.-Y. Pu, “Fault analysis of induction motor based on discrete fractional fourier transform,” in *2016 International Symposium on Computer, Consumer and Control (IS3C)*. IEEE, 2016, pp. 69–72.
- [84] X. Su, R. Tao, and X. Kang, “Analysis and comparison of discrete fractional fourier transforms,” *Signal Processing*, vol. 160, pp. 284–298, 2019.
- [85] R. Isermann, *Fault-diagnosis systems: an introduction from fault detection to fault tolerance*. Springer Science Business Media, 2005.
- [86] Á. D. P. Ramírez, J. I. De la Rosa Vargas, and R. R. Valdez, “Escuchando a la naturaleza: Del reconocimiento de voz a la bioacústica,” *Pistas Educativas*, vol. 38, no. 120, 2018.
- [87] D. Gaglione, C. Clemente, C. V. Ilioudis, A. R. Persico, I. K. Proudler, J. J. Soraghan, and A. Farina, “Waveform design for communicating radar systems using fractional fourier transform,” *Digital Signal Processing*, vol. 80, pp. 57–69, 2018. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1051200418302070>
- [88] D. Houser, D. Helweg, and P. Moore, “Classification of dolphin echolocation clicks by energy and frequency distributions,” *The Journal of the Acoustical Society of America*, vol. 106, no. 3, pp. 1579–1585, 1999.
- [89] F. Itakura, “Minimum prediction residual principle applied to speech recognition,” *IEEE Transactions on acoustics, speech, and signal processing*, vol. 23, no. 1, pp. 67–72, 1975.

- [90] H. Ding, B. Qian, Y. Li, and Z. Tang, “A method combining lpc-based cepstrum and harmonic product spectrum for pitch detection,” in 2006 International Conference on Intelligent Information Hiding and Multimedia. IEEE, 2006, pp. 537–540.
- [91] X. Su, R. Tao, and X. Kang, “Analysis and comparison of discrete fractional fourier transforms,” Signal Processing, vol. 160, pp. 284–298, 2019.
- [92] L. Castro, A. S. del Riego, and J. D. de la Calle, “Redes de neuronas artificiales,” pp. –76, 2002.
- [93] G. B. Mindlin and R. Laje, The physics of birdsong. Springer Science & Business Media, 2006.
- [94] A. Farina, P. James, C. Bobryk, N. Pieretti, E. Lattanzi, and J. McWilliam, “Low cost (audio) recording (lcr) for advancing soundscape ecology towards the conservation of sonic complexity and biodiversity in natural and urban landscapes,” Urban ecosystems, vol. 17, no. 4, pp. 923–944, 2014.
- [95] M. K. Obrist, G. Pavan, J. Sueur, K. Riede, D. Llusia, and R. Márquez, “Bioacoustics approaches in biodiversity inventories,” Abc Taxa, vol. 8, pp. 68–99, 2010.
- [96] A. Dawson, V. M. King, G. E. Bentley, and G. F. Ball, “Photoperiodic control of seasonality in birds,” Journal of biological rhythms, vol. 16, no. 4, pp. 365–380, 2001.
- [97] H. Pröhl, S. Hagemann, J. Karsch, and G. Höbel, “Geographic variation in male sexual signals in strawberry poison frogs (*dendrobates pumilio*),” Ethology, vol. 113, no. 9, pp. 825–837, 2007.
- [98] H. Bennet-Clark, “Efectos de tamaño y escala como limitaciones en la comunicación sonora de los insectos,” Transacciones filosóficas de la Royal Society de Londres. Serie B: Ciencias Biológicas, vol. 353, no. 1367, pp. 407–419, 1998.
- [99] R. Resnick, D. Halliday, and J. Walker, “Fundamentals of physics, vol. 1,” Hoboken: John Wiley, 1988.
- [100] J. Serrano, “Comunicación acústica de hembras y machos de la rana *eleutherodactylus cystignathoides* (anura: Eleutherodactylidae) en el centro de veracruz, méxico,” Unpublished M. Sc. Thesis, Instituto de Ecología AC, 2009.
- [101] J. Florentin, T. Dutoit, and O. Verlinden, “Detection and identification of european woodpeckers with deep convolutional neural networks,” Ecological Informatics, vol. 55, p. 101023, 2020.
- [102] S. M. Kay, Fundamentals of statistical signal processing: estimation theory. Prentice-Hall, Inc., 1993.
- [103] A. Gogu, S. K. Chitimalla, and S. Das, “Identification of bird species using spectrogram image classification and deep learning,” Applied Acoustics, vol. 178, p. 107862, 2021.

- [104] S. Kumar *et al.*, “Automatic bird species recognition using deep learning algorithms,” *Applied Acoustics*, vol. 151, pp. 11–20, 2019.
- [105] R. Dubey *et al.*, “Classification of mammalian vocalizations using convolutional neural networks,” *Applied Acoustics*, vol. 154, pp. 41–50, 2019.
- [106] D. Stowell *et al.*, “Deep neural networks for acoustic scene classification in domestic environments,” *Journal of the Acoustical Society of America*, vol. 141, no. 6, pp. 3957–3968, 2017.
- [107] J. Sueur, T. Aubin, and C. Simonis, “Seewave, a free modular tool for sound analysis and synthesis,” *Bioacoustics*, vol. 18, no. 2, pp. 213–226, 2008.
- [108] B. P. Lathi and R. A. Green, *Signal processing and linear systems*. Oxford University Press Oxford, 1998, vol. 2.
- [109] H. C. Gerhardt and F. Huber, “Acoustic communication in insects and anurans: common problems and diverse solutions,” 2003.
- [110] J. M. Savage, *The amphibians and reptiles of Costa Rica: a herpetofauna between two continents, between two seas*. University of Chicago press, 2002.
- [111] M. J. Lannoo, *Amphibian declines: the conservation status of United States species*. Univ of California Press, 2005.
- [112] C. A. M. del Castillo and, E. B. Fernández, L. P. Pelea, F. Cézilly, and R. A. Bosch, “Predicting the invasion of the acoustic niche: potential distribution and call transmission efficiency of a newly introduced frog in cuba,” *Perspectives in Ecology and Conservation*, vol. 19, no. 1, pp. 90–97, 2021.
- [113] Heyer and M. Celso, “Calls and calling behaviour of the frog *leptodactylus natalensis* (amphibia: Anura: Leptodactylidae),” *Proceedings of the Biological Society of Washington*, 2000.
- [114] Y. Velázquez, O. Flores-Villela, L. Ochoa-Ochoa, and G. P.-P. de León, “Gathering morphological and molecular data for identifying two species of trematodes from the neotropical vaillant’s frog, *lithobates vaillanti* (amphibia: Ranidae) in the highlands of chiapas, south-eastern mexico,” *Journal of Helminthology*, vol. 97, p. e13, 2023.
- [115] G. Köhler, “Amphibians of central america,” 2013.
- [116] A. A. Giaretta, A. G. Lopes, and D. L. Bang, “Reassessment of the advertisement call of toptypic *scinax squalirostris* (anura: Hylidae), with an acoustic evaluation of its occurrence in the serra da mantiqueira, southeastern brazil,” *Phyllomedusa: Journal of Herpetology*, vol. 19, no. 1, pp. 49–61, 2020.

- [117] G. Ehret, E. Keilwerth, and T. Kamada, “The lung–eardrum pathway in three treefrog and four dendrobatid frog species: some properties of sound transmission,” Journal of Experimental Biology, vol. 195, no. 1, pp. 329–343, 1994.
- [118] W. E. Duellman, “Courtship isolating mechanisms in costa rican hylid frogs,” Herpetologica, vol. 23, no. 3, pp. 169–183, 1967.
- [119] K. H. Beard, S. McCullough, and A. K. Eschtruth, “Society for the study of amphibians and reptiles,” Journal of Herpetology, vol. 37, no. 1, pp. 10–17, 2003.
- [120] D. Varela-Soto, J. G. Abarca, E. Brenes-Mora, V. Aspinall, T. Leenders, and A. Shepack, “A new species of brilliant green frog of the genus *tlalocohyla* (anura, hylidae) hiding between two volcanoes of northern costa rica,” Zootaxa, vol. 5178, no. 6, pp. 501–531, 2022.
- [121] R. Laje, A. Cobo-Cuan, F. Ronco, and D. Castro, “Application of fractional fourier transform to study the acoustic communication in anurans,” Ecological Informatics, vol. 47, pp. 75–82, 2018.
- [122] M. Sarria-Paja et al., “Fractal fourier analysis for classification of bat echolocation calls,” Ecological Informatics, vol. 52, pp. 119–128, 2019.
- [123] J. Beltran et al., “Fractal dimension estimation of bird songs using the fractional fourier transform,” Applied Acoustics, vol. 165, p. 107334, 2020.
- [124] A. Das et al., “Comparative analysis of vocalization of anuran species using fractional fourier transform and other signal processing techniques,” Ecological Informatics, vol. 51, pp. 78–89, 2019.
- [125] M. Zaguri, S. Kandel, S. A. Rinehart, V. R. Torsekar, and D. Hawlena, “Protein quantification in ecological studies: a literature review and empirical comparisons of standard methodologies,” Methods in Ecology and Evolution, vol. 12, no. 7, pp. 1240–1251, 2021.
- [126] Y. Niu et al., “Bird sound classification using fractal features and multilayer perceptron,” Ecological Informatics, vol. 55, p. 101023, 2020.
- [127] H. E. Martínez, “Una novedosa definición de la transformada fraccionaria de fourier y sus aplicaciones,” Universidad, Ciencia y Tecnología, vol. 16, no. 62, pp. 42–46, 2012.
- [128] K. Kaiser, C. Boehlke, E. Navarro Pérez, A. Vega, S. Dudgeon, and J. Robertson, “Local preference encoded by complex signaling: mechanisms of mate preference in the red-eyed treefrog (*agalychnis callidryas*),” Behavioral Ecology and Sociobiology, vol. 72, 11 2018.
- [129] L. A. Gray and A. S. Rand, “A daybreak chorus in the frog, *agalychnis callidryas*,” Journal of Herpetology, vol. 31, no. 3, pp. 440–441, 1997.
- [130] V. S. Briggs, “Call trait variation in morelett’s tree frog, *agalychnis moreletii*, of belize,” Herpetologica, vol. 66, no. 3, pp. 241–249, 2010.

- [131] R. Louren, A. S. Lantyer-Silva, L. F. Toledo, and M. Solé, “Tadpole, oophagy, advertisement call, and geographic distribution of *Aparasphenodon arapapa pimenta*, *napoli* and *haddad* 2009 (Anura, Hylidae),” *Journal of Herpetology*, vol. 47, no. 4, pp. 575–579, 2013.
- [132] D. Batallas and J. Brito, “Análisis bioacústico de las vocalizaciones de seis especies de anuros de la laguna cormorán, complejo lacustre de Sardinayacu, Parque Nacional Sangay, Ecuador,” *Revista Mexicana de Biodiversidad*, vol. 87, no. 4, pp. 1292–1300, 2016.
- [133] M. S. Reichert, “Aggressive thresholds in *Dendropsophus ebraccatus*: habituation and sensitization to different call types,” *Behavioral Ecology and Sociobiology*, vol. 64, pp. 529–539, 2010.
- [134] M. Ferrão, J. Moravec, J. Hanken, and A. P. Lima, “A new species of *Dendropsophus* (Anura, Hylidae) from southwestern Amazonia with a green bilobate vocal sac,” *ZooKeys*, vol. 942, p. 77, 2020.
- [135] J. M. Serrano, “El canto de anuncio de la rana endémica del pedregal de la ciudad de México,” *Revista Mexicana de Biodiversidad*, vol. 87, no. 2, pp. 535–539, 2016.
- [136] A. C. Gutiérrez, P. Rodríguez-Umaña, L. Sandoval, and A. García-Rodríguez, “Variación en la actividad acústica de *Hyalinobatrachium fleischmanni* (Anura: Centrolenidae) en un ambiente urbano con diferentes niveles de ruido antropogénico,” *Revista de Biología Tropical*, vol. 67, no. 2, pp. 249–258, 2019.

# Anexo A

## Producto de investigación

Artículo presentado en el 1.º congreso internacional de tecnología y ciencia aplicada llevado a cabo en CENIDET

### Classification of anuran species based on bio-acoustic signals using the fractional Fourier transform

C.D. Solorzano-Madrigal,\* H.M. Cortés-Campos,\*  
L.F. Avalos-Ruíz,\* J.F. Gómez-Aguilar.\*\*

\* *Tecnológico Nacional de México/CENIDET. Interior Internado Palmira S/N, Col. Palmira, C.P. 62490, Cuernavaca, Morelos, México.*

\*\* *CONAHCyT-Tecnológico Nacional de México/CENIDET. Interior Internado Palmira S/N, Col. Palmira, C.P. 62490, Cuernavaca, Morelos, México.*

#### Abstract

This work presents a methodology for the classification of anuran species based on bioacoustic signals. Features were obtained using a 5-level wavelet decomposition and fractional Fourier transform. For the classification stage, a neural network was trained, achieving an accuracy of 91.27%. The proposed methodology can be used for non-invasive observation and recording of species in ecosystems.

*Keywords:* Classification, Neural Networks, Fractional Fourier Transform, Bioacoustics.

#### 1. INTRODUCCIÓN

La conservación de los ecosistemas es de vital importancia para mantener la biodiversidad y el equilibrio ecológico. Estudios recientes, han demostrado cómo el monitoreo bioacústico puede ser esencial en esta tarea, permitiendo la identificación y seguimiento de especies clave, de igual manera se demuestra que la bioacústica desempeña un rol crucial en la conservación de ecosistemas al permitir un monitoreo no invasivo y preciso de la biodiversidad.

La bioacústica es el estudio de los sonidos producidos por los organismos vivos y su papel en la comunicación, el comportamiento y la ecología de las especies Pieretti et al. (2011). La bioacústica se utiliza para comprender y monitorear ecosistemas naturales, un estudio de Ordóñez (2019) evaluó el paisaje acústico en una zona protegida, identificando patrones de actividad que son fundamentales para la conservación, en este estudio se utilizó la bioacústica para identificar doce especies de anuros, incluyendo algunas a nivel de género, esta metodología ofrece una forma efectiva de evaluar y conservar la vida silvestre.

El procesamiento de señales en bioacústica enfrenta desafíos significativos, en particular en la clasificación precisa de especies a partir de las señales acústicas. El desafío principal en bioacústica es la clasificación precisa de especies a partir de señales sonoras. Un estudio reciente de Zhang et al. (2021) logró una alta precisión del 94.5% al utilizar la Transformada de Fourier y una red neuronal convolucional para clasificar aves, este enfoque es esencial para proteger la diversidad de aves.

La bioacústica también enfrenta desafíos como variabilidad estacional, ruido ambiental y similitudes morfológicas entre especies, como se evidenció en la revisión literaria. La bioacústica desempeña un papel clave en la conservación y comprensión de los ecosistemas naturales Xie et al. (2021). Superar estos retos es esencial para aprovechar al máximo la bioacústica en la conservación de ecosistemas y la monitorización de la biodiversidad, si bien las redes neuronales han demostrado ser prometedoras, la mejora continua de los métodos de procesamiento de señales es necesaria para abordar la variabilidad de los datos y aumentar la precisión en la identificación de especies la bioacústica es invaluable en la preservación de la vida silvestre y la conservación de ecosistemas de una manera no invasiva.

El uso de la Transformada de Fourier fraccionaria (FRFT) en señales bioacústicas se ha destacado en varios estudios, ofreciendo una herramienta eficaz para el análisis de análisis de vocalizaciones de ranas, mamíferos y aves. En el estudio de Laje et al. (2018), se utilizó la FRFT para extraer características temporales y espectrales de los cantos de ranas, lo que contribuyó a una mejor comprensión de los procesos de comunicación acústica en estas especies. En la investigación de Sarria Sarria-Paja et al. (2019), se desarrolló una técnica que mejoró la identificación de patrones en murciélagos con mayor resolución en el análisis de tiempo-frecuencia. Beltran Beltran et al. (2020) empleó la FRFT para analizar señales de canto de aves y facilitar la identificación de patrones y clasificación de especies. En el estudio de Li Li et al. (2020), la FRFT se utilizó para calcular MFCC a partir de sonidos de ballenas, logrando una precisión del 94.6% en su clasificación. Por otro lado, Das Das et al. (2019) aplicó la FRFT en señales de



# EL TECNOLÓGICO NACIONAL DE MÉXICO A TRAVÉS DEL CENTRO NACIONAL DE INVESTIGACIÓN Y DESARROLLO TECNOLÓGICO

OTORGA EL PRESENTE

## RECONOCIMIENTO

A

**Carlos Daniel Solorzano Madrigal, Hector Martin Cortés Campos,  
Luis Felipe Avalos Ruiz, Jose Francisco Gomez Aguilar**

Por su invaluable presentación del artículo Classification of anuran species based on bio-acoustic signals using the fractional Fourier transform en el 1er Congreso Internacional de Tecnología y Ciencia Aplicada, desarrollado en el Tecnológico Nacional de México/Centro Nacional de Investigación y Desarrollo Tecnológico, TecNM/CENIDET, del 15 al 17 de noviembre de 2023.

Cuernavaca, Morelos, Noviembre de 2023



**DR. ARTURO ERNESTO MARES GARDEA**  
DIRECTOR DEL CENTRO NACIONAL DE INVESTIGACIÓN  
Y DESARROLLO TECNOLÓGICO

Sello Digital:

wcUNuqLD2ic5zW+0wlHa1KFse/H8fDDpIeiWW95ppEKF+sZA2WdnPoz0kU9F3QUdctLEkfbnGOuk9zHHiKZncw  
ft70TVgaaFH1TywdmMOHF4rtxYMXcfIN6pjpIkCokjknMBynVzEZi3YyvV7k7BX7zhR8QanWn4/cGv+gCQVXHU6q  
qiz+SF7LscfCvGeua9UNkvWDKT7HdZW/q4v90QmJAPu63q1w1ToCP965WudyRqQrp6na4zBxjtd2UbFYDokSYe  
J4D2sjv7vOLzuY5/Hsfa13NLGr3EP+cUuf4PBh0meHHS38P/TPMHSnfAJQznTYRJo9H4sETH8wmFu8XF6zMA==

C0231123

<http://constancias.cenidet.tecnm.mx>

# Anexo B

## Pseudocódigos

Pseudocódigo 1

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from os import listdir
from scipy.io import wavfile
import pydub
from tqdm import tqdm
from tensorflow import keras
from sklearn import preprocessing
import collections
import statistics as stat
from PyEMD import EMD
from scipy import signal
import scipy.io
import scipy.io
import math
import os
import random
import seaborn as sns
import tensorflow as tf
import Extrac_class
import Ext_STFRFT
from matplotlib import cm
from matplotlib.ticker import LinearLocator
from sklearn.preprocessing import StandardScaler
from sklearn.model_selection import train_test_split

SEED=1
def set_seeds(seed=SEED):
```

---

```

os.environ['PYTHONHASHSEED'] = str(seed)
random.seed(seed)
tf.random.set_seed(seed)
np.random.seed(seed)

def set_global_determinism(seed=SEED):
    set_seeds(seed=seed)

    os.environ['TF_DETERMINISTIC_OPS'] = '1'
    os.environ['TF_CUDNN_DETERMINISTIC'] = '1'

    tf.config.threading.set_inter_op_parallelism_threads(1)
    tf.config.threading.set_intra_op_parallelism_threads(1)

# Call the above function with seed value
set_global_determinism(seed=SEED)

def read(f, normalized=False):
    """MP3 to numpy array"""
    a = pydub.AudioSegment.from_mp3(f)
    y = np.array(a.get_array_of_samples())
    if a.channels == 2:
        y = y.reshape((-1, 2))
    if normalized:
        return a.frame_rate, np.float32(y) / 2**15
    else:
        return a.frame_rate, y

def write(f, sr, x, normalized=False):
    """numpy array to MP3"""
    channels = 2 if (x.ndim == 2 and x.shape[1] == 2) else 1
    if normalized: # normalized array - each item should be a float in [-1, 1)
        y = np.int16(x * 2 ** 15)
    else:
        y = np.int16(x)
    song = pydub.AudioSegment(y.tobytes(), frame_rate=sr,

    sample_width=2, channels=channels)

    song.export(f, format="mp3", bitrate="320k")

def OrdenarCuarto(DAT,CCc,NCLASES,Ndata):

```

---

---

```

Ndata2 = len(DAT.T)
Fi = CCc[1]
NMClass = np.zeros((Ndata, NCLASES))
NMData = np.zeros((Ndata, Ndata2))

q = 0
for m in range(NCLASES):
    for n in range(Ndata):
        if Fi[n] == m:
            NMClass[q, m] = 1
            NMData[q, :] = DAT[n, :]
            q = q + 1
return NMClass, NMData

path_data= r'D:\Daniel\Proyecto _daniel\Analisis\Dataset_para_carct'
direct = listdir(path_data)
Num_data=len(direct)
All_data=[]
data_info=np.zeros((Num_data,5))
Data_array=np.zeros((Num_data,48000))

clases, Num_class=Extrac_class.M_class(direct)

for i in tqdm(range(Num_data)):
    ext = direct[i].endswith('.wav')
    Name_data_file = path_data + '\\\' + direct[i]
    # print(i)
    if ext == True:
        Fs_sound, data = wavfile.read(Name_data_file)
        N_ch=len(data.T)
        L_data = len(data)
        data_1 = np.zeros((1, L_data))
        if N_ch==2:
            data_1[0,:] = (data[:,0]+ data[:,1])/2
        else:
            data_1[0,:] = data

    else:
        Fs_sound, data = read(Name_data_file)
        N_ch = len(data.T)

```

---

---

```

L_data = len(data)
data_1=np.zeros((1,L_data))
if N_ch == 2:
    data_1[0,:] = (data[:, 0] + data[:,1]) / 2
else:
    data_1[0,:] = data
# L_data = len(data_1)
max_value = max(data_1[0,:])
min_value = min(data_1[0,:])
duration_signal= L_data/Fs_sound
data_norm= (data_1[0,:] - min_value)/ (max_value - min_value)
All_data.append(data_norm)
Data_array[i,0:L_data]=data_norm
data_info[i,0]=Fs_sound
data_info[i,1]=min(data_norm)
data_info[i,2]=max(data_norm)
data_info[i,3]=L_data
data_info[i,4]=duration_signal

NCLASES=len(classes.T)
CCc=np.where(classes==1)
Fi=CCc[1]

class_ord,data_ord=OrdenarCuarto(Data_array,CCc,NCLASES,Num_data)

scipy.io.savemat('Data_unbalanced.mat', {'Data': data_ord, 'Class':
class_ord, 'Num_class':Num_class})
data_redu=np.zeros((30,48000))
M_class_red= np.zeros((30,18))
data_redu[0:30,:]=Data_array[0:30,:]
M_class_red[0:30,:]=classes[0:30,:]

data_redu=np.append(data_redu,Data_array[182:219], axis=0)
data_redu=np.append(data_redu,Data_array[220:249], axis=0)

a=1

```

---

## Pseudocódigo 2

```
from sklearn.preprocessing import StandardScaler
from sklearn.model_selection import train_test_split
# from sklearn.metrics import confusion_matrix
# from sklearn.metrics import plot_confusion_matrix
import scipy.io
import keras
import scipy.io
# from tensorflow import keras
import Extrac_Features
import matplotlib.pyplot as plt
import numpy as np
import pandas as pd
import seaborn as sns
import tensorflow as tf

import os
import random

def del_col_data(Data, classes1, del_cls):
    U = np.where(classes1 == 1)
    d = np.where(U[1] == del_cls)
    New_L = len(U[0]) - len(d[0])

    Newdata = np.zeros((New_L, len(Data.T)))
    # Newclass = np.delete(classes, d[0], 0)
    # Newclass = np.delete(Newclass, del_cls, 1)
    q = 0
    for k in range(len(classes1)):
        if U[1][k] != del_cls:
            Newdata[q, :] = Data[k, :]
            q = q + 1
    return Newdata

def del_col_class(clses1, del_cls):
    U = np.where(clses1 == 1)
    d = np.where(U[1] == del_cls)
    New_L = len(U[0]) - len(d[0])

    # Newdata = np.zeros((New_L, len(Data.T)))
    Newclass = np.delete(clses1, d[0], 0)
    Newclass = np.delete(Newclass, del_cls, 1)
    return Newclass
```

---

---

```
SEED=3
def set_seeds(seed=SEED):
    os.environ['PYTHONHASHSEED'] = str(seed)
    random.seed(seed)
    tf.random.set_seed(seed)
    np.random.seed(seed)

def set_global_determinism(seed=SEED):
    set_seeds(seed=seed)

    os.environ['TF_DETERMINISTIC_OPS'] = '1'
    os.environ['TF_CUDNN_DETERMINISTIC'] = '1'

    tf.config.threading.set_inter_op_parallelism_threads(1)
    tf.config.threading.set_intra_op_parallelism_threads(1)

# Call the above function with seed value
set_global_determinism(seed=SEED)

mat = scipy.io.loadmat(r'C:\Users\Daniel\1_Programas\Daniel_pro\Data_db4.mat')
CD1=mat['CD1']
CD2=mat['CD2']
Data_array=mat['Data']

clases = mat['Class']
alpha=1
# beta=1.46775868

del_class=16
del_class2=11
del_class3=8

CD1_nw=del_col_data(CD1,clases,del_class)
CD2_nw=del_col_data(CD2,clases,del_class)
Data_nw=del_col_data(Data_array,clases,del_class)
Clases_nw=del_col_class(clases,del_class)
```

---

```

CD1_nw2=del_col_data(CD1_nw,Clases_nw,del_class2)
CD2_nw2=del_col_data(CD2_nw,Clases_nw,del_class2)
Data_nw2=del_col_data(Data_nw,Clases_nw,del_class2)
Clases_nw2=del_col_class(Clases_nw,del_class2)

CD1_nw3=del_col_data(CD1_nw2,Clases_nw2,del_class3)
CD2_nw3=del_col_data(CD2_nw2,Clases_nw2,del_class3)
Data_nw3=del_col_data(Data_nw2,Clases_nw2,del_class3)
Clases_nw3=del_col_class(Clases_nw2,del_class3)

Car1 = Extrac_Features.Features_Exctrac('FRFT', Data_nw3, alpha)
# Car2 = Extrac_Features.Features_Exctrac('FRFT', CD2_nw3, beta)
# C1_norm = StandardScaler().fit_transform(Car1)
# C2_norm = StandardScaler().fit_transform(Car2)

Car_all = np.concatenate((Car1,Data_nw3), axis=1)

Features_all_norm = StandardScaler().fit_transform(Car_all)

x_train, x_test, y_train, y_test =

train_test_split(Features_all_norm, Clases_nw3, test_size=0.3)

Num_epochs = 30
model = keras.Sequential([
    keras.layers.Dense(2048, activation="relu"),
    keras.layers.Dense(1024, activation="relu"),
    keras.layers.Dense(512, activation="relu"),
    keras.layers.Dense(256, activation="relu"),
    keras.layers.Dense(15, activation="softmax")
])

model.compile(optimizer='adam',
              loss='binary_crossentropy',
              metrics=['accuracy', 'Precision', 'Recall',
'mean_absolute_error'])

history = model.fit(x_train, y_train, epochs=Num_epochs)

test_loss, test_acc, test_precision,

```

---

---

```

test_recall,testMAE=model.evaluate(x_test, y_test, verbose = 2)

print('Test accuracy: ', test_acc)

predictions = model.predict(x_test)

n=len(predictions)
Y_est=np.zeros((1,n))
Y_real=np.zeros((1,n))
for i in range(n):

    Y_real[0, i] = np.argmax(y_test[i, :])
    Y_est[0, i] = np.argmax(predictions[i, :])

scipy.io.savemat('Class_clasic.mat', {'Y_real': Y_real, 'Y_est':
Y_est , 'accuracy':test_acc,
'Precision':test_precision, 'recall':test_recall, 'alpha':alpha})
d={'Clases reales':Y_real[0,:], 'Clases estimadas':Y_est[0,:]}
rf={'Clases reales':Y_real[0,:], 'Clases estimadas':Y_est[0,:]}
df=pd.DataFrame(data=d)

pCF=pd.DataFrame(data=rf, columns=['Clases reales', 'Clases estimadas'])

Confusion_matrix = pd.crosstab(pCF['Clases reales'], pCF['Clases
estimadas'], rownames=['Actual'], colnames=['Predicted'])

sns.heatmap(Confusion_matrix, annot=True, cmap='GnBu',linewidth=0.5,
linecolor='black')

# plt.subplots_adjust(left=0.035, right=0.980, top=0.950, bottom=0.060)
plt.title('Matrix confusion wavelet-FRFT')
plt.show()

```

---

---

### Pseudocódigo 3

```
import numpy as np
import pandas as pd
from tqdm import tqdm
from tensorflow import keras
from sklearn import preprocessing
from sklearn.preprocessing import StandardScaler
from sklearn.model_selection import train_test_split

from scipy import signal
import matplotlib.pyplot as plt

import scipy.io
import os
import random
import seaborn as sns
import tensorflow as tf

SEED=1
def set_seeds(seed=SEED):
    os.environ['PYTHONHASHSEED'] = str(seed)
    random.seed(seed)
    tf.random.set_seed(seed)
    np.random.seed(seed)

def set_global_determinism(seed=SEED):
    set_seeds(seed=seed)

    os.environ['TF_DETERMINISTIC_OPS'] = '1'
    os.environ['TF_CUDNN_DETERMINISTIC'] = '1'

    tf.config.threading.set_inter_op_parallelism_threads(1)
    tf.config.threading.set_intra_op_parallelism_threads(1)

# Call the above function with seed value
set_global_determinism(seed=SEED)
mat = scipy.io.loadmat
(r'C:\Users\Daniel\Documents\\1_Programas\Bioacustics_proyect\Cicada\D
ata_Cicada_unbalanced.mat')
Data_array=mat['Data']
classes=mat['Class']
```

---

```

Num_class=mat['Num_class']
Ldta=len(Data_array[0,:])

A1=np.zeros((int(Num_class[0,0]),len(Data_array[0,:])))
A2=np.zeros((int(Num_class[0,1]),len(Data_array[0,:])))
A3=np.zeros((int(Num_class[0,2]),len(Data_array[0,:])))
A4=np.zeros((int(Num_class[0,3]),len(Data_array[0,:])))
A5=np.zeros((int(Num_class[0,4]),len(Data_array[0,:])))
A6=np.zeros((int(Num_class[0,5]),len(Data_array[0,:])))

A1[:,:]=Data_array[0:int(Num_class[0,0]),:]

A2[:,:]=Data_array[int(Num_class[0,0]):int(Num_class[0,0] + Num_class[0,1]),:]

A3[:,:]=Data_array[int(Num_class[0,0]+ Num_class[0,1]):int(Num_class[0,0] +
Num_class[0,1]+ Num_class[0,2]),:]

A4[:,:]=Data_array[int(Num_class[0,0]+ Num_class[0,1]+ Num_class[0,2]):
int(Num_class[0,0] + Num_class[0,1]+ Num_class[0,2]+ Num_class[0,3]),:]

A5[:,:]=Data_array[int(Num_class[0,0]+ Num_class[0,1]+ Num_class[0,2]+ Num_class[0,3]):
int(Num_class[0,0] + Num_class[0,1]+ Num_class[0,2]+ Num_class[0,3]+ Num_class[0,4]),:]

A6[:,:]=Data_array[int(Num_class[0,0]+ Num_class[0,1]+
Num_class[0,2]+ Num_class[0,3]+ Num_class[0,4]):
int(Num_class[0,0] + Num_class[0,1]+ Num_class[0,2]+
Num_class[0,3]+ Num_class[0,4]+ Num_class[0,5]),:]

np.random.shuffle(A1)
np.random.shuffle(A2)
np.random.shuffle(A3)
np.random.shuffle(A4)
np.random.shuffle(A5)
np.random.shuffle(A6)

Data_Lnorm=np.zeros((int(250*6),Ldta))
Data_Lnorm[0:250,:]=A1[0:250,:]
Data_Lnorm[250:500,:]=A2[0:250,:]

```

---

---

```
Data_Lnorm[500:750,:]=A3[0:250,:]  
Data_Lnorm[750:1000,:]=A4[0:250,:]  
Data_Lnorm[1000:1250,:]=A5[0:250,:]  
Data_Lnorm[1250:1500,:]=A6[0:250,:]  
  
Classes_Lnorm=np.zeros((int(250*6),6))  
  
Classes_Lnorm[0:250,0]=1  
Classes_Lnorm[250:500,1]=1  
Classes_Lnorm[500:750,2]=1  
Classes_Lnorm[750:1000,3]=1  
Classes_Lnorm[1000:1250,4]=1  
Classes_Lnorm[1250:1500,5]=1  
  
scipy.io.savemat('Data_Cicada_balanced.mat',  
{'Data': Data_Lnorm, 'Class': Classes_Lnorm})  
  
a=1
```

---

## Pseudocódigo 4

```
import numpy as np
import pandas as pd
from tqdm import tqdm
from tensorflow import keras
import keras
from sklearn import preprocessing
from sklearn.preprocessing import StandardScaler
from sklearn.model_selection import train_test_split
# from pyemd import emd
import pywt
from scipy import signal
import matplotlib.pyplot as plt
import Extrac_Features
import scipy.io
import os
import random
import seaborn as sns
import tensorflow as tf

SEED=1
def set_seeds(seed=SEED):
    os.environ['PYTHONHASHSEED'] = str(seed)
    random.seed(seed)
    tf.random.set_seed(seed)
    np.random.seed(seed)

def set_global_determinism(seed=SEED):
    set_seeds(seed=seed)

    os.environ['TF_DETERMINISTIC_OPS'] = '1'
    os.environ['TF_CUDNN_DETERMINISTIC'] = '1'

    tf.config.threading.set_inter_op_parallelism_threads(1)
    tf.config.threading.set_intra_op_parallelism_threads(1)

# Call the above function with seed value
set_global_determinism(seed=SEED)
mat = scipy.io.loadmat(r'C:\Users\Daniel\Documents\\1_Programas\Bioacustics_
proyect\Cicada\Data_Cicada_balanced.mat')
Data_array=mat['Data']
```

---

---

```

classes=mat['Class']

Ndata = len(Data_array)

window='db4'

Coeff = pywt.wavedec(Data_array[0, :], window, level=5)
Nv1 = len(Coeff[1])
Nv2 = len(Coeff[2])
Nv3 = len(Coeff[3])
Nv4 = len(Coeff[4])
Nv5 = len(Coeff[5])
CA = np.zeros((Ndata, Nv1))
CA_T = np.zeros((Ndata, Nv1))
CD1 = np.zeros((Ndata, Nv1))
CD2 = np.zeros((Ndata, Nv2))
CD3 = np.zeros((Ndata, Nv3))
CD4 = np.zeros((Ndata, Nv4))
CD5 = np.zeros((Ndata, Nv5))

for k in range(Ndata):
    Coeff = pywt.wavedec(Data_array[k, :], window, level=5)
    CA[k, :], CD1[k, :], CD2[k, :], CD3[k, :], CD4[k, :], CD5[k, :] =Coeff

scipy.io.savemat('Data_'+window+'.mat',

{'Data':Data_array,'CA': CA,'CD1': CD1,'CD2': CD2,'CD3': CD3,'CD4':
CD4,'CD5': CD5, 'Class':classes})

Car2=Extrac_Features.Features_Exctrac('FRFT',CD3,0.5)
Car1=Extrac_Features.Features_Exctrac('FRFT',CD4,0.5)

Car_all=np.concatenate((Car1,Car2,Data_array), axis=1)
Features_all_norm=StandardScaler().fit_transform(Car_all)

x_train, x_test, y_train, y_test =

train_test_split(Features_all_norm,classes, test_size=0.35)

Num_epochs=30
model = keras.Sequential([
    # keras.layers.Dense(4096, activation="relu"),

```

---

---

```

    # keras.layers.Dense(2048, activation="relu"),
    # keras.layers.Dense(1024, activation="relu"),
    keras.layers.Dense(512, activation = "relu"),
    keras.layers.Dense(256, activation = "relu"),
    keras.layers.Dense(6, activation="softmax")
])

model.compile(optimizer = 'adam', ##adam
              # loss = 'categorical_crossentropy',
              loss='binary_crossentropy',
              metrics = ['accuracy', 'Precision', 'Recall', 'mean_absolute_error'])
history=model.fit(x_train, y_train, epochs = Num_epochs)

plt.figure()
plt.plot(history.history['accuracy'])
plt.plot(history.history['precision'])
plt.plot(history.history['recall'])
plt.plot(history.history['mean_absolute_error'])
plt.plot(history.history['loss'])
plt.legend(['Accuracy', 'Precision', 'Recall', 'MAE', 'Loss'])
plt.xlabel('Epochs')
plt.xlim([0, Num_epochs])
plt.title('Training Metrics')
plt.grid()

plt.show()

test_loss, test_acc, test_precision,

test_recall, testMAE=model.evaluate(x_test, y_test, verbose = 2)
print('Test accuracy: ', test_acc)

predictions = model.predict(x_test)

n=len(predictions)
Y_est=np.zeros((1,n))
Y_real=np.zeros((1,n))
for i in range(n):
    Y_real[0, i] = np.argmax(y_test[i, :])
    Y_est[0, i] = np.argmax(predictions[i, :])

# scipy.io.savemat('Clas_WDFRFT.mat', {'Y_real': Y_real, 'Y_est':

```

---

---

```
Y_est , 'accuracy':test_acc, 'Precision':test_prprecision, 'recall':test_recall})
d={'Clases reales':Y_real[0,:], 'Clases estimadas':Y_est[0,:]}
rf={'Clases reales':Y_real[0,:], 'Clases estimadas':Y_est[0,:]}
df=pd.DataFrame(data=d)

pCF=pd.DataFrame(data=rf, columns=['Clases reales', 'Clases estimadas'])

Confusion_matrix = pd.crosstab(pCF['Clases reales'], pCF['Clases
estimadas'], rownames=['Actual'], colnames=['Predicted'])

sns.heatmap(Confusion_matrix, annot=True, cmap='GnBu',linewidth=0.5, linecolor='black')

# plt.subplots_adjust(left=0.035, right=0.980, top=0.950, bottom=0.060)

plt.title('Matrix confusion wavelet-FRFT')
plt.show()

a=1
```