



INSTITUTO POLITÉCNICO NACIONAL
CENTRO DE INVESTIGACIÓN EN COMPUTACIÓN



Reconocimiento de clases de aeronaves mediante el patrón acústico producido durante el despegue

TESIS

Para obtener el grado de:

**MAESTRO EN CIENCIAS EN INGENIERÍA DE
CÓMPUTO CON OPCIÓN EN SISTEMAS DIGITALES**

Presenta

Miguel Márquez Molina

Directores de Tesis: Dr. Luis P. Sánchez Fernández

Dr. Sergio Suárez Guerra

México, D.F. 2013



INSTITUTO POLITÉCNICO NACIONAL SECRETARÍA DE INVESTIGACIÓN Y POSGRADO

ACTA DE REVISIÓN DE TESIS

En la Ciudad de México, D.F. siendo las 11:00 horas del día 13 del mes de noviembre de 2013 se reunieron los miembros de la Comisión Revisora de la Tesis, designada por el Colegio de Profesores de Estudios de Posgrado e Investigación del:

Centro de Investigación en Computación

para examinar la tesis titulada:

“Reconocimiento de clases de aeronaves mediante el patrón acústico producido durante el despegue”

Presentada por el alumno:

Márquez
Apellido paterno

Molina
Apellido materno

Miguel
Nombre(s)

Con registro:

B	1	1	0	9	3	4
---	---	---	---	---	---	---

aspirante de: **MAESTRÍA EN CIENCIAS EN INGENIERÍA DE CÓMPUTO CON OPCIÓN EN SISTEMAS DIGITALES**

Después de intercambiar opiniones los miembros de la Comisión manifestaron **APROBAR LA TESIS**, en virtud de que satisface los requisitos señalados por las disposiciones reglamentarias vigentes.

LA COMISIÓN REVISORA Directores de Tesis

Dr. Luis Pastor Sánchez Fernández

Dr. Sergio Suárez Guerra

Dr. Oleksiy Pogrebynyak

Dr. José de Jesús Medel Juárez

Dr. José Juan Carbajal Hernández

M. en C. Romeo Urbieta Parrazales

PRESIDENTE DEL COLEGIO DE PROFESORES

Dr. Luis Alfonso Villa Vargas
INSTITUTO POLITÉCNICO NACIONAL
CENTRO DE INVESTIGACION
EN COMPUTACION
DIRECCION



INSTITUTO POLITECNICO NACIONAL

SECRETARÍA DE INVESTIGACIÓN Y POSGRADO

CARTA CESIÓN DE DERECHOS

En la Ciudad de México el día 22 del mes de Noviembre del año 2013, el que suscribe Miguel Márquez Molina alumno del Programa de Maestría en Ciencias en Ingeniería de Cómputo con número de registro B110934, adscrito al Centro de Investigación en Computación, manifiesta que es autor intelectual del presente trabajo de Tesis bajo la dirección del Dr. Luis Pastor Sánchez Fernández y el Dr. Sergio Suárez Guerra y cede los derechos del trabajo intitulado Reconocimiento de clases de aeronaves mediante el patrón acústico producido durante el despegue, al Instituto Politécnico Nacional para su difusión, con fines académicos y de investigación.

Los usuarios de la información no deben reproducir el contenido textual, gráficas o datos del trabajo sin el permiso expreso del autor y/o directores del trabajo. Este puede ser obtenido escribiendo a la siguiente dirección mmarquez_b11@sagitario.cic.ipn.mx. Si el permiso se otorga, el usuario deberá dar el agradecimiento correspondiente y citar la fuente del mismo.

Miguel Márquez Molina

Nombre y firma

RESUMEN

El transporte aéreo es uno de los servicios más importantes del mundo ya que contribuye enormemente al progreso de la sociedad moderna. Este tiene un impacto sobre el medio ambiente, haciendo que el ruido de las aeronaves durante el despegue sea un problema de salud pública ambiental cerca de los aeropuertos y un tema importante de monitoreo y de investigación.

En esta perspectiva, las acciones prácticas para analizar y controlar la exposición al ruido ambiental son esenciales, debido a que el crecimiento de la contaminación acústica implica efectos nocivos para la salud humana, tanto directos como acumulativos. Además, la tarea de clasificación en relación a la fuente del evento de ruido, es un punto débil de las unidades de monitoreo actuales en los aeropuertos.

En este trabajo, se presenta un modelo computacional para el reconocimiento de clases de aeronaves basado en la extracción de rasgos característicos de la señal registrada durante el despegue y un modelo neuronal artificial para la clasificación, permitiendo su uso en sistemas de monitoreo de ruidos ambientales para planificación y gestión del ruido en las cercanías de los aeropuertos.

Las señales del despegue de las aeronaves son adquiridas a 25 kHz a 24 bits y una duración de 24 segundos. Posteriormente, se obtienen 96 rasgos a través del análisis 1/24 de octava y 40 rasgos mediante los coeficientes cepstrales en la escala de Mel (MFCC). La clasificación de aeronaves se realiza mediante el uso de dos redes neuronales artificiales en paralelo, la primera red es entrenada con los rasgos de octava, la segunda es entrenada con los rasgos MFCC, y un módulo de toma de decisión interconectado a las salidas de ambas redes. Las aeronaves son agrupadas en clases dependiendo del tipo de motor instalado. El modelo realiza la clasificación en 13 clases de aeronaves, con una precisión del 83%.

ABSTRACT

Air transportation is one of the most important services in the world, contributing greatly to the advancement of modern society. It has a local and a global impact on the environment making aircraft take-off noise an important environmental public health concern near airports and this is a significant subject for monitoring and research.

In this perspective, practical actions to analyze and control environmental noise exposure are essential, due to growth of noise pollution involves direct and cumulative adverse effects to human health. Besides, the classification task in relation to the source of the noise event, it is a weak point of current monitoring units near airports.

This work presents a computational model for aircraft classification based on feature extraction of the recorded signal during take-off and an artificial neural model for classification, allowing its use in environmental noise monitoring systems for planning and management of noise near airports.

Aircraft take-off signals are acquired at 25 kHz at 24 bits with a length of 24 seconds. Subsequently, 96 features are obtained through 1/24 octave analysis and 40 features by Mel-frequency cepstral coefficients (MFCC). Aircraft classification is performed by using two parallel neural networks, the first network is trained with octave features, the second is trained with MFCC features, and a decision-making module interconnecting the outputs of both networks. The aircrafts are clustered into classes depending on installed engine type. This model has 13 aircraft classes and a classification accuracy of 83%.

AGRADECIMIENTOS

A Dios.

Por la oportunidad que me brinda para cumplir un objetivo más en mi vida.

A mi madre y hermanas.

Por sus consejos y apoyo incondicional.

A mi padre.

Sus recuerdos siguen presentes en mi vida.

A mi sobrina Michelle.

A mis compañeros.

Por compartir su amistad, consejos y experiencias.

A mis directores de tesis, Dr. Sergio Suárez y Dr. Luis P. Sánchez.

Por su guía durante mi formación y en la elaboración de este trabajo.

Al Instituto Politécnico Nacional.

Al Consejo Nacional de Ciencia y Tecnología, CONACYT.

Por su apoyo económico durante los estudios de maestría.

ÍNDICE

ÍNDICE DE FIGURAS	IV
ÍNDICE DE TABLAS	VIII
GLOSARIO	IX
Capítulo 1. Introducción.....	1
1.1 Antecedentes	1
1.2 Formulación de los problemas.....	2
1.3 Hipótesis.....	3
1.4 Objetivos	3
1.4.1 Objetivo general.....	3
1.4.2 Objetivos específicos.....	3
1.5 Alcance	4
1.6 Contribuciones	4
1.7 Método de investigación y desarrollo utilizado	4
1.8 Estructura de la tesis	5
Capítulo 2. Estado del arte	7
2.1 Contaminación acústica	7
2.2 Establecimiento de prioridades en la gestión del ruido.....	8
2.3 Iniciativas para evaluación, gestión y legislación del ruido.....	8
2.4 Legislaciones para el control de la emisión de ruido en la Ciudad de México.....	11
2.5 Evolución del transporte aéreo	12
2.6 Sistemas de monitoreo del ruido	14
2.7 Reconocimiento de clases de aeronaves	17
2.8 Conclusión del capítulo	19
Capítulo 3. Marco teórico	21
3.1 Conceptos de acústica.....	21
3.1.1 Tipos de ruido.....	22
3.1.2 Propagación del ruido	23

3.1.3 Fuentes de ruido	25
3.1.4 Instrumentos de medición	27
3.1.5 Indicadores de valoración del sonido.....	30
3.2 Técnicas de procesamiento de voz	31
3.2.1 Codificación predictiva lineal (LPC)	32
3.2.2 Predicción perceptual lineal (PLP).....	35
3.2.3 Coeficientes cepstrales en las frecuencias de Mel (MFCC).....	39
3.2.4 Análisis de octava	42
3.2.5 Análisis cepstrum	44
3.3 Redes neuronales artificiales	45
3.3.1 Perceptrón multicapa (MLP)	46
3.4 Conclusión del capítulo	47
Capítulo 4. Análisis de las mediciones del ruido generado durante el despegue.....	48
4.1 Sistema de medición	48
4.2 Punto de medición.	50
4.3 Señal de ruido de una aeronave durante el despegue	51
4.4 Base de datos de ruido generado durante el despegue	53
4.5 Análisis y extracción de rasgos característicos.....	54
4.5.1 Pre-procesamiento.....	55
4.5.2 Procesamiento	59
4.5.3 Extracción de rasgos mediante el análisis de octava	60
4.5.4 Extracción de rasgos mediante el análisis MFCC	62
4.6 Conclusión del capítulo	65
Capítulo 5. Método de reconocimiento	66
5.1 Etapa de reconocimiento	66
5.2 Normalización de los datos de entrada.....	67
5.3 Entrenamiento de las redes neuronales multicapa	68
5.4 Módulo de toma de decisión	71
5.5 Conclusión del capítulo	73
Capítulo 6. Pruebas y resultados	74

6.1 Modelo computacional para el reconocimiento de aeronaves	74
6.1.1 Implementación del modelo computacional para el reconocimiento de aeronaves	75
6.2 Procedimiento experimental.....	76
6.2.1 Prueba a la red neural para rasgos de octava.....	76
6.2.2 Prueba a la red neural para rasgos MFCC.....	77
6.2.3 Prueba al modelo de reconocimiento con el módulo de decisión.....	77
6.3 Conclusión del capítulo	79
Capítulo 7. Conclusiones y trabajo futuro	80
7.1 Conclusiones.....	80
7.2 Trabajo futuro	82
Referencias bibliográficas	83
Anexo A. Conjunto de aeronaves y patrones extraídos por clase.....	87
A.1 A320 1	87
A.2 A320 2	88
A.3 A320 3	89
A.4 A320_B737-800.....	90
A.5 ATR-42.....	91
A.6 B737-100/200	92
A.7 B737-600/700	93
A.8 B747-400.....	94
A.9 F100.....	95
A.10 F100 2.....	96
A.11 F100_B737-200	97
A.12 F100_B737-200 2	98
A.13 MD.....	99
Anexo B. Efectos potencialmente nocivos a la salud y confort en el ser humano.....	100
Anexo C. Diagrama Entidad-Relación para la base de datos del modelo computacional.	101
Anexo D. Publicaciones generadas.	102

ÍNDICE DE FIGURAS

Fig. 1-1. Vista actual del Aeropuerto Internacional de la Ciudad de México.	2
Fig. 2-1. Dependencia entre las regulaciones y el impacto del ruido con respecto al desarrollo industrial	9
Fig. 2-2. Topología de un sistema de monitoreo ANOMS.	15
Fig. 2-3. Nivel de ruido vs tiempo. La señal de audio de diversos ruidos.	16
Fig. 2-4. Ejemplo de los rasgos del ruido de los aviones Falcon.	18
Fig. 2-5. Ejemplos de rasgos utilizando LPC para aeronave MD87.	18
Fig. 2-6. Procedimiento para extracción y selección de rasgos con segmentación en el tiempo.	19
Fig. 3-1. Fuente de ruido por tráfico de vehículos.	25
Fig. 3-2. Fuente de ruido por tráfico aéreo.	26
Fig. 3-3. Ruido producido por maquinaria en obras públicas.	26
Fig. 3-4. Ruido generado por actividades industriales.	26
Fig. 3-5. Ruido producido por actividades urbanas.	27
Fig. 3-6. Sonómetro digital de la compañía TES Electrical Corp.	28
Fig. 3-7. Curvas de ponderación estandarizadas internacionalmente.	30
Fig. 3-8. Diagrama de bloques para el análisis PLP.	35
Fig. 3-9. Umbrales y contornos de igual nivel de sonoridad.	38
Fig. 3-10. Relación entre la escala de frecuencia y la escala de Mel.	40
Fig. 3-11. Banco de filtros espaciados logarítmicamente.	42
Fig. 3-12. Filtro de octava, un filtro pasa banda que cubre una octava.	43
Fig. 3-13. Diagrama de bloques para el cálculo del cepstrum.	45
Fig. 3-14. Red perceptrón multicapa con una capa oculta.	47
Fig. 4-1. Arquitectura del sistema de medición	48
Fig. 4-2. Respuesta en frecuencia del micrófono MP20.	49
Fig. 4-3. Hoja de calibración del micrófono MP201.	49
Fig. 4-4. Ubicación del punto de medición, dirección y punto aproximado de despegue de las aeronaves en el AICM.	51

Fig. 4-5. Señal de ruido durante el despegue de un avión muestreada a 25 kHz.	52
Fig. 4-6. Espectrograma para aeronave 737-200 de la compañía Boeing.	52
Fig. 4-7. Modelos de aeronaves Airbus pertenecientes a la clase A320.	53
Fig. 4-8. Diagrama de bloques para la extracción de rasgos característicos.	55
Fig. 4-9. Algoritmo para detección del centro aplicado a la señal del 737-200.	56
Fig. 4-10. Ubicaciones del centro para las señales: (a) F100, (b) A318.	56
Fig. 4-11. Respuesta de frecuencia del filtro Butterworth pasa banda de segundo orden.	57
Fig. 4-12. Señal original de ruido durante el despegue y señal filtrada: (a) señal del MD87, (b) señal filtrada del MD87, (c) señal del F100, (d) señal filtrada del F100.	58
Fig. 4-13. Diezmado de la señal filtrada: (a) señal del 737-200, (b) señal diezmada del 737-200, (d) señal del A318, (d) señal diezmada del A318.	59
Fig. 4-14. Extracción de rasgos característicos mediante el análisis de octava para el A320.	61
Fig. 4-15. Banco de filtros triangulares espaciados logarítmicamente.	62
Fig. 4-16. Representación gráfica de la respuesta del análisis del banco de filtros triangulares, espectro de potencia de la señal del ruido.	63
Fig. 4-17. Coeficientes obtenidos mediante el banco de filtros triangulares.	63
Fig. 4-18. Rasgos característicos calculados mediante MFCC: (a) para la señal del ruido del MD87, MD88, (b) para la señal de ruido del ATR-42.	64
Fig. 5-1. Esquema que muestras las fases dentro de la etapa de reconocimiento.	66
Fig. 5-2. Gráfica de la función de activación log-sigmoide.	67
Fig. 5-3. Arquitectura de la red neural para la identificación usando el análisis de octava.	69
Fig. 5-4. Gráfica de entrenamiento para la red neural de la Fig. 5-3.	69
Fig. 5-5. Arquitectura de la red neural para la identificación usando el análisis MFCC.	70
Fig. 5-6. Gráfica de entrenamiento para la red neural de la Fig. 5-5.	70
Fig. 5-7. Esquema del módulo para la toma de decisión en el modelo de reconocimiento neuronal.	72
Fig. 6-1. Diagrama de bloques del modelo computacional para el reconocimiento.	74
Fig. 6-2. Modelo de reconocimiento neuronal empleando programación gráfica con LabVIEW®.	75
Fig. 6-3. Interfaz gráfica del modelo computacional para el reconocimiento de clases de aeronaves.	75
Fig. A.1-1. Señal de ruido registrado durante el despegue para la clase A320 1.	87

Fig. A.1-2. Patrón de 96 elementos mediante análisis 1/24 de Octava para la clase A320 1.	87
Fig. A.1-3. Patrón de 40 elementos a través del análisis MFCC para la clase A320 1.	87
Fig. A.2-1. Señal de ruido registrado durante el despegue para la clase A320 2.	88
Fig. A.2-2. Patrón de 96 elementos mediante análisis 1/24 de Octava para la clase A320 2.	88
Fig. A.2-3. Patrón de 40 elementos a través del análisis MFCC para la clase A320 2.	88
Fig. A.3-1. Señal de ruido registrado durante el despegue para la clase A320 3.	89
Fig. A.3-2. Patrón de 96 elementos mediante análisis 1/24 de Octava para la A320 3.	89
Fig. A.3-3. Patrón de 40 elementos a través del análisis MFCC para la clase A320 3.	89
Fig. A.4-1. Señal de ruido registrado durante el despegue para la clase A320_B737-800.	90
Fig. A.4-2. Patrón de 96 elementos usando análisis 1/24 Octava de la clase A320_B737-800.	90
Fig. A.4-3 Patrón de 40 elementos a través del análisis MFCC para la clase A320_B737-800.	90
Fig. A.5-1. Señal de ruido registrado durante el despegue para la clase ATR-42.	91
Fig. A.5-2. Patrón de 96 elementos mediante análisis 1/24 de Octava para la clase ATR-42.	91
Fig. A.5-3. Patrón de 40 elementos a través del análisis MFCC para la clase ATR-42.	91
Fig. A.6-1. Señal de ruido registrado durante el despegue para la clase B737-100/200.	92
Fig. A.6-2. Patrón de 96 elementos usando análisis 1/24 de Octava de la clase B737-100/200.	92
Fig. A.6-3. Patrón de 40 elementos a través del análisis MFCC para la clase B737-100/200.	92
Fig. A.7-1. Señal de ruido registrado durante el despegue para la clase B737-600/700.	993
Fig. A.7-2. Patrón de 96 elementos usando análisis 1/24 de Octava de la clase B737-600/700.	93
Fig. A.7-3. Patrón de 40 elementos a través del análisis MFCC para la clase B737-600/700.	93
Fig. A.8-1. Señal de ruido registrado durante el despegue para la clase B747-400.	94
Fig. A.8-2. Patrón de 96 elementos mediante análisis 1/24 de Octava para la clase B747-400.	94
Fig. A.8-3. Patrón de 40 elementos a través del análisis MFCC para la clase B747-400.	94
Fig. A.9-1. Señal de ruido registrado durante el despegue para la clase F100.	95
Fig. A.9-2. Patrón de 96 elementos mediante análisis 1/24 de Octava para la clase F100.	95
Fig. A.9-3. Patrón de 40 elementos a través del análisis MFCC para la clase F100.	95
Fig. A.10-1. Señal de ruido registrado durante el despegue para la clase F100 2.	96
Fig. A.10-2. Patrón de 96 elementos mediante análisis 1/24 de Octava para la clase F100 2.	96
Fig. A.10-3. Patrón de 40 elementos a través del análisis MFCC para la clase F100 2.	96
Fig. A.11-1. Señal de ruido registrado durante el despegue para la clase F100_B737-200.	97
Fig. A.11-2. Patrón de 96 elementos usando análisis 1/24 Octava de la clase F100_B737-200.	97
Fig. A.11-3. Patrón de 40 elementos usando el análisis MFCC para la clase F100_B737-200.	97

Fig. A.12-1. Señal de ruido registrado durante el despegue para la clase F100_B737-200 2.	98
Fig. A.12-2 Patrón de 96 elementos usando análisis 1/24 Octava a la clase F100_B737-200 2.	98
Fig. A.12-3. Patrón de 40 elementos usando el análisis MFCC de la clase F100_B737-200 2.	98
Fig. A.13-1. Señal de ruido registrado durante el despegue para la clase MD.	99
Fig. A.13-2. Patrón de 96 elementos mediante el análisis 1/24 de Octava para la clase MD.	99
Fig. A.13-3. Patrón de 40 elementos a través del análisis MFCC para la clase MD.	99
Fig. C.1. Diagrama Entidad-Relación de la base de datos en el modelo computacional.	101

ÍNDICE DE TABLAS

Tabla 3.1. Correspondencia entre presión sonora y niveles de presión sonora.	22
Tabla 4.1. Características del micrófono MP201.	49
Tabla 4.2. Clases de aviones y cantidad de muestras del ruido de aeronaves.	53
Tabla 4.3. Comparativa de técnicas de procesamiento de voz en la identificación de clases de aeronaves.	54
Tabla 5.1. Clases de aviones y conjuntos de patrones para entrenamiento/validación/prueba.	68
Tabla 5.2. Valores propuestos en los pesos para el módulo de toma de decisión.	72
Tabla 6.1. Resultado de reconocimiento para la red neuronal que emplea rasgos de octava.	77
Tabla 6.2. Resultado de reconocimiento para la red neuronal que emplea rasgos MFCC.	78
Tabla 6.3. Resultado de reconocimiento para el modelo computacional y comparación con el existente.	79
Tabla B.1. Efecto al ser humano, frecuencias, nivel de presión sonora y tiempo de exposición asociados a cada efecto potencialmente nocivo.	100

GLOSARIO

<i>ACI</i>	Airports Council International. El Consejo Internacional de Aeropuertos promueve estándares para la administración y operación de aeropuertos.
<i>AICM</i>	Aeropuerto internacional de la ciudad de México.
<i>CNEL</i>	Community Noise Equivalent Level. Es un indicador de presión sonora similar a Leq con la diferencia de que compensa la molestia ocurrida por las noches. Los eventos ocurridos entre las 7:00 p.m. y las 10 p.m. se compensan agregando 4.77 dB a cada uno, y los eventos ocurridos entre las 10 p.m. y las 7 a.m. se compensan con 10 dB.
<i>Curvas de ruidosidad</i>	Fueron creadas para evaluar el ruido de aviones por observadores en tierra, las curvas de ruidosidad están relacionadas con el indicador PNL.
<i>Curvas de sonoridad</i>	Indican el nivel de sonoridad y reflejan contornos de igual sonoridad.
<i>Decibelio (dB)</i>	Es una unidad logarítmica que relaciona la magnitud de interés y una magnitud de referencia, utilizada en acústica como la unidad para indicar el nivel de intensidad del sonido.
<i>DNL</i>	Day/Night Level. Es un indicador de presión sonora similar a Leq con la diferencia de que compensa la molestia ocurrida por las noches. Los eventos ocurridos entre las 10 p.m. y las 7 a.m. se compensan con 10 dB.
<i>EMU</i>	Environmental Monitoring Unit. Unidad de monitoreo ambiental, es un dispositivo que cuentan con: un micrófono, una unidad de almacenamiento y un modem para transmitir datos a la central.
<i>EPNL</i>	Effective Perceived Noise Level. Es el nivel en dB de la integral del antilogaritmo de la décima parte del tono corregido del PNL durante el paso de un avión con una duración de 10 s.
<i>Espectrograma</i>	Es una representación visual de las variaciones de la frecuencia en el eje vertical, y de la intensidad mediante los niveles de colores o grises, a lo largo del tiempo que se representa en el eje horizontal.

<i>FAA</i>	Federal Aviation Administration. La Administración Federal de Aviación es la entidad gubernamental responsable de la regulación de todos los aspectos de la aviación civil en los Estados Unidos.
<i>FDPS</i>	Flight Data Processing System. El Sistema de procesamiento de datos de vuelo gestiona los datos relacionados con el plan de vuelo y la distribuye a los sistemas de visualización, disponible a los controladores de vuelo.
<i>FFT</i>	Fast Fourier Transform. Algoritmo que permite calcular la transformada de Fourier discreta.
<i>Fonos</i>	Unidad del nivel de sonoridad.
<i>GPS</i>	Global Positioning System. Es un sistema global de navegación por satélite que permite determinar en todo el mundo la posición de un objeto, persona o vehículo.
<i>ICAO</i>	International Civil Aviation Organization. La Organización de Aviación Civil Internacional es una agencia que promueve reglamentos y normas en la aeronáutica civil internacional.
<i>Leq</i>	Equivalent Sound Level. Es el nivel de energía sonora que tendría un ruido constante en el mismo periodo que el ruido medido.
<i>Lmax</i>	Es el nivel sonoro más alto que se registra durante un periodo de tiempo.
<i>Lmin</i>	Es el menor nivel que se registra durante un periodo de tiempo.
<i>Lp</i>	Nivel de presión sonora que se registra en un instante de medición. También conocido como SPL (Sound Pressure Level).
<i>MFCC</i>	Mel-frequency cepstral coefficients. Los coeficientes cepstrales en las frecuencias de Mel son coeficientes para la representación del habla basados en la percepción auditiva humana.
<i>Octava</i>	Es el intervalo que separa dos sonidos cuyas frecuencias fundamentales tienen una relación de dos a uno.
<i>Pascal (Pa)</i>	Es la unidad de presión del sistema internacional de unidades.
<i>Percentiles</i>	Es el nivel sonoro que es superado un determinado porcentaje de tiempo.

<i>PNL</i>	Perceived Noise Level (PNL). Es un indicador de nivel de presión sonora con frecuencias ponderadas que combina 24 bandas en tercio de octava que van de los 50 Hz. a los 10 KHz, expresada en dB.
<i>RADAR</i>	RAdio Detection And Ranging. Es un sistema que usa ondas electromagnéticas para medir distancias, altitudes, direcciones y velocidades de objetos como aeronaves, vehículos, etc.
<i>SEL</i>	Sound Exposure Level (SEL). Es el nivel sonoro que, si se mantiene constante durante 1 segundo, tendría la misma energía que el evento sonoro medido.
<i>Sonómetro</i>	Es el dispositivo que sirve para medir los niveles de sonido. Es un equipo que permite cuantificar el nivel de presión sonora.
<i>Sonoridad</i>	Es el nivel sonoro subjetivo del sonido. Es la percepción que se tiene de la intensidad sonora. La sonoridad depende de la intensidad sonora, de la frecuencia y la duración del sonido.
<i>Umbral auditivo</i>	Es un valor de referencia y corresponde a 20 μ Pa.
<i>Umbral de dolor</i>	Es un valor de referencia y corresponde a 100 Pa.

Capítulo 1. Introducción

1.1 Antecedentes

El ruido ha sido un problema ambiental muy importante para el ser humano, por los efectos dañinos que puede causar en él. Sin embargo los problemas causados por el ruido en el pasado no son comparables con los que se tienen en la actualidad.

En nuestros días un gran número de autos y transportes de carga cruzan regularmente nuestras ciudades día y noche; sin embargo, los que añaden una gran cantidad de ruido al ambiente son el transporte aéreo y ferroviario. Siendo en la actualidad el transporte aéreo el principal factor.

En comparación con otros contaminantes ambientales, el control de ruido en el ambiente ha sido obstaculizado por el insuficiente conocimiento de sus efectos en los humanos, así como la falta de criterios definidos internacionalmente. Los efectos del ruido son amplios y las consecuencias a largo plazo para la salud.

En esta perspectiva, las acciones prácticas para analizar y controlar la exposición al ruido ambiental son esenciales, ya que el crecimiento de la contaminación acústica implica efectos adversos para la salud humana, tanto directos y también efectos acumulativos.

Este tipo de ambientes ruidosos ya no solo se encuentra en países desarrollados, actualmente también los países en desarrollo presentan este tipo de problemas, debido a la mala planificación y construcción de edificios, aeropuertos y conjuntos habitacionales. Estudios muestran que más del 30% de la población en la comunidad europea está expuesta durante la noche a niveles de presión acústica superiores a 55 dB, ocasionando perturbación del sueño.

Este tipo de escenarios se encuentran en la ciudad de México (ver Fig. 1-1), un ejemplo de ello está en los alrededores del aeropuerto internacional de la ciudad de México, debido a la planeación de construcción, desarrollo y ampliación se encuentra rodeado por zonas de viviendas.



Fig. 1-1. Vista actual del Aeropuerto Internacional de la Ciudad de México.

1.2 Formulación de los problemas

- Los sistemas comerciales actuales de monitoreo de ruido en aeropuertos no proporcionan la clase o tipo de aeronave que produce el ruido durante el despegue.
- Trabajos de investigación reportados, solo proporcionan la identificación de la presencia de una aeronave ante otras fuentes de ruido.

- En el estado del arte consultado existe un método de clasificación de aeronaves y estimación del impacto acústico, con un porcentaje de reconocimiento del 80% sin segmentación de la serie de tiempo (Sánchez-Fernández et al., 2012).

1.3 Hipótesis

Considerando los rasgos característicos extraídos mediante técnicas de procesamiento de voz basadas en la percepción del sonido, se puede implementar un modelo computacional que permita incrementar la eficiencia de reconocimiento de aeronaves durante el despegue en sistemas de monitoreo de ruidos ambientales.

1.4 Objetivos

1.4.1 Objetivo general

- Desarrollar un modelo computacional para el reconocimiento de clases de aeronaves mediante el patrón acústico producido durante el despegue mediante técnicas de procesamiento de voz.

1.4.2 Objetivos específicos

- Extraer rasgos característicos mediante la aplicación de técnicas de procesamiento de voz.
- Comparar la eficiencia de reconocimiento para cada una de las técnicas de extracción de rasgos característicos.
- Implementar el modelo computacional basado en redes neuronales perceptrón multicapa (MLP) para el reconocimiento de aeronaves.
- Realizar pruebas al modelo de reconocimiento.

1.5 Alcance

En este trabajo de investigación se presenta un modelo computacional capaz de realizar el reconocimiento de clases de aeronaves mediante el patrón acústico producido durante el despegue. Para el desarrollo del modelo se hace uso de técnicas de procesamiento de voz utilizadas ampliamente y que demuestran un mejor porcentaje en la eficiencia de reconocimiento del habla.

1.6 Contribuciones

Un modelo computacional capaz de realizar la identificación de la clases de aeronaves mediante señales registradas durante el despegue, y así permitir su uso en sistemas de monitoreo de ruidos ambientales.

El procesamiento de las señales está basado en el análisis de octava y la técnica de procesamiento de voz en escala de MEL el cual basa su análisis en la percepción del sonido.

1.7 Método de investigación y desarrollo utilizado

El desarrollo del presente trabajo se realizó con la metodología siguiente:

- Se realizó la búsqueda de trabajos de investigación que abordan la problemática del reconocimiento de aeronaves, así también, de sistemas de monitorio de ruido ambiental en aeropuertos.
- Se identificaron los métodos y/o técnicas empleados en estos trabajos, así como el de correcta identificación de aeronaves.

- Se recopiló la base de datos con señales de ruido generado por aeronaves durante el despegue. Esta adquisición de ruido de aeronaves se realizó en un trabajo previo de investigación, basado en aeronaves de las aerolíneas que realizan operaciones en el AICM y organizados con base en el modelo y tipo de motor instalado.
- Se realizó la extracción de patrones característicos con base en su análisis espectral, haciendo uso de técnicas de procesamiento de voz y análisis de octava.
- Se empleó un modelo de inteligencia artificial basado en redes neuronales artificiales para realizar pruebas de reconocimiento empleando los patrones extraídos, y así identificar cuál de estos proporcionaba mejor información.
- Se realizaron pruebas con distintas topologías de redes neuronales artificiales, interactuando con la cantidad de neuronas de entrada, así como la cantidad de neuronas en la capa oculta, para identificar la más adecuada para las técnicas de extracción de patrones seleccionados.
- Se implementó el modelo computacional basado en redes neuronales artificiales con las dos técnicas de extracción de rasgos característicos y un módulo de decisión a sus salidas, se realizaron las pruebas para comprobar su correcto funcionamiento.

1.8 Estructura de la tesis

El presente trabajo se encuentra estructurado de 7 capítulos.

El Capítulo 1, contiene la presente introducción.

El Capítulo 2, hace una revisión del estado del arte actual de las técnicas y modelos computacionales empleados en el reconocimiento de aeronaves.

El Capítulo 3, presenta los sistemas de monitoreo actuales para la medición de ruido de aeronaves en aeropuertos. Describe también el fundamento teórico utilizado en modelos de

reconocimiento de aeronaves, técnicas de procesamiento de voz y redes neuronales artificiales.

El Capítulo 4, describe la obtención de patrones y presenta una comparativa de las técnicas de procesamiento de voz empleadas en el reconocimiento de aeronaves haciendo uso de redes neuronales artificiales.

El Capítulo 5, presenta la arquitectura del modelo de reconocimiento neuronal y la descripción de cada uno de los módulos funcionales.

El capítulo 6, presenta los resultados obtenidos durante las pruebas del modelo computacional para el reconocimiento de aeronaves.

El Capítulo 7, presenta las conclusiones y trabajos futuros.

Capítulo 2. Estado del arte

En este capítulo se hace la revisión de los aspectos más relevantes de la gestión, control y monitoreo del ruido. Se inicia con la descripción de la contaminación acústica y prioridades sugeridas para la gestión del ruido. Posteriormente se presentan las iniciativas más relevantes para la evaluación, gestión y legislación del ruido de las principales regiones del mundo. Se describe la evolución del transporte aéreo para presentar los sistemas de monitoreo del ruido ambiental utilizados en aeropuertos. Finalmente, se hace la revisión de los trabajos relacionados con la identificación de aeronaves.

2.1 Contaminación acústica

La contaminación acústica se ha convertido en una de las razones más importantes de preocupación en relación con el medio ambiente y nuestras vidas, parece una consecuencia lamentable pero inevitable de la tecnología actual. La tendencia hacia el uso de equipos más automatizados, equipo de sonido de alta potencia, maquinaria de construcción más grande, el creciente número de vehículos terrestres y aeronaves ha creado una aceptación gradual del ruido como un subproducto natural del progreso. De hecho, antes de 1972 la única actividad importante en la legislación federal de control de ruido era una enmienda de 1968 a la Ley de Aviación Federal, por lo que la FAA fue destinada a regular el ruido de aeronaves civiles durante los aterrizajes y despegues, incluyendo explosiones sónicas.

Diversos estudios de monitoreo del ruido e informes sociológicos en los últimos años han señalado la necesidad de la reducción del ruido. La contaminación acústica es, pues, otro contaminante ambiental que debe ser reconocido oficialmente como una verdadera amenaza para la salud humana y la calidad de vida. La idea fundamental que hemos adquirido es que el ruido puede ser considerado definitivamente como un contaminante de la atmósfera tanto como una partícula o un gas contaminante.

Hay evidencia de que el ruido puede poner en peligro la eficiencia, afectar negativamente a la salud, y aumentar las tasas de accidentes (Hansell et al., 2013). A niveles suficientemente altos, el ruido puede dañar de inmediato la audición, e incluso en los niveles inferiores puede haber un deterioro progresivo de la audición (Chambers, 2005).

2.2 Establecimiento de prioridades en la gestión del ruido

Las prioridades en la gestión del ruido varían entre los países, de acuerdo con los objetivos de su política, necesidades y capacidades. El establecimiento de prioridades en la gestión del ruido se refiere a dar prioridad a los riesgos de salud y en la concentración de las fuentes más importantes de ruido. Para la gestión eficaz del ruido, los objetivos, las políticas y los sistemas de control de ruido tienen que ser definidos. Los objetivos para la gestión del ruido incluyen la eliminación o la reducción del ruido a niveles aceptables, y evitar los efectos nocivos del ruido a la salud humana, en el anexo B se describen a detalle estos efectos. Las políticas para la gestión del ruido abarcan leyes y reglamentos para el establecimiento de normas de ruido y para asegurar su cumplimiento. La cantidad de información que debe incluirse en la implementación de planes de bajo nivel de ruido y en el uso de comparaciones de costo-beneficio también entra dentro del ámbito de las políticas de gestión del ruido. Las técnicas para el control del ruido incluyen control de la fuente, los obstáculos en las vías de ruido y protección auricular. Modelos adecuados en el cálculo para la propagación del ruido, así como los sistemas de monitoreo de ruido, son parte de un plan general de control de ruido.

2.3 Iniciativas para evaluación, gestión y legislación del ruido.

El gobierno de cada país tiene la responsabilidad de establecer las políticas y la legislación para el control de ruido de la comunidad. Existe una relación directa entre el nivel de desarrollo de un país y el grado de contaminación acústica que afecta a su población. Conforme se desarrolla la sociedad, aumenta su nivel de urbanización e industrialización, y

se extiende su sistema de transporte. Cada uno de estos desarrollos trae un aumento en la carga de ruido. Sin una intervención adecuada el impacto del ruido en las comunidades se intensificará (ver Fig. 2-1). Si los gobiernos aplican políticas y regulaciones de ruido débiles, no serán capaces de evitar un aumento continuo de la contaminación acústica y los efectos nocivos asociados a la salud. También el incumplimiento de regulaciones estrictas es ineficaz en la lucha contra el ruido.

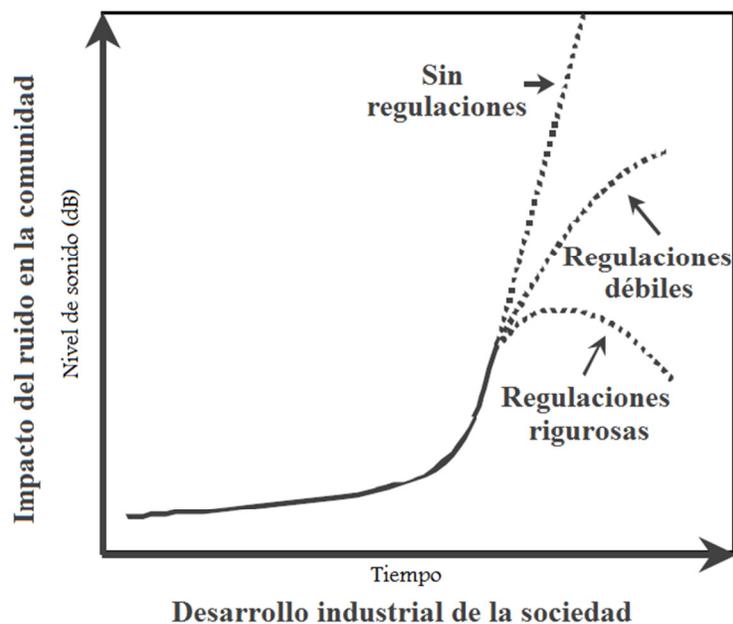


Fig. 2-1. Dependencia entre las regulaciones y el impacto del ruido con respecto al desarrollo industrial (Hede, 1998).

Las normas regulatorias pueden basarse únicamente en los datos científicos y técnicos que muestran los efectos nocivos del ruido en la salud pública. Sin embargo, otros aspectos se consideran normalmente, ya sea al establecer normas o en el diseño de las medidas apropiadas para la reducción del ruido. Estos aspectos incluyen la viabilidad tecnológica, los costos de cumplimiento, los niveles de exposición predominantes, y las condiciones sociales, económicas y culturales (Gottlob, 1995).

Con el fin de gestionar y reducir la contaminación acústica y sus efectos nocivos, algunas iniciativas legislativas se han llevado a cabo alrededor del mundo, entre ellas:

- *Normas ICAO*: En 2001, la 33^a Asamblea de la ICAO aprobó la Resolución A33/7 (ICAO, 2007), la cual respaldó el concepto de un "enfoque equilibrado" para la gestión del ruido de las aeronaves, mediante la identificación del problema del ruido en un aeropuerto y luego analizar las diversas medidas disponibles para reducir el ruido a través de la exploración de los elementos principales, como son: La reducción de la fuente (aeronaves más silenciosas), planificación y gestión del uso del suelo, procedimientos operativos de reducción del ruido y restricciones operativas. La ICAO ha elaborado políticas en cada uno de estos elementos, así como sobre las cargas del ruido.
- *Políticas de la ACI*: El consejo internacional de Aeropuertos (ACI del inglés Airports Council International) en la sección 6.1 de su manual de políticas y prácticas recomendadas (AIC, 2008) describe una serie de políticas relacionadas con el ruido en los aeropuertos y contiene una discusión sobre las mejores prácticas mundiales en lo que respecta a la aplicación de cada política.

Las políticas más relevantes de la ACI relacionadas con el ruido son: Minimizar o mitigar los efectos nocivos de ruido, la planificación del uso del suelo para minimizar el impacto, el aislamiento acústico como parte de la solución para residencias y edificios, el monitoreo del ruido en los aeropuertos e indicadores del ruido como un instrumento de información.

- *Directivas Europeas 2002/30/CE y 2002/49/CE*: La directiva 2002/30 establece las reglas y procedimientos acerca de la implantación de restricciones operativas relacionadas con el ruido, específicamente: establecer normas para facilitar el establecimiento de restricciones operativas de manera consistente en los aeropuertos con el fin de limitar o reducir el número de personas que padecen los efectos

nocivos del ruido, promover el desarrollo de la capacidad aeroportuaria en armonía con el medio ambiente, facilitar el logro de los objetivos específicos de reducción del ruido a nivel de cada aeropuerto y proporcionar una estructura que satisfaga los requisitos del mercado interno.

A un nivel más amplio (porque se aplica no sólo a los aeropuertos, sino también a los ferrocarriles, carreteras y grandes ciudades), la directiva 2002/49 (European Parliament, 2002) establece indicadores acordados para el ruido ambiental y promueve que los países desarrollen y publiquen mapas estratégicos de ruido y planes de acción para los principales aeropuertos, es decir, los aeropuertos con más de 50,000 movimientos de aviones por año.

- *Ley de 1990 en los EE.UU.*: Dos importantes disposiciones de la ley (comúnmente conocida como la política nacional de ruido) fueron el establecimiento de una política de ruido de la aviación nacional (secciones 9308 y 9309) y la creación de un cargo de servicio de pasajeros (secciones 9110 y 9111), que permite a los patrocinadores del aeropuerto imponer tarifas sobre los boletos emitidos a los pasajeros elegibles. Se estableció un umbral de 65 dB DNL (Day-Night average sound level) en los EE.UU., que establece que las personas que viven en zonas con este nivel de ruido o superior tienen derecho a un apoyo, por lo general en forma de compra de la propiedad o subsidios para cubrir los trabajos de construcción y aislamiento.

2.4 Legislaciones para el control de la emisión de ruido en la Ciudad de México.

Las condiciones actuales de urbanización en la Ciudad de México exponen a millones de personas a niveles de ruido capaces de ocasionar efectos nocivos a su salud como: hipertensión arterial (McNamee et al., 2006), impactos cardiovasculares (Hansell et al., 2013) y pérdida paulatina de capacidad auditiva (Berglund et al., 1999), entre otros.

Expertos en acústica y en el cuidado de la audición, coinciden en que la Ciudad de México se ubica entre las cinco ciudades más ruidosas de América Latina, debido al exceso de sonido ocasionado por la actividad humana, la industria, el tráfico vehicular y aéreo, entre otras fuentes. Unas de las primeras legislaciones para el control de la emisión de ruido es la norma oficial mexicana *NOM-081-SEMARNAT-1994*, la cual establece los límites máximos permisibles de emisión de ruido que genera el funcionamiento de las fuentes fijas y el método de medición. Esta se aplica a pequeñas, medianas y grandes industrias, comercios establecidos, servicios públicos o privados y actividades en la vía pública.

Con el incremento del tráfico aéreo en el espacio mexicano, en el año 2001 se emitió la norma *NOM-036-SCT3-2000*, que establece dentro de la república mexicana los límites máximos permisibles de emisión de ruido producido por las aeronaves de reacción subsónicas, propulsadas por hélice, supersónicas y helicópteros, su método de medición, así como los requerimientos para dar cumplimiento a dichos límites. Finalmente, la Secretaría del Medio Ambiente del Gobierno del Distrito Federal estableció desde el año 2006 mediante la norma oficial *NADF-005-AMBT-2006*, las condiciones de medición y los límites máximos permisibles de emisiones sonoras, que deberán cumplir los responsables de fuentes emisoras ubicadas en la Ciudad de México.

2.5 Evolución del transporte aéreo

El transporte aéreo es uno de los servicios más importantes del mundo, que contribuye en gran medida al progreso de la sociedad moderna. El uso de la aviación comercial ha crecido más de siete veces desde en el primer vuelo de avión de pasajeros en 1949, y su crecimiento es incomparable con cualquier otra forma de transporte. Las aeronaves modernas han transformado los viajes de lujo internacionales para unos pocos, en una opción accesible para la mayoría de nosotros. Hoy en día, el negocio del transporte aéreo es global, en el que participan diferentes áreas, como los fabricantes de aeronaves, fabricantes de motores, proveedores de componentes de aeronaves, aeropuertos, la industria de servicios de tierra,

proveedores de combustible, autoridades locales, regionales e internacionales, organizaciones y organismos reguladores, etc. Convirtiéndose en una fuerza económica y una fuente de gran riqueza (Prats i Menéndez, 2011).

El transporte aéreo tiene un impacto local y global en el medio ambiente. Las emisiones de las aeronaves representan aproximadamente el 4% de las emisiones atmosféricas (hechas por el hombre) del mundo, de acuerdo con el Grupo Intergubernamental sobre el Cambio Climático (IPCC, 1999). Estas emisiones impactan de manera significativa el cambio climático (el efecto invernadero) y niveles en la calidad del aire. Otra cuestión ambiental importante es el ruido de los aviones.

Como es bien sabido, el ruido nos perturba o molesta. En particular, la presencia de ruido ambiental interfiere con las actividades que realizamos, tales como la comunicación, escuchar música, relajarse, dormir, leer, trabajar, estudiar, etc. Las quejas sobre la exposición al ruido es una de las que con más frecuencia se reportan por las poblaciones que viven en las grandes ciudades (Martin-Houssart et al., 2002). Por ejemplo, de acuerdo con (Roy, 2003), en el año 2001, el 51% de los ciudadanos franceses reconocen haber sido perturbados por el ruido ambiental. En este contexto, el ruido es la molestia más importante que se reporta por las personas que viven en grandes ciudades como París. Dentro de este 51% de personas que sufren molestias debido al ruido, el 66% reporta el tráfico carretero como la principal fuente de molestia, mientras que el tráfico aéreo representa sólo el 17%. El ruido por tráfico carretero se vuelve aún más importante si se consideran sólo las grandes ciudades, pero el ruido por las aeronaves se vuelve cada vez más importante. De acuerdo con la Oficina Parlamentaria de Ciencia y Tecnología (UK-Parliament, 2003), el ruido de las aeronaves tiene el potencial de afectar la calidad de vida de por lo menos medio millón de personas que viven cerca de los aeropuertos del Reino Unido. El 80% de estas personas viven cerca de los principales aeropuertos del sureste de Inglaterra. Además, la Oficina de Contabilidad General de los Estados Unidos (GAO, 2000) ha reportado el ruido como el mayor problema ambiental de 29 de los 50 aeropuertos con más tráfico de Estados Unidos.

El ruido de las aeronaves es un sonido no deseado en las proximidades de los aeropuertos que perturba las actividades diarias y la paz de la población que habita estas áreas, y es reconocido como un importante obstáculo para la expansión de las operaciones aeroportuarias. Si bien se ha avanzado en la reducción de ruido de las aeronaves, nuevas reducciones se vuelven más difíciles de lograr. El problema se hace más difícil por el aumento del ruido debido al crecimiento de las operaciones de las aeronaves. En este contexto, la previsión de vuelos en el Eurocontrol Statistical Reference Area (ESRA) para el 2030 es de entre 1,7 y 2,9 veces el tráfico de 2007 (Eurocontrol, 2008). Por lo tanto, se espera un crecimiento promedio de 2,3% a 3,5% por año. También se espera que la demanda en aviación general y de negocios aumenten en el largo plazo, a un promedio de 1,8% al año hasta el 2025 (FAA, 2009). Por otra parte, los fabricantes de aeronaves son un poco más optimistas y prevén cifras más grandes. Airbus, por ejemplo, prevé un aumento de tres veces en el tráfico aéreo de todo el mundo para el año 2025 (Airbus, 2007), mientras que Boeing pronostica un crecimiento promedio de 4,8% anual del tráfico aéreo en los próximos 20 años. Ambos fabricantes de aviones también estiman que la frecuencia de vuelos entre destinos será más del doble durante el próximo período de 20 años.

2.6 Sistemas de monitoreo del ruido

En relación a las infraestructuras de transporte, los sistemas de monitoreo de ruido son muy importantes para las etapas de planificación y gestión del ruido, los cuales pueden fijar indicadores utilizados en la implementación de nuevas normas sobre el control del ruido. Las unidades de supervisión y monitoreo del ruido, especialmente aquellos integrados en los sistemas de vigilancia de aeropuertos, deben ser capaces de medir los niveles de ruido para la creación de históricos, identificando sucesos del ruido y clasificar los eventos producidos por las aeronaves.

Un sistema de monitoreo cuenta con por lo menos 5 EMU (Environmental Monitoring Unit), existen sistemas con hasta 25 EMU y una unidad central de procesamiento, normalmente se requiere la entrada de información del sistema de RADAR, FDPS (Flight Data Processing System), GPS (Global Position System), esto para correlacionar los datos. Adicionalmente, algunas de estas unidades son capaces de distinguir automáticamente el tipo de ruido detectado, es decir, si es un avión de turbinas, de hélices, un helicóptero o simplemente es ruido de fondo como es el caso del EMU 2100 de Lochard. Uno de los principales sistemas de monitoreo utilizado en algunos de principales aeropuertos del mundo es el ANOMS de la compañía Brüel & Kjær, la Fig. 2-2 muestra el esquema del sistema (Brüel & Kjær, 2012).

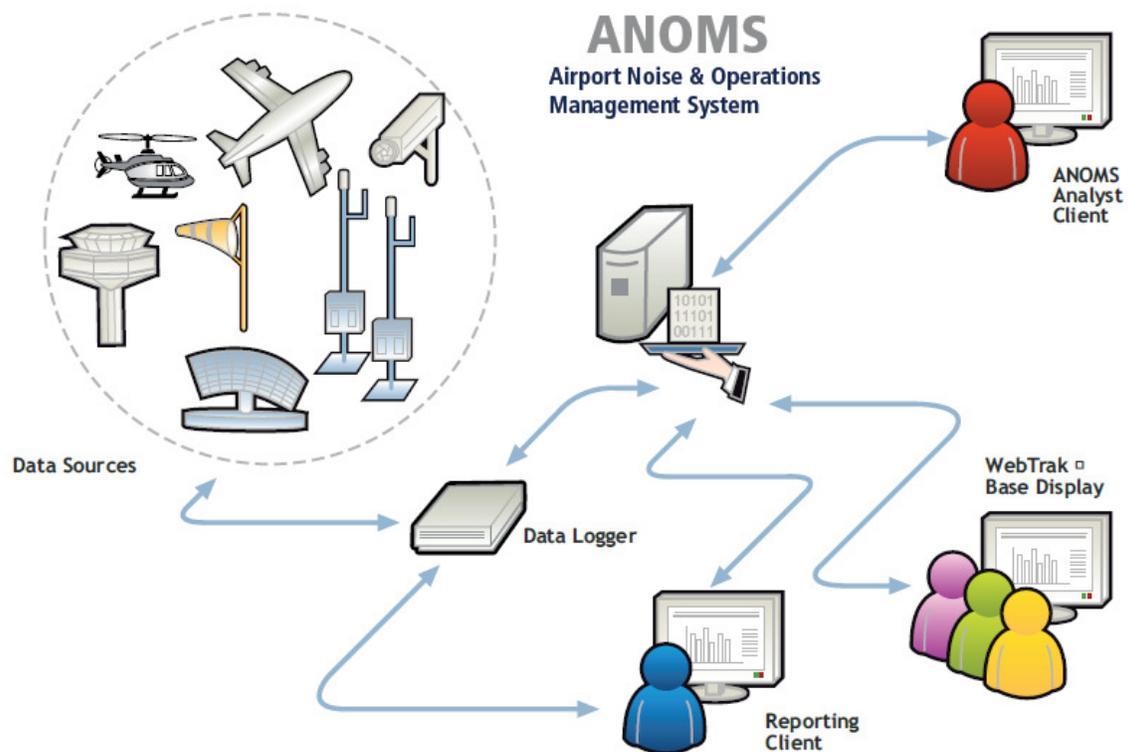


Fig. 2-2. Topología de un sistema de monitoreo ANOMS (cortesía Brüel & Kjær).

La tarea de clasificación, en relación a la fuente de sonido del evento de ruido, es un punto débil de las unidades de monitoreo. Una unidad de control sencilla detecta eventos de ruido utilizando umbrales aplicados a series de datos del ruido en el tiempo (ver Fig. 2-3).

Cuando el nivel de ruido alcanza un valor por encima del umbral durante más de una duración establecida, se detecta un evento de ruido (Barbo et al., 2009).

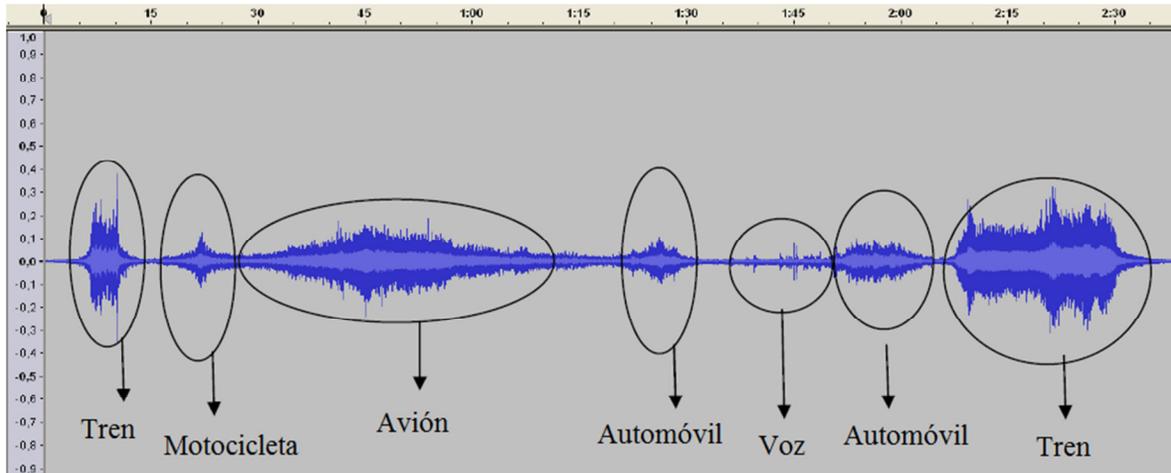


Fig. 2-3. Nivel de ruido vs tiempo. La señal de audio de diversos ruidos.

La clasificación de estos eventos en la mayoría de los sistemas de monitoreo de los aeropuertos internacionales se lleva a cabo utilizando pistas del radar de los vuelos realizados. Si el evento de ruido se detecta cuando una aeronave se encuentra cerca del receptor, este evento será clasificado como producido por una aeronave y no se consideran otras características acústicas del sonido (Bekebrede et al., 1984).

Se han hecho algunas otras investigaciones para clasificar los eventos de ruido ambiental (Goldhor, 1993), aplicando métodos de reconocimiento de patrones y técnicas de reconocimiento de voz con el fin de clasificar los eventos sonoros ambientales. La mayoría de ellos aplican un enfoque de detección y clasificación utilizando redes neuronales, modelos ocultos de Markov (Couvreur et al., 2004) y han mostrado buenos resultados, pero el principal problema al que se han enfrentado es la detección en entornos ruidosos. Un trabajo reciente presenta un método en tiempo real para el seguimiento continuo de la semejanza de un audio de entrada y el ruido de una aeronave, así la unidad de monitoreo pueda ser capaz de marcar eventos de ruido generados por aeronaves (Asensio et al., 2010), mediante la extracción de coeficientes cepstrales en las frecuencias de Mel.

2.7 Reconocimiento de clases de aeronaves

En la actualidad los trabajos de investigación que se encuentran en el estado del arte relacionados con la identificación del ruido producido por aeronaves está dirigido a tener sistemas capaces no solo de presentar información relacionada con los indicadores de ruido sino sistemas de monitoreo con la habilidad de reconocer la clase de aeronave que realiza el evento de ruido, logrando proporcionar más información para un mejor análisis y gestión del ruido. Estos trabajos son realizados principalmente por el grupo de trabajo del Dr. Luis P. Sánchez Fernández y el Dr. Sergio Suárez Guerra, en el Centro de Investigación en Computación del IPN México.

La primera etapa en sus investigaciones fue hacer un análisis de las señales del ruido producido por las aeronaves durante el despegue (Sánchez F et al., 2007), y que les permitiera la creación de un método de reconocimiento que hiciera posible identificar tipos o clases de aeronaves por medio de sus patrones de ruido. Siendo estos de hélice, turborreactor y reacción. Este modelo combina un decimado espectral utilizando el método de Barlett-Welch (Oppenheim et al., 1989), un filtro media móvil y un decimado promedio del espectro para la extracción de rasgos característicos (ver Fig. 2-4), estos fueron utilizados para el entrenamiento de un modelo de reconocimiento neural artificial.

Posteriormente se presentó un trabajo de investigación basado en la extracción de rasgos característicos mediante LPC (Linear predictive coding) la cual es una técnica de procesamiento de voz que realiza su análisis en el dominio del tiempo, su objetivo principal es obtener una cantidad reducida de coeficientes y que representen de una manera suavizada la envolvente del espectro de densidad espectral de la señal en análisis (ver Fig. 2-5), adicionalmente se le agregó un análisis de 1/12 octava, el cual basa su análisis mediante un banco de filtros, estos bancos están definidos por una frecuencia inferior y otra superior y se eligen de forma que la superior sea el doble que la inferior.

Para el modelo de reconocimiento se utilizaron dos redes neuronales artificiales MLP (Multi-Layer Perceptron) en paralelo, este modelo alcanzó una eficiencia del 80% de reconocimiento trabajando con 13 clases (Rojo R et al., 2008).

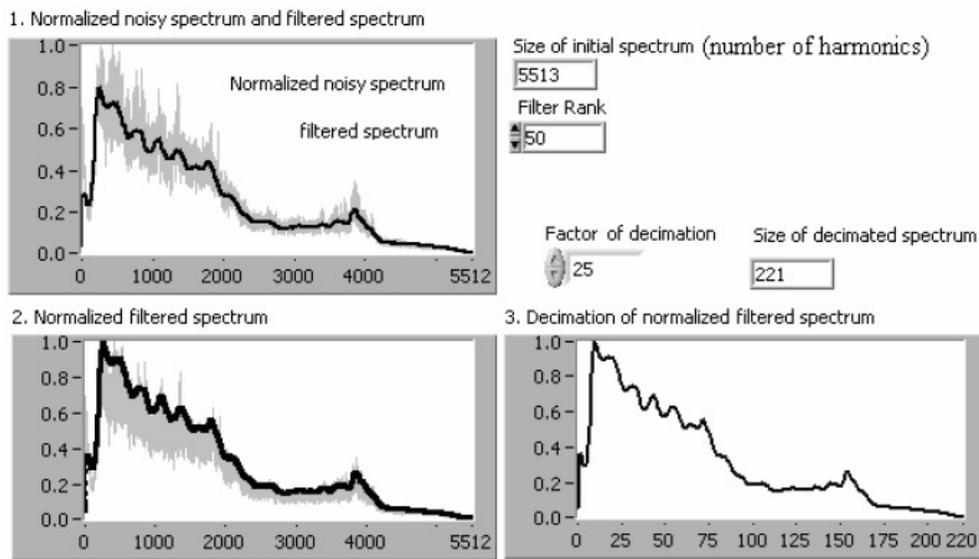


Fig. 2-4. Ejemplo de los rasgos (línea negra) del ruido de los aviones Falcon (turborreactor).

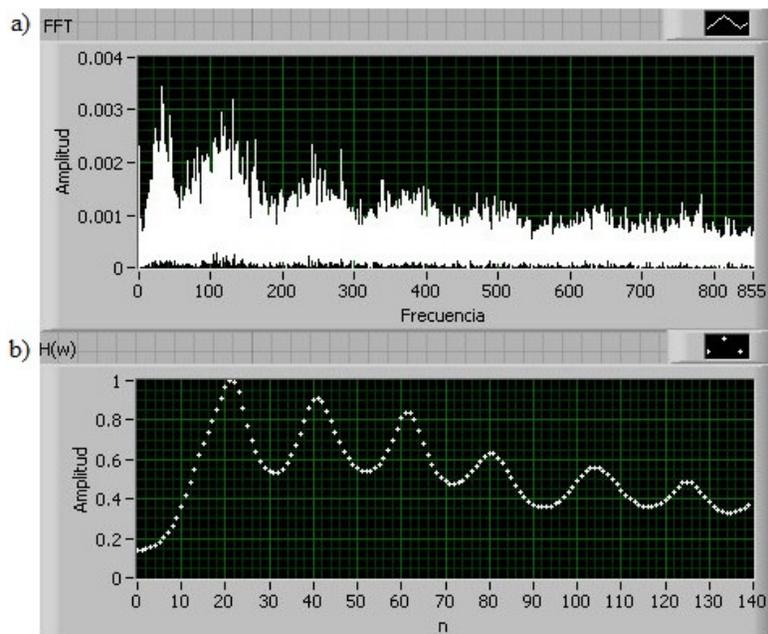


Fig. 2-5. Ejemplos de rasgos utilizando LPC para aeronave MD87. a) FFT, b) coeficientes.

Recientemente fue presentado un modelo computacional para identificar las clases de aeronaves el cual propone una segmentación en el tiempo de la señal del ruido generado durante el despegue. Se creó un método para segmentar la señal en cuatro fragmentos y se extrajeron rasgos característicos utilizando LPC (ver Fig. 2-6). Para el reconocimiento se combinaron las salidas de cuatro redes neuronales artificiales MLP, una para cada segmento. El desempeño de cada red se optimizó con un algoritmo de selección de características para mejorar la eficiencia y reducir el costo computacional. Este modelo alcanzó un nivel de reconocimiento del 85% trabajando con 13 clases (Sánchez-Pérez et al., 2013).

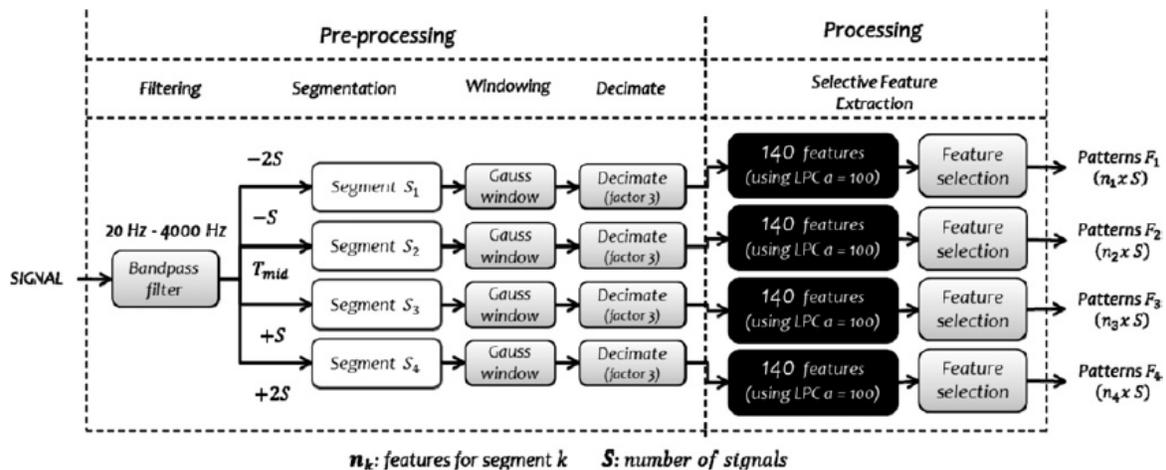


Fig. 2-6. Procedimiento para extracción y selección de rasgos con segmentación en el tiempo.

2.8 Conclusión del capítulo

En este capítulo se presentó el panorama actual relacionado con la gestión, control y monitoreo del ruido. Los problemas asociados al ruido deben ser considerados como un factor más de contaminación al ambiente, principalmente en áreas cercanas a los aeropuertos que es donde se registran niveles altos de ruido. Las organismos mundiales como la Organización Mundial de la Salud (WHO) y Unión Europea (EU) han emitido recomendaciones para el control, reducción y legislación del ruido, sin embargo, éstas no

son tan estrictas en aeropuertos localizados dentro de la mancha urbana. En México se emitió la norma NOM-036-SCT3-2000 con el propósito de establecer límites máximos permisibles de emisión de ruido producidos por las aeronaves, pero los organismos nacionales no reportan con claridad el estado actual de las emisiones de ruido al medioambiente.

Capítulo 3. Marco teórico

En este capítulo se presenta una breve introducción a los conceptos de acústica, tipos y fuentes de ruido, factores que afectan la propagación e indicadores del ruido, así como los instrumentos de medición utilizados. Posteriormente se describen algunos de las técnicas de procesamiento de voz utilizadas para la extracción de características. Finalmente, se presenta la teoría asociada al modelo de reconocimiento basado en redes neuronales artificiales.

3.1 Conceptos de acústica

El sonido puede ser definido como cualquier variación de presión que el oído humano pueda detectar. Los sonidos se pueden clasificar también por su respuesta subjetiva, así los más usuales como por el ejemplo el habla, pueden considerarse como sonidos, siempre que los niveles de presión sonora que producen no sean excesivos, ya que en este caso se tendrían que denominar ruidos, entendiéndose por tal, *todo sonido no deseado*. Por tanto, vemos que la diferencia entre sonido agradable y sonido molesto, depende tanto del nivel de presión sonora, como de la respuesta subjetiva. El grado de molestia de un ruido depende principalmente de su nivel de presión sonora, siendo la respuesta subjetiva dependiente de la naturaleza del sonido. En el aire, el sonido se propaga a una velocidad de 340 m/s aproximadamente. (Brüel & Kjær, 2000; Recuero, 1994).

Físicamente en este proceso ocurren pequeñas variaciones de la presión en el aire (u otro gas o fluido). A estas pequeñas variaciones de presión, que se combinan con la presión estática p_0 , se les denomina presión sonora p . Esta magnitud, dependiente del tiempo y del espacio, es la magnitud acústica más importante, dada por la ecuación (3.1). La radiación de la fuente produce un campo sonoro con una determinada distribución espacial, al que en cada instante de tiempo le corresponde una nueva presión instantánea (Möser, 2009).

$$L_p = 20 \log \left(\frac{p}{p_0} \right) \quad (3.1)$$

donde L es el nivel de presión sonora, p la presión sonora medida y $p_0 = 2 \times 10^{-5} \text{ N/m}^2$ presión sonora de referencia.

Como se puede ver en la tabla 3.1, mediante la asociación de niveles a distintos valores de presión incluidos en el intervalo de presión sonora, se obtiene una escala que va desde los 0 a los 140 dB. En la tabla se incluyen algunos ejemplos del orden de magnitud de los niveles de presión sonora para situaciones de ruido habituales.

Tabla 3.1. Correspondencia entre presión sonora y niveles de presión sonora.

Presión efectiva <i>N/m²</i>	Nivel de presión <i>dB</i>	Situación
2×10^{-5}	0	Mínimo perceptible
2×10^{-4}	20	Bosque con poco viento
2×10^{-3}	40	Biblioteca
2×10^{-2}	60	Oficina
2×10^{-1}	80	Calle con tránsito
2×10^0	100	Sirena, martillo neumático
2×10^1	120	Motor a reacción
2×10^2	140	Umbral del dolor

El número de variaciones de presión por segundo se llama frecuencia del sonido y se mide en hercios (Hz). La percepción auditiva normal de una persona joven saludable varía aproximadamente desde 20 Hz hasta 20000 Hz (20 kHz).

3.1.1 Tipos de ruido

Todo ruido se puede considerar como una señal deseada cuando se va a medir, aunque esto sólo sea momentáneamente (Recuero, 1994). Para que las medidas sean significativas, el nivel de ruido de fondo deberá ser al menos 10 dB inferior al nivel de la señal. La relación

entre el nivel de la señal y el nivel de ruido de fondo se llama relación señal / ruido. Algunos tipos de ruido son:

- *Ruido continuo constante*: Es aquel cuyo nivel de presión sonora no fluctúa a lo largo del tiempo. Por ejemplo una maquinaria operando sin interrupción.
- *Ruido continuo intermitente*: El nivel de presión sonora fluctúa pero un margen moderado a lo largo del tiempo. Por ejemplo el pasar de vehículos aislados.
- *Ruido impulsivo repetitivo*: Es aquel que presenta impulsos repetidos, por ejemplo los producidos por una prensa.
- *Ruido impulsivo simple*: Es el que se presenta impulsos aislados, por ejemplo un disparo.
- *Ruido de fondo*: Es el ruido circundante, asociado con un entorno dado siendo generalmente una composición de sonidos de muchas fuentes cercanas o lejanas.
- *Ruido de banda estrecha*: Es un ruido que se presenta en una región limitada del espectro.
- *Ruido de banda ancha*: Presenta un espectro continuo.
- *Ruido blanco*: Ruido en banda ancha con igual amplitud en cada frecuencia discreta.
- *Ruido rosa*: Ruido en banda ancha tal que su densidad espectral de potencia es proporcional al recíproco de su frecuencia. Su contenido de energía disminuye en 3dB por octava, haciendo que cada banda de frecuencias de igual anchura (en octavas) contenga la misma energía total.

3.1.2 Propagación del ruido

Los factores más importantes que afectan a la propagación del ruido son (Brüel & Kjær, 2000):

- *Tipo de fuente:*
 - *Puntual:* Si las dimensiones de una fuente de ruido son pequeñas comparadas con la distancia al oyente, entonces se llama fuente puntual, por ejemplo, ventiladores y chimeneas. La energía sonora se propaga de forma esférica, por lo que el nivel de presión del sonido es el mismo en todos los puntos que se encuentran a la misma distancia de la fuente.
 - *Lineal:* Si una fuente de ruido es estrecha en una dirección y larga en la otra comparada con la distancia al oyente, ésta es llamada fuente lineal. El nivel de sonido se propaga cilíndricamente, por lo que el nivel de presión sonora es el mismo en todos los puntos a la misma distancia de la línea, por ejemplo una sucesión de vehículos en una carretera concurrida.
 - *Estática:* La fuente se mantiene estática a lo largo del tiempo. Por ejemplo una fábrica.
 - *Móvil:* La fuente cambia de posición a lo largo del tiempo, por ejemplo, aeronaves, automóviles, etc.
- *Atenuación atmosférica:* La reducción de ruido al pasar a través del aire depende de muchos factores incluyendo, distancia desde la fuente, contenido frecuencial del ruido, temperatura ambiental, humedad relativa y presión ambiental.
- *Viento:* La velocidad del viento aumenta con la altitud, la cual desviará la trayectoria del sonido para “hacerla converger” en el lado situado a favor del viento y crear una “sombra” en el lado de la fuente que se encuentra en contra del viento.
- *Temperatura:* Los gradientes de temperatura crean efectos similares a los de los gradientes de viento, excepto en que los primeros son uniformes en todas direcciones a partir de la fuente.
- *Efecto Doppler:* Este efecto se produce cuando la fuente de ondas y el observador están en movimiento relativo con respecto al medio material en el cual la onda se propaga, la frecuencia de las ondas observadas es diferente de la frecuencia de las ondas emitidas por la fuente (Alt et al., 2004).

3.1.3 Fuentes de ruido

El grado de contaminación ambiental en las grandes ciudades debido al ruido tiene cada día más transcendencia, por lo que se trata de estudiar y conocer con profundidad las fuentes sonoras y sus características físicas para disminuir los niveles de ruido que generan. A continuación se enumeran algunas de las principales fuentes de ruido.

- *Ruido debido al tráfico rodado:* Es producido por vehículos en movimiento por medio de su motor, transmisión, neumático, (ver figura 3-1) etc. Las legislaciones que existen en varios países marcan niveles máximos que no deben superarse, que van desde los 80 dB a los 90 dB para automóviles y de 70 dB a 80 dB para motocicletas.



Fig. 3-1. Fuente de ruido por tráfico de vehículos.

- *Ruido por tráfico aéreo:* Las aeronaves son una fuente de potencia acústica muy importante, y las condiciones de propagación del ruido son muy favorables en espacios sin obstáculos, ver Fig. 3-2. En la fase de despegue es cuando los aviones producen más ruido, ya que la potencia requerida en este proceso es máxima.



Fig. 3-2. Fuente de ruido por tráfico aéreo.

- *Ruido debido a obras públicas:* Estas fuentes de ruido existen en la construcción, debido principalmente a la maquinaria pesada que se emplea, que produce diferentes tipos de ruido (ver Fig. 3-3).



Fig. 3-3. Ruido producido por maquinaria en obras públicas.

- *Ruido debido a actividades industriales:* Son los producidos por la industria en general, cuyo nivel y espectro sonoro puede ser muy variado, ya que depende del proceso industrial en sí, un ejemplo se puede observar en la Fig. 3-4.



Fig. 3-4. Ruido generado por actividades industriales.

- *Ruido debido a actividades urbanas comunitarias*: Estos ruidos se deben a que en algunas zonas de una ciudad existen en determinados intervalos de tiempo concentraciones de personas que producen ruidos de tipo intermitente con variación de niveles. La Fig. 3-5 muestra el ruido generado por aglomeraciones de personas.



Fig. 3-5. Ruido producido por actividades urbanas.

3.1.4 Instrumentos de medición

El sonómetro es el dispositivo que se emplea para medir los niveles de sonido. Es un equipo que permite cuantificar el nivel de presión sonora. Existen una gran variedad de dispositivos ya que dependiendo de las características del sonido que se desee medir es el dispositivo que se utilizará (ver Fig. 3-6). Dentro de las características a considerar tenemos el tipo de ruido a medir: impulsivo, continuo, intermitente; el tipo de medición que se quiera realizar, etc. Los sonómetros se clasifican en:

- Clase 0. Se utiliza en laboratorios y como referencia (error de +/- 0.4 dB).
- Clase 1. Se emplea para mediciones de precisión en campo (error de +/- 0.7 dB).
- Clase 2. Se utiliza en mediciones generales de campo (error +/- 1.0 dB).
- Clase 3. Se emplea para realizar reconocimientos y mediciones aproximadas (error +/- 1.5 dB).



Fig. 3-6. Sonómetro digital de la compañía TES Electrical Corp.

Esta clasificación está basada en la norma de la “International Electrotechnical Commission” IEC 651(1979). Además de esta norma, los sonómetros se rigen por: IEC 804(1985) en Europa y en el caso de América por la norma “American National Standard Specification for Sound Level Meters” ANSI S1.4 (1983).

Un sistema de medición de sonido se compone de un sensor de presión acústica (micrófono), unidad de acondicionamiento, unidad de procesamiento y unidad de presentación. El micrófono o sensor de presión acústica se encarga de transformar las ondas sonoras en impulsos eléctricos que son ingresados al sistema. En la unidad de acondicionamiento se realiza la conversión analógico-digital, se hace la conversión a unidades de presión sonora (Pascales, N/m^2) y se realiza un filtrado de los datos con los llamados filtros de ponderación (Sexto, 2007) ver Fig. 3-7, a continuación se presenta una breve descripción:

- *Filtro de ponderación A:* Fue creado para modelar la respuesta del oído humano para niveles bajos (del orden de los 40 fonos). Actualmente casi todas las leyes y reglamentos lo utilizan para delimitar los niveles aceptables de ruido. Los niveles de sonido ponderados con el filtro A se denominan decibelio A dB(A), (ecuación 3.2).

$$A(f) = 2.0 + 20 \log_{10} \left[\frac{12200^2 \cdot f^4}{(f^2 + 20.6^2) \cdot \sqrt{(f^2 + 107.7^2)(f^2 + 737.9^2)} \cdot (f^2 + 12200^2)} \right] \quad (3.2)$$

- *Filtro de ponderación B*: Fue creado para modelar la respuesta del oído humano a intensidades medias aproximadamente (70 fonos), (ecuación 3.3).

$$B(f) = 0.17 + 20 \log_{10} \left[\frac{12200^2 \cdot f^3}{(f^2 + 20.6^2) \cdot \sqrt{(f^2 + 158.5^2)} \cdot (f^2 + 12200^2)} \right] \quad (3.3)$$

- *Filtro de ponderación C*: Fue creado para modelar la respuesta del oído humano ante sonidos de gran intensidad (aproximadamente 100 fonos). Se utiliza para evaluar sonidos ambientales, así como, sonidos de baja frecuencia en la banda de frecuencias audibles (ecuación 3.4).

$$C(f) = 0.06 + 20 \log_{10} \left[\frac{12200^2 \cdot f^2}{(f^2 + 20.6^2) \cdot (f^2 + 12200^2)} \right] \quad (3.4)$$

- *Filtro de ponderación D*: Surgió a partir de las curvas de ruidosidad percibidas y fue concebido para evaluar un evento único de ruido aeronáutico (ecuación 3.5).

$$D(f) = 20 + \log_{10} \left[\frac{f}{6.8966888496475 \times 10^{-5}} \cdot \sqrt{\frac{h(f)}{(f^2 + 79919.29) \cdot (f^2 + 1345600)}} \right] \quad (3.5)$$

donde

$$h(f) = \frac{(1037918.48 - f^2)^2 + (1080768.16 \cdot f^2)}{(9837328 - f^2)^2 + (11723776 \cdot f^2)} \quad (3.6)$$

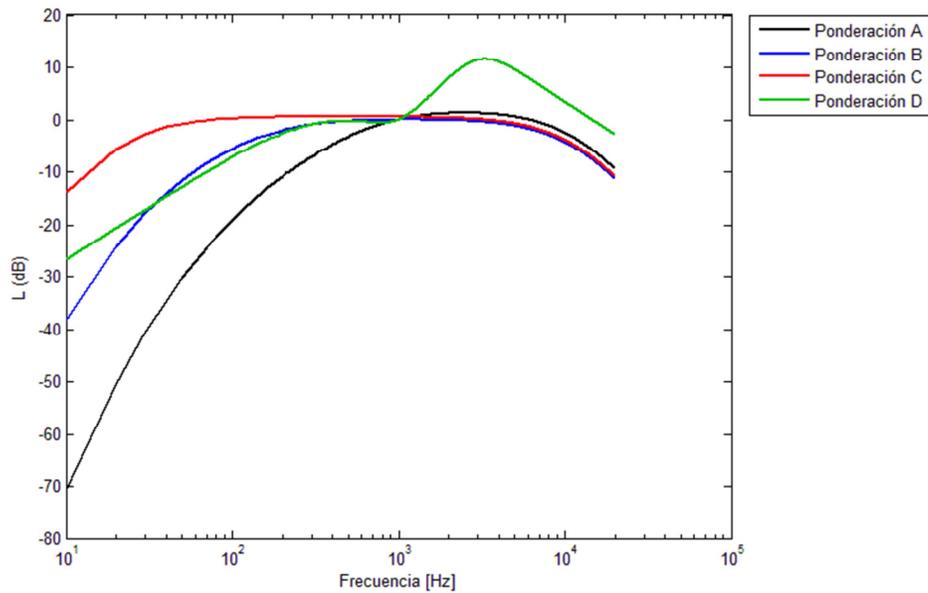


Fig. 3-7. Curvas de ponderación estandarizadas internacionalmente.

3.1.5 Indicadores de valoración del sonido

Los seres humanos se encuentran rodeados por el ruido en todas sus actividades, por lo que si se desea conocer y valorar la reacción de una persona o de un colectivo ante el ruido, es necesario crear una escala que relacione la respuesta subjetiva de las personas con alguna propiedad física medible de la fuente sonora (potencia emitida, intensidad en un punto situado a una distancia m de la fuente, presión acústica en un punto situado a una distancia m de la fuente), los indicadores de valoración del sonido nos ayudan a crear criterios que nos darán valores del índice de ruido que no debe superar (Berglund et al., 1999; Crocker, 1998; Kinsler et al., 1999). Algunos de los más utilizados son:

- *Nivel instantáneo (L_p):* Nivel de presión sonora que se registra en un instante de medición. También se denomina SPL (Sound Pressure Level), ver ecuación (3.1).

- *Nivel Sonoro Continuo Equivalente (L_{eq})*: Es el nivel de energía sonora que tendría un ruido constante en el mismo periodo de tiempo que el ruido medido. El L_{eq} representa la energía sonora que contiene el ruido en un determinado tiempo.
- *Nivel máximo (L_{max})*: Es el nivel sonoro más alto que se registra durante un período de tiempo.
- *Nivel mínimo (L_{min})*: Es el menor nivel sonoro que se registra durante un intervalo de tiempo.
- *Percentiles (L_{10}, L_{50}, L_{90} etc.)*: Es el nivel sonoro que es superado determinado porcentaje de tiempo. En el caso del L_{10} , es el nivel sonoro que superó el 10% del tiempo de la medición.
- *SEL (Sound Exposure Level)*: Es el nivel sonoro que si se mantiene constante durante 1 segundo, tendría la misma energía que el evento sonoro medido. Se usa para medir eventos aislados, como el paso de aviones, etc. También es conocido como (Single Event Level).

Existen otros indicadores importantes tales como: PNL (Perceived Noise Level), EPNL (Effective Perceived Noise Level), DNL (Day/Night Level), CNEL (Community Noise Equivalent Level).

3.2 Técnicas de procesamiento de voz

La extracción y la selección de la mejor representación paramétrica de las señales es una tarea importante en el reconocimiento de patrones. A continuación se describen algunos de las técnicas utilizadas en el procesamiento de voz, utilizadas para la extracción de características.

3.2.1 Codificación predictiva lineal (LPC)

El modelo de filtro “todo polos” es el más utilizado y el análisis de auto recursividad de la señal es la herramienta para hallar los coeficientes del filtro en cuestión. La funcionalidad matemática que da como resultado los coeficientes del filtro, es una relación matricial que se obtiene al realizar la predicción lineal de las muestras de las señales, con lo cual se obtienen los coeficientes de predicción lineal (Lineal Predictive Coding), también llamados parámetros LPC, que no son otra cosa que los coeficientes de un filtro “todo polos”. El cálculo de parámetros LPC es un procedimiento que se realiza en el dominio del tiempo, y está basado en la consideración de que el término n ésimo $s(n)$ de una secuencia de valores en el tiempo, puede ser estimado mediante una combinación lineal a partir de los p términos anteriores, como se describe en la ecuación (3.7) (Atal et al., 1971; Makhoul, 1975).

$$\hat{s}(n) = \alpha_1 s(n-1) + \alpha_2 s(n-2) + \dots + \alpha_p s(n-p) \quad (3.7)$$

Donde $\hat{s}(n)$ es el término estimado de la secuencia. Entonces consideramos la combinación lineal de las muestras anteriores definida como:

$$\hat{s}(n) = \sum_{k=1}^p a_k s(n-k) \quad (3.8)$$

El cálculo del error de predicción (señal real $s(n)$ menos señal predica $\hat{s}(n)$) se define como:

$$e(n) = s(n) - \hat{s}(n) = s(n) - \sum_{k=1}^p a_k s(n-k) \quad (3.9)$$

Para obtener las ecuaciones que deben ser resueltas para determinar los coeficientes de predicción LPC, definimos los segmentos de voz y de error en un segmento de datos, y los

tiempos en función de n , buscamos minimizar la señal de error mínimo cuadrado en el intervalo, ya que el error es mayor según sea menor k y disminuye al aumentar el número de datos considerados para la predicción. A partir del error cuadrático medio M tenemos:

$$M = \sum_n e^2(n) = \sum_n \left[s(n) - \sum_{k=1}^p a_k s(n-k) \right]^2 \quad (3.10)$$

Para obtener el valor mínimo de M , se deriva respecto a cada una de las variables a_j , como se muestra en las ecuaciones (3.11) a (3.14):

$$\frac{\partial M}{\partial a_j} = 0, \text{ para } 1 \leq j \leq p \quad (3.11)$$

$$\frac{\partial M}{\partial a_j} = \frac{\partial}{\partial a_j} \sum_n \left[s(n) - \sum_{k=1}^p a_k s(n-k) \right]^2 = 0 \quad (3.12)$$

$$\frac{\partial M}{\partial a_j} = -2s(n-j) \left[s(n) - \sum_{k=1}^p a_k s(n-k) \right] = 0 \quad (3.13)$$

$$\sum_{k=1}^p a_k \sum_n s(n-j) \cdot s(n-k) = \sum_n s(n) \cdot s(n-j) \quad (3.14)$$

El método de autocorrelación sugiere una manera simple y eficiente de definir los límites de las sumatorias al asumir que los segmentos de voz $s(n)$ son nulos fuera del intervalo $0 \leq n \leq N-1$. La función de autocorrelación permite medir matemáticamente el parecido existente entre una señal y una versión retrasada en el tiempo de la misma señal. El pico mayor de la función de autocorrelación está localizado en la posición cero de desplazamiento. La localización del pico siguiente, máximo global de la función tras el primer cruce por cero, da una estimación del período, y la altura una indicación de la periodicidad de la señal. La autocorrelación está dada por la ecuación (3.15).

$$\varphi(k) = R(k) = \sum_{n=0}^{N-1} s(n) \cdot s(n+k) \quad (3.15)$$

Si ponemos los términos de la sumatoria de productos en función de la autocorrelación, tenemos:

$$\varphi(j, k) = \sum_n s(n-j) \cdot s(n-k) \quad (3.16)$$

$$\varphi(j, k) = R_n(|j-k|), \quad j = 1, 2, \dots, p \quad \text{y} \quad k = 0, 1, \dots, p \quad (3.17)$$

Sustituyendo (3.17) en (3.14) tenemos,

$$\sum_{n=1}^p a_n R_n(|j-k|) = R_n(j), \quad \text{con} \quad 1 \leq j \leq p \quad (3.18)$$

Como la función de autocorrelación es simétrica $R_n(j) = R_n(-j)$ las ecuaciones que deben cumplir los parámetros LPC en la ecuación (3.18) se pueden expresar como:

$$\begin{bmatrix} R_n(0) & R_n(1) & R_n(2) & \cdots & R_n(p-1) \\ R_n(1) & R_n(0) & R_n(1) & \cdots & R_n(p-2) \\ R_n(2) & R_n(1) & R_n(0) & \cdots & R_n(p-3) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ R_n(p-1) & R_n(p-2) & R_n(p-3) & \cdots & R_n(0) \end{bmatrix} \cdot \begin{bmatrix} a_1 \\ a_2 \\ a_3 \\ \vdots \\ a_p \end{bmatrix} = \begin{bmatrix} R_n(0) \\ R_n(1) \\ R_n(2) \\ \vdots \\ R_n(p-1) \end{bmatrix} \quad (3.19)$$

Esta matriz de $p \times p$ valores de autocorrelación es una matriz tipo Toeplitz, donde p es el número de coeficientes o parámetros LPC que se quieren calcular, este sistema (expresión 3.19) puede resolverse mediante el algoritmo Levinson-Durbin (Durbin, 1960; Levinson, 1947), este método solo requiere un número de operaciones del orden de η^2 , mientras que el método de eliminación de Gauss requiere del orden de η^3 operaciones. Estos coeficientes permiten aproximar la señal original minimizando el error cuadrático medio.

3.2.2 Predicción perceptual lineal (PLP)

La técnica de codificación predictiva lineal (LPC) ha sido utilizada en el reconocimiento del habla por mucho tiempo. LPC modela el tracto vocal como un modelo todo-polos y aproxima de buena manera la forma de la señal del habla en todas las frecuencias de análisis. Esta característica es incompatible con la audición humana, que tiene una sensibilidad que varía con la frecuencia. El análisis PLP (Hermansky, 1990) fue desarrollado como un intento de corregir esta inconsistencia. Modela la percepción auditiva haciendo uso de la curva de banda crítica, la curva de igualdad de sonoridad y la ley de potencia de intensidad-sonoridad.

Para calcular los coeficientes PLP, se simulan varias propiedades de la audición mediante aproximaciones prácticas de ingeniería, y el espectro resultante del habla basado en la audición, es aproximado por un modelo auto regresivo (AR) todo-polos. La Fig. 3-8 muestra las diferentes etapas de análisis PLP. Cada etapa es descrita a detalle a continuación.

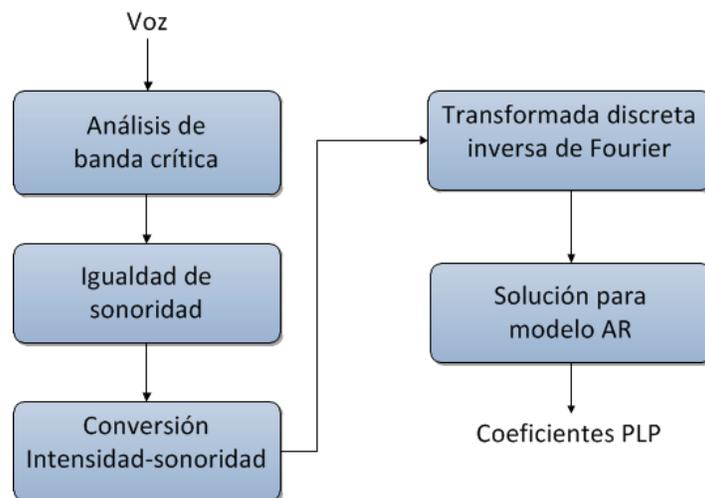


Fig. 3-8. Diagrama de bloques para el análisis PLP.

- Análisis espectral:

Se aplica la transformada discreta de Fourier (DFT) a la señal de voz para llevarla al dominio de la frecuencia. Se utiliza una ventana de Hamming, dada por la siguiente ecuación:

$$W(n) = 0.54 + 0.46 \cos\left(\frac{2\pi n}{N-1}\right) \quad (3.20)$$

donde N es el largo de la ventana en muestras.

Para obtener el espectro de potencia $P(\omega)$, se suman los cuadrados de la parte real e imaginaria de la transformada de Fourier $S(\omega)$, tenemos:

$$P(\omega) = \text{Re}[S(\omega)]^2 + \text{Im}[S(\omega)]^2 \quad (3.21)$$

- Resolución espectral de banda críticas:

El espectro $P(\omega)$ es desplazado a lo largo del eje de frecuencia ω hacia la escala de frecuencia de Bark Ω .

$$\Omega(\omega) = 6 \ln \left[\frac{\omega}{1200\pi} + \sqrt{\left(\frac{\omega}{1200\pi}\right)^2 + 1} \right] \quad (3.22)$$

donde ω es la frecuencia angular en rad/s .

El espectro de potencia resultante se convoluciona con el espectro de potencia de la curva de enmascaramiento simulada de banda crítica $\Psi(\Omega)$. En el análisis PLP, la curva de banda crítica está dada por:

$$\Psi(\omega) = \begin{cases} 0 & \text{para } \Omega < -1.3 \\ 10^{2.5(\Omega+0.5)} & \text{para } -1.3 \leq \Omega \leq -0.5 \\ 1 & \text{para } -0.5 < \Omega < 0.5 \\ 10^{-1.0(\Omega-0.5)} & \text{para } 0.5 \leq \Omega \leq 2.5 \\ 0 & \text{para } \Omega > 2.5 \end{cases} \quad (3.23)$$

La curva entrecortada es una aproximación a la curva asimétrica de enmascaramiento de Schroeder (Schroeder, 1977). Obtenemos muestras del espectro de potencia de banda crítica llevando a cabo la convolución de $\Psi(\omega)$ con $P(\omega)$, como se muestra en la ecuación siguiente:

$$\Theta(\Omega_i) = \sum_{\Omega=-1.3}^{2.5} P(\Omega - \Omega_i)\Psi(\Omega) \quad (3.24)$$

La convolución reduce la resolución espectral de $\Theta(\Omega)$ en comparación con $P(\omega)$, permitiendo así una reducción de resolución. Así, $\Theta(\Omega)$ es muestreada aproximadamente en intervalos de 1-Bark en este análisis. El valor exacto de los intervalos de muestreo se elige de manera que cubra toda la banda de análisis. Típicamente, son usados 18 intervalos de $\Theta[\Omega(\omega)]$ para cubrir la banda de análisis de 0 a 16.9 Bark (0 a 5 kHz).

- Igualdad de sonoridad:

La muestra $\Theta[\Omega(\omega)]$ es pre-enfatizada mediante la curva de igualdad de sonoridad (ver Fig. 3-9), dada por:

$$\Xi[\Omega(\omega)] = E(\omega) \Theta[\Omega(\omega)] \quad (3.25)$$

donde $E(\omega)$ aproxima las distintas sensibilidades del oído humano para cada una de las diferentes frecuencias (Robinson et al., 1956) y simula la sensibilidad de la audición a un nivel de 40 dB. Esta aproximación es tomada de (Makhoul et al., 1976) y está dada por:

$$E(\omega) = \frac{(\omega^2 + 56.8 \times 10^6) \omega^4}{(\omega^2 + 6.3 \times 10^6)^2 (\omega^2 + 0.38 \times 10^9)} \quad (3.26)$$

La expresión anterior es la función de transferencia de un filtro con asíntota de 12 dB/oct de 0 a 400 Hz, 0 dB/oct de 400 Hz a 1200 Hz, 6 dB/oct de 1200 a 3100 Hz y 0 dB/oct de 3100 Hz a la frecuencia de Nyquist.

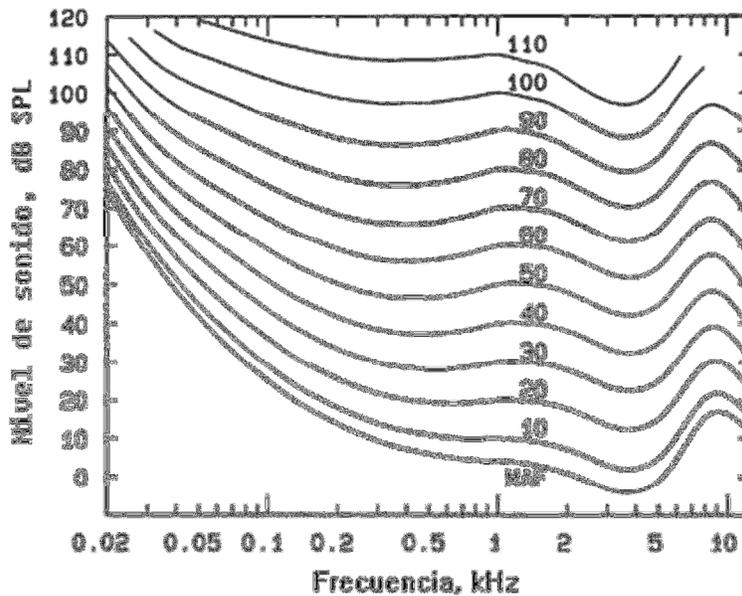


Fig. 3-9. Umbrales y contornos de igual nivel de sonoridad.

- Ley de potencia de intensidad-sonoridad:

Antes del modelo de todo-polos, se lleva a cabo una compresión de amplitud de raíz cúbica como una aproximación a la ley de potencia de la audición (Stevens, 1957), mediante:

$$\Phi(\Omega) = \sqrt[3]{E(\Omega)} \quad (3.27)$$

Esta operación simula la relación de no linealidad entre la intensidad del sonido y la sonoridad percibida.

- Modelo auto regresivo

Como última operación en el análisis PLP, $\Phi(\Omega)$ es aproximado como el espectro de un modelo todo-polos usando el método de autocorrelación, obteniendo así los coeficientes del modelo auto regresivo de orden M seleccionado.

3.2.3 Coeficientes cepstrales en las frecuencias de Mel (MFCC).

La extracción y la selección de la mejor representación paramétrica de las señales acústicas es una importante tarea en el diseño de cualquier sistema de reconocimiento de voz, ya que son una representación compacta mediante un conjunto de características y han demostrado ser muy eficaces (Davis et al., 1980). Los coeficientes MFCC se utilizan ampliamente en el reconocimiento automático de voz, se derivan de la magnitud del espectro de la transformada de Fourier mediante la aplicación de un banco de filtros espaciados en la escala de frecuencia de Mel. Se calcula el logaritmo de la energía en cada filtro y se suma esta energía antes de aplicar la transformada discreta de coseno (DCT) para obtener el vector de características MFCC (Shannon et al., 2003).

La escala de frecuencia utilizada para la separación de los filtros es la escala Mel. La escala de Mel es una escala perceptual que fue propuesta por (Stevens et al., 1937). La escala se diseñó a través de experimentos de la percepción humana, donde se pedía a los sujetos ajustar un tono de estímulo perceptualmente a la mitad de separación de un tono de referencia. La escala resultante fue una en la que 1 Mel representa una milésima parte del tono de 1 kHz (Huang et al., 2001) y una duplicación de Mels produce una duplicación de percepción del tono (Zheng et al., 2001). El cálculo de la MFCC incluye los siguientes pasos:

- Se aplica la transformada discreta de Fourier al segmento de la señal ventaneada para obtener su respuesta en el dominio de la frecuencia, obteniendo el espectro de potencia $P(f)$.

$$P_k(f) = \sum_{n=0}^{N-1} x(n) e^{-j2\pi k/n} \quad (3.28)$$

- El espectro $P(f)$ es mapeado a lo largo del eje de frecuencia f (en Hertz) hacia el eje de frecuencia de Mel $P(B)$ donde B es la frecuencia de Mel, usando la ecuación (3.29) (Picone, 1993; Schroeder, 1977) (ver fig. 3-10). Esto es aproximadamente el reflejo de la percepción del oído humano:

$$B(f) = 1125 \log_{10} \left(1 + \frac{f}{700} \right) \quad (3.29)$$

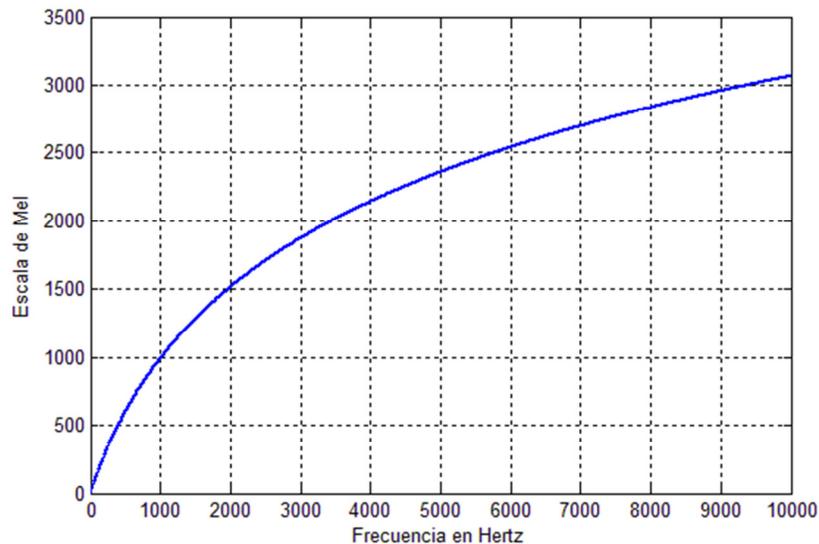


Fig. 3-10. Relación entre la escala de frecuencia y la escala de Mel.

- El espectro de potencia resultante se convoluciona con un filtro triangular pasa banda $P(B)$ en $\theta(B)$. La convolución con las curvas de enmascaramiento de banda crítica $\psi(B)$, ecuación (3.30), reduce significativamente la resolución espectral de $\theta(B)$ en comparación con la original $P(f)$, que permite la disminución de resolución de $\theta(B)$. La Fig. 3-11 muestra un ejemplo del banco de filtros triangulares espaciados logarítmicamente.

$$\psi_k(B) = \begin{cases} 0 & k < f[m-1] \\ \frac{2(k - f[m-1])}{(f[m+1] - f[m-1])(f[m] - f[m-1])} & f[m-1] \leq k \leq f[m] \\ \frac{2(f[m+1] - k)}{(f[m+1] - f[m-1])(f[m+1] - f[m])} & f[m] \leq k \leq f[m+1] \\ 0 & k > f[m+1] \end{cases} \quad (3.30)$$

donde $1 \leq k \leq f_s/2$ y $1 \leq m \leq M$, la cantidad de filtros es representada por M .

- Mediante la convolución discreta de $\psi(B)$ con $\theta(B)$ se obtienen muestras del espectro de potencia para cada banda crítica, y posteriormente se obtiene una salida logarítmica de energía, dada por la siguiente ecuación:

$$X_i(f) = \log_{10} \left(\sum_{k=0}^{N-1} |\theta(f)|^2 \psi_i(f) \right) \quad , i = 1, 2, \dots, M \quad (3.31)$$

- Los coeficientes MFCC son obtenidos mediante la ecuación (3.32), la transformada coseno de Fourier es utilizada para su cálculo.

$$C_j = \sum_{i=1}^M X_i \cos \left(j \left(i - 1/2 \right) \frac{\pi}{M} \right) \quad , j = 1, 2, \dots, J \quad (3.32)$$

donde M es el número de filtros y J es el número de coeficientes que se desean calcular.

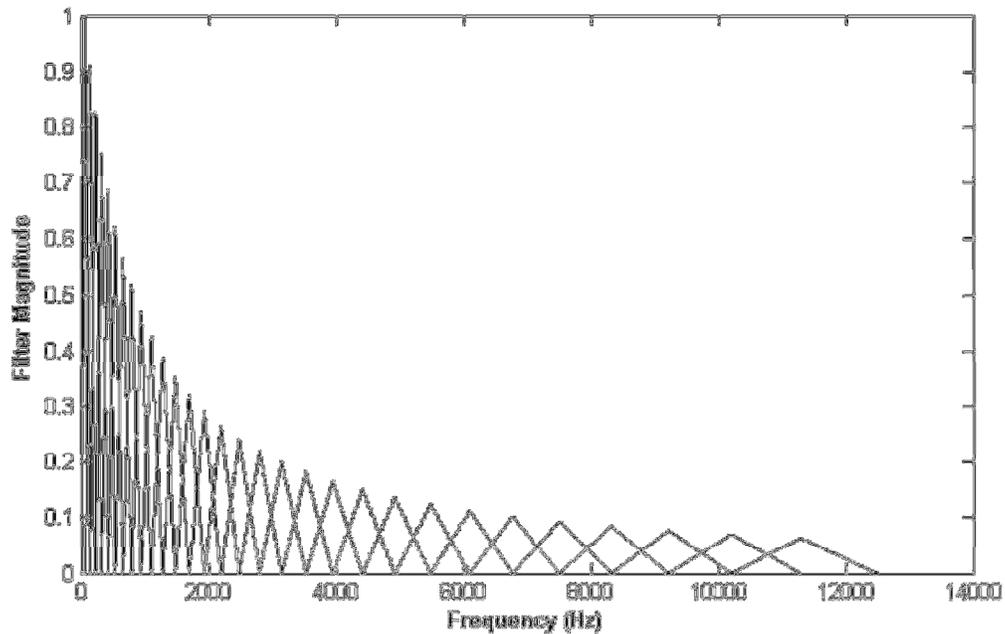


Fig. 3-11. Banco de filtros espaciados logarítmicamente.

3.2.4 Análisis de octava

En algunos casos, una alta resolución espectral no es ni deseable ni necesaria. Si por ejemplo, se necesita una estimación de la composición espectral del ruido de un vehículo o una aeronave, es conveniente subdividir el rango de frecuencia en un pequeño número de intervalos secundarios. En el análisis de octava la señal a ser analizada se divide en señales parciales empleando un banco de filtros que permite la medición de las componentes espectrales. Una octava es el intervalo entre dos frecuencias que tienen una proporción de 2:1, ver la Fig. 3-12.

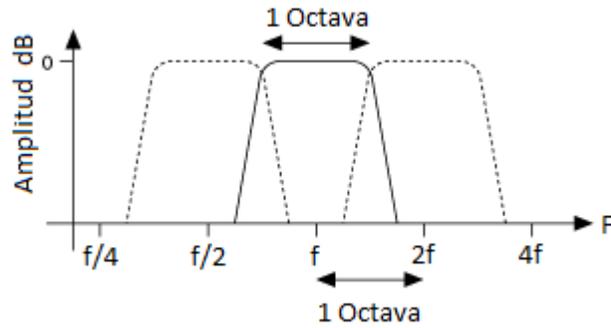


Fig. 3-12. Filtro de octava, un filtro pasa banda que cubre una octava.

Cada filtro se caracteriza por su ancho de banda Δf , frecuencia de corte inferior f_l y superior f_u , la frecuencia central f_c . El ancho de banda se determina con la diferencia de f_u y f_l : $\Delta f = f_u - f_l$. La frecuencia central de una octava, que se extiende de f_l a f_u , es la frecuencia f_c , que divide a la octava en dos intervalos iguales en la escala logarítmica. La frecuencia central está determinada por la siguiente ecuación:

$$f_c = \sqrt{f_l f_u} \quad (3.33)$$

Dado que se conocen las características del filtro, $f_u = 2 f_l$ entonces $f_c = \sqrt{2} f_l$ y el ancho de banda del filtro de una octava es:

$$\Delta f = f_u - f_l \quad (3.34)$$

Sustituyendo f_u en la ecuación (3.34), tenemos:

$$\Delta f = 2f_l - f_l \quad (3.35)$$

$$\Delta f = f_l = \frac{f_c}{\sqrt{2}} \quad (3.36)$$

Para un tercio de octava (1/3 octava) la frecuencia de corte superior del filtro pasa banda es $f_u = \sqrt[3]{2} f_l$, la frecuencia central quedaría de como $f_c = \sqrt[6]{2} f_l = 1.12 f_l$, de esta manera el ancho de banda del filtro es $\Delta f = 0.26 f_l$.

Cuando se necesita información mucho más detallada del espectro del ruido que la obtenida con las octavas, se emplean las bandas de 1/n octavas, que tienen un ancho de banda más pequeño, con lo que las medidas realizadas son más exactas. Las frecuencias de corte inferior y superior de los filtros están estandarizadas por normas internacionales como ANSI S1.11-2004 e IEC 1260:1995(ANSI, 2004; IEC, 1995).

3.2.5 Análisis cepstrum

El cepstrum es definido como la transformada inversa de Fourier del logaritmo de la magnitud del espectro de la transformada de Fourier (Bogert et al., 1963), dado por:

$$c(\tau) = \mathcal{F}^{-1}\{\log|\mathcal{F}\{x(n)\}|\} \quad (3.37)$$

donde \mathcal{F} denota la transformada de Fourier y \mathcal{F}^{-1} la transformada inversa de Fourier.

La palabra cepstrum es un anagrama de la palabra *spectrum* (espectro), el eje de las abscisas (τ) es llamado *quefrequency*, un anagrama de *frequency* (frecuencia). Es método común de detección de tono en el dominio de la frecuencia en investigaciones relacionadas con el habla, siendo utilizado por primera vez en el análisis de voz por (Noll, 1967; Schafer et al., 1970). Una forma sencilla de describir el Cepstrum es decir que tiende a separar una componente de tono fuerte del resto del espectro. La Fig. 3-13 muestra un breve esquema para el cálculo del cepstrum de una secuencia de muestras.

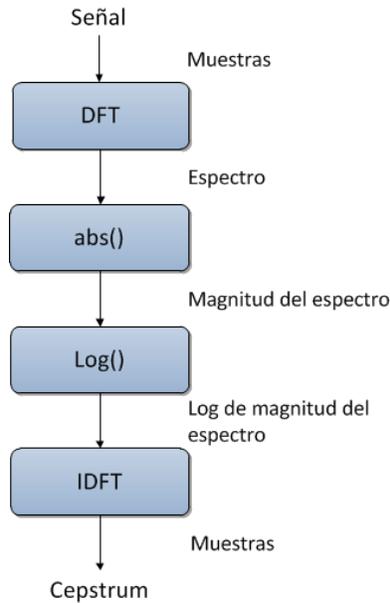


Fig. 3-13. Diagrama de bloques para el cálculo del cepstrum.

Formalmente se define el cepstrum complejo de una secuencia de muestras, por la siguiente ecuación:

$$c_c(\tau) = \frac{1}{2\pi} \int_{-\pi}^{\pi} \left[\log|X(e^{j\omega})| + j \varphi(X(e^{j\omega})) \right] e^{j\omega\tau} d\omega \quad (3.38)$$

Y el cepstrum real para una secuencia de muestras, está dado por:

$$c_c(\tau) = \frac{1}{2\pi} \int_{-\pi}^{\pi} \log|X(e^{j\omega})| e^{j\omega\tau} d\omega \quad (3.39)$$

3.3 Redes neuronales artificiales

Las redes neuronales artificiales (RNA) exhiben propiedades interesantes ya que intentan reflejar las capacidades de procesamiento de información de los sistemas nerviosos. Estas redes no operan secuencialmente y tienen una estructura multicapa jerárquica que permite transmitir la información desde una unidad a sus vecinos más distantes e inmediatos calculando los parámetros de la red neuronal por medio de la adaptación de valores y

usando canales de entrada, un cuerpo celular y un canal de salida. Las sinapsis biológicas se simulan con puntos de contacto entre el cuerpo celular y las conexiones de salida o entrada asociando un “peso” a tales puntos (Rojas, 1996; Vázquez S, 2007).

3.3.1 Perceptrón multicapa (MLP)

En 1958, Frank Rosenblatt propuso el modelo del perceptrón definiendo pesos numéricos y un patrón espacial de interconexión donde el aprendizaje toma lugar adaptando los pesos de la red mediante un algoritmo numérico. La red MLP (del inglés Multi-Layer Perceptron) consiste en un conjunto de neuronas organizadas por capas: capa de entrada, una o más capas ocultas y la capa de salida (ver Fig. 3-14). A partir de múltiples entradas, el perceptrón calcula una salida única formando una combinación lineal con sus pesos de entrada y estableciendo la salida con cierta función de activación como se expresa en la siguiente ecuación (Haykin, 1998):

$$y = f\left(\sum_{i=1}^n w_i \cdot x_i + b\right) \quad (3.40)$$

Antes de usar una red MLP, se debe entrenar para que una entrada en particular conduzca a un objetivo de salida específico. Para esto, se aplica un algoritmo de entrenamiento que tiene como objetivo adaptar los valores de los pesos y bias, dado un vector de entrada y el error asociado. El proceso para hallar nuevos pesos y nuevos bias se repite hasta que el error se reduce al mínimo deseado. Las redes MLP se pueden entrenar usando el algoritmo de retro-propagación (Rumelhart et al., 1986).

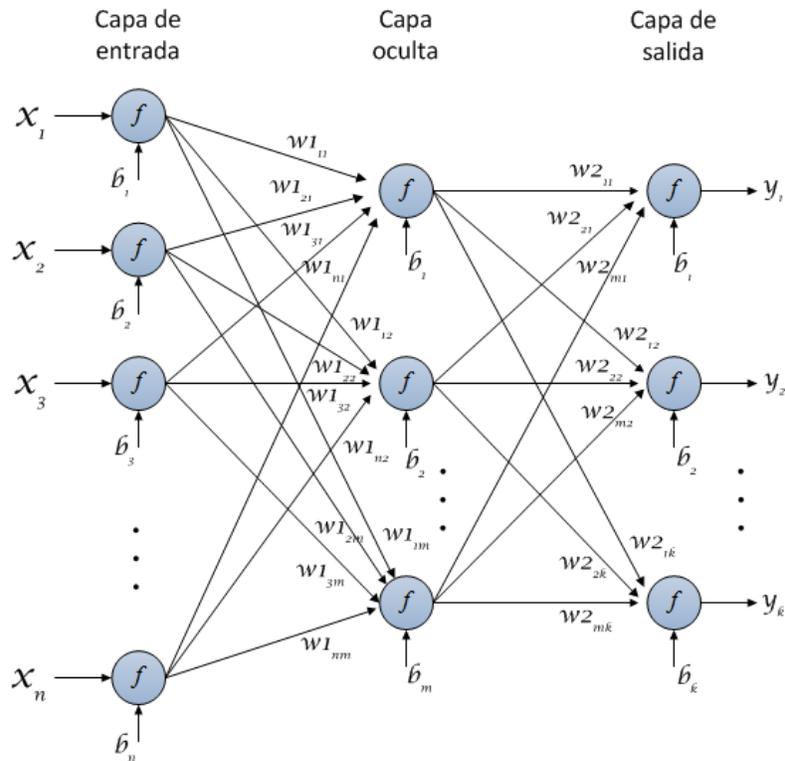


Fig. 3-14. Red perceptrón multicapa con una capa oculta.

3.4 Conclusión del capítulo

En este capítulo se describieron los principales indicadores de valoración del sonido, establecidos por normas internacionales, los cuales sí son útiles para crear criterios de evaluación del impacto acústico. En relación a las técnicas de procesamiento de voz para la extracción de rasgos característicos, se identificó la técnica MFCC como uno de los métodos más utilizados, dado que ha mostrado niveles altos de certeza en los sistemas de reconocimiento de voz. Para problemas asociados al reconocimiento de patrones, en la literatura existen trabajos que presenta al método neural artificial MLP como un clasificador universal que presenta buenos resultados en tareas de clasificación e identificación.

Capítulo 4. Análisis de las mediciones del ruido generado durante el despegue.

En este capítulo se presenta el sistema de medición utilizado para la adquisición de las señales del ruido de las aeronaves generadas durante el despegue y el punto de medición en el AICM. Posteriormente se presenta la base de datos de ruidos obtenidos durante las etapas de medición. Finalmente, se describen las características de una señal de ruido generada durante el despegue para realizar el análisis y la extracción de rasgos característicos mediante las técnicas de procesamiento de voz: análisis de octava y análisis MFCC.

4.1 Sistema de medición

Las señales de ruido de aviones durante el despegue fueran adquiridas mediante el sistemas de medición presentado en el trabajo de maestría titulado: Sistema de monitoreo de ruidos ambientales producidos por aviones en el AICM (Aeropuerto Internacional de la Ciudad de México) (Rojo R, 2008), ver Fig. 4-1, el cual está formado principalmente por:

- Un micrófono MPA201 marca BSWA-Tech que cumple con la norma IEC 61672 clase 1.
- Una tarjeta de adquisición NI USB-9233.
- Un programa informático como interfaz gráfica de usuario.

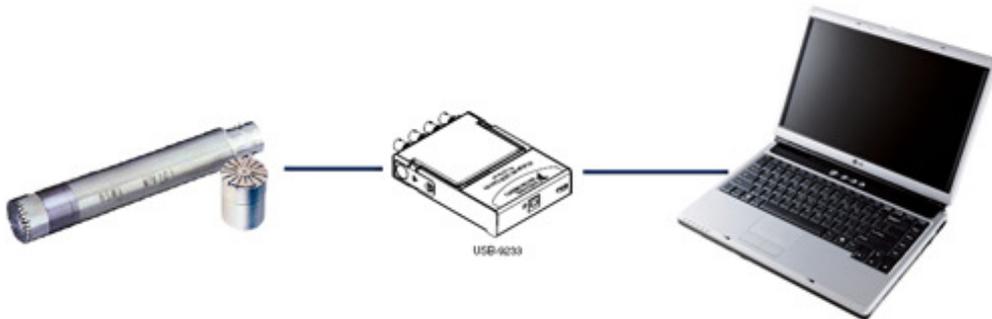


Fig. 4-1. Arquitectura del sistema de medición (Rojo R, 2008)

Las especificaciones principales del micrófono son las siguientes:

Tabla 4.1. Características del micrófono MP201.

Micrófono MP201 (IEC 61672 Clase 1)	
Respuesta	A campo abierto
Sensibilidad a circuito abierto	50 mV / Pa
Respuesta de frecuencia	20 Hz – 20 KHz
Voltaje de Polarización	0 V
Capacitancia (Típica)	16 pF
Temperatura de Operación	-30°C – 80°C
Humedad de Operación	0 – 98% RH
Coefficiente de temperatura (-10°C – 50°C)	-0.005 dB / °C
Coefficiente de Humedad	-0.003 dB / %RH

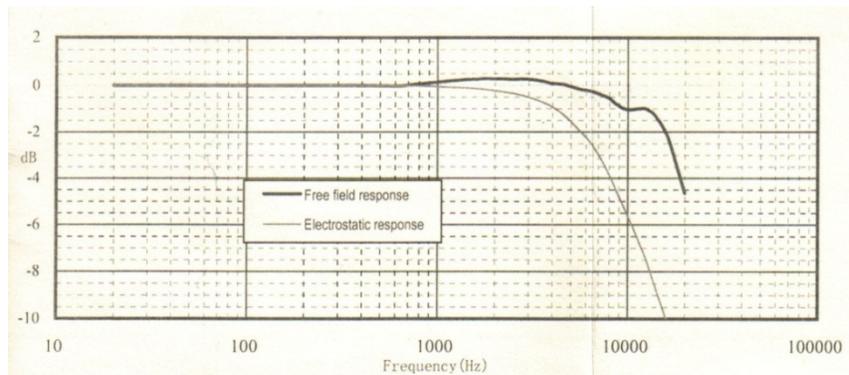


Fig. 4-2. Respuesta en frecuencia del micrófono MP201 (cortesía de BSWA-Tech).

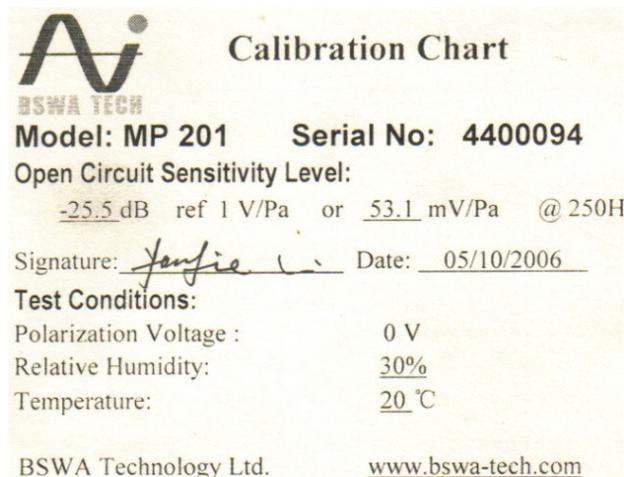


Fig. 4-3. Hoja de calibración del micrófono MP201 (cortesía de BSWA-Tech).

4.2 Punto de medición.

El reconocimiento de clases de aeronaves del presente trabajo se basa en el ruido generado por las aeronaves durante el despegue, debido a esto la elección del punto de medición es de gran importancia. La norma mexicana NOM-036-SCT3-2000 en la sección de medición para la evaluación del ruido, menciona los puntos de referencia que se deben tener en cuenta para la medición del ruido, los cuales son: un punto de referencia de medición de ruido lateral a plena potencia, un punto de referencia de medición de ruido de sobrevuelo y un punto de referencia de medición de ruido de aproximación.

El punto de medición seleccionado se encuentra aproximadamente a 130 metros de manera perpendicular al eje de la pista, y se encuentra en el límite del terreno del aeropuerto y las casas. Este punto se encuentra en la esquina de Poniente 11 y Norte 1 Col. Cuchilla del Tesoro, con coordenadas geográficas $19^{\circ}26'41''$ N, $-99^{\circ}3'44''$. Además, permite realizar las mediciones de los despegues a campo abierto sin construcciones o estructuras que reflejen u obstruyan el ruido. La Fig. 4-4 muestra el punto de medición y la dirección de despegue en condiciones normales de viento para realizar las mediciones.



Fig. 4-4. Ubicación del punto de medición, dirección y punto aproximado de despegue de las aeronaves en el AICM (Google Maps).

4.3 Señal de ruido de una aeronave durante el despegue

Las señales de ruido durante el despegue son capturadas mediante el sistema de monitoreo y medición descrito en la sección 4.1, el cual realiza la medición durante 24 segundos con una frecuencia de muestreo de 25 kHz y una resolución de 24 bits del convertidor analógico a digital. La Fig. 4-5 muestra la señal típica en el tiempo y las componentes de frecuencia del ruido durante el despegue de un avión. En la Fig. 4-5 (a) se puede observar que el ruido de fondo es más notorio al final de la señal, en la parte central el ruido está enmascarado por la alta intensidad del ruido generado. En la Fig. 4-5 (b) se observa que la frecuencia de muestreo utilizada permite adquirir frecuencias superiores a las que contienen la información de la señal (componentes de frecuencia por debajo de 6000 Hz).

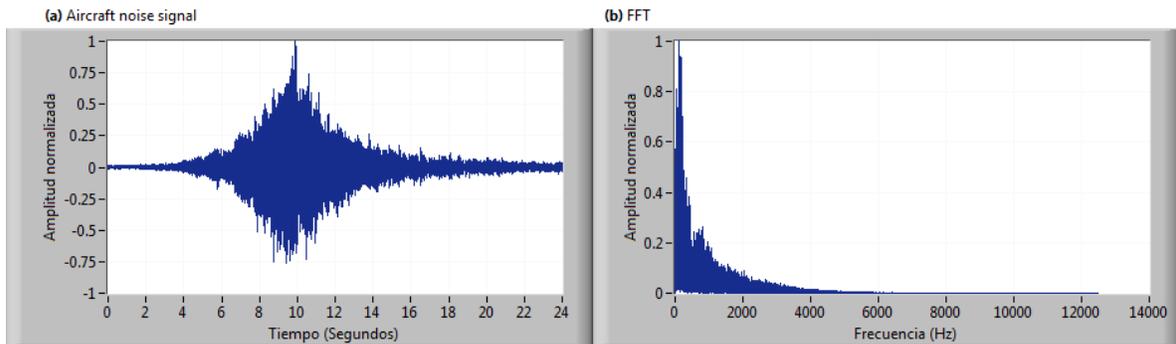


Fig. 4-5. Señal de ruido durante el despegue de un avión muestreada a 25 kHz, (a) Señal en el tiempo, (b) espectro de frecuencia.

La Fig. 4-6 muestra el espectrograma para una señal de ruido del despegue para la aeronave 737-200 de la compañía Boeing, y en la cual se aprecian las principales componentes de frecuencia de este tipo de señales.

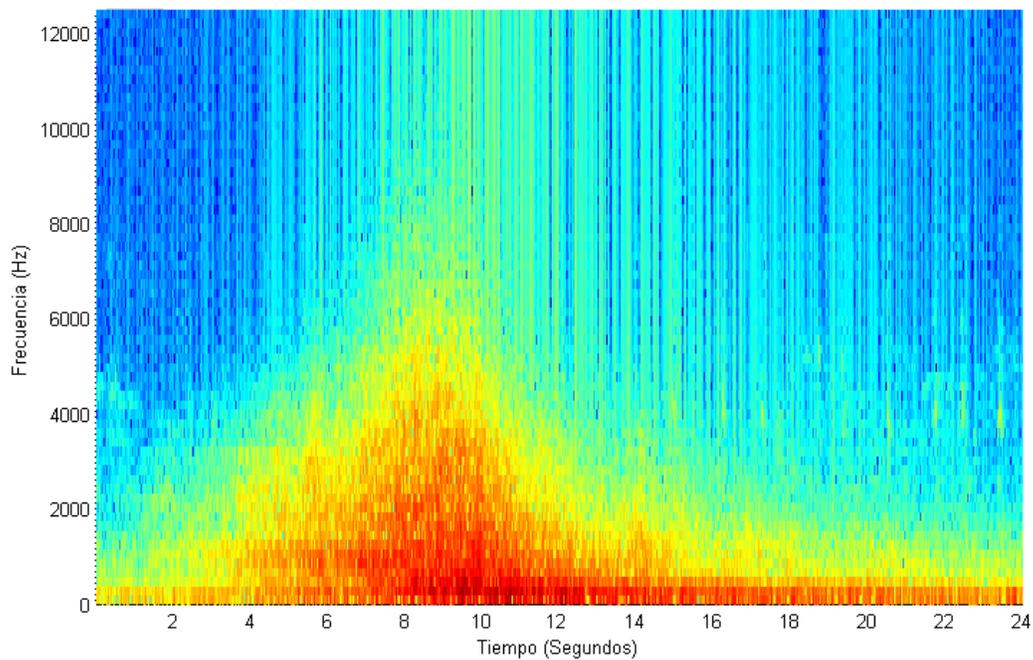


Fig. 4-6. Espectrograma para aeronave 737-200 de la compañía Boeing.

4.4 Base de datos de ruido generado durante el despegue

Después de realizar mediciones se obtuvo un conjunto de archivos los cuales contenían la información capturada del ruido generado por las aeronaves durante el despegue. Con base en el tipo de motor instalado se realizó la organización de los archivos de ruido en clases de aeronaves y así formar la base de datos a ser analizada (Rojo R, 2008). La base datos de ruido de aeronaves es la que se muestra en la tabla siguiente:

Tabla 4.2. Clases de aeronaves y cantidad de muestras del ruido de aeronaves.

Clase de aeronaves (Nombre)	Número de muestras
Airbus 318, 319, 320 (A320 1)	16
Airbus 318, 319, 320 (A320 2)	17
Airbus 318, 319, 320 (A320 3)	17
Airbus, Boeing 737-800 (A320_B737-800)	18
ATR-42 (ATR-42)	14
Boeing 737-100, 737-200 (B737-100/200)	22
Boeing 737-600, 737-700 (B737-600/700)	20
Boeing 747-400 (B747-400)	15
Fokker F100 (F100)	17
Fokker F100 2 (F100 2)	17
Fokker F100, Boeing 737-200 (F100_B737-200)	14
Fokker F100, Boeing 737-200 2 (F100_B737-200 2)	15
McDonnell Douglas 87, 88 (MD)	20
Total	222

En la Tabla 4.2 se observan cada una de las clases de aeronaves y los modelos que componen cada una de éstas. Por ejemplo, la clase A320 1 se compone de los aviones Airbus 318, 319 y 320 (ver Fig. 4-7). La cantidad de señales registradas no es la misma para todas las clases debido a la frecuencia de despegue de las aeronaves.



Fig. 4-7. Modelos de aeronaves que pertenecen a la clase A320, (a) A318, (b) A319 y (c) A320.

4.5 Análisis y extracción de rasgos característicos

La extracción de características fiables es una tarea importante cuando se trabaja en un problema de reconocimiento de patrones. Estas características deben ser capaces de representar de la mejor forma el caso de estudio para lograr un buen nivel de identificación. Como primera etapa del modelo de reconocimiento de clases de aeronaves fue seleccionar las técnicas para la extracción de rasgos característicos, para ello se realizó una comparativa del desempeño de reconocimiento basado en una red neural MLP de cada una de las técnicas de procesamiento de voz presentadas en el Capítulo 3. La tabla 4.3 muestra de manera breve los resultados obtenidos en esta primera etapa de experimentación. Se llegó a la conclusión de incluir el análisis de MFCC y octava para implementar el modelo computacional de reconocimiento de clases de aeronaves. En el caso de MFCC mostró buenos resultados como los encontrados en trabajos de investigación relaciones con el reconocimiento de voz (Qi et al., 2011), también se obtuvo un buen desempeño con el análisis de octava como el obtenido en el reconocimiento de clases de aeronaves por (Rojo R, 2008).

Tabla 4.3. Comparativa de técnicas de procesamiento de voz en la identificación de clases de aeronaves.

Técnica	% de reconocimiento
PLP	77
MFCC	80
Cepstrum	76
Octava	78

La Fig. 4-8 muestra el procedimiento de extracción de rasgos característicos para obtener el conjunto de patrones del modelo computacional propuesto para el reconocimiento de clases de aeronaves basado en el ruido generado durante el despegue.

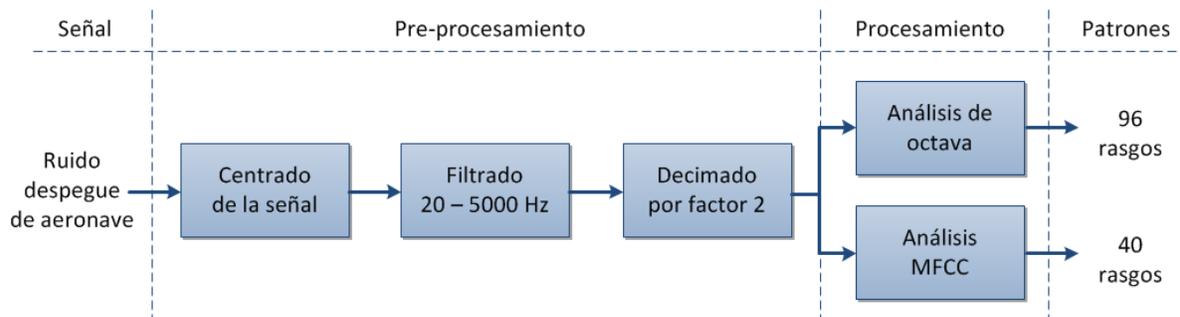


Fig. 4-8. Diagrama de bloques para la extracción de rasgos característicos.

4.5.1 Pre-procesamiento

4.5.1.1 Centrado de la señal

Como las señales obtenidas durante las mediciones no se centraron en función de su longitud, se necesita un proceso de centrado de la señal para evitar la inclusión de ruido no deseado y para analizar sólo la parte significativa de la señal de despegue de aeronaves. Centrar una señal de avión es un proceso común con el apoyo del método de Organización de Aviación Civil Internacional para calcular las curvas de ruido alrededor de los aeropuertos (ICAO, 2008), en la que sólo se utiliza la parte de la señal dentro de 10 dB de valor máximo.

Para las señales en este trabajo el centro no siempre representa el contenido más significativo de la señal. Esto puede ser causado por el ruido aditivo irregular cerca del punto de medición. En este documento se utiliza un algoritmo para detectar el centro de la señal usando una técnica basada en la correlación. Se calcula el valor absoluto de cada muestra y la señal resultante se compara con una ventana de Gauss utilizando el método de correlación PHAT (Phase Transform). Se seleccionó la ventana de Gauss debido a la similitud observada con respecto a la señal absoluta. Después, se calcula el valor máximo de la función de correlación, que representa el centro de la señal. La Fig. 4-9 muestra la señal, la ventana de Gauss, la función de correlación y la ubicación del centro de una señal

para la aeronave 737-200. Tanto la señal como la ventana de Gauss se normalizan para una mejor visualización. Otros ejemplos del algoritmo de centrado para las señales de las aeronaves F100 y A318 se muestran en la Fig. 4-10.

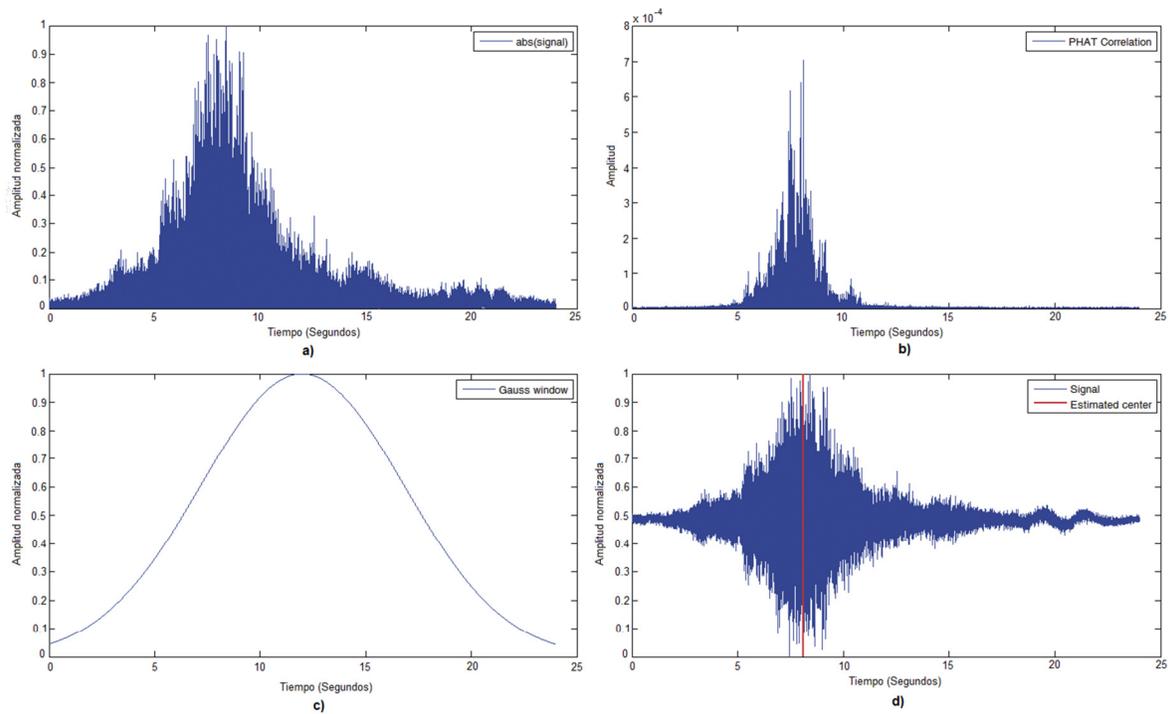


Fig. 4-9. Algoritmo para detección del centro aplicado a la señal del 737-200: (a) Señal absoluta, (b) Correlación PHAT entre señal absoluta y ventana de Gauss, (c) Ventana de Gauss, (d) Ubicación del centro.

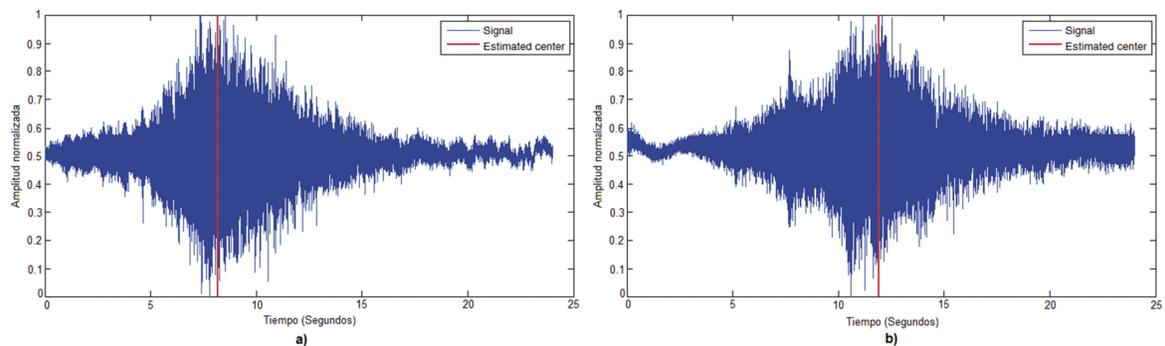


Fig. 4-10. Ubicaciones del centro para las señales: (a) F100, (b) A318.

4.5.1.2 Filtrado de la señal

Las señales de ruido durante el despegue como la que se muestra en la Fig. 4-5 se capturaron con una frecuencia de muestreo de 25 kHz. Previo a la fase de extracción rasgos característicos, se aplica un filtro Butterworth pasa banda de segundo orden para evitar el aliasing cuando se realice el diezmado de la señal. La Fig 4-11 muestra la respuesta del filtro Butterworth pasa banda con frecuencia de corte inferior de 20Hz y superior de 5 kHz; además, se observan los puntos para cada una de las frecuencias de corte (normalizadas), frecuencia de corte inferior: $0.00158 \approx 20\text{Hz}$ y frecuencia de corte superior: $0.40 \approx 5\text{ kHz}$.

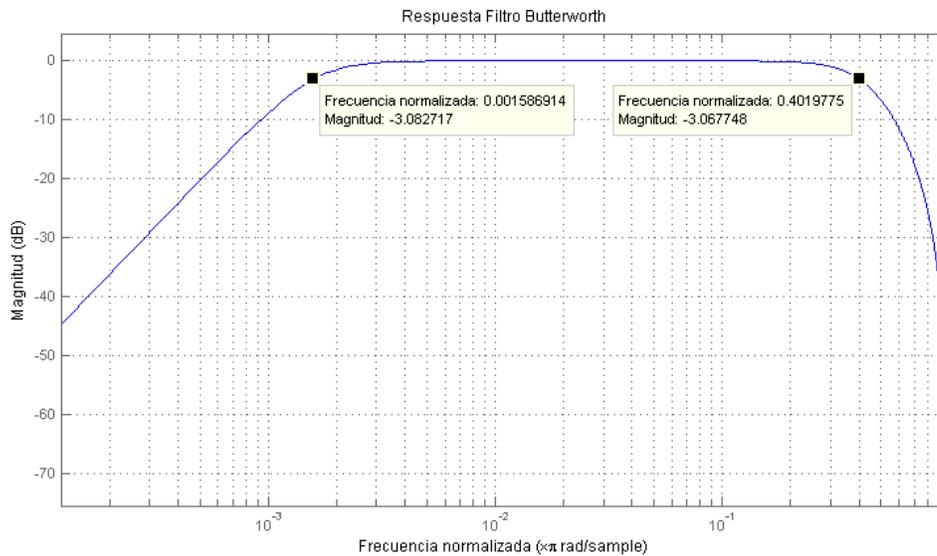


Fig. 4-11. Respuesta de frecuencia del filtro Butterworth pasa banda de segundo orden.

La Fig. 4-12 muestra el proceso de filtrado para las señales de ruido de las aeronaves durante el despegue. En la Fig. 4-12 (a), (c) se observan las señales de ruido originales registradas durante el despegue de las aeronaves MD87 y F100, respectivamente; mientras en (b) y (d), se presenta el resultado de las señales después de la fase de filtrado para el MD87 y F100, respectivamente.

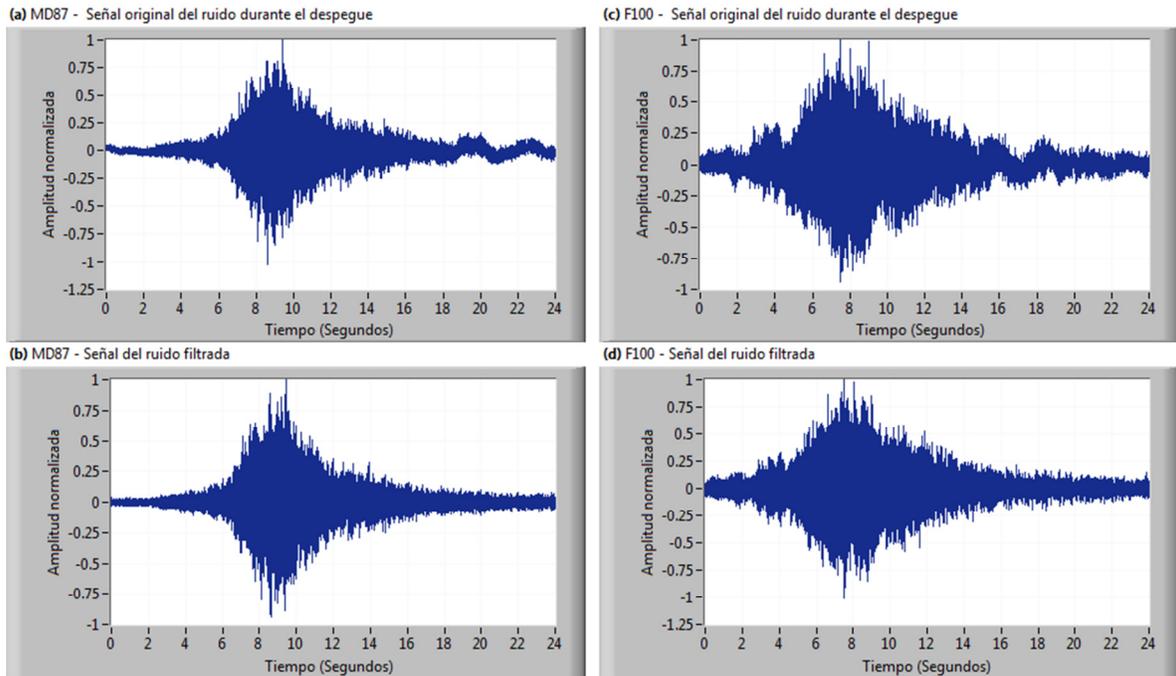


Fig. 4-12. Señal original de ruido durante el despegue y señal filtrada: (a) señal del MD87, (b) señal filtrada del MD87, (c) señal del F100, (d) señal filtrada del F100.

4.5.1.3 Diezmado de la señal

Después del filtrado de la señal de ruido se realiza una disminución de la frecuencia de muestreo por un factor de 2. De esta forma, la frecuencia de muestreo se reduce de 25 kHz a 12.5 kHz, permitiendo tener una representación de la señal con una cantidad menor de muestras reduciendo el costo computacional durante la extracción de rasgos característicos. La reducción de muestras se realizó mediante la siguiente ecuación:

$$y_i = x_i \cdot m \quad (4.1)$$

para $i = 0, 1, 2, \dots, tam - 1$

$$tam = \left\lfloor \frac{n}{m} \right\rfloor$$

donde n es el número de elementos de x , m es el factor de diezmado, y es el arreglo resultante, tam es el número de elementos del arreglo resultante y $\lfloor \cdot \rfloor$ da un número entero, menor o igual al número dado por n/m . ejemplo: $n = 11$ y $m = 2$ entonces $\lfloor 11/2 \rfloor = 5$. La Fig. 4-13 muestra la forma de las señales del ruido después de la disminución de la frecuencia de muestreo, obteniendo una representación muy semejante, en (a) y (c) se observan las señales para el 737-200 y A318 respectivamente, y en (b) y (d) después del proceso de diezmado para el 737.200 y A318.

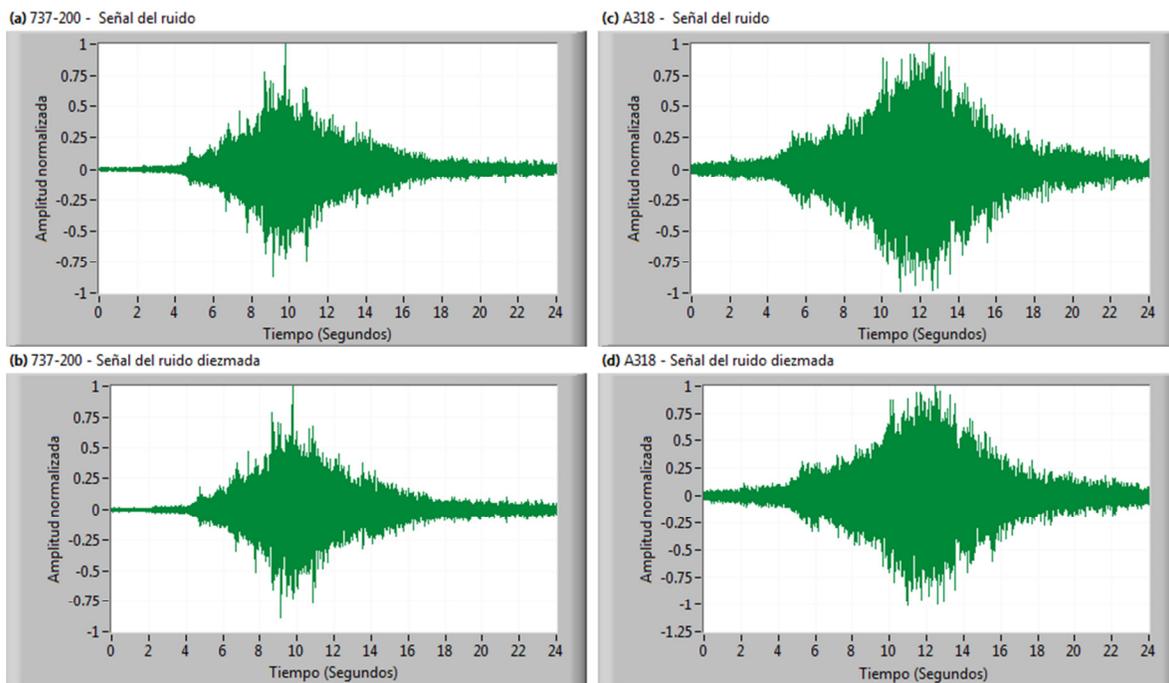


Fig. 4-13. Diezmado de la señal filtrada: (a) señal del 737-200, (b) señal diezmada del 737-200, (d) señal del A318, (d) señal diezmada del A318.

4.5.2 Procesamiento

Ahora, la señal de ruido de las aeronaves durante el despegue contiene armónicos de 20 Hz a 6250 Hz ($F_s/2$) preservando el rango espectral de interés mostrado en la Fig. 4-5 (b), que permite la extracción de características de 20 hasta 5000 Hz, según el análisis. En este estudio se propone la extracción de características de la forma de onda completa de la señal

de ruido de las aeronaves sin realizar alguna segmentación, como lo propuesto por (Sánchez-Pérez et al., 2013). Para este trabajo se utilizó el análisis de octava y análisis MFCC, los cuales se describen a continuación.

4.5.3 Extracción de rasgos mediante el análisis de octava

Como se mencionó en la sección 3.2.4, en el análisis de octava, la señal a ser analizada se divide en señales parciales por un banco de filtros que permite la medición de las componentes espectrales. Para este trabajo, se utilizó el análisis de 1/24 de octava con el propósito de obtener el primer conjunto de rasgos característicos para entrenar la primera red MLP, estos rasgos se presentan en la Fig. 4-14. Un trabajo reciente proponen el uso de 1/12 de octava (Sánchez-Fernández et al., 2012), en este trabajo se extraen más características con el fin de mejorar la identificación.

Para el análisis 1/N octava, las frecuencias centrales de los filtros pasa banda se definen por la norma IEC 1260 y ANSI S1.11: 2004, mediante las ecuaciones (4.2) y (4.3). El rango de frecuencia para el análisis se estableció de 20 a 5000 Hz y se tomó un total de 96 rasgos. Esta cantidad de rasgos característicos se eligió después de pruebas experimentales y se encontró que estos proporcionaban una mejor identificación. Dado que los valores resultantes son negativos se realizó un acondicionamiento de los datos en la capa de entrada de la red MLP, este proceso se describe en capítulo 5.

Si N es par:

$$f_i = 1000 * 2^{ib} \quad (4.2)$$

Si N es impar:

$$f_i = 1000 * 2^{(i+1)b/2} \quad (4.3)$$

donde f_i es la frecuencia central de filtro i -ésimo expresada en Hertz, i indicada el índice de la banda, y b es el tipo de análisis de banda, igual a 1 para el análisis de octava, 1/3 para el análisis de 1/3 de octava, 1/6 para el análisis de 1/6 de octava, 1/12 para el análisis de 1/12 de octava y 1/24 para el análisis de 1/24 de octava.

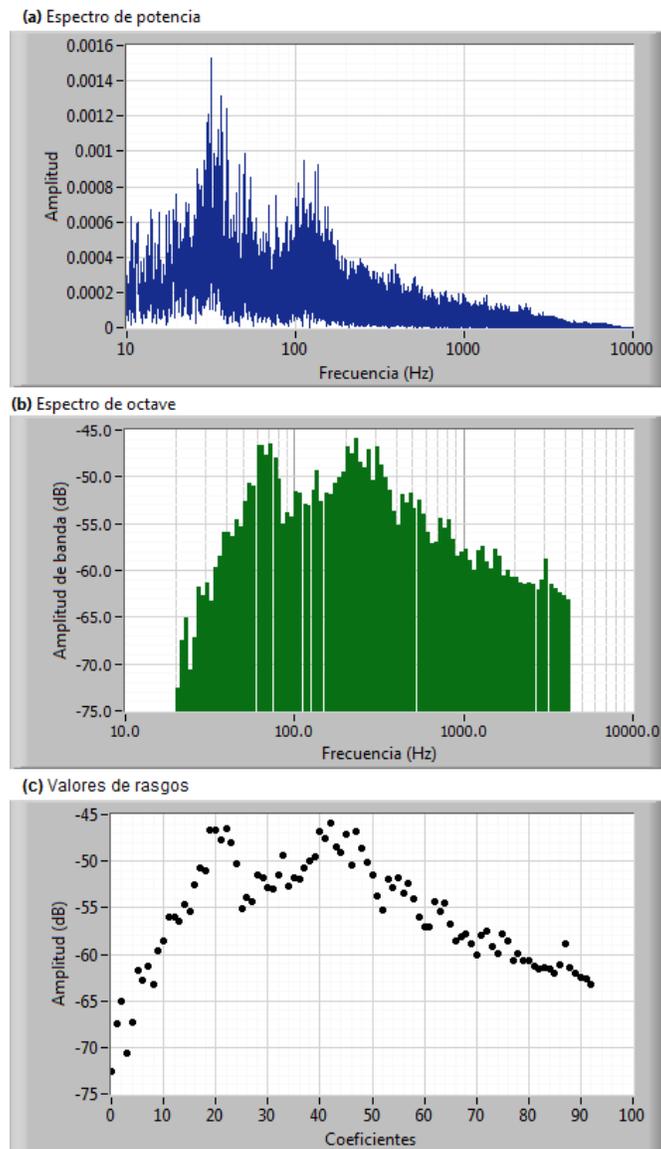


Fig. 4-14. Extracción de rasgos característicos mediante el análisis de octava para el A320: (a) espectro de potencia de la señal del ruido, (b) análisis de octava de la señal, (c) rasgos característicos resultantes.

En el anexo A se muestran los patrones característicos obtenidos para cada una de las clases empleando el análisis de 1/24 de octava.

4.5.4 Extracción de rasgos mediante el análisis MFCC

Como se describió en la sección 3.2.3, los rasgos mediante el análisis MFCC se derivan de la magnitud del espectro de la transformada de Fourier mediante la aplicación de un banco de filtros espaciados en la escala de frecuencia de Mel. El rango de frecuencias de análisis va de 20 Hz a 4000 Hz, con esto, los filtros se presentan en este rango de frecuencias. El número de filtros corresponde al número de rasgos característicos que se quieren extraer, en este trabajo se eligieron 40 rasgos MFCC, durante las pruebas este número presentó buenos resultados de reconocimiento y con mayor cantidad no aumentaba el nivel de reconocimiento. Se hace uso de la ecuación (3.30) para la creación de estos filtros. La Fig. 4.15 muestra el arreglo de filtros para realizar el análisis MFCC, 40 filtros triangulares espaciados logarítmicamente, van desde el rango de frecuencia de 20 Hz hasta 4000 Hz.

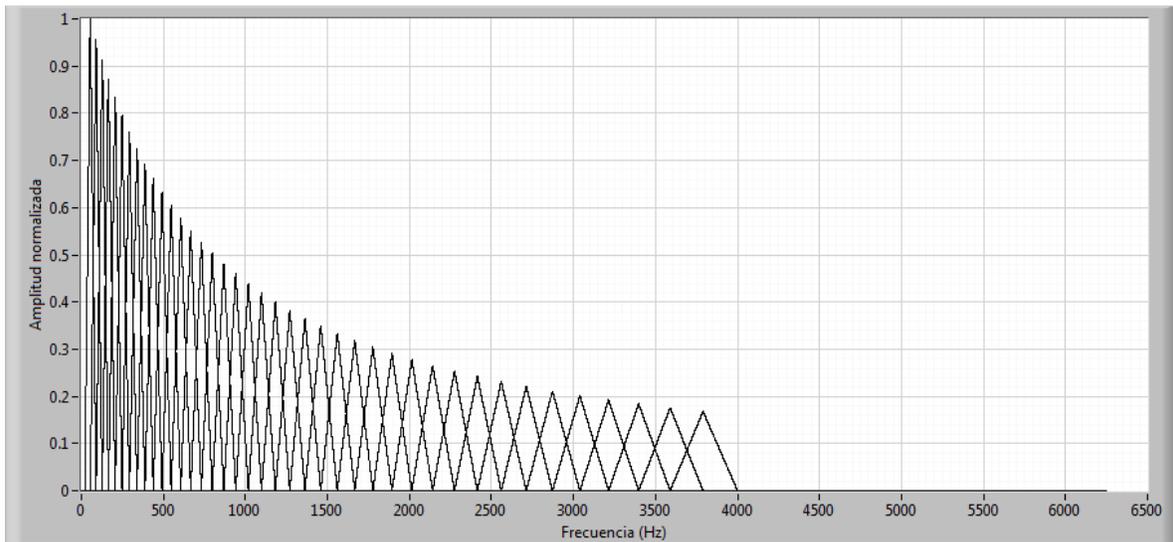


Fig. 4-15. Banco de filtros triangulares espaciados logarítmicamente.

Después de haber obtenido el espectro de frecuencia de la señal del ruido durante el despegue se obtiene la energía de esta señal, posteriormente se realiza el análisis empleando el bando de filtros (ver Fig. 4-15), mediante la convolución de éstas dos señales, la energía del espectro de frecuencia y el banco de filtros, al resultado se aplica el logaritmo, todo esto mediante la ecuación (3.31). En la Fig. 4-16 se observa una representación gráfica de la

convolución entre el banco de filtros triangulares y el espectro de potencia de señal del ruido.

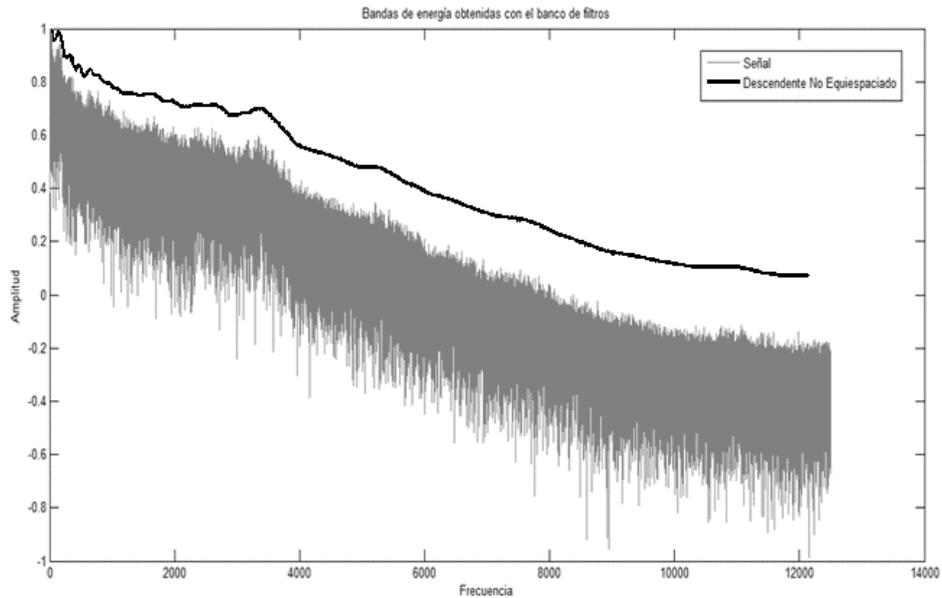


Fig. 4-16. Representación gráfica de la respuesta del análisis del banco de filtros triangulares (negro), espectro de potencia de la señal del ruido (gris).

Una vez obtenidos estos coeficientes mediante el banco de filtros, tantos coeficientes como filtros como se muestra en la Fig. 4-17, Posteriormente se aplica la transformada discreta coseno a este vector de coeficientes, mediante la ecuación 3.32, obteniendo así el vector resultante con los rasgos característicos utilizando el análisis MFCC.

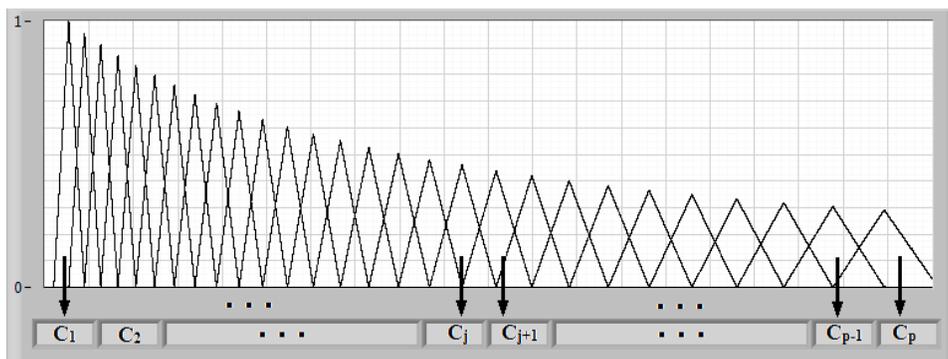


Fig. 4-17. Coeficientes obtenidos mediante el banco de filtros triangulares.

La segunda red MLP se entrena con los 40 rasgos característicos obtenidos por el análisis MFCC. Como se mencionó en la sección 3.2.3, este conjunto de características proporcionar información relacionada con la percepción auditiva humana. Una característica de los coeficientes MFCC es que no muestran una relación con el espectro de potencia de la señal del ruido como es el caso de otras técnicas de procesamiento de voz, tales como la envolvente LPC, análisis de octava, etc. La Fig. 4-18 (a) muestra los rasgos o coeficientes MFCC calculados para las muestras que pertenecen a la clase MD de acuerdo con la Tabla 4.2, que se compone de las aeronaves MD87 y MD88, así la Fig. 4-18 (b) muestra los rasgos MFCC para las aeronaves ATR-42, cada color representa los rasgos para las muestras registradas. El anexo A muestra los rasgos característicos para cada una de las clases, a través del análisis MFCC.

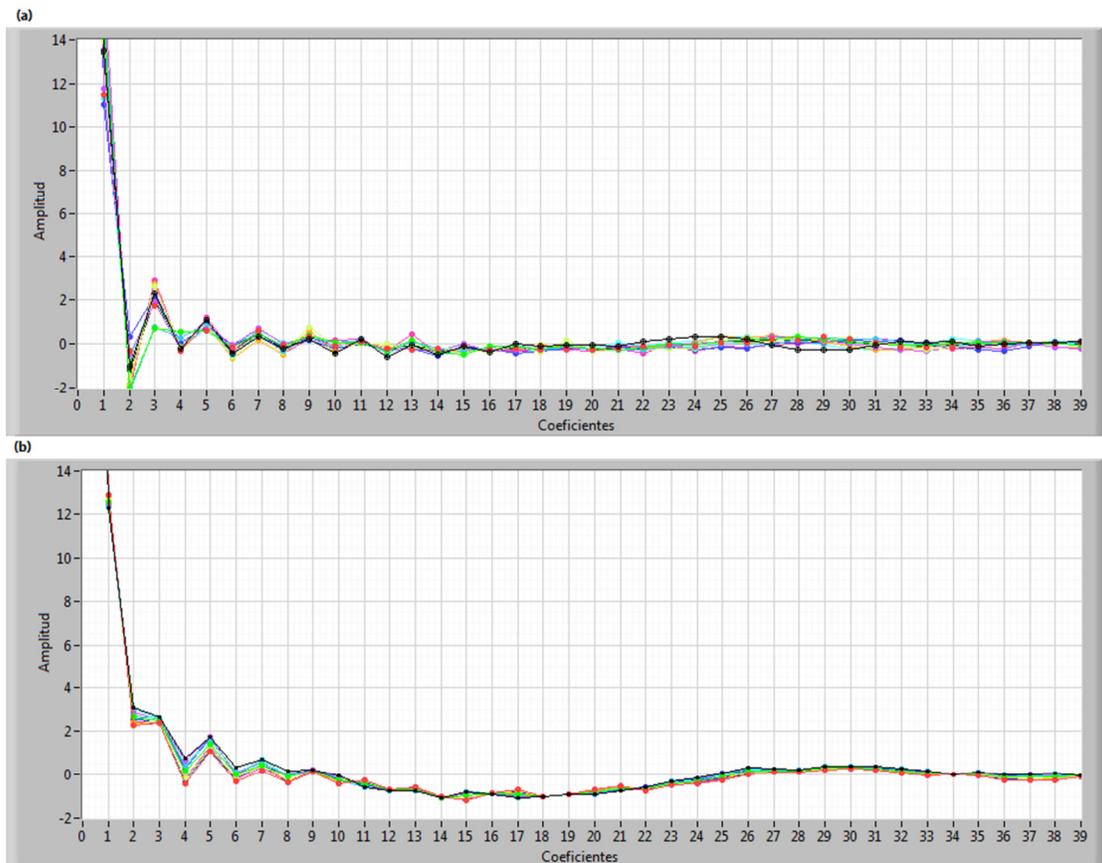


Fig. 4-18. Rasgos característicos calculados mediante MFCC: (a) para la señal del ruido del MD87, MD88, (b) para la señal de ruido del ATR-42. Cada color representa una muestra de la clase.

4.6 Conclusión del capítulo

Se presentó el sistema de medición para capturar las señales del ruido de las aeronaves durante el despegue, con una frecuencia de muestreo de 25kHz, esta frecuencia de muestreo permitió registrar las componentes de frecuencia con la información del ruido generado durante el despegue (un rango de 0 a 6000 Hz), también permitió obtener frecuencias por encima de 6000 Hz y hasta 12500 Hz, y se observó la atenuación de estas frecuencias para una señal típica del despegue de una aeronave. La etapa de pre-procesamiento permitió acondicionar las señales para la extracción de los rasgos a cada una de estas. Se obtuvieron 96 rasgos mediante el análisis 1/24 de octava y 40 rasgos utilizando el análisis MFCC.

Capítulo 5. Método de reconocimiento

En el presente capítulo, se describen las partes que componen el modelo de reconocimiento de clases de aeronaves mediante el patrón acústico. Se describen el modelo neural artificial, arquitectura, funciones de activación, y la etapa de normalización de datos de entrada, provenientes de los rasgos característicos descritos en el capítulo anterior. Posteriormente, se presenta la etapa de entrenamiento de las redes MLP: algoritmo de entrenamiento, conjuntos de aprendizaje, validación y prueba.

5.1 Etapa de reconocimiento

En este trabajo de tesis se utilizaron dos redes neuronales MLP en paralelo para el modelo computacional. Esta arquitectura proporciona la capacidad de mejorar la decisión mediante el uso de dos MLP. Cada MLP es una red de dos capas con propagación hacia adelante con función de activación log-sigmoide en las neuronas de la capa oculta y de salida. La Fig. 5-1 presenta cada una de las partes de la etapa de reconocimiento. La Fig. 5-2 muestra la gráfica de la función de activación, las salidas de la red van de 0 a 1.

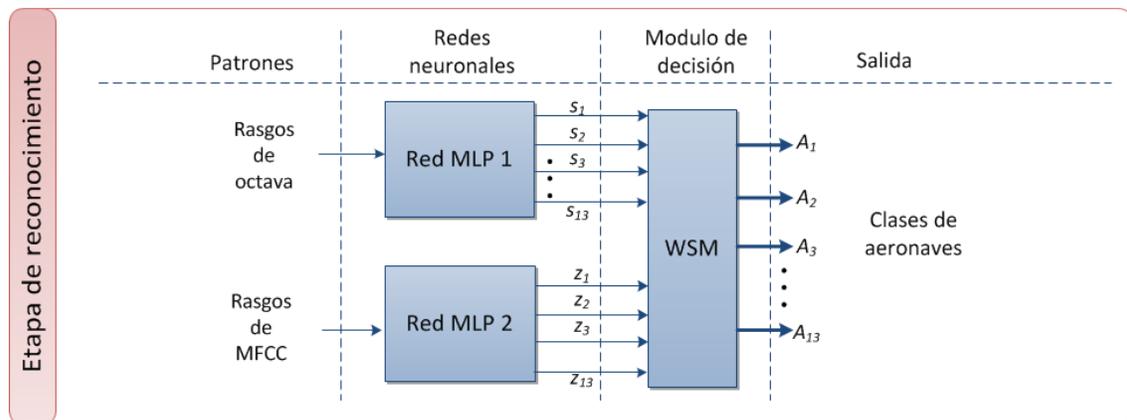


Fig. 5-1. Esquema que muestra las partes dentro de la etapa de reconocimiento.

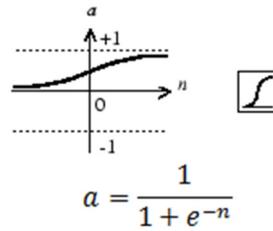


Fig. 5-2. Gráfica de la función de activación log-sigmoide.

5.2 Normalización de los datos de entrada

Antes de llevar a cabo el entrenamiento de las redes MLP se realizó una normalización del conjunto de rasgos, esta se efectuó mediante el uso de la ecuación (5.2), ya que es conveniente escalar los valores de entradas y de salida para que los datos dentro de la red caigan dentro de un rango específico entre -1 y 1, dados en las expresiones (5.1), mejorando el entrenamiento y por consiguiente la identificación (Mathworks, 2012).

$$y_{min} = -1 \quad (5.1a)$$

$$y_{max} = +1 \quad (5.1b)$$

Se asume que el conjunto de rasgos X (matriz de dimensión $N \times Q$) tiene un número finito de valores reales, y que los elementos de cada fila no son todos iguales, Y es el conjunto de rasgos normalizados (matriz de dimensión $M \times Q$, donde $M = N$).

$$y = (y_{max} - y_{min}) \cdot (x - x_{min}) / (x_{max} - x_{min}) + y_{min} \quad (5.2)$$

donde x es un vector fila de la matriz de rasgos X , y es el vector fila resultante con los valores normalizados de x , y_{min} es el valor mínimo (5.1a) para cada fila de Y , y_{max} es el valor máximo (5.1b) para cada fila de Y , x_{min} es el valor mínimo para cada fila de X , x_{max} es el valor máximo para cada fila de X . (Si $x_{max} = x_{min}$ o bien x_{max} o x_{min} no son finitos, entonces $y = x$ y no se produce cambio).

5.3 Entrenamiento de las redes neuronales multicapa

Para llevar a cabo la etapa de aprendizaje de las redes MLP, el conjunto de patrones para entrenamiento, validación y prueba se muestra en la tabla 5.1, se buscó que cada clase tuviera la misma cantidad de patrones para el entrenamiento y validación, para tener un número equilibrado de muestras al realizar el aprendizaje de cada una de las clases. En ambas redes neuronales se empleó el algoritmo *Resilient backpropagation* como algoritmo de entrenamiento supervisado (Riedmiller et al., 1993).

Tabla 5.1. Clases de aeronaves y conjuntos de patrones para entrenamiento/validación/prueba.

Clase de aeronaves (Nombre)	Conjunto de patrones Entrenamiento/Validación/Prueba
Airbus 318, 319, 320 (A320 1)	8/3/5
Airbus 318, 319, 320 (A320 2)	8/3/6
Airbus 318, 319, 320 (A320 3)	8/3/6
Airbus, Boeing 737–800 (A320_B737-800)	8/3/7
ATR-42 (ATR-42)	8/3/3
Boeing 737–100, 737–200 (B737-100/200)	8/3/11
Boeing 737–600, 737–700 (B737-600/700)	8/3/9
Boeing 747–400 (B747-400)	8/3/4
Fokker F100 (F100)	8/3/6
Fokker F100 2 (F100 2)	8/3/6
Fokker F100, Boeing 737–200 (F100_B737-200)	8/3/3
Fokker F100, Boeing 737–200 2 (F100_B737-200 2)	8/3/4
McDonnell Douglas 87, 88 (MD)	8/3/9
Total	104/39/79

La primer red MLP etiquetada como “red MLP 1” en la Fig. 5-1, utiliza los rasgos obtenidos mediante el análisis de octava para el proceso de entrenamiento, esta red tiene 96 neuronas en la capa de entrada, 30 neuronas en la capa oculta y 13 neuronas en la capa de salida. La figura 5-3 muestra la arquitectura de esta red, las entradas o_1, o_2, \dots, o_{96} , la capa intermedia con función de activación log-sigmoide y las trece salidas s_1, s_2, \dots, s_{13} , tantas salidas como el número de clases que se quiere identificar.

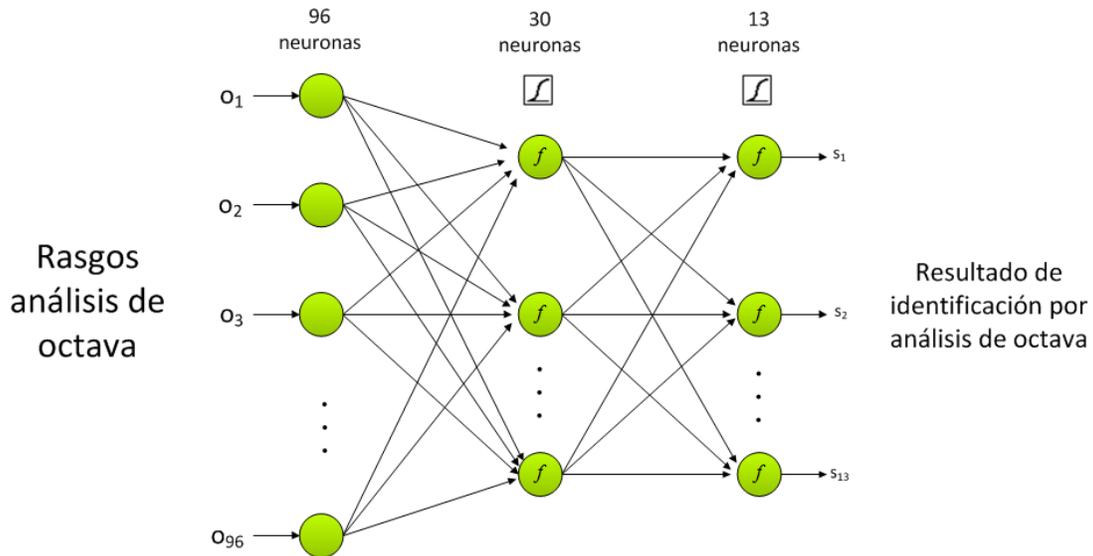


Fig. 5-3. Arquitectura de la red MLP para la identificación usando el análisis de octava.

La gráfica de entrenamiento de la red MLP para los rasgos de 1/24 de octava se muestra en la Fig.5-4, en la cual se observa que el mejor desempeño de validación ocurrió en la época 63.

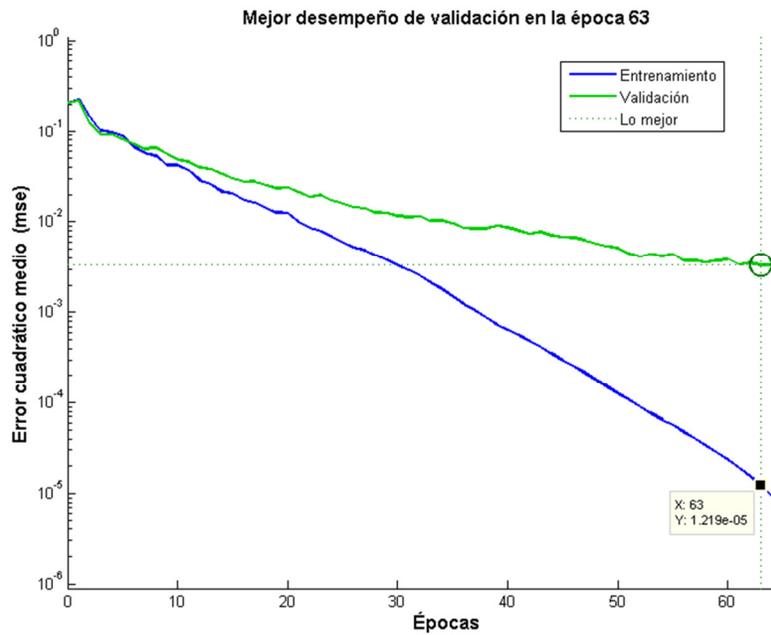


Fig. 5-4. Gráfica de entrenamiento para la red MLP 1.

La segunda red MLP etiquetada como “red MLP 2”, utiliza para su entrenamiento los rasgos obtenidos a través de la técnica de análisis MFCC, con 40 neuronas en la capa de entrada, 27 neuronas en la capa oculta y 13 neuronas en la capa de salida. En la Fig. 5-5 se observa la arquitectura para esta red, las entradas dadas por m_1, m_2, \dots, m_{40} , la capa oculta con función de activación log-sigmoide y las salidas z_1, z_2, \dots, z_{13} .

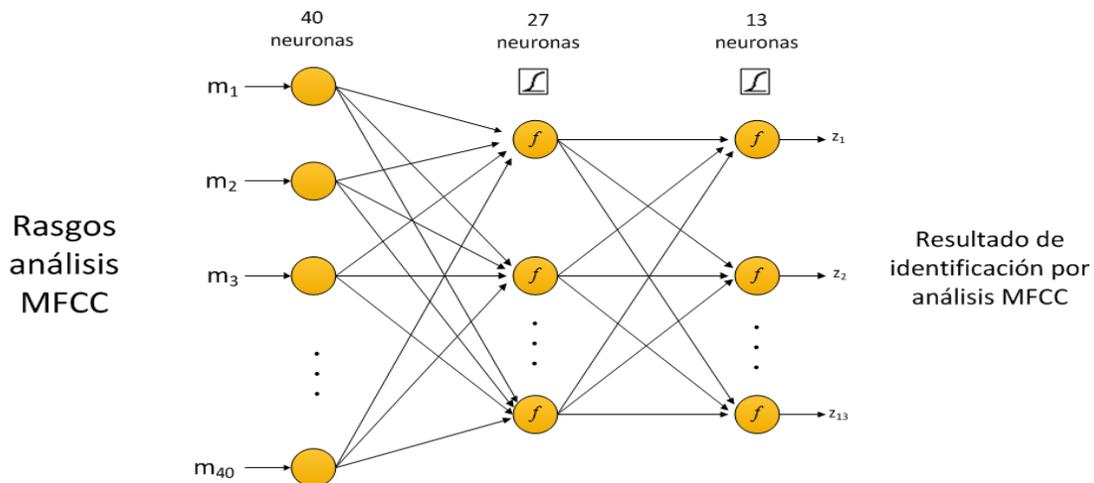


Fig. 5-5. Arquitectura de la red MLP para la identificación usando el análisis MFCC.

La gráfica de entrenamiento de la red MLP con los rasgos MFCC se muestra en la Fig. 5-6, el mejor desempeño de validación ocurrió en la época 27.

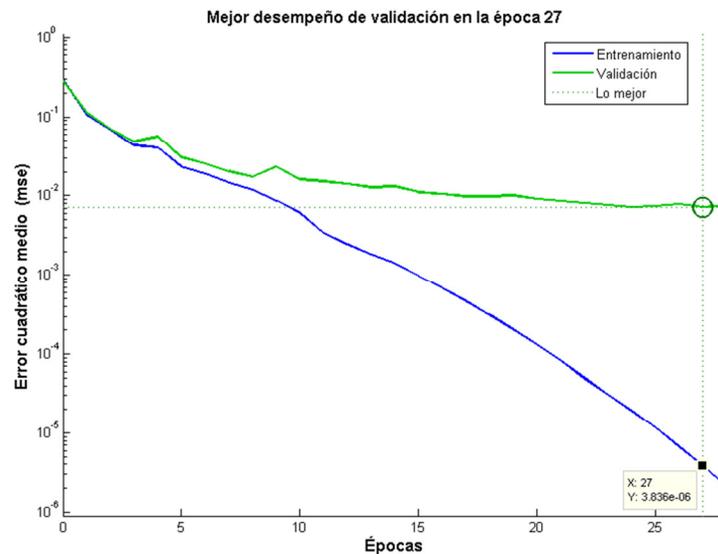


Fig. 5-6. Gráfica de entrenamiento de la red MLP 2.

5.4 Módulo de toma de decisión

Cada red neuronal entrega un conjunto de salida de 13 elementos (número de clases a identificar), s_1, s_2, \dots, s_{13} para la primer red MLP y z_1, z_2, \dots, z_{13} para la segunda red MLP, dado que tenemos dos salidas para cada clase, se utilizó un módulo de decisión para elegir entre una de estas dos salidas. Para esta tarea se utilizó el método de la suma ponderada (WSM, del inglés weighted sum method) el cual se basa en asignar pesos a los criterios dados por el módulo de toma de decisiones. Cada criterio tiene un peso no negativo, y las alternativas se clasifican mediante la evaluación de la suma ponderada de los criterios. Si hay M alternativas, la mejor alternativa es la que satisface la siguiente expresión:

$$A_{WSM}^* = \max_i \sum_{j=1}^N a_{ij} w_j \quad \text{para } i = 1, 2, \dots, M \quad (5.3)$$

donde A_{WSM}^* = al resultado WSM de la mejor alternativa, N = al número de criterios, a_{ij} = el valor actual de la i -ésima alternativa en términos del j -ésimo criterio, w_j = al peso de importancia del j -ésimo criterio. Por lo tanto, los pesos para el módulo de decisión se designan de acuerdo con las salidas de las redes neuronales para cada clase, por lo tanto, se le dio más peso a la salida de la red neuronal que mejor identifica una clase, se utilizó este mismo enfoque en resto de las clases.

Por ejemplo, en la Tabla 6.1 se observa que la red neural MLP 1 identificó sin errores la clase A320 2, pero ésta misma clase fue identificada con un error por la red neuronal MLP 2. Por lo tanto, a la salida de la red neuronal MLP 1 para la clase A320 2 se le otorgó más peso que a la salida de la red neuronal MLP 2 para esta misma clase. La Fig. 5-7 muestra el módulo de toma de decisión dentro del modelo reconocimiento.

Los valores propuestos en el módulo de decisión para cada una de las salidas de las redes MLP 1 y 2 se muestran en la Tabla 5.2, en ella se puede observar la prioridad que se otorga a la salida de una red MLP con respecto a la otra, según la clase a reconocer.

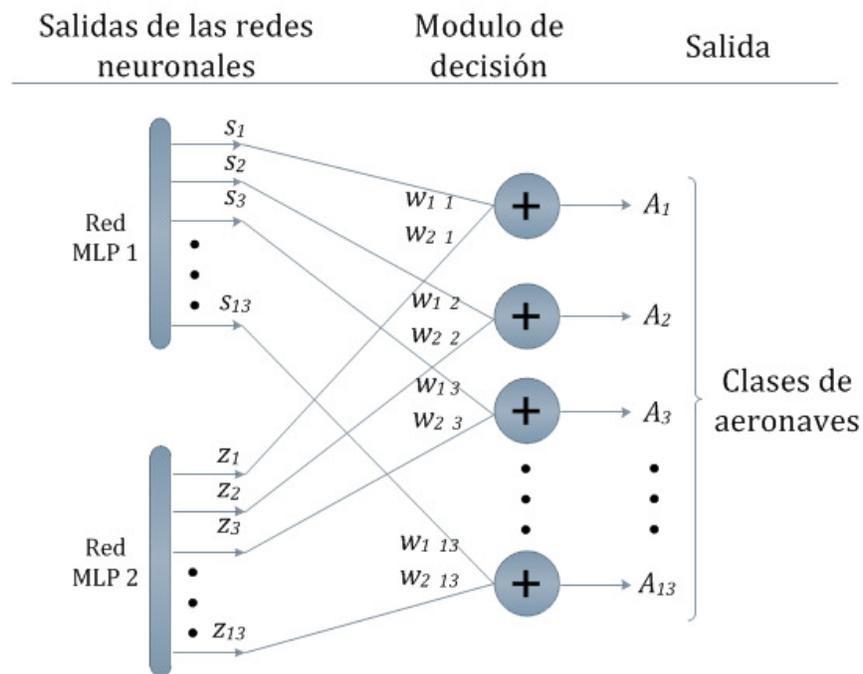


Fig. 5-7. Esquema del módulo para la toma de decisión en el modelo de reconocimiento neuronal.

Tabla 5.2. Valores propuestos en los pesos para el módulo de decisión.

Clase de aeronaves (Nombre)	Pesos:	
	MLP 1	MLP 2
Airbus 318, 319, 320 (A320 1)	0.3	0.7
Airbus 318, 319, 320 (A320 2)	0.6	0.4
Airbus 318, 319, 320 (A320 3)	0.7	0.3
Airbus, Boeing 737–800 (A320_B737-800)	0.5	0.5
ATR-42 (ATR-42)	1	1
Boeing 737–100, 737–200 (B737-100/200)	1	1
Boeing 737–600, 737–700 (B737-600/700)	0.4	0.6
Boeing 747–400 (B747-400)	0.4	0.6
Fokker F100 (F100)	0.5	0.5
Fokker F100 2 (F100 2)	0.5	0.5
Fokker F100, Boeing 737–200 (F100_B737-200)	0.7	0.3
Fokker F100, Boeing 737–200 2 (F100_B737-200 2)	0.5	0.5
McDonnell Douglas 87, 88 (MD)	1	0

5.5 Conclusión del capítulo

En este capítulo se presentó el modelo de reconocimiento neuronal basado en dos redes neuronales MLP operando en paralelo, la primera red se entrenó con los rasgos de octava y se obtuvo una certeza en el reconocimiento del 78%, la segunda se entrenó a partir de los rasgos MFCC y logró un reconocimiento del 80%. En ambas redes se utilizó la función de activación log-sigmoide para las neuronas de la capa oculta y de salida, el algoritmo de entrenamiento fue el resilient backpropagation. Dado que se tiene dos salidas por cada clase, una por cada red MLP, se utilizó un módulo de toma de decisión para dar prioridad a una de las salidas de las redes.

Capítulo 6. Pruebas y resultados

En este capítulo, se muestran las pruebas realizadas y los resultados obtenidos en el desarrollo del modelo computacional para el reconocimiento de aeronaves. En la parte inicial se presenta y describe la implementación del modelo, posteriormente se describen las pruebas y las condiciones de éstas, por último, se exponen los resultados obtenidos.

6.1 Modelo computacional para el reconocimiento de aeronaves

La estructura principal del modelo computacional se encuentra formada por una etapa para extracción de rasgos característicos, descrito en el capítulo 4, y la etapa de reconocimiento neuronal, descrito en el capítulo 5. La Fig. 6-1 muestra el esquema del modelo computacional, en éste se observa en la parte superior la extracción de rasgos mediante el pre-procesamiento y procesamiento, y en la parte inferior la etapa de reconocimiento basado en redes MLP y un módulo de decisión.

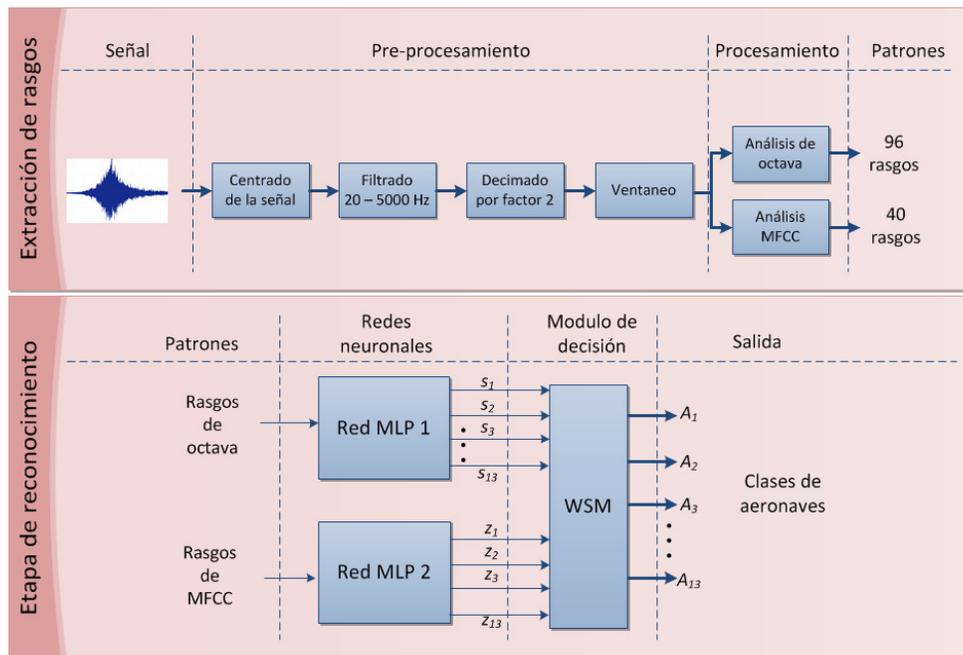


Fig. 6-1. Diagrama de bloques del modelo computacional para el reconocimiento.

6.1.1 Implementación del modelo computacional para el reconocimiento de aeronaves

Para la implementación se utilizó la plataforma de desarrollo LabVIEW® de National Instruments. LabVIEW® es un entorno de desarrollo con un lenguaje de programación gráfico que ayuda a ingenieros y programadores a escalar desde el diseño hasta pruebas y desde sistemas pequeños hasta grandes sistemas. Ofrece integración sin precedentes con software existente y hardware al aprovechar las últimas tecnologías de cómputo. La Fig. 6-2 muestra la programación gráfica del modelo de reconocimiento neuronal, la interfaz gráfica desarrollada para el modelo computacional de reconocimiento se aeronaves se muestra en la Fig. 6-3. El anexo C muestra el diagrama Entidad-Relación de la base de datos para recuperar la información de la clase a la que pertenece la aeronave identificada.

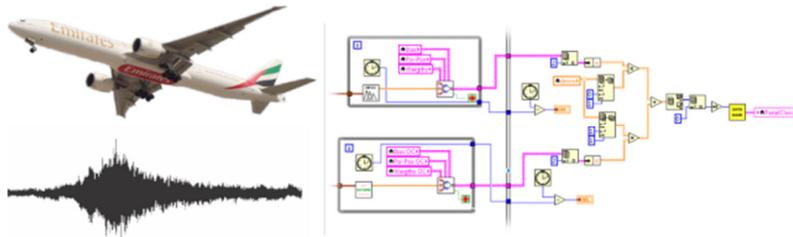


Fig. 6-2. Modelo de reconocimiento neuronal empleando programación gráfica con LabVIEW®.

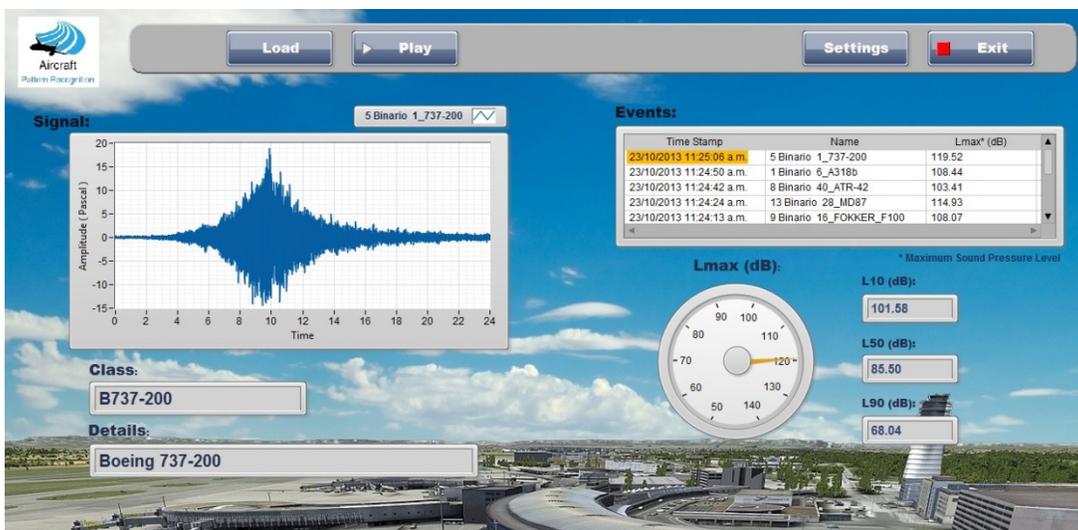


Fig. 6-3. Interfaz gráfica del modelo computacional para el reconocimiento de clases de aeronaves.

6.2 Procedimiento experimental

Durante el desarrollo e implementación del modelo computacional para el reconocimiento de aeronaves se realizaron diferentes pruebas experimentales. A lo largo de este proceso se requirió la configuración de las redes MLP, ajustando sus pesos y bias durante el proceso de entrenamiento. Lo anterior permitió acordar los parámetros necesarios para la configuración del módulo de toma de decisión. Una vez hecho esto, fue posible efectuar las pruebas experimentales al modelo computacional para el reconocimiento de aeronaves. Para esto, se realizaron los siguientes experimentos:

- Prueba de reconocimiento a la red MLP mediante el uso de rasgos de octava.
- Prueba de reconocimiento a la red MLP mediante el uso de rasgos MFCC.
- Prueba al modelo computacional de reconocimiento de aeronaves basado en dos redes neuronales artificiales y un módulo de decisión a sus salidas.

6.2.1 Prueba a la red neural para rasgos de octava.

Posterior al proceso de entrenamiento, validación e implementación de la red MLP 1 con base en la distribución de los conjuntos de patrones de la Tabla 5.1, damos paso a la evaluación de ésta, para ello se realizó la etapa de prueba con el conjunto de patrones para éste propósito, se utilizó un total de 79 tuplas.

Se introdujeron cada una de las tuplas a la red MLP 1, registrando el resultado de reconocimiento obtenido y se comparó con el resultado esperado, marcando las muestras que se reconocieron incorrectamente. La Tabla 6.1 presenta el resultado de reconocimiento de la red MLP 1 para ésta prueba experimental.

Tabla 6.1. Resultado de reconocimiento para la red neuronal que emplea rasgos de octava.

Clase de aeronave	Conjunto de Prueba	Red MLP 1
		Análisis Octava No. de errores
A320 1	5	2
A320 2	6	0
A320 3	6	1
A320_B737-800	7	1
ATR-42	3	0
B737-100/200	11	2
B737-600/700	9	2
B747-400	4	0
F100	6	1
F100 2	6	0
F100_B737-200	3	2
F100_B737-200 2	4	1
MD	9	4
Total	79	16

6.2.2 Prueba a la red neural para rasgos MFCC

Ahora toca el turno de efectuar la evaluación a la red MLP 2, una vez realizada su implementación, entrenamiento y validación, se procede a realizar la etapa de prueba a esta red. También se introdujeron las 79 tuplas del conjunto de prueba dispuesto en la Tabla 5.1, se registraron y corroboraron los resultados obtenidos con los esperados, también marcando las muestras reconocidas incorrectamente. Los resultados de ésta prueba experimental se presenta en la Tabla 6.2, indica la cantidad de errores obtenidos en cada clase.

6.2.3 Prueba al modelo de reconocimiento con el módulo de decisión

Las pruebas experimentales realizadas en las dos subsecciones anteriores permitieron establecer los parámetros de configuración y elaboración del módulo de toma de decisión requerido en este trabajo, el cual basa el ajuste de sus pesos en los resultados de las dos pruebas anteriores, el desarrollo se describe ampliamente en la sección 5.4, los parámetros de los pesos del módulo se muestran en la Tabla 5.2.

Tabla 6.2. Resultado de reconocimiento para la red neuronal que emplea rasgos MFCC.

Clase de aeronave	Conjunto de Prueba	Red MLP 2
		Análisis MFCC
		No. de errores
A320 1	5	1
A320 2	6	1
A320 3	6	0
A320_B737-800	7	1
ATR-42	3	0
B737-100/200	11	1
B737-600/700	9	1
B747-400	4	0
F100	6	0
F100 2	6	1
F100_B737-200	3	1
F100_B737-200 2	4	1
MD	9	3
Total	79	11

Esta prueba experimental se realiza al modelo computacional de la Figura 6.1, donde se tienen implementadas cada una de las partes que allí se muestra. La etapa de extracción de rasgos, la cual incluye la sección de pre-procesamiento y la de procesamiento; la etapa de reconocimiento neural, ésta contiene las redes MLP para rasgos de octava y para rasgos MFCC y adicionalmente el módulo de toma de decisión.

El proceso de experimentación se llevó a cabo ingresando cada una de los 79 tuplas del conjunto de prueba previsto para este propósito, ver Tabla 5.1. Posteriormente se registró el resultado obtenido y se validó con el resultado esperado, marcando las muestras que se reconocieron incorrectamente. El resultado de esta prueba experimental permitió conocer el nivel de reconocimiento total del modelo computacional para el reconocimiento de aeronaves, obteniendo un total de 7 muestras reconocidas incorrectamente del conjunto total de 79 muestras de prueba.

La Tabla 6.3 muestra el total de muestras identificadas incorrectamente, etiquetadas como “modelo propuesto”; así también, se presenta la comparativa con el modelo de

reconocimiento existente en la literatura (Rojo R et al., 2008), etiquetado como “modelo existente”. Se observa que el modelo computacional desarrollado en este trabajo tiene la capacidad de reconocer muestras que el modelo existente no identifica correctamente; por lo tanto, incrementando el nivel de reconocimiento.

Tabla 6.3. Resultado de reconocimiento para el modelo computacional y comparación con el existente.

Clase de aeronave	Conjunto de prueba	No. de errores por clase	
		Modelo existente	Modelo propuesto
A320 1	5	0	0
A320 2	6	0	0
A320 3	6	2	1
A320_B737-800	7	1	1
ATR-42	3	0	0
B737-100/200	11	1	1
B737-600/700	9	2	2
B747-400	4	0	0
F100	6	0	0
F100 2	6	0	0
F100_B737-200	3	0	0
F100_B737-200 2	4	0	0
MD	9	3	2
Total	79	9	7

6.3 Conclusión del capítulo

En este capítulo se presentaron las pruebas experimentales para evaluar el desempeño en el reconocimiento de aeronaves. Se evaluó a cada una de las dos redes MLP, y se observó la capacidad de identificación de las redes a cada una de las muestras de prueba, la red MLP con rasgos de MFCC presentó un mejor porcentaje de reconocimiento sobre la red MLP con rasgos de octava. Estos resultados permitieron el ajuste de los pesos en el módulo de toma de decisión. Posteriormente se evaluó el desempeño del modelo computacional con el módulo de toma de decisión y se logró un reconocimiento del 83%.

Capítulo 7. Conclusiones y trabajo futuro

En este capítulo se presentan las conclusiones alcanzadas durante el desarrollo del trabajo. Se describen las aportaciones obtenidas conforme a los objetivos planteados, así como las conclusiones obtenidas durante el desarrollo de las pruebas. Finalmente, se describen algunos puntos a realizar como trabajos futuros motivando la continuación del presente trabajo de investigación.

7.1 Conclusiones

Los sistemas de monitoreo de ruido ambiental son de mucha importancia en la actualidad, debido a la gran cantidad de fuentes de ruido que se encuentran en las ciudades desarrolladas y en vías de desarrollo, así como por los efectos potencialmente nocivos asociados al ruido (ver Anexo B), más aún en las cercanías de los aeropuertos con el gran aumento en las operaciones en éste tipo de transporte. Los sistemas que se encuentran en operación en las cercanías de los aeropuertos no cuentan con la capacidad de reconocer la clase de aeronave asociada a los niveles de ruido que producen durante el despegue.

En el presente trabajo, se ha realizado la implementación de modelo computacional para el reconocimiento de aeronaves basado en dos redes neuronales artificiales y un módulo de toma de decisión a sus salidas, que hace uso del patrón acústico de las aeronaves producido durante el despegue, permitiendo su uso en sistemas de monitoreo de ruidos ambientales localizados en las cercanías de los aeropuertos, proveyendo a estos la capacidad de identificar la clase de aeronave que produce tal nivel de ruido y proporcionar información complementaria a los sistemas instalados actualmente.

La utilización de técnicas de procesamiento de voz para el análisis de las señales de ruido de las aeronaves producidas durante el despegue, fue posible para la extracción de rasgos característicos, y permitió utilizarlos para la identificación de clases de aeronaves.

En cuanto a la comparación de eficiencia de reconocimiento de aeronaves empleando las técnicas de procesamiento de voz para la extracción de rasgos característicos, se ha podido identificar que técnica obtiene un mejor porcentaje de reconocimiento. La técnica MFCC presentó mejor eficiencia de reconocimiento con un 80%, posteriormente la técnica de análisis de Octava representó 78% de reconocimiento, por encima de la técnica PLP y Cepstrum con un reconocimiento del 77% y 76% respectivamente.

Se implementó el modelo de reconocimiento basado en redes neuronales artificiales, haciendo uso de dos redes MLP operando en paralelo, la primera utiliza los rasgos extraídos empleando la técnica de Octava, y la segunda haciendo uso de los rasgos extraídos mediante la técnica MFCC. Se utilizó un módulo de decisión a las salidas de ambas redes MLP para obtener un resultado de reconocimiento por clase.

El modelo computacional fue capaz de realizar el reconocimiento de clases de aeronaves mediante señales de ruido registradas durante el despegue, las pruebas realizadas permitió observar una mejora en el reconocimiento de las clase debido a los patrones añadidos con los métodos de extracción de rasgos característicos relacionados con la percepción auditiva humana (MFCC). Se logró una efectividad de reconocimiento total de 83%. El modelo propuesto se comportó mejor que el propuesto por (Sánchez-Fernández et al., 2012), 3% más en comparación con el 80% del modelo existente. Además, es importante señalar que estos patrones están contaminados con voces, ladridos, sonidos de aves, música de fondo, etc., y se han obtenido en diversas condiciones climáticas durante 13 mediciones distintas.

Con base en lo anterior los objetivos de la tesis fueron cumplidos, así mismo la hipótesis fue verificada.

7.2 Trabajo futuro

En cuanto a trabajo futuro se pueden destacar las siguientes oportunidades de estudio y mejora:

- Realizar más mediciones del despegue de aeronaves incrementaría la cantidad de muestras de la base de datos, dando la oportunidad de aumentar la cantidad de patrones por clase de aeronaves para el entrenamiento de la red neuronal y permitir una mejor clasificación. Contemplar características propias de la ciudad de México como: presión atmosférica, condiciones ambientales, etc. Así también, permitiría incluir nuevos modelos de aeronaves dentro de las clases existentes o la creación de clases nuevas.
- Estudiar el análisis de las señales de ruido registradas durante el despegue mediante técnicas novedosas de procesamiento de señales y voz, tales como: Wavelets, MFCC-Filtros Wavelets, etc. Permitir con esto, obtener patrones con características temporales y espectrales que suministren patrones con una mejor representación de las señales. Así también, sub-muestrear más la señal aplicado un decimado con factor 5, reduciendo el tiempo de cálculo.
- Mejorar el modelo de reconocimiento usando modelos neuronales alternativos, tales como memorias asociativas, máquinas de vector soporte, etc., los cuales han demostrado su capacidad para resolver problemas de clasificación.
- Combinar las propuestas anteriores con la segmentación espacio-temporal de la serie de tiempo del ruido del despegue.

Referencias bibliográficas

- AIC. (2008). *Policy and recommended practices handbook* (6th ed ed.). Geneva, Switzerland: Airports Council International (AIC).
- Airbus. (2007). *Flying by nature. Global market forecast 2007-2026*. Toulouse, France: Airbus SAS.
- Alt, R., & Wiley, S. (2004). A Generalized Wave Diagram for Moving Sources. *The Physics Teacher*, 42(9), 526-527.
- Alves-Pereira, M., & Castelo Branco, N. (2004). *Vibroacoustic disease* (Vol. 6).
- ANSI. (2004). Standard S1.11-2004: Specification for octave band and fractional octave band analog and digital filters: American National Standards Institute.
- Asensio, C., Ruiz, M., & Recuero, M. (2010). Real-time aircraft noise likeness detector. *Appl. Acoust.*, 71(6), 539-545. doi: <http://dx.doi.org/10.1016/j.apacoust.2009.12.005>
- Atal, B. S., & Hanauer, S. (1971). Speech Analysis and Synthesis by Linear Prediction of the Speech Wave. *J. Acoust. Soc. Am.*, 50(2B), 637-655.
- Barbo, B., Rosin, C., & Machet, J. M. (2009). A pattern recognition approach for aircraft noise detection.
- Bekebrede, G., & Hagenberg, T. (1984). Design of a flight track and aircraft noise monitoring system. *14th International council of the aeronautical sciences*, 2, 1096-1105.
- Berglund, B., Lindvall, T., & Schwela, D. H. (1995). *Community noise*: World Health Organization (WHO).
- Berglund, B., Lindvall, T., & Schwela, D. H. (1999). *Guidelines for Community Noise*: World Health Organization (WHO).
- Bogert, B., Healy, M., & Tukey, J. (1963). *The quefreny alanalysis of time series for echoes: Cepstrum, pseudo-autocovariance, cross-Cepstrum and saphe cracking*. Paper presented at the Proc. Symp. on Time Series Analysis.
- Brüel & Kjær. (2000). *Environmental noise*: Brüel & Kjær sound & vibration measurement A/S.
- Brüel & Kjær. (2012). ANOMS: Airport noise and operations monitoring system (Brochure). Denmark: Brüel & Kjær.
- Couvreur, L., & Laniray, M. (2004). Automatic noise recognition in urban environments based on artificial neural networks and hidden Markov models. *Inter-noise 2004 proceedings*.
- Crocker, M. J. (1998). *Handbook of acoustics*: John Wiley & Sons Inc.
- Chambers, J. (2005). Noise Pollution. In L. Wang, N. Pereira & Y.-T. Hung (Eds.), *Advanced Air and Noise Pollution Control* (Vol. 2, pp. 441-452): Humana Press.
- Davis, S., & Mermelstein, P. (1980). Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences. *Acoustics, Speech and Signal Processing, IEEE Transactions on*, 28(4), 357-366.
- Durbin, J. (1960). The fitting of time series models. *Rev. Inst. Int. Stat.*, 28(3), 233-244.
- Eurocontrol. (2008). Eurocontrol long-term forecast: IFR flight movements 2008-2030. Brussels, Belgium: Doc No DAS/DIA/STATFOR 302.
- European Parliament. (2002). Directive 2002/49/EC of the European Parliament and of the Council of 25 June 2002 relating to the assessment and management of environmental noise.
- FAA. (2009). Aerospace forecast: Fiscal years 2009-2025: Federal aviation administration.

- GAO. (2000). Aviation and the environment: Airport operations and future growth present environmental challenges: General accounting office (GAO). Document No: GAO/RCED-00-153.
- Goldhor, R. S. (1993). *Recognition of environmental sounds*. Paper presented at the Acoustics, Speech, and Signal Processing, 1993. ICASSP-93., 1993 IEEE International Conference on.
- Gottlob, D. (1995). Regulations for community noise: Noise/News International.
- Hansell, A. L., Blangiardo, M., Fortunato, L., Floud, S., Hoogh, K. d., Fecht, D., . . . Elliott, P. (2013). Aircraft noise and cardiovascular disease near Heathrow airport in London: small area study. *BMJ*, *347*. doi: 10.1136/bmj.f5432
- Harris, C. (1995). *Handbook of acoustical measurements and noise control*: McGraw-Hill.
- Haykin, S. (1998). *Neural networks - A comprehensive foundation* (2 ed ed.): Prentice-Hall.
- Hede, A. (1998). Environmental noise regulation: A public policy perspective. Sydney, Australia: In N.L. Carter and R.F.S. Job (eds.).
- Hermansky, H. (1990). Perceptual linear predictive (PLP) analysis of speech. *J. Acoust. Soc. Am.*, *87*(4), 1738-1752.
- Huang, X., Acero, A., & Hon, H. (2001). *Spoken language processing: A guide to theory, algorithm, and system development*: Prentice Hall.
- ICAO. (2007). *Update of the balanced approach guidance*: International Civil Aviation Organization (ICAO).
- ICAO. (2008). *Recommended Method for Computing Noise Contours Around Airports*. . Quebec: International Civil Aviation Organization (ICAO).
- IEC. (1995). Standard IEC1260: Electroacoustics - Octave-band and fractional-octave-band filters: International Electrotech Commission.
- IPCC. (1999). Aviation and the global atmosphere. Cambridge University Press.
- Kinsler, L. E., Frey, A. R., Coppens, A. B., & Sanders, J. V. (1999). *Fundamentals of acoustics*: John Wiley & Sons.
- Knipschild, P. (1977). V. Medical effects of aircraft noise: Community cardiovascular survey. *Int. Arch. Occ. Env. Hea*, *40*(3), 185-190.
- Kryter, K. D. (1985). *The effects of Noise in Man*: Academic Press.
- Levinson, N. (1947). The Wiener RMS error criterion in filter design and prediction. *J. Math. Phys.*, *25*(4), 261-278.
- Makhoul, J. (1975). Linear prediction: A tutorial review. *Proceedings of the IEEE*, *63*(4), 561-580. doi: 10.1109/PROC.1975.9792
- Makhoul, J., & Cosell, L. (1976). *An LPC vocoder with linear predictive spectral warping*. Paper presented at the Acoustics, Speech, and Signal Processing, IEEE International Conference on ICASSP '76.
- Martin-Houssart, G., & Rizk, C. (2002). Mesurer la qualite de vie dans les grandes agglomerations: Institut National de la Statistique et des etudes economiques.
- Mathworks. (2012). *Neural Network Toolbox: User's guide*: Mathworks Inc.
- McNamee, R., Burgess, G., Dippnall, W. M., & Cherry, N. (2006). Occupational noise exposure and ischaemic heart disease mortality. *Occup. Environ. Med.*, *63*(12), 813-819. doi: 10.1136/oem.2005.026245
- Michaud, D. S., Fidell, S., Pearsons, K., Campbell, K. C., & Keith, S. E. (2007). Review of field studies of aircraft noise-induced sleep disturbance. *J. Acoust. Soc. Am.*, *121*(1), 32-41.

- Möser, M. (2009). *Engineering Acoustics: An Introduction to Noise Control* (2nd ed.): Springer-Verlag Berlin Heidelberg.
- Noll, A. M. (1967). Cepstrum pitch determination. *J. Acoust. Soc. Am.*, 41(2), 293-309.
- Oppenheim, A. V., & Schaffer, R. W. (1989). *Discrete-time signal processing*. Englewood Cliffs, NJ: Prentice Hall.
- Ostrosky-Solís, F. (2001). *Toc toc, ¿Hay alguien ahí?* : Infored.
- Picone, J. W. (1993). Signal modeling techniques in speech recognition. *Proc. IEEE*, 81(9), 1215-1247. doi: 10.1109/5.237532
- Prats i Menéndez, X. (2011). Contributions to the optimisation of aircraft noise abatement procedures (Doctoral Thesis). Barcelona: Universitat politècnica de catalunya.
- Qi, L., & Yan, H. (2011). An Auditory-Based Feature Extraction Algorithm for Robust Speaker Identification Under Mismatched Conditions. *IEEE Trans. Audio Speech Lang. Processing*, 19(6), 1791-1801. doi: 10.1109/TASL.2010.2101594
- Recuero, M. (1994). *Ingeniería acústica*: Paraninfo.
- Riedmiller, M., & Braun, H. (1993, 1993). *A direct adaptive method for faster backpropagation learning: the RPROP algorithm*. Paper presented at the IEEE International Conference on Neural Networks.
- Robinson, D. W., & Dadson, R. S. (1956). A redetermination of the equal-loudness relations for pure tones. *Br. J. Appl. Phys.*, 7, 166-181.
- Rojas, R. (1996). *Neural Networks - A Systematic Introduction*. Berlin, Germany: Springer-Verlag.
- Rojo R, A. (2008). *Sistema de monitoreo de ruidos ambientales producidos por aviones en el AICM*. (Maestría en Ciencias), Centro de investigación en computación - IPN, México.
- Rojo R, A., Sánchez F, L. P., Felipe R, E., & Suárez G, S. (2008). Computational Model for Aircraft's Takeoffs Pattern Recognition *Progress in Pattern Recognition, Image Analysis and Applications* (Vol. 5197, pp. 14-21): Springer Berlin Heidelberg.
- Roy, A. (2003). La sensibilité des français à leur environnement de proximité. Societe – Les données de l'environnement: Institut français de l'environnement (IFEN).
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536.
- Sánchez-Fernández, L. P., Sánchez-Pérez, L. A., Carbajal-Hernández, J. J., & Rojo-Ruiz, A. (2012). Aircraft Classification and Acoustic Impact Estimation Based on Real-Time Take-off Noise Measurements. *Neural Process. Lett.*, 38(2), 239-259. doi: 10.1007/s11063-012-9258-5
- Sánchez-Pérez, L. A., Sánchez-Fernández, L. P., Suárez-Guerra, S., & Carbajal-Hernández, J. J. (2013). Aircraft class identification based on take-off noise signal segmentation in time. *Expert. Syst. Appl.*, 40(13), 5148–5159. doi: <http://dx.doi.org/10.1016/j.eswa.2013.03.017>
- Sánchez F, L. P., Suárez G, S., Pogrebnyak, O., & Oropeza R, J. L. (2007). Noise Pattern Recognition of Airplanes Taking Off: Task for a Monitoring System *Progress in Pattern Recognition, Image Analysis and Applications* (Vol. 4756, pp. 831-840): Springer Berlin Heidelberg.
- Schafer, R. W., & Rabiner, L. R. (1970). System for automatic formant analysis of voiced speech. *J. Acoust. Soc. Am.*, 47(2B), 634-648.
- Schroeder, M. R. (1977). Recognition of complex acoustic signals. *Life sciences research report - Abakon Verlag*, 5, 324.
- Sexto, L. F. (2007). *Como elegir un sonómetro*. Habana, Cuba: Instituto Superior Politécnico José Antonio Echeverría.

- Shannon, B. J., & Paliwal, K. K. (2003). *A comparative study of filter bank spacing for speech recognition*. Paper presented at the Microelectronic engineering research conference.
- Stevens, S. S. (1957). On the psychophysical law. *Psychol. Rev.*, *64*, 153-181.
- Stevens, S. S., Volkman, J., & Newman, E. B. (1937). A scale for the measurement of the psychological magnitude of pitch. *J. Acoust. Soc. Am.*, *8*, 185-190.
- UK-Parliament. (2003). *Postnote – Aviation and the environment. Report summary 195*. Oficina parlamentaria de ciencia y tecnología (www.parliament.uk/post).
- Vázquez S, E. F. (2007). *Estudios en ensambles de redes neuronales*. (Maestría en ciencias), CINVESTAV - IPN, Ciudad de México.
- Zheng, F., Zhang, G., & Song, Z. (2001). Comparison of different implementations of MFCC. *J. Comput. Sci. Technol.*, *16*(6), 582-589. doi: 10.1007/BF02943243

Anexo A. Conjunto de aeronaves y patrones extraídos por clase.

A.1 A320 1

Esta clase contiene los modelos de aeronaves Airbus 318, 319 y 320.

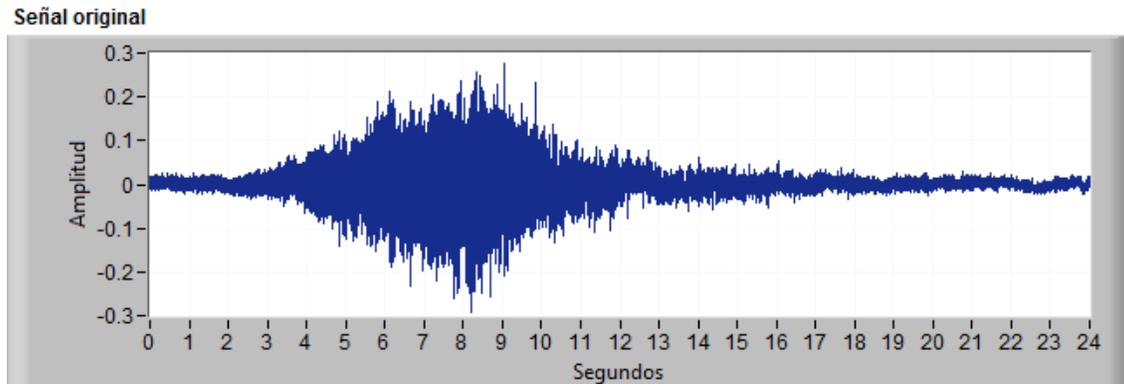


Fig. A.1-1 Señal de ruido registrado durante el despegue para la clase A320 1.

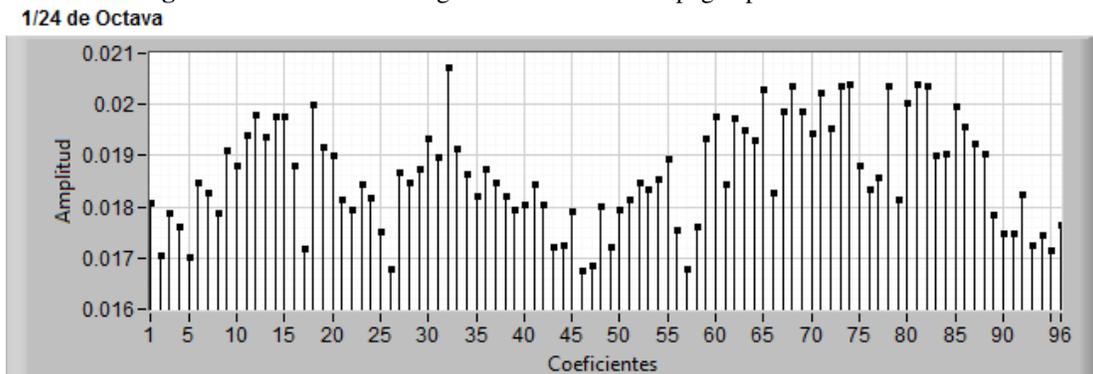


Fig. A.1-2 Patrón de 96 elementos mediante análisis 1/24 de Octava para la clase A320 1.

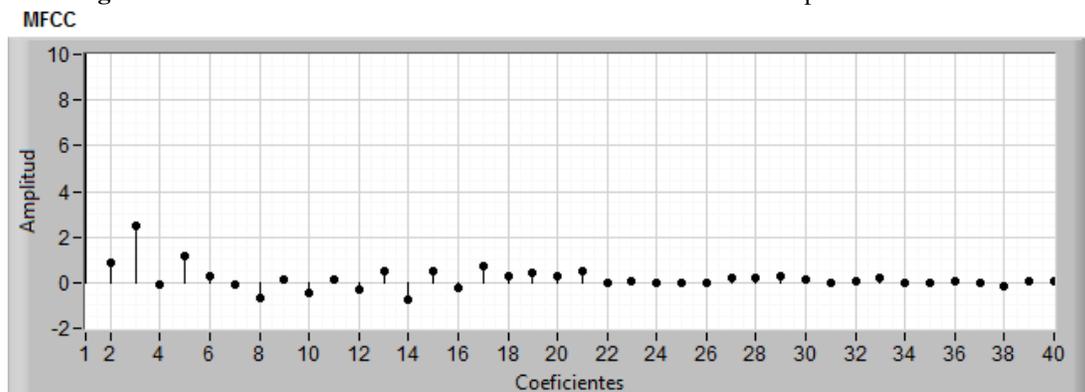


Fig. A.1-3 Patrón de 40 elementos a través del análisis MFCC para la clase A320 1.

A.2 A320 2

Esta clase contiene los modelos de aeronaves Airbus 318, 319 y 320.

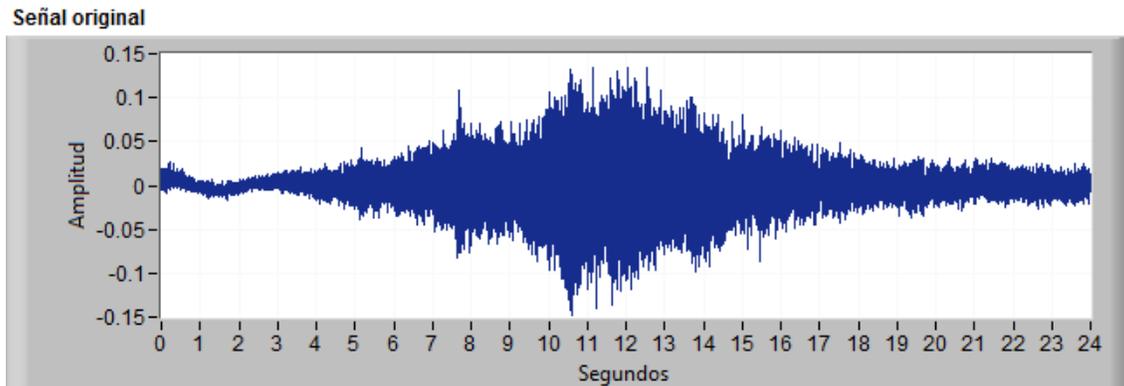


Fig. A.2-1 Señal de ruido registrado durante el despegue para la clase A320 2.

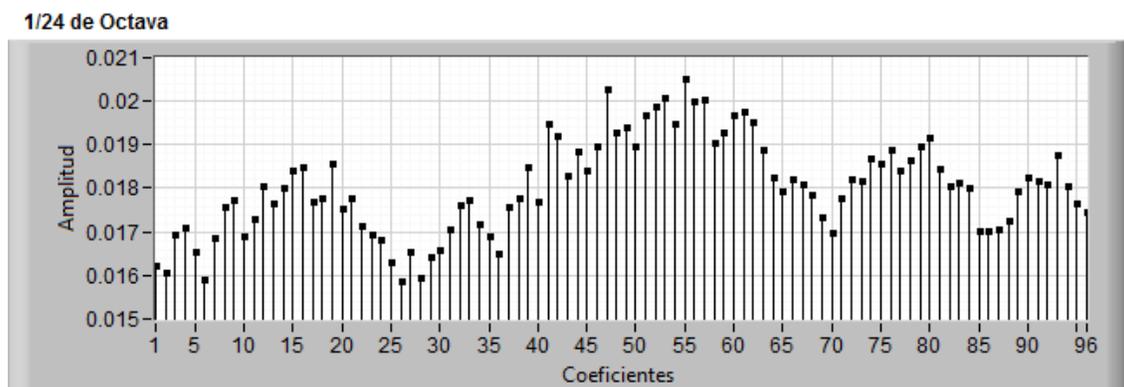


Fig. A.2-2 Patrón de 96 elementos mediante análisis 1/24 de Octava para la clase A320 2.

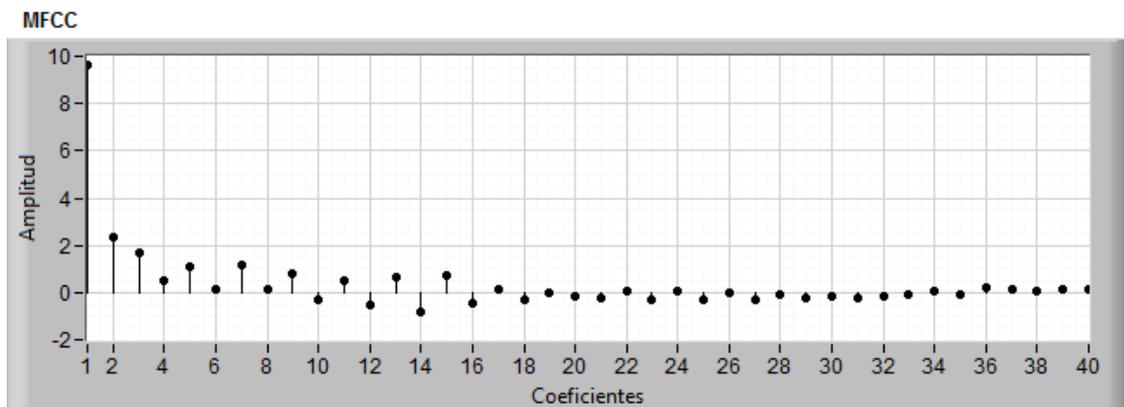


Fig. A.2-3 Patrón de 40 elementos a través del análisis MFCC para la clase A320 2.

A.3 A320 3

Esta clase contiene los modelos de aeronaves Airbus 318, 319 y 320.

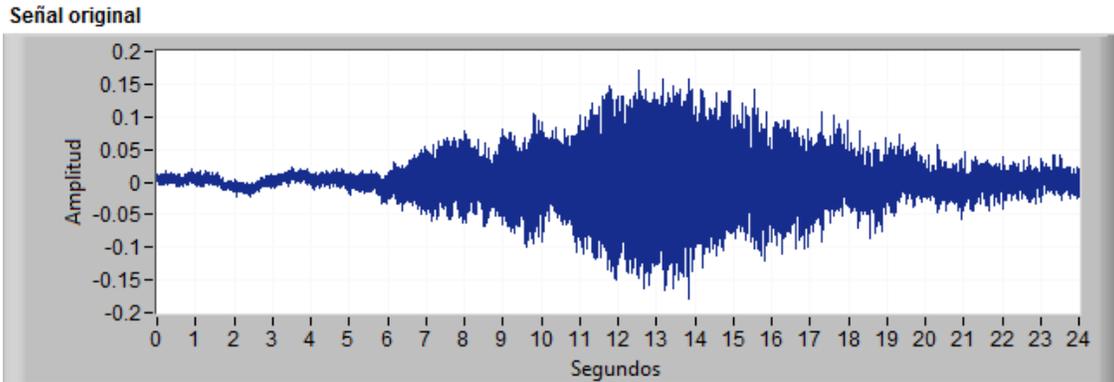


Fig. A.3-1 Señal de ruido registrado durante el despegue para la clase A320 3.

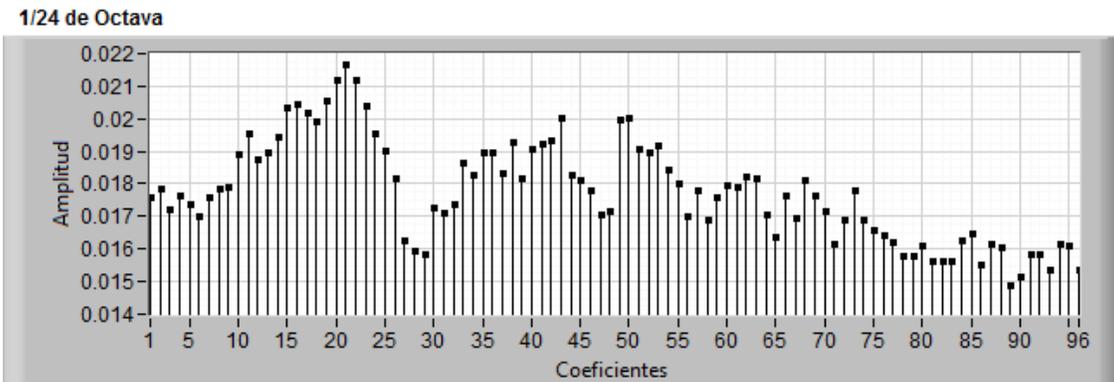


Fig. A.3-2 Patrón de 96 elementos mediante análisis 1/24 de Octava para la A320 3.

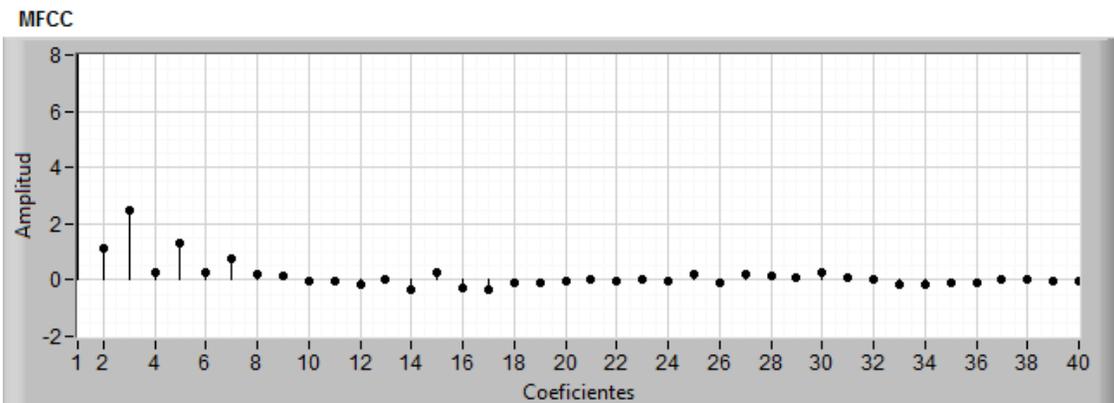


Fig. A.3-3 Patrón de 40 elementos a través del análisis MFCC para la clase A320 3.

A.4 A320_B737-800

Esta clase contiene los modelos de aeronaves Airbus 318, 319, 320 y Boeing 737-800.

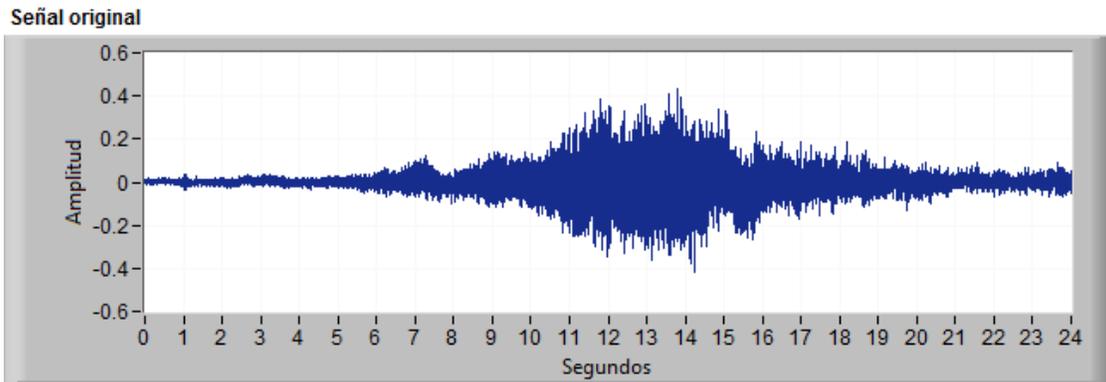


Fig. A.4-1 Señal de ruido registrado durante el despegue para la clase A320_B737-800.

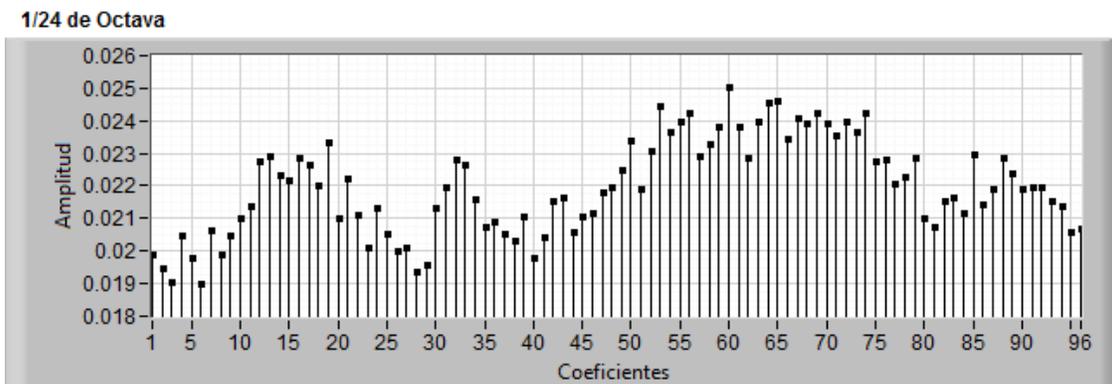


Fig. A.4-2 Patrón de 96 elementos mediante análisis 1/24 de Octava para la clase A320_B737-800.

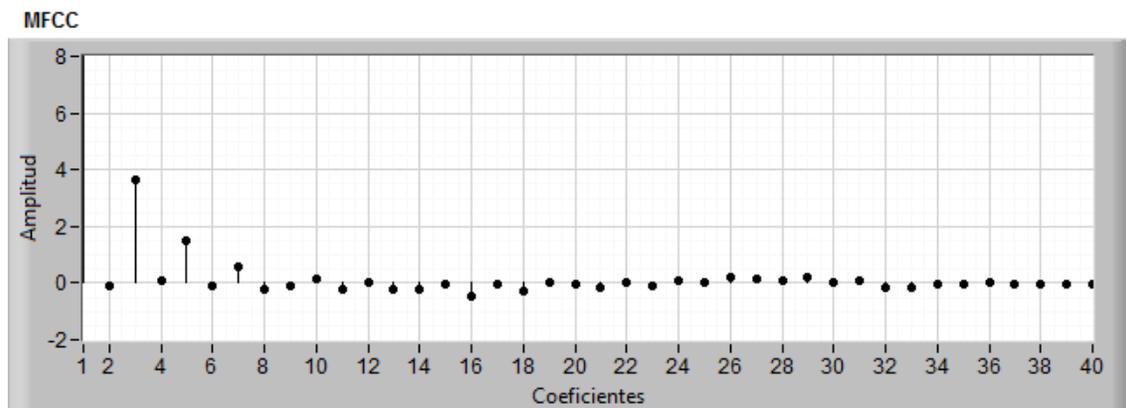


Fig. A.4-3 Patrón de 40 elementos a través del análisis MFCC para la clase A320_B737-800.

A.5 ATR-42

Esta clase contiene los modelos de aeronaves ATR-42-300 y ATR-42-500.

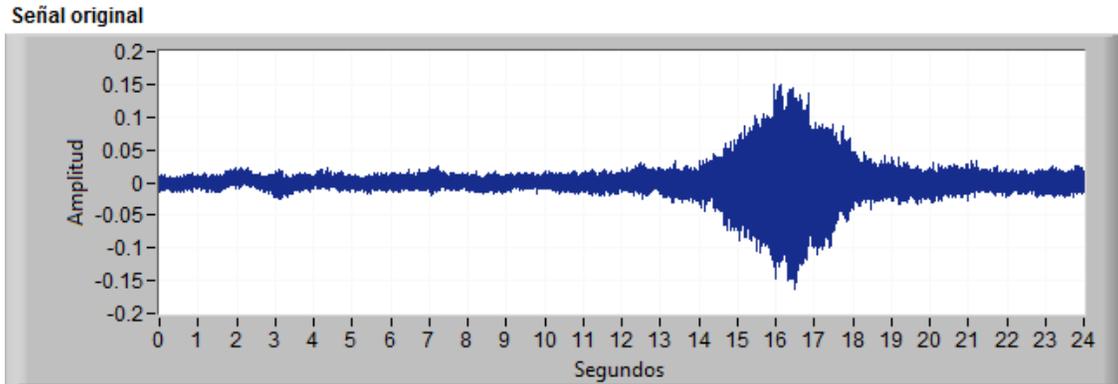


Fig. A.5-1 Señal de ruido registrado durante el despegue para la clase ATR-42.

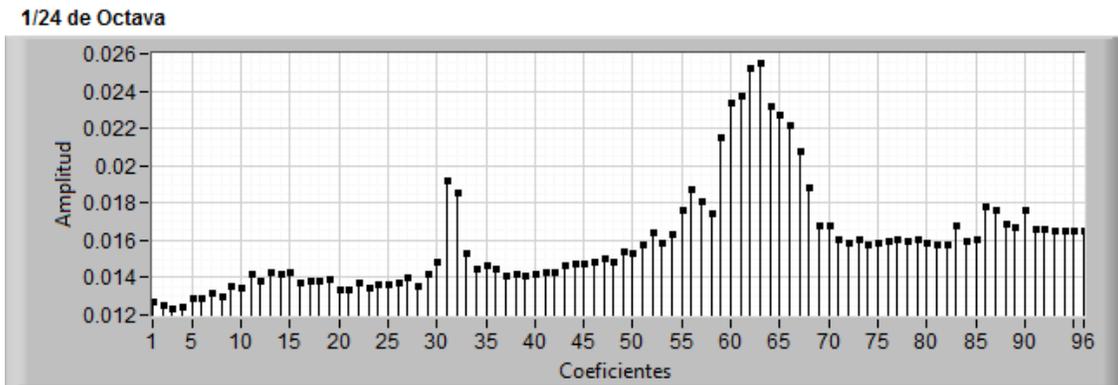


Fig. A.5-2 Patrón de 96 elementos mediante análisis 1/24 de Octava para la clase ATR-42.

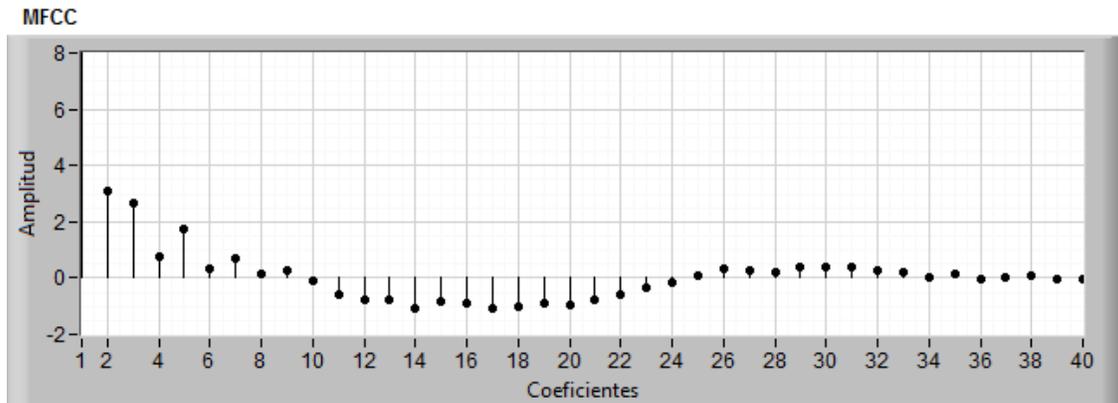


Fig. A.5-3 Patrón de 40 elementos a través del análisis MFCC para la clase ATR-42.

A.6 B737-100/200

Esta clase contiene los modelos de aeronaves Boeing 737-100 y 737-200.

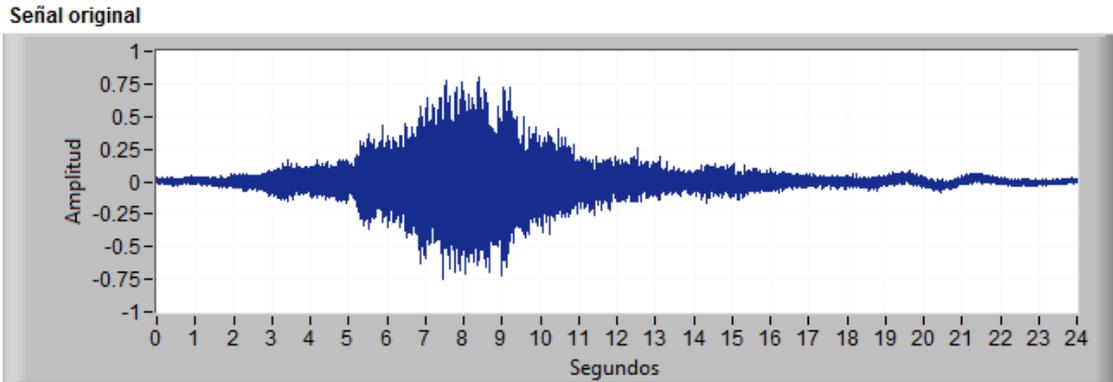


Fig. A.6-1 Señal de ruido registrado durante el despegue para la clase B737-100/200.

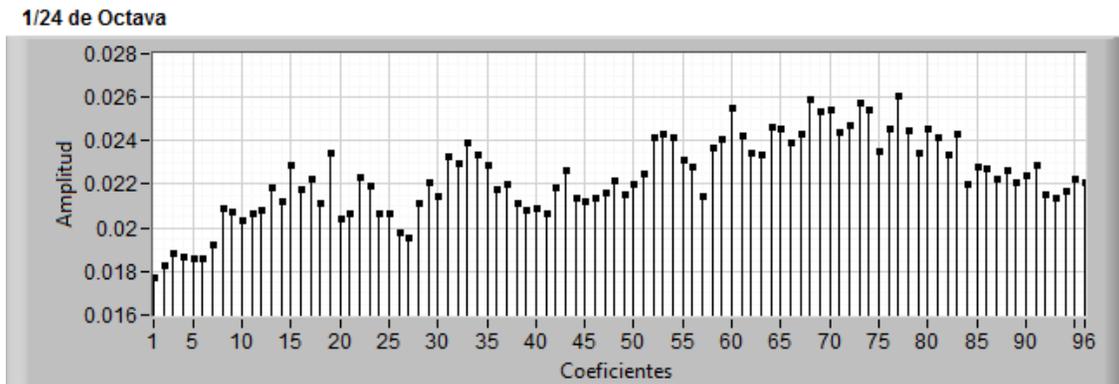


Fig. A.6-2 Patrón de 96 elementos mediante análisis 1/24 de Octava para la clase B737-100/200.

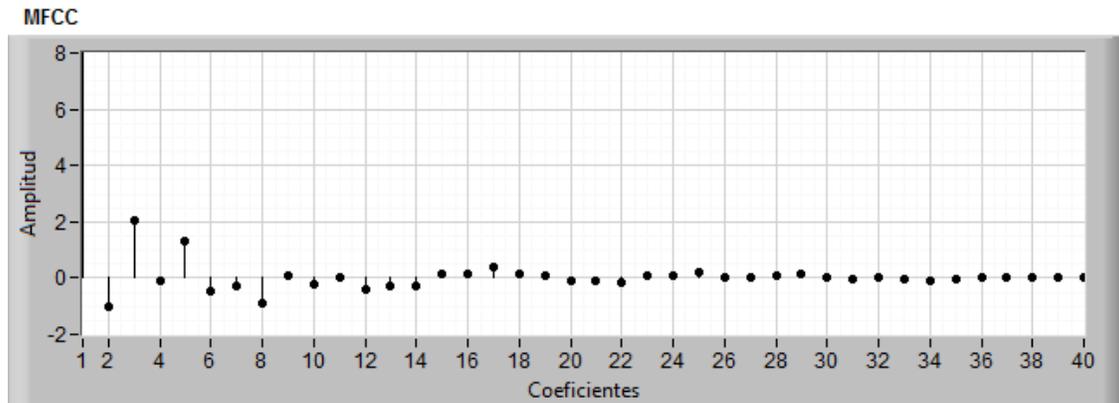


Fig. A.6-3 Patrón de 40 elementos a través del análisis MFCC para la clase B737-100/200.

A.7 B737-600/700

Esta clase contiene los modelos de aeronaves Boeing 737-600 y 737-700.

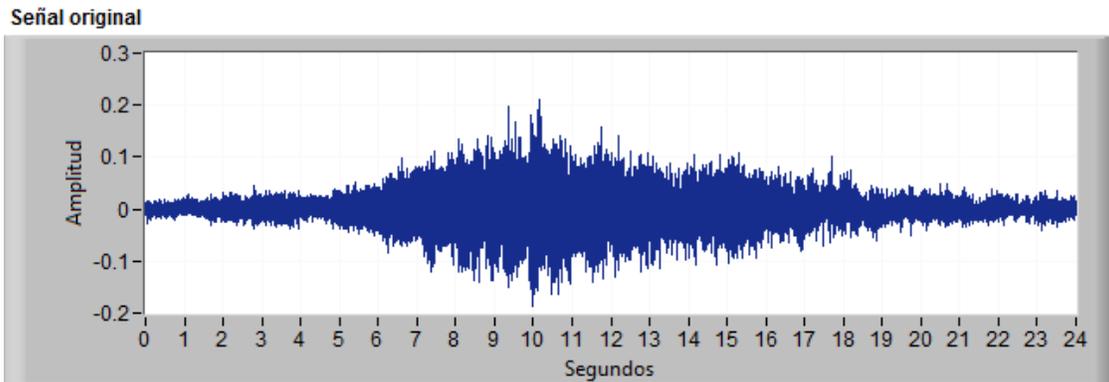


Fig. A.7-1 Señal de ruido registrado durante el despegue para la clase B737-600/700.

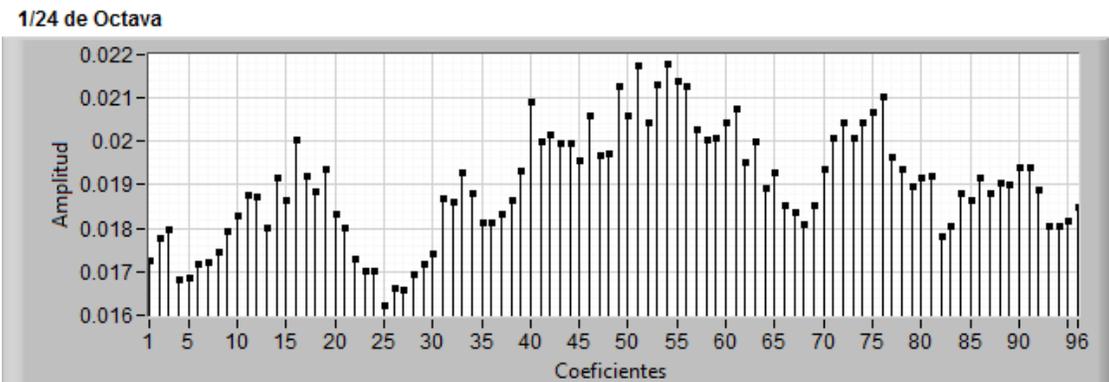


Fig. A.7-2 Patrón de 96 elementos mediante análisis 1/24 de Octava para la clase B737-600/700.

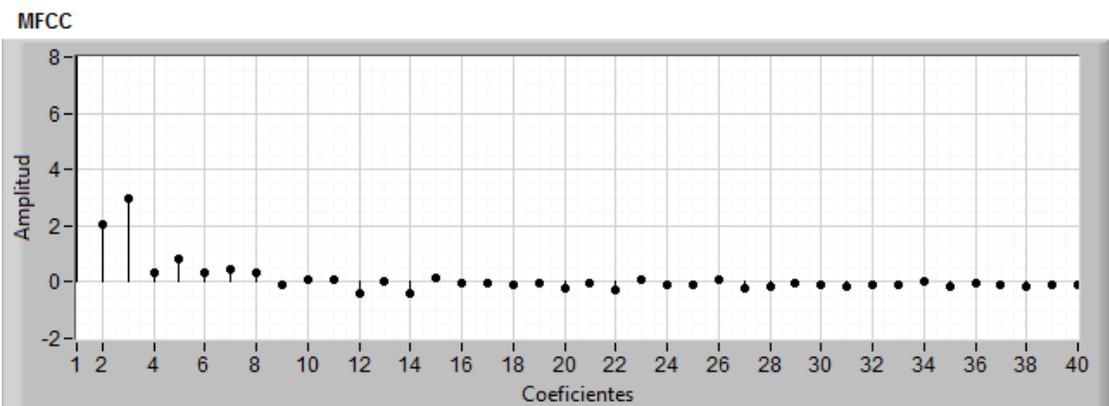


Fig. A.7-3 Patrón de 40 elementos a través del análisis MFCC para la clase B737-600/700.

A.8 B747-400

Esta clase contiene el modelo de aeronave Boeing 747-400.

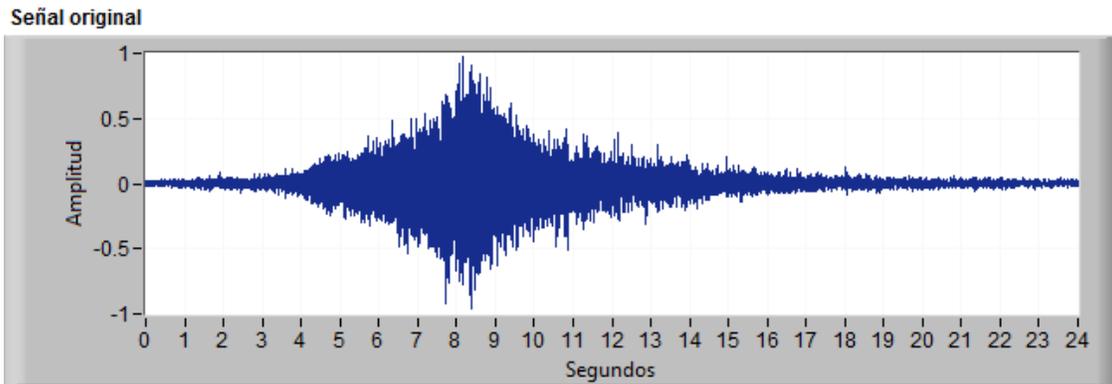


Fig. A.8-1 Señal de ruido registrado durante el despegue para la clase B747-400.

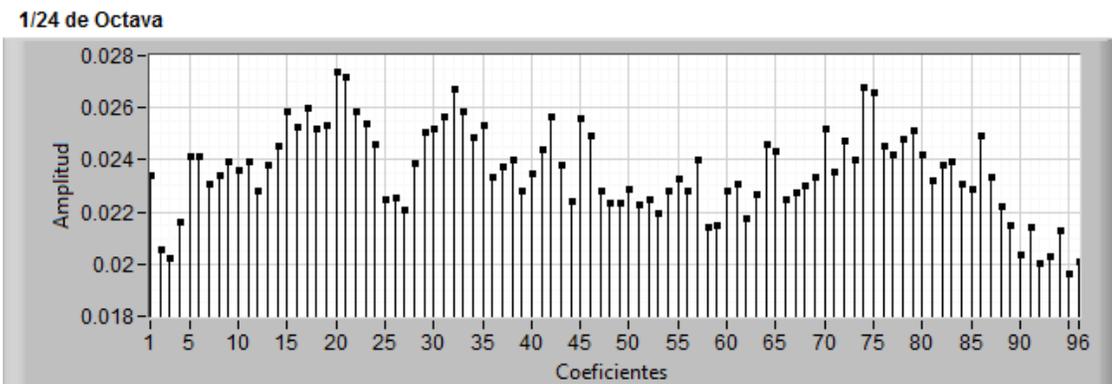


Fig. A.8-2 Patrón de 96 elementos mediante análisis 1/24 de Octava para la clase B747-400.

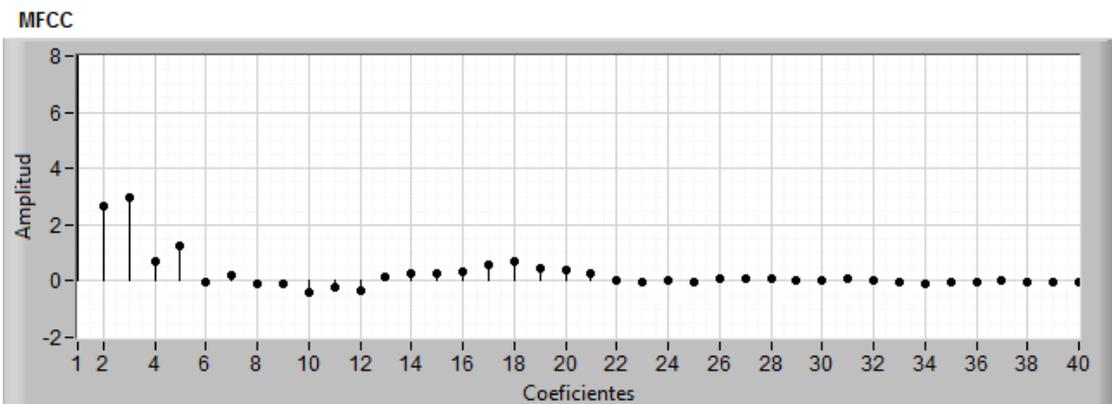


Fig. A.8-3 Patrón de 40 elementos a través del análisis MFCC para la clase B747-400.

A.9 F100

Esta clase contiene el modelo de aeronave Fokker F100.

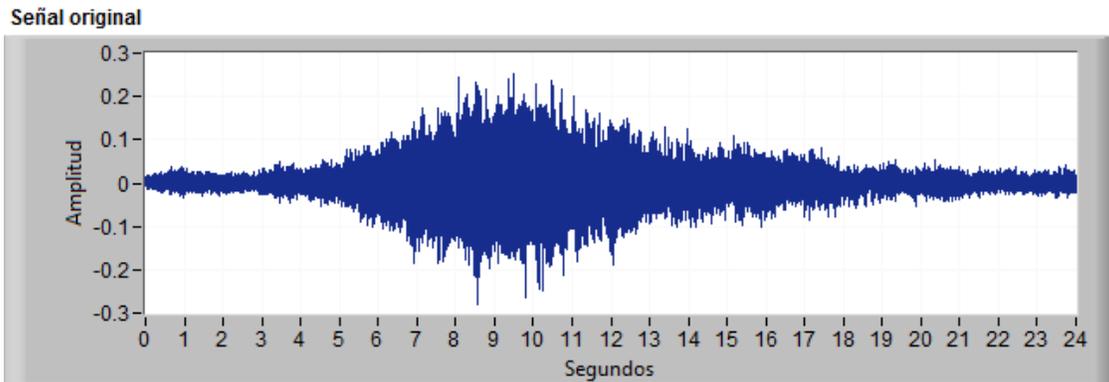


Fig. A.9-1 Señal de ruido registrado durante el despegue para la clase F100.

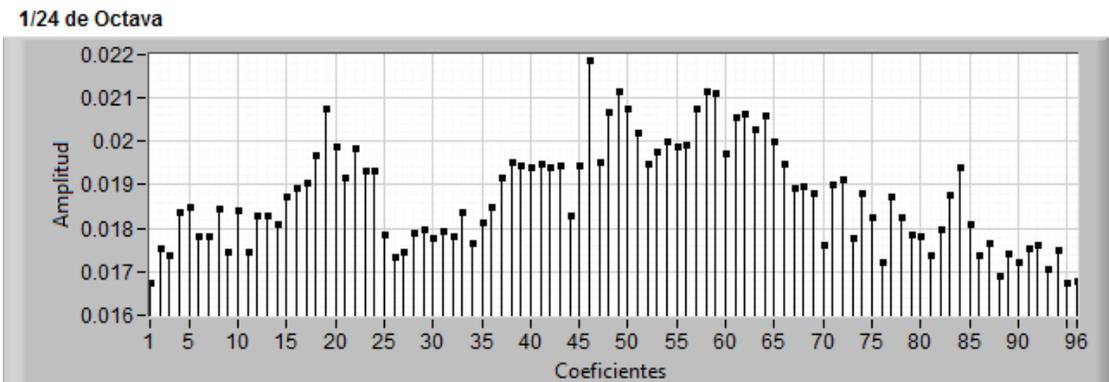


Fig. A.9-2 Patrón de 96 elementos mediante análisis 1/24 de Octava para la clase F100.

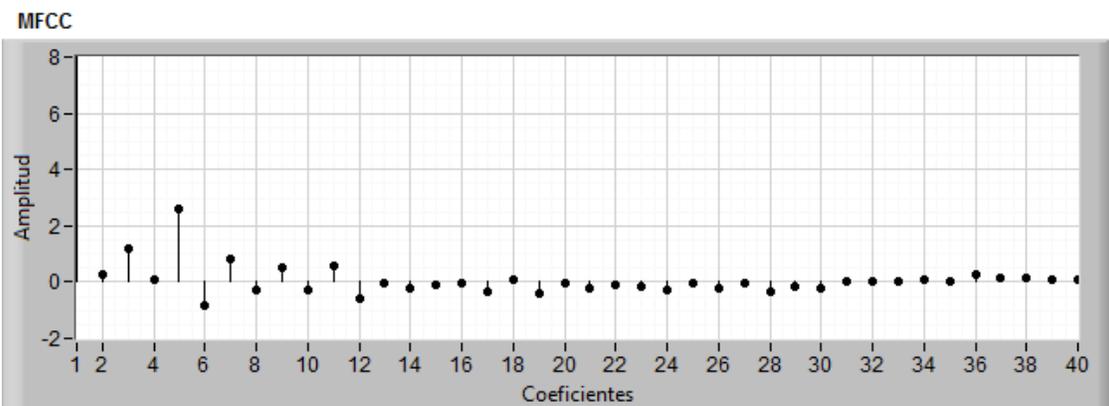


Fig. A.9-3 Patrón de 40 elementos a través del análisis MFCC para la clase F100.

A.10 F100 2

Esta clase contiene el modelo de aeronave Fokker F100.

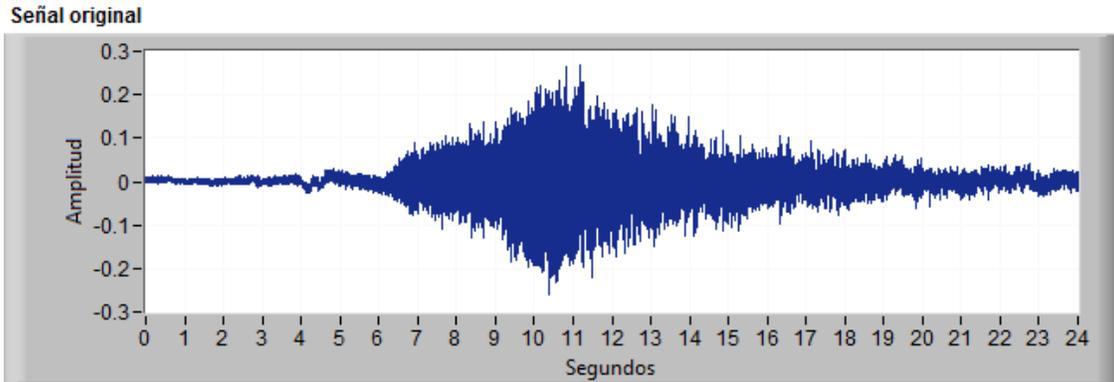


Fig. A.10-1 Señal de ruido registrado durante el despegue para la clase F100 2.

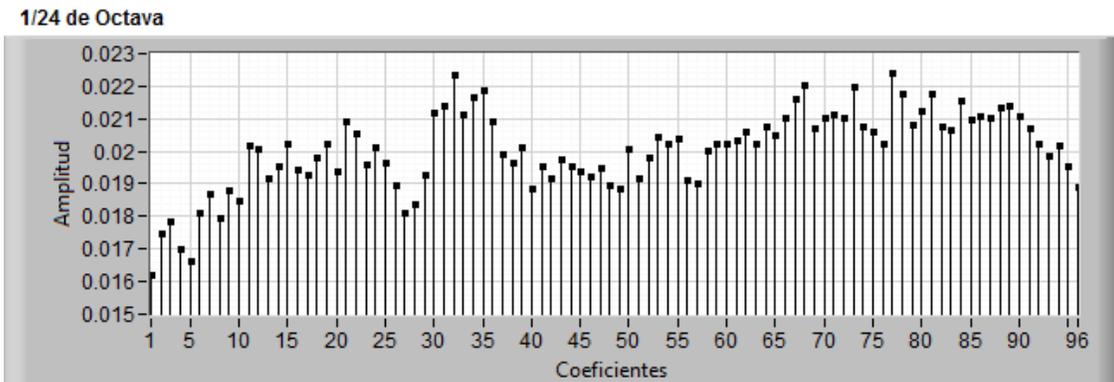


Fig. A.10-2 Patrón de 96 elementos mediante análisis 1/24 de Octava para la clase F100 2.

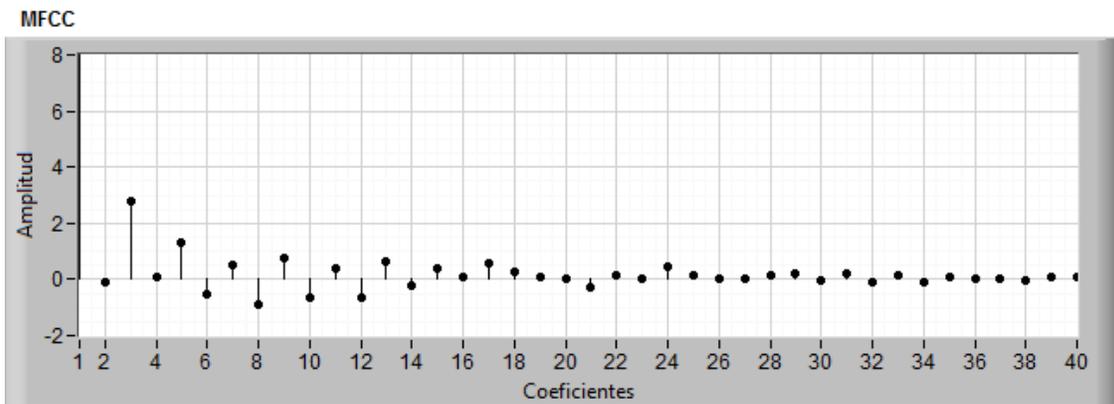


Fig. A.10-3 Patrón de 40 elementos a través del análisis MFCC para la clase F100 2.

A.11 F100_B737-200

Esta clase contiene los modelos de aeronaves Fokker F100 y Boeing 737-200.

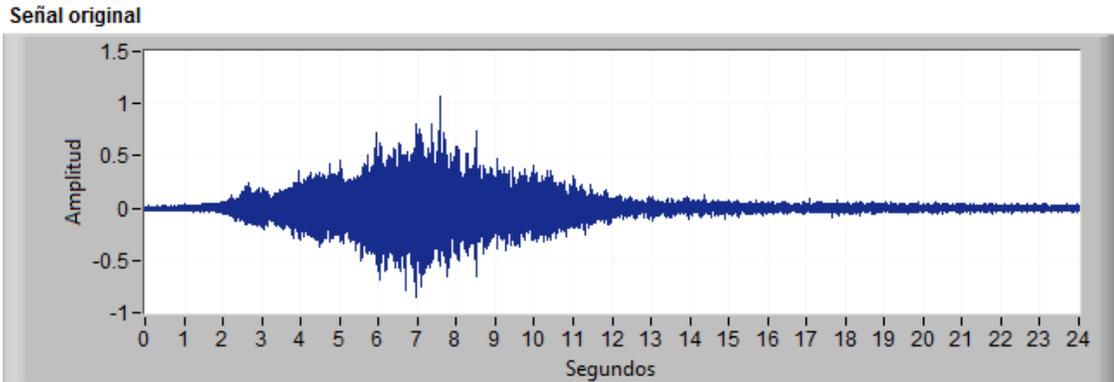


Fig. A.11-1 Señal de ruido registrado durante el despegue para la clase F100_B737-200.

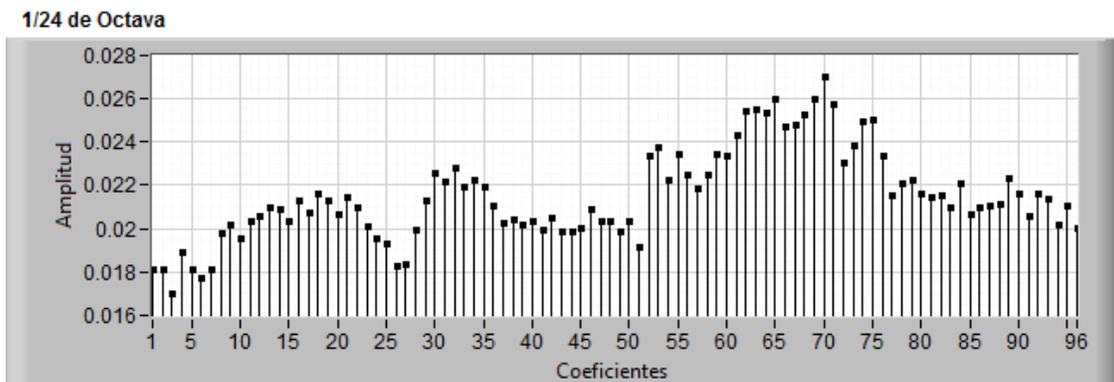


Fig. A.11-2 Patrón de 96 elementos mediante análisis 1/24 de Octava para la clase F100_B737-200.

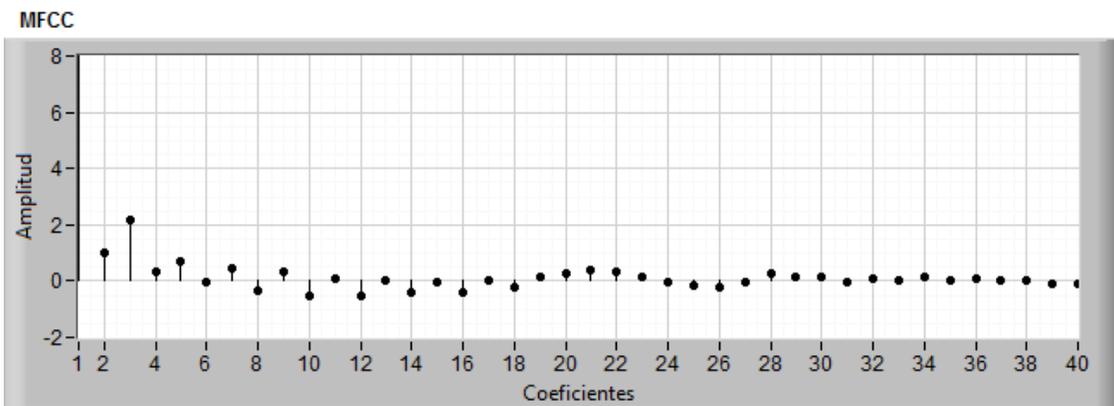


Fig. A.11-3 Patrón de 40 elementos a través del análisis MFCC para la clase F100_B737-200.

A.12 F100_B737-200 2

Esta clase contiene los modelos de aeronaves Fokker F100 y Boeing 737-200.

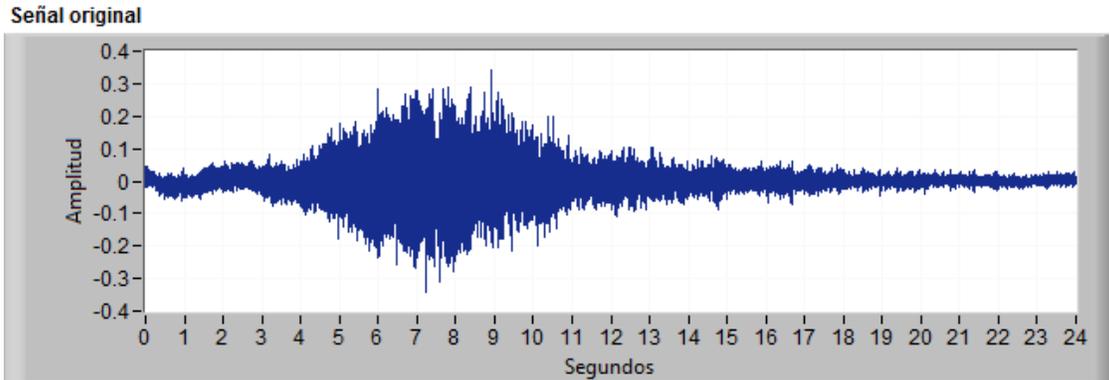


Fig. A.12-1 Señal de ruido registrado durante el despegue para la clase F100_B737-200 2.

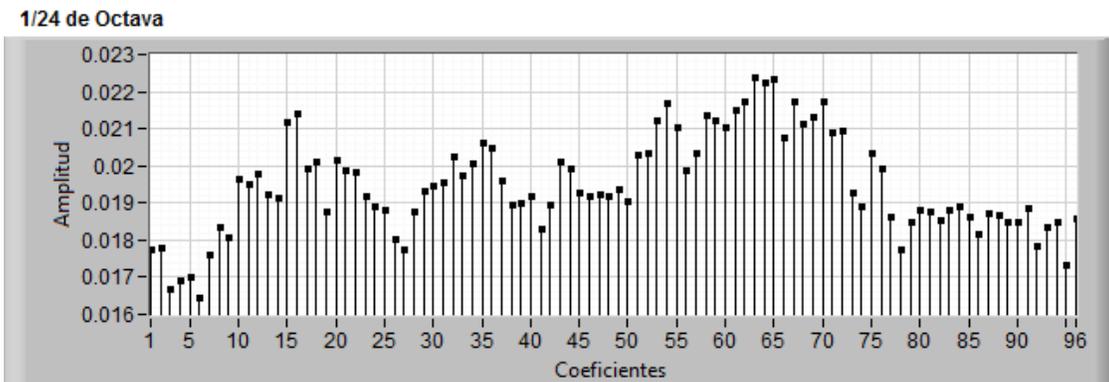


Fig. A.12-2 Patrón de 96 elementos usando análisis 1/24 de Octava para la clase F100_B737-200 2.

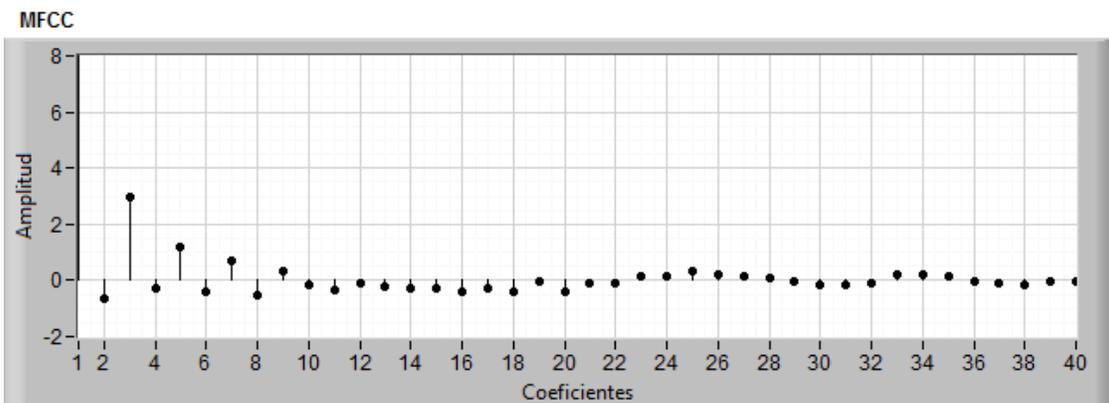


Fig. A.12-3 Patrón de 40 elementos a través del análisis MFCC para la clase F100_B737-200 2.

A.13 MD

Esta clase contiene los modelos de aeronaves McDonnell Douglas 87 y 88.

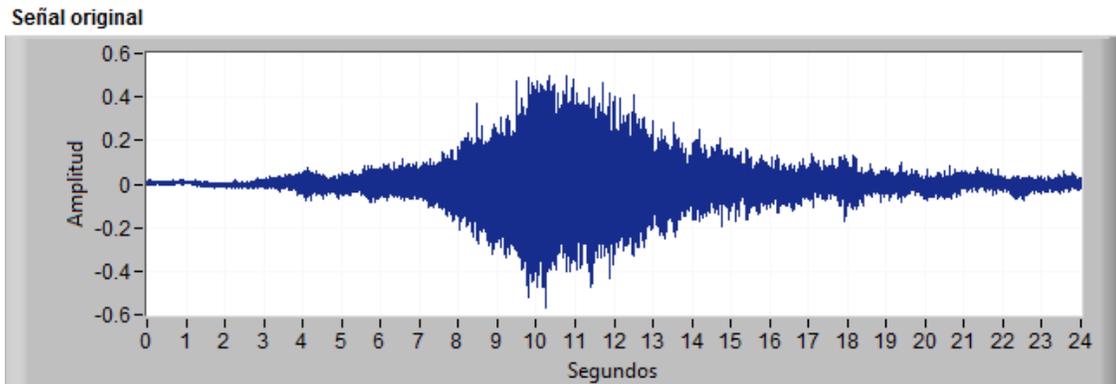


Fig. A.13-1 Señal de ruido registrado durante el despegue para la clase MD.

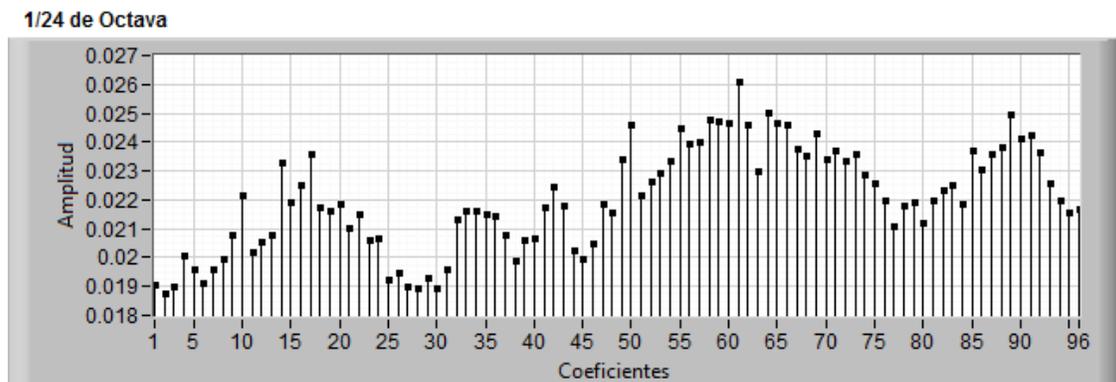


Fig. A.13-2 Patrón de 96 elementos mediante el análisis 1/24 de Octava para la clase MD.

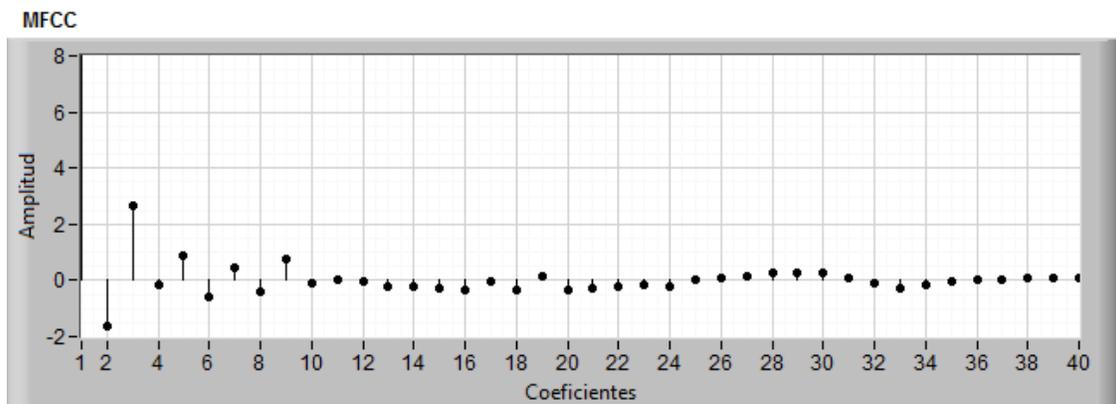


Fig. A.13-3 Patrón de 40 elementos a través del análisis MFCC para la clase MD.

Anexo B. Efectos potencialmente nocivos a la salud y confort en el ser humano.

Tabla B.1. Efecto al ser humano, frecuencias, nivel de presión sonora y tiempo de exposición asociados a cada efecto potencialmente nocivo.

Efecto	Frecuencias asociadas	Nivel de presión sonora	Tiempo de exposición
Desplazamiento de umbrales auditivos y pérdida auditiva (Berglund et al., 1999; Harris, 1995; Kryter, 1985)	3000 - 6000 Hz	80 dB	Meses
Dolor de oído o malestar (Berglund et al., 1995; Kryter, 1985)	50 - 8000 Hz	110 dB	Segundos
Interferencia en la comunicación (Berglund et al., 1999; Kryter, 1985)	100 - 4000 Hz	50 dB	Minutos
Enfermedad vibro-acústica (Alves-Pereira et al., 2004)	< 500 Hz	90 dB	Años
Efectos cardiovasculares (Berglund et al., 1999)	< 500 Hz	90 dB	Años
Variación en frecuencia de respiración (Berglund et al., 1995; Kryter, 1985)	0.5 - 100 Hz	70 dB	Segundos
Alteraciones en la motilidad gástrica (Harris, 1995)	800 Hz	80 dB	Segundos
Cambios endócrinos (Berglund et al., 1995; Kryter, 1985)	3000 - 4000 Hz	80 dB	Días
Variaciones de la agudeza visual (Kryter, 1985; Recuero, 1994)	4 a 800 Hz	110 dB	Segundos
Vibraciones localizadas en el cuerpo humano (Recuero, 1994)	4 a 100 Hz	105 dB	Segundos
Estrés (Ostrosky-Solís, 2001)	Todo el espectro en general	105 dB	Minutos
Alteración del sueño (Knipschild, 1977; Michaud et al., 2007)	Asociado al ruido de aeronaves	45 dB	10 - 15 eventos por noche
Hipertensión arterial (Knipschild, 1977; Ostrosky-Solís, 2001)	Asociado al ruido de aeronaves	50 dB	Años

Anexo C. Diagrama Entidad-Relación para la base de datos del modelo computacional.

En la implementación del modelo computacional se hace uso de una base de datos para recuperar la información de la clase a la que pertenece la aeronave identificada. La Fig. C.1 muestra el diagrama Entidad-Relación de esta base de datos.

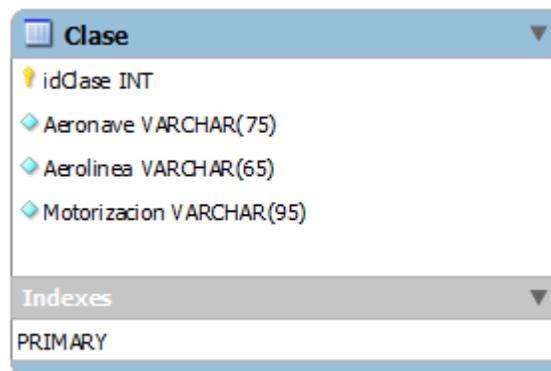


Fig. C.1. Diagrama Entidad-Relación de la base de datos en el modelo computacional.

Anexo D. Publicaciones generadas.

EN REVISTA APPLIED ACOUSTICS. JCR-Impact-factor: 1.233.

Miguel Márquez-Molina, Luis P. Sánchez Fernández, Sergio Suarez Guerra and Luis A. Sánchez-Pérez. *Aircraft take-off noises classification based on human auditory's matched features extraction*. EN IMPRENTA.

EN MEMORIAS DE CONGRESO INTERNACIONAL

Miguel Márquez-Molina, Luis P. Sánchez Fernández, Sergio Suarez Guerra. *Aircraft recognition at take-off based on neural network and speech processing techniques*. 2nd International Conference on Computational and Informatics Sciences, Informática 2013, Habana, Marzo 2013. ISBN: 978-959-7213-02-4.

EN REVISTA DIGITAL SIGNAL PROCESSING. JCR-Impact-factor: 1.918.

Geo-referenced flight path estimation based on spatio-temporal information extracted from aircraft take-off noise (Cuarto autor)

EN ARBITRAJE: Primera revisión: CON CAMBIOS