



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Dpto. de Ingeniería Mecánica y de Materiales

Clasificación de impactos en placas de material compuesto de fibra de carbono (CFRP) utilizando Inteligencia Artificial basada en el análisis en frecuencia de señales de emisión acústica

Trabajo Fin de Máster

Máster Universitario en Ingeniería Mecánica

AUTOR/A: Barriga Machado, Byron

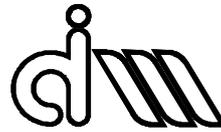
Tutor/a: Giner Maravilla, Eugenio

Cotutor/a: Infante García, Diego

CURSO ACADÉMICO: 2022/2023

UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Departamento de Ingeniería Mecánica y de Materiales



Trabajo Fin de Máster en Ingeniería Mecánica

“CLASIFICACIÓN DE IMPACTOS EN PLACAS DE MATERIAL COMPUESTO DE FIBRA DE CARBONO (CFRP) UTILIZANDO INTELIGENCIA ARTIFICIAL BASADA EN EL ANÁLISIS EN FRECUENCIA DE SEÑALES DE EMISIÓN ACÚSTICA”

Presentado por: D. Byron Barriga Machado
Dirigido por: Dr. D. Eugenio Giner Maravilla
Codirigido por: Dr. D. Diego Infante García

Valencia, septiembre de 2023

Resumen

En el presente trabajo se expone el proceso para la detección y clasificación de impactos sobre una placa de polímero reforzada con fibras de carbono unidireccionales (CFRP, por sus siglas en inglés) utilizando inteligencia artificial (AI) y señales de emisión acústica (AE). Se ha desarrollado un modelo basado en el algoritmo de bosques aleatorios que utiliza características del contenido en frecuencia, que han demostrado un alto poder discriminativo para este tipo de aplicaciones.

En primer lugar, se lleva a cabo una revisión exhaustiva del estado del arte y de los fundamentos teóricos para comprender la situación actual de este campo de investigación. Se analiza la propagación de ondas de emisión acústica en materiales compuestos, las características que se pueden extraer de estas señales, así como también los principales algoritmos de inteligencia artificial utilizados.

Las señales de emisión acústica fueron generadas mediante impactos sobre la placa utilizando tres fuentes distintas: arena, esfera metálica y trozos de hielo. Para registrarlas se utilizaron dos sensores piezoeléctricos (PZT). Previo al entrenamiento del modelo se realizó un proceso de filtrado para descartar aquellas señales que presentaban ruido. Para la extracción de características se utilizó la transformada de Fourier de tiempo reducido (STFT) que incluye una segmentación de la señal transitoria y la aplicación de una ventana Hamming. Las principales características obtenidas fueron la frecuencia pico ponderada, frecuencia centroide y los niveles de potencia parcial.

Los datos obtenidos fueron divididos en dos subconjuntos, uno de entrenamiento y uno de evaluación. Los criterios de evaluación utilizados fueron la exactitud y la puntuación F1, métricas comúnmente usadas en este tipo de clasificadores. Además, se estableció un proceso de búsqueda de características relevantes y ajuste de hiperparámetros para mejorar el rendimiento del modelo.

Finalmente, se realizó un análisis de los resultados obtenidos, evaluando la correspondencia de las características con las fuentes de impacto. El modelo propuesto presentó un desempeño satisfactorio, alcanzando una exactitud de hasta el 90,4%. Además, en la sección de discusión, se realizó una comparativa con investigaciones relacionadas. Por último se planteó la posibilidad de futuros trabajos orientados hacia la identificación de mecanismos de fallos en materiales compuestos.

Palabras Clave: Inteligencia artificial; *Machine Learning*; Materiales compuestos; Fibra de carbono; Emisiones acústicas.

Resum

En el present treball s'exposa el procés per a la detecció i classificació d'impactes sobre una placa de polímer reforçada amb fibres de carboni unidireccionals (CFRP, per les seues sigles en anglés) utilitzant intel·ligència artificial (AI) i senyals d'emissió acústica (AE). S'ha desenvolupat un model basat en l'algorisme de boscos aleatoris que utilitza característiques del contingut en freqüència, que han demostrat un alt poder discriminatori per a aquesta mena d'aplicacions.

En primer lloc, es duu a terme una revisió exhaustiva de l'estat de l'art i dels fonaments teòrics per a comprendre la situació actual d'aquest camp d'investigació. S'analitza la propagació d'ones d'emissió acústica en materials compostos, les característiques que es poden extraure d'aquests senyals, així com també els principals algorismes d'intel·ligència artificial utilitzats.

Els senyals d'emissió acústica van ser generades mitjançant impactes sobre la placa utilitzant tres fonts diferents: arena, esfera metàl·lica i trossos de gel. Per a registrar-les es van utilitzar dos sensors piezoelèctrics (PZT). Previ a l'entrenament del model es va realitzar un procés de filtrat per a descartar aquells senyals que presentaven soroll. Per a l'extracció de característiques es va utilitzar la transformada de Fourier de temps reduït (STFT) que inclou una segmentació del senyal transitori i l'aplicació d'una finestra *Hanning*. Les principals característiques obtingudes van ser la freqüència pique ponderada, freqüència centroide i els nivells de potència parcial.

Les dades obtingudes van ser dividits en dos subconjunts, un d'entrenament i un d'avaluació. Els criteris d'avaluació utilitzats van ser l'exactitud i la puntuació F1, mètriques comunament usades en aquesta mena de classificadors. A més, es va establir un procés de cerca de característiques rellevants i ajust de hiperparàmetres per a millorar el rendiment del model.

Finalment, es va realitzar una anàlisi dels resultats obtinguts, avaluant la correspondència de les característiques amb les fonts d'impacte. El model proposat va presentar un acompliment satisfactori, aconseguint una exactitud de fins al 90,4%. A més, en la secció de discussió, es va realitzar una comparativa amb investigacions relacionades. Finalment es va plantejar la possibilitat de futurs treballs orientats cap a la identificació de mecanismes de fallades en materials compostos.

Paraules Clau: Intel·ligència artificial; *Machine Learning*; Materials compostos; Fibra de carboni; Emissions acústiques.

Abstract

This work presents a process for detecting and classifying impacts on a unidirectional carbon fiber-reinforced polymer (CFRP) plate using artificial intelligence (AI) and acoustic emission (AE) signals. A model based on the random forest algorithm has been developed, which utilizes frequency content features shown to be highly discriminative for this application.

Firstly, a comprehensive review of the state-of-the-art and theoretical foundations is conducted to understand the current situation in this research field. The propagation of acoustic emission waves in composite materials, the extractable signal characteristics, and the leading artificial intelligence algorithms are analyzed.

Acoustic emission signals were generated by impacts on the plate using three different sources: sand, a metal sphere, and ice chunks. Two piezoelectric sensors (PZT) were used to record these signals. Before model training, a filtering process was applied to remove noisy signals. For feature extraction, the Short-Time Fourier Transform (STFT) was employed, which includes transient signal segmentation and the application of a Hamming window. The main obtained features were peak frequency, centroid frequency, and partial power levels.

The collected data were divided into two subsets, one for training and one for evaluation. Evaluation criteria included accuracy and the F1 score, metrics commonly used in this type of classifiers. Additionally, selection of relevant features and hyperparameter tuning were conducted to improve the model performance.

Finally, the obtained results were analyzed, evaluating how well the features matched the impact sources. The proposed model demonstrated satisfactory performance, achieving an accuracy of up to 90,4%. Furthermore, the results were compared to related research in the discussion section, and the possibility of future work to identify failure mechanisms in composite materials was considered.

Keywords: Artificial Intelligence; Machine Learning; Composite Materials; Carbon Fiber; Acoustic Emissions.

Agradecimientos

A mis padres, por haberme guiado a lo largo de toda vida y por haberme brindado la oportunidad de crecer profesional, académica y personalmente.

A mis tutores y compañeros de trabajo, por todo su apoyo, consideración y tiempo dedicado para la culminación de este trabajo.

A Annabell, por todo su tiempo, cariño y confianza en mí, así como por su constante apoyo para mejorar cada día.

Índice general

Resumen	i
Índice general	ix
Índice de figuras	xiii
Índice de tablas	xv
I Memoria	1
1 Introducción	3
1.1 Estado del arte	4
1.2 Objetivos	7
1.3 Estructura del trabajo	8
2 Fundamentos Teóricos	11
2.1 Materiales compuestos y sus propiedades	11
2.1.1 Clasificación de los materiales compuestos	12
2.1.2 Aplicaciones de los materiales compuestos	12
2.2 Plásticos reforzados con fibras de carbono (CFRP)	13
2.2.1 Laminados de fibras de carbono	13
2.2.2 Propagación de ondas en laminados	14
2.3 Emisiones acústicas	18
2.3.1 Fuentes de emisión acústica en laminados de fibras de carbono	20
2.3.2 Parámetros de adquisición y características de las señales de emisión acústica	20
2.3.3 Tipos de sensores	23
2.4 Análisis en frecuencia de las señales	23
2.4.1 Dominio del tiempo	24
2.4.2 Dominio de la frecuencia	24
2.4.3 Dominio tiempo-frecuencia	26

2.4.4	Transformada de Fourier de tiempo reducido - STFT	26
2.4.5	Características en frecuencia	28
2.5	Aprendizaje automático	31
2.5.1	Tipos de aprendizaje automático	32
2.5.2	Árboles de decisión y bosques aleatorios	33
2.5.3	Procedimiento para generar un modelo	36
2.5.4	Métricas de evaluación	39
3	Metodología	43
3.1	Ensayo experimental.	43
3.2	Adquisición de datos.	45
3.3	Procesamiento de datos y extracción de características	46
3.3.1	Filtrado de datos	48
3.3.2	Aplicación de la transformada de Fourier de tiempo reducido	49
3.3.3	Extracción de características	50
3.4	Entrenamiento del modelo de aprendizaje automático	52
3.4.1	Separación del conjunto de datos.	52
3.4.2	Entrenamiento y validación	52
3.4.3	Evaluación del modelo	54
4	Resultados	57
4.1	Optimización del modelo de clasificación	57
4.1.1	Configuración base del modelo	57
4.1.2	Importancia del filtrado de datos.	58
4.1.3	Normalización de características	59
4.1.4	Selección de características	61
4.1.5	Ajuste de hiperparámetros.	62
4.2	Correspondencia entre características de frecuencia y fuentes de impacto.	64
4.3	Discusión	67
5	Conclusiones	71
	Bibliografía	73
II	Anexos	77
A	Código fuente	79
A.1	Librerías y directorio	79
A.2	Segmentación y extracción de características	80
A.3	División en subconjuntos y normalización	84
A.4	Modelo de bosques aleatorios	85
A.5	Selección de características	87
A.6	Importación de datos y entrenamiento del modelo.	88

B ODS Agenda 2030	89
B.1 Objetivos de desarrollo sostenible de la agenda 2030	89
III Pliego de condiciones	91
C Pliego de condiciones	93
C.1 Obligaciones y derechos de los trabajadores	93
C.2 Condiciones del puesto de trabajo	93
C.3 Condiciones del teletrabajo	94
C.4 Condiciones y especificaciones técnicas	95
C.5 Control de calidad	96
C.6 Supervisión	96
IV Presupuesto	97
D Presupuesto	99
D.1 Desglose de costes	99
D.2 Coste total	101

Índice de figuras

2.1	Esquema de la configuración de un laminado.	14
2.2	Tipos de movimiento ondulatorio [18].	15
2.3	Influencia del espesor de placa en la propagación de una onda en un laminado de T800/913 [19].	16
2.4	Influencia de la secuencia de apilado en la propagación de una onda en un laminado de T800/913 [19].	17
2.5	Ilustración de un transductor piezoeléctrico resonante y cómo se transforma una señal de AE en una señal eléctrica. [22].	18
2.6	Contribución individual del tipo de material y geometría, características del sensor en el espectro de frecuencia de una señal de emisión acústica [23].	19
2.7	Ejemplo de una señal transitoria de AE (a) y un segmento de señal continua de AE (b). [23].	21
2.8	Parámetros de adquisición y características de un hit de emisión acústica [21].	22
2.9	Tipos de sensores piezoeléctricos incluyendo especificaciones del fabricante [25].	24
2.10	Curvas de respuesta en frecuencia para el sensor resonante (a), multi-resonante (b) y de banda ancha (c) [25].	25
2.11	Esquema de proceso de la transformada de Fourier de tiempo reducido - STFT [34].	28
2.12	Ejemplo de una señal de emisión acústica en el dominio del tiempo (a) y de frecuencia (b) [19].	29
2.13	Comparación entre la programación clásica y el aprendizaje automático [38].	32
2.14	Árbol de decisión para el conjunto de datos <i>Iris</i> [39].	34
2.15	Límites de decisión del árbol para el conjunto de datos <i>Iris</i> [39].	35
2.16	Límites de decisión del árbol para el conjunto de datos <i>Iris</i> modificado [39].	35
2.17	Predicciones de un bosque aleatorio con varios árboles de decisión [39].	36

2.18	Diagrama de flujo para un modelo de aprendizaje automático.	37
2.19	Matriz de confusión ilustrada para el conjunto de datos <i>MNIST</i> [39].	40
2.20	Etiquetado de la matriz de confusión multi-clase en referencia a la clase “b” [41].	41
3.1	Esquema de la ubicación de los sensores y la zona de impacto.	43
3.2	Fuentes de impacto para el ensayo.	44
3.3	Sujeción de los sensores con pinzas de compresión.	44
3.4	Montaje del sistema de adquisición de datos.	45
3.5	Esquema de la prueba de Hsu-Nielsen [42].	45
3.6	Señal transitoria para un impacto de esfera metálica.	47
3.7	Comparación entre una señal de impacto de esfera metálica (a) y una señal resultante de un rebote de esfera metálica (b).	48
3.8	Segmentación para un impacto de esfera metálica.	50
3.9	Intervalos de potencia parcial 1, 2 y 3.	51
3.10	División del conjunto de datos utilizando la técnica de validación cruzada.	53
4.1	Matriz de confusión para la configuración base del modelo.	58
4.2	Matriz de confusión para datos sin filtro de conteo.	59
4.3	Histograma de la frecuencia centroide (a), y potencia parcial 3 (b) del segmento 1.	60
4.4	Histograma de la potencia parcial 3 del segmento 1 con la transformación logarítmica.	60
4.5	Matriz de confusión con la técnica de eliminación hacia atrás y transformación logarítmica.	62
4.6	Matriz de confusión para la configuración final del modelo.	63
4.7	Diagrama de dispersión t-SNE para el subconjunto de características relevantes.	64
4.8	Comparación de señales transitorias de impactos de esfera metálica (a), arena (b) y hielo (c).	65
4.9	Comparación del espectrograma para los impactos de esfera metálica (a), arena (b) y hielo (c).	65
4.10	Diagrama de dispersión de la frecuencia pico ponderada - 1 vs la potencia parcial 2 - 1.	66
4.11	Diagrama de dispersión de la frecuencia centroide - 1 vs la potencia parcial 3 - 2.	66

Índice de tablas

2.1	Características de señal básicos utilizados para la definición de características en frecuencia.	30
2.2	Características en frecuencia de una señal de emisión acústica.	30
2.3	Ejemplo de intervalos de frecuencia para los niveles de potencia parcial.	31
3.1	Parámetros de adquisición de datos para el ensayo.	46
3.2	Características extraídas del archivo primario <i>.pridb</i>	47
3.3	Características en frecuencia para una señal discreta.	51
3.4	Intervalos de frecuencia para los niveles de potencia parcial.	51
3.5	Valores para el ajuste de hiperparámetros.	55
4.1	Configuración base del modelo de clasificación.	58
4.2	Métricas para los casos de normalización.	61
4.3	Características seleccionadas con la técnica de eliminación hacia atrás.	61
4.4	Importancia relativa de las características.	62
4.5	Configuración final del modelo de clasificación.	63
B.1	Relación de la investigación con los ODS.	89
C.1	Especificaciones del equipo informático.	95
D.1	Desglose de costes de personal.	99
D.2	Desglose de costes de equipo de emisiones acústicas.	100
D.3	Desglose de costes de hardware.	100
D.4	Desglose de costes de software.	100

D.5 Presupuesto global. 101

Parte I

Memoria

Capítulo 1

Introducción

La creciente demanda de la industria por materiales con mejores propiedades ha impulsado una constante evolución en la ingeniería. La búsqueda de un rendimiento óptimo en los componentes implica desafíos, como maximizar su resistencia o rigidez, al mismo tiempo que se reduce su peso y el coste asociado a su producción. Esta evolución no solo ha mejorado el diseño y fabricación en materiales comúnmente utilizados como el acero o el aluminio, sino que también ha impulsado el desarrollo de nuevos materiales como los compuestos. Estos últimos, presentan la capacidad de combinar las propiedades de sus materiales constituyentes logrando un efecto sinérgico, que da como resultado un material de altas prestaciones, con diseños más eficientes y que representan soluciones innovadoras en una gran variedad de industrias.

Los materiales compuestos y, en particular, los laminados reforzados con fibras de carbono, han redefinido los límites de la ingeniería estructural gracias a su alta rigidez y resistencia específica. Su aplicación se ha extendido desde la industria aeronáutica hasta la automotriz, e incluso la construcción. Este tipo de materiales ha permitido diseños más eficientes y livianos, ya que cuando se produce un material compuesto, en realidad se está manufacturando el propio componente en sí. Esta particularidad conlleva ventajas significativas al no necesitar un mecanizado posterior ni generar residuos de material. Sin embargo, es importante destacar que el proceso de producción de materiales compuestos tiende a ser más costoso en comparación con otros materiales convencionales.

La creciente integración de los materiales compuestos ha elevado la importancia de la monitorización de su integridad estructural. Durante su vida útil, los laminados de fibras de carbono pueden estar expuestos, además de sus solicitaciones de esfuerzos, a impactos y condiciones ambientales adversas que pueden comprometer su funcionamiento. Detectar el desgaste, los defectos internos, la aparición de grietas y su propagación o cualquier otra señal de deterioro es crucial para evitar el fallo del componente y extender su vida útil. Diferentes técnicas, como las mediciones de vibración, termografía y emisiones acústicas, han sido desarrolladas para detectar y prevenir posibles fallos en los materiales.

Entre estas técnicas, las emisiones acústicas han surgido como una técnica verdaderamente útil, ya que permiten la monitorización en tiempo real de eventos internos en el material, como por ejemplo, fallo en la matriz, interfase o incluso rotura de las fibras. Sin embargo, la anisotropía de los materiales compuestos puede influir en la propagación y detección de este tipo de señales. Las características de atenuación y velocidad de propagación pueden variar según la dirección de las fibras, lo que puede complicar su interpretación. Otro aspecto que puede dificultar su interpretación es la gran cantidad de datos que se recogen en la monitorización de un componente, muchos de los cuales puede no representar información valiosa con respecto al estado del material. Además, los datos recogidos pueden ser interpretados desde distintas perspectivas considerando sus características temporales, contenido en frecuencia, o una combinación de ambas dependiendo de la aplicación.

El análisis en frecuencia o en tiempo-frecuencia presenta ventajas sobre el uso de características temporales. Permite descomponer las señales en sus componentes espectrales, de la cual se puede obtener información sobre las frecuencias dominantes y la distribución de energía en diferentes bandas de frecuencia. En general proporciona una visión más completa de las señales de AE, lo que puede ayudar a identificar patrones distintivos y características relevantes asociadas a las distintas fuentes de emisión. Entre las principales técnicas se pueden destacar la transformada de Fourier de tiempo reducido y la transformada de *wavelet*.

En el contexto de la era digital y el rápido avance de la inteligencia artificial, la capacidad para interpretar grandes volúmenes de datos de manera efectiva ha aumentado significativamente. Este avance ha brindado oportunidades para una mayor precisión en la interpretación y análisis de señales, como por ejemplo, de aquellas provenientes de emisiones acústicas. Las técnicas de aprendizaje automático y análisis de datos son herramientas que pueden ser utilizadas para la identificación de las fuentes que han producido estas señales. Dentro del contexto de la integridad estructural de los laminados de fibras de carbono esto resulta de mucha utilidad, pues se puede aplicar estas técnicas para la identificación de fuentes y zonas de impacto, así como también de cantidad de daño acumulado en un componente, e incluso el tipo de fallo que puede producirse.

La combinación de la potencia de la inteligencia artificial con las capacidades de detección de las emisiones acústicas abre nuevas perspectivas en la monitorización del estado de componentes y en la toma de decisiones para su mantenimiento. En este contexto, el presente trabajo se enfoca en el desarrollo y análisis de un modelo de clasificación que utiliza técnicas de inteligencia artificial para la identificación de fuentes de impacto en laminados reforzados con fibras de carbono, en base a señales de emisión acústica.

1.1 Estado del arte

A continuación, se realiza un análisis de los estudios e investigaciones existentes relacionados con el uso de técnicas de inteligencia artificial en la caracterización de fallos y la identificación de fuentes de impacto en materiales compuestos mediante señales de emisión acústica. Esta revisión bibliográfica permite comprender el contexto actual de la investigación y sirve como punto de partida para el presente trabajo.

En el panorama actual de la ingeniería, los materiales compuestos han emergido como una solución versátil industrias como la aeronáutica, o a la automoción gracias a su rigidez y resistencia

específica elevadas. Debido a este aumento en su uso, se ha planteado la necesidad de garantizar la integridad y durabilidad de este tipo de materiales. En este contexto, el desarrollo y la aplicación de la inteligencia artificial han experimentado un crecimiento en los últimos años, permitiendo analizar una mayor cantidad de datos de manera más rápida y eficiente. La combinación de la inteligencia artificial con los métodos no destructivos, como las emisiones acústicas, constituye una herramienta muy útil para la monitorización de la integridad estructural de los materiales compuestos. Este enfoque ofrece la capacidad de detectar y caracterizar fallos, optimizar el rendimiento y extender la vida útil de los componentes, que pueden ser aprovechadas en las aplicaciones industriales.

En este contexto, se han realizado numerosas investigaciones, algunas de las cuales se destacan en el presente trabajo. Para su mejor entendimiento se han dividido en tres categorías: una de clasificación y localización de impactos, otra referente a la extracción de características, y una última a la identificación de mecanismos de fallo. A continuación, se presentan estas investigaciones en orden descendente según el año de publicación:

Identificación y localización de impactos

- *Spatial-temporal graph convolutional networks (STGCN) based method for localizing acoustic emission sources in composite panels* de Zhao, Zhimin, and Nian-Zhong Chen publicado en *Composite Structures* (2023) [1]: Propone un método basado en redes de convolucionales espacial-temporal para la localización de fuentes de emisión acústica en paneles de material compuesto. Se basa en redes de convolución en grafos donde las señales se representan mediante una estructura de grafo, en la cual las características temporales extraídas utilizando redes neuronales de convolución unidimensionales (1D-CNN) y la información espacial de los sensores constituyen las características de los nodos. Finalmente, se valida experimentalmente el método propuesto en un panel de plástico reforzado con fibra de vidrio (GFRP) con ensayos de rotura de mina (PLB).
- *Deep learning for impact detection in composite plates with sparsely integrated sensors* de Damm, Andreas M., et al. publicado en *Smart Materials and Structures* (2020) [2]: Este trabajo se centra en la detección de impactos, su localización y energía sobre placas de laminado cruzado de fibras de carbono. En él se llevaron a cabo pruebas de impacto en distintas ubicaciones de la placa y con distinta fuerza. Las señales de los sensores se procesaron mediante transformación de Fourier de tiempo reducido (STFT) para la obtención de espectrogramas de frecuencia. Con estas imágenes se alimentó una red neuronal convolucional, que estaba preentrenada con un modelo analítico del ensayo. Como resultado la red era capaz de clasificar correctamente la ubicación y energía del impacto.
- *A convolutional neural network for impact detection and characterization of complex composite structures* de Tabian, I., et al. publicado en *Sensors* (2019) [3]: Este estudio propone una red neuronal convolucional para la detección, localización y caracterización de eventos de impacto en estructuras de material compuesto complejas. Utiliza una red de sensores piezoeléctricos para registrar las señales de emisión acústica. Las convierte en imágenes como un mapa de superficie de voltaje en función del tiempo, para cada sensor. Presenta la novedad que los impactos se realizaron en una sección curva de fuselaje de CFRP reforzado con nervaduras, con una disposición de capas de $[45/-45/90/0/90]_S$. La red neuronal es capaz de localizar los impactos y determinar su nivel de energía con bastante precisión.

Extracción de características

- *Acoustic emission signal clustering in CFRP laminates using a new feature set based on waveform analysis and information entropy analysis* de Karimian, Seyed Fouad, y Mohammad Modarres publicado en *Composite Structures* (2021) [4]: En este trabajo se estudia la distribución de la forma de la onda en base al ancho de la ventana temporal de la señal de emisión acústica. Propone un análisis de la influencia de la selección del ancho de esta ventana en la extracción de características a través de la transformada de *wavelet*. Se realizan una serie de pruebas de tracción en especímenes de CFRP de agujero abierto con disposición cruzada y cuasiisótropa. Este enfoque divide las señales en dos grupos; un grupo con señales dominadas por fallo en la matriz y otro dominado por el fallo de las fibras.
- *Pattern recognition approach to identify natural clusters of acoustic emission signals* de Sause, Markus GR, et al. publicado en *Pattern Recognition Letters* (2012) [5]: Presenta un nuevo enfoque para identificar grupos naturales de señales de emisión acústica. Esta técnica se basa en un análisis exhaustivo que tiene en cuenta todas las combinaciones posibles de características extraídas de las señales de AE registradas. Además se presentan las principales características en el dominio de la frecuencia que se pueden extraer de una señal. Se utilizan esquemas de votación para evaluar cada combinación de forma individual. Finalmente, se demuestra la aplicación del enfoque para el agrupamiento de señales de AE obtenidas durante el ensayo de especímenes de CFRP sometidos a carga de tracción.

Identificación de mecanismos de fallo

- *A waveform-based clustering and machine learning method for damage mode identification in CFRP laminates* de Jie Wang, et al. publicado en *Composite Structures* (2023) [6]: Analiza las señales de emisión acústica producidas durante un ensayo de flexión en tres puntos en laminados unidireccionales con y sin defectos. Utiliza las transformadas de *wavelet* para extraer características en el dominio de la frecuencia con los que entrena los modelos de inteligencia artificial, en concreto, combina un autonencoder con redes neuronales y posteriormente el algoritmo no supervisado *k-means ++*. Este modelo es capaz de separar los diferentes tipos de fallo en el laminado.
- *Damage mechanism identification in composites via machine learning and acoustic emission* de C. Nuir, et al. publicado en *npj Computational Materials* (2021) [7]: Asume que se presentan diferencias en las señales de AE generadas por los diferentes tipos de fallo en un laminado, como agrietamiento de la matriz, delaminaciones y ruptura de fibras. Además el estudio destaca la extracción de características temporales y de frecuencia mediante transformadas de *wavelet*. Utiliza algoritmos de aprendizaje automático no supervisado para agruparlas y encontrar patrones en las señales.
- *Damage analysis of composite CFRP tubes using acoustic emission monitoring and pattern recognition approach* de Michal Sofrer, et al. publicado en *Materials* (2021) [8]: Utiliza las señales de emisión acústica para clasificar los tipos de fallo en tubos reforzados con fibras de carbono sometidos a ensayos de flexión en tres puntos. Combina técnicas de aprendizaje automático no supervisado con extracción de características mediante la transformada de Fourier de tiempo reducido. Identifica cuatro mecanismos de fallo que son rotura de fibras, delaminación, desprendimiento y agrietamiento de la matriz.

- *Do high frequency acoustic emission events always represent fibre failure in CFRP laminates?* de Fatih E. Oz, et al. publicado en *Composites Part A: Applied Science and Manufacturing* (2017) [9]: Este estudio demuestra que las señales de emisión acústica correspondientes a la rotura de fibras en CFRP, no siempre se corresponden con frecuencias altas. Para ello analiza las señales de AE producidas durante ensayos de tracción y las agrupa mediante técnicas de algoritmos no supervisados. Además, se utiliza correlación digital de imágenes (DIC) en la superficie y análisis con microscopio óptico para etiquetar las instancias.
- *Unsupervised learning for classification of acoustic emission events from tensile and bending experiments with open-hole carbon fiber composite samples* de Hisham A. Sawan, et al. publicado en *Composites Science and Technology* (2015) [10]: Se centra en comparar varios métodos de aprendizaje no supervisado para la agrupación de señales de emisión acústica. Los datos fueron recopilados durante ensayos de tracción y flexión sobre especímenes de laminados reforzados con fibras de carbono con distintas orientaciones. Combina el uso de datos en el dominio de la frecuencia y en el del tiempo. Finalmente los agrupamientos fueron etiquetados con la ayuda de correlación digital de imágenes, donde se observaron correlaciones entre los mecanismos de daño y las orientaciones de las láminas.
- *Classification of delamination and matrix cracking in carbon fibre composite plates using acoustic emission (AE)* de Dirk Aljets et al. publicado en *ASME 2009 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference* (2010) [11]: Utiliza una red neuronal para distinguir entre fallos provocados por delaminaciones o por ruptura de matriz en laminados reforzados con fibras de carbono. Se llevan a cabo ensayos de tracción y pandeo para recoger las señales de emisión acústica, de las cuales se extraen características temporales para el entrenamiento de la red.

1.2 Objetivos

El objetivo principal de este trabajo es desarrollar un modelo de clasificación de fuentes de impacto en una lámina unidireccional reforzada con fibras de carbono basado en técnicas de inteligencia artificial. Para ello se hará uso de características procedentes del contenido en frecuencia de las señales de emisión acústica generadas por los impactos.

Con el propósito de alcanzar el objetivo principal de este trabajo, se plantean los siguientes objetivos específicos:

- Realizar una revisión de la literatura sobre materiales compuestos, laminados reforzados con fibras de carbono, métodos de análisis de señales de emisión acústica y aplicaciones de inteligencia artificial y aprendizaje automático en este contexto.
- Recopilar y preparar un conjunto de datos de señales de emisión acústica a partir de un ensayo experimental con diferentes fuentes de impacto sobre una laminado unidireccional reforzado con fibras de carbono.
- Extraer características relevantes del contenido en frecuencia de las señales mediante el uso de la transformada de Fourier de tiempo reducido.
- Desarrollar un modelo de clasificación de las fuentes de impacto basado en bosques aleatorios, considerando las características extraídas previamente.

- Evaluar distintas configuraciones del modelo variando las características utilizadas, las técnicas de normalización el ajuste de los hiperparámetros para determinar la combinación con mejor rendimiento.
- Identificar la correspondencia entre las características extraídas de las señales de emisión acústica y las fuentes de impacto que las generaron, y cuáles de ellas son las más relevantes y discriminatorias para la clasificación.
- Establecer un marco de características y algoritmos de aprendizaje automático que pueden ser utilizados para la construcción de un modelo de identificación de tipos de fallos en laminados de fibras de carbono.

1.3 Estructura del trabajo

La organización del presente trabajo lleva la siguiente estructura:

- En este primer capítulo se presenta una introducción sobre los materiales compuestos y sus aplicaciones, y como el uso de las señales de AE conjuntamente con técnicas de inteligencia artificial puede ser utilizadas para distinguir entre distintas fuentes de impacto. Además se realiza una revisión del estado del arte y, finalmente se presentan los objetivos del trabajo.
- En el segundo capítulo se explican los fundamentos teóricos de los campos involucrados en el estudio. En él se destacan las secciones de materiales compuestos, propagación de ondas, análisis de las señales de emisión acústica y aprendizaje automático.
- En el tercer capítulo se habla sobre la metodología llevada a cabo tanto para el ensayo experimental de impactos, como del desarrollo, entrenamiento y evaluación del modelo de clasificación. Se presenta una descripción de la geometría y características del laminado, así como también del equipo de adquisición de datos y sus parámetros de configuración. Además, se detalla el proceso de extracción de características, incluyendo la aplicación de la transformada de Fourier de tiempo reducido. Finalmente, se explica el proceso de entrenamiento y evaluación del modelo junto con las métricas utilizadas para medir su rendimiento.
- El cuarto capítulo está dedicado a la presentación y análisis de los resultados obtenidos. Se examinan las diversas configuraciones del modelo de clasificación que se han explorado y se destaca cómo el rendimiento ha evolucionado al aplicar diferentes técnicas como la selección de características, la normalización y el ajuste de hiperparámetros. Se realiza una interpretación de las características utilizadas en el modelo y se establece su relación con las fuentes de emisión acústica correspondientes. Además, se contrastan y discuten estos resultados con otras investigaciones anteriores de este campo, destacando las similitudes y diferencias encontradas. Esta sección brinda una visión completa de cómo cada elección y enfoque ha influido en la capacidad del modelo para identificar con precisión las fuentes de impacto en el laminado.
- El quinto y último capítulo de este trabajo expone las conclusiones derivadas de la investigación realizada. Finalmente, se presenta la bibliografía empleada a lo largo del estudio.

Después de la memoria, se presentan tres apartados adicionales:

- Un apartado de anexos, donde se incluye el código empleado en los capítulos 3 y 4.
- El pliego de condiciones, que recoge las regulaciones, condiciones técnicas y legales enmarcadas en la elaboración del proyecto.
- Por último en el apartado de presupuesto se detalla la lista de costes requeridos para la realización y desarrollo del trabajo.

Fundamentos Teóricos

2.1 Materiales compuestos y sus propiedades

Un material compuesto es una combinación de dos o más materiales a escala macroscópica, que tienen distintas propiedades físicas o químicas. Esto los diferencia de las aleaciones donde los materiales se combinan en una escala microscópica y el material resultante es homogéneo macroscópicamente [12]. Además, la dispersión de un material en otro puede ser controlada a la hora de su fabricación. La combinación de estos materiales permite obtener un componente con propiedades superiores a sus materiales constituyentes, produciéndose un efecto sinérgico [13].

Dentro de las propiedades que se pueden mejorar con un material compuesto están:

- Límite elástico
- Rigidez
- Resistencia a la corrosión
- Resistencia al desgaste
- Baja densidad
- Vida a fatiga
- Aislamiento térmico
- Aislamiento acústico
- Conductividad térmica

2.1.1 Clasificación de los materiales compuestos

Los materiales compuestos típicamente se pueden clasificar en:

- **Compuestos reforzados con fibras:** Están compuestos por fibras orientadas en direcciones determinadas embebidas dentro de una matriz, comúnmente polimérica. Las fibras pueden ser de dos tipos: fibras largas y fibras cortas (whiskers). Las primeras presentan una relación longitud/diámetro muy elevada (en el orden de 10 000:1) [14] y el tamaño del cristal es del mismo orden de magnitud que su diámetro, lo que permite que su estructura interna presente menos defectos internos que el material en bruto. Esta poca presencia de defectos se ve reflejada en mejores propiedades del material. Por ejemplo, el límite de rotura de una fibra de vidrio es de 80 a 200 veces superior al vidrio en su forma bruta.

En cambio en las fibras cortas la relación longitud/diámetro es menor (en torno a 100:1). Si bien su estructura presenta pocos defectos, al igual que las fibras largas, resulta complicado y costoso incorporarlas con un alto grado de orientación y alineación dentro de un material.

- **Compuestos laminados:** Se trata de compuestos formados por láminas dispuestas en forma de capas apiladas y unidas entre sí. Pueden ser de distintos tipos como por ejemplo: bimetales, metales recubiertos, vidrio laminado, laminados de base plástica. Uno de los laminados más utilizados son aquellos reforzados con fibras, es decir, que cada una de las láminas son compuestos reforzados con fibras. Su mayor ventaja es que se puede disponer cada capa con distintas orientaciones dependiendo de los requerimientos y aplicación [15].
- **Compuestos reforzados con partículas:** En este caso el refuerzo se realiza mediante partículas. Existen diferentes combinaciones para este tipo de materiales, en general se distinguen cuatro:
 - Partículas no metálicas en matriz no metálica. Por ejemplo el hormigón.
 - Partículas metálicas en matriz no metálica. Como el combustible sólido usado en cohetes (polvo de aluminio aglutinado con caucho de poliuretano).
 - Partículas metálicas en matriz metálica. Partículas de plomo incluidas en aleaciones de cobre y acero, para dar un efecto lubricante.
 - Partículas no metálicas en matriz metálica. Por ejemplo varillas de reactores nucleares (óxido de uranio en matriz de acero inoxidable) [13].

2.1.2 Aplicaciones de los materiales compuestos

Las principales aplicaciones de los materiales compuestos son:

- **Aeronáutica:** En esta industria la utilización de materiales compuestos tiene un gran impacto por la reducción de peso que estos permiten. Por ejemplo con el uso de una aleación metálica se puede obtener una relación empuje/peso de 5 a 1. Mientras que con un plástico reforzado esta relación puede ser de 16 a 1 o incluso mayor [13].
- **Automoción y ferrocarril:** Muchas de las piezas estructurales y auxiliares se pueden fabricar con materiales compuestos. Como por ejemplo: parachoques, capot, puertas, interior de los habitáculos, etc.

- **Industria química:** Combina la resistencia a alta presión y la resistencia a la corrosión. Utilizado en recipientes a presión, reactores, tuberías.
- **Medicina:** Instrumental médico y prótesis.
- **Material deportivo:** Equipamiento de alta competición, raquetas de tenis, cascos, tablas de surf, cañas de pescar, etc.
- **Construcción:** Aislamiento térmico y acústico, mamparas, piscinas.

2.2 Plásticos reforzados con fibras de carbono (CFRP)

Los plásticos reforzados con fibras de carbono (*Carbon fiber reinforced polymer - CFRP*) son materiales compuestos catalogados como refuerzos de alto rendimiento. Las fibras de carbono generalmente están embebidas en resina termoestable como epoxi, aunque también puede usarse polímeros termoplásticos como poliéster o nylon.

Las fibras de carbono oscilan entre 7 i 8 μm y presentan una estructura cristalina. Además, tienen un elevado módulo de rigidez en dirección al eje paralelo a la fibra producto de que las capas de átomos de carbono, que aunque no sean planas, tienden a estar paralelas a este eje. Esto produce que el módulo en la dirección de la fibra sea mucho mayor que en dirección transversal. Lo mismo ocurre con la conductividad térmica y eléctrica que son más altas en la dirección de la fibra, mientras que el coeficiente de expansión térmica es menor en la dirección de la fibra [16].

Se pueden diferenciar dos tipos de fibras de carbono: las de alta rigidez y las de alta resistencia. Las primeras presenta un módulo de elasticidad aproximadamente cuatro veces mayor al del acero y con una densidad cuatro veces menor, aunque presentan menor resistencia que las fibras de vidrio. En cuanto las fibras de alta resistencia tienen una resistencia a la tracción 40 % mayor comparado con las fibras de vidrio y además presentan una densidad 30 % menor a éstas [17].

2.2.1 Laminados de fibras de carbono

Un laminado se trata de un componente que está constituido por un número determinado de láminas, generalmente unidireccionales, donde una de sus dimensiones (su espesor) es mucho menor que las otras dos, colocadas una sobre otras y unidas entre sí (Figura 2.1). Su utilización es apropiada cuando los esfuerzos principales se desarrollan en el plano del laminado o tangentes a la superficie neutra donde predominan los esfuerzos de membrana [13].

Para su nomenclatura se puede utilizar el código propuesto por S. W. Tsai que se basa en la utilización de una línea de referencia contenida en el plano medio a partir del cual, mediante ángulos se definen las orientaciones de cada una de las láminas unidireccionales. Además se cumplen los siguientes criterios:

- Para indicar la orientación de las láminas se comienza por la lámina superior y finaliza con la inferior. Para el caso de laminados simétricos se finaliza con la capa media.
- Para laminados no simétricos se puede utilizar el subíndice T o bien no utilizar ninguno. Mientras que para los laminados simétricos se indica la orientación de la mitad de las capas y se utiliza el subíndice S .

- Si existen láminas adyacentes con igual orientación se debe indicar con un subíndice numérico.
- También es posible indicar un sublaminao que se repite varias veces incluyéndolo entre corchetes y utilizando un índice para indicar cuantas veces se repite.

A continuación se presenta un ejemplo de notación de un laminado: $[0_3/90_2/45/-45]_S$.

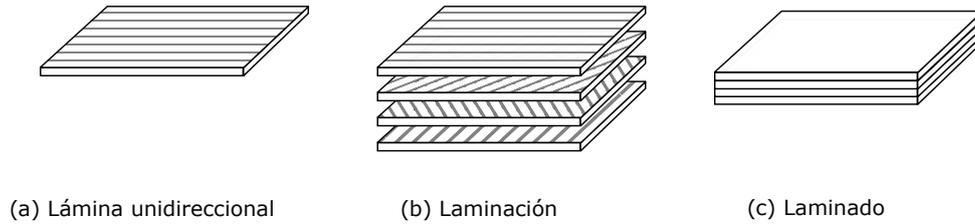


Figura 2.1: Esquema de la configuración de un laminado.

La orientación de las láminas puede influir en el comportamiento final del conjunto. La configuración más sencilla de todas se trata del laminado unidireccional, donde todas las láminas que lo componen están orientadas en la misma dirección. Existen también los laminados cruzados (*crossed-ply*) donde las direcciones de las láminas pueden ser solo 0° y 90° .

Otras configuraciones son el laminado equilibrado y el simétrico. En el primero para cada lámina con orientación θ existe otra con orientación $-\theta$, mientras que en el simétrico para cada lámina con orientación θ a una distancia z_i del plano medio, existe otra lámina idéntica a una distancia $-z_i$ del plano medio.

Al combinar algunas de estas combinaciones se pueden obtener diferentes comportamientos a nivel de acoplamiento, es decir, cuando esfuerzos normales pueden causar deformaciones tangenciales o esfuerzos tangenciales causar deformaciones normales. Un ejemplo de ello son los laminados cuasiortótropos, que se tratan de laminados simétricos y equilibrados cuyo comportamiento es parecido al de una lámina ortótropa. En cambio si un laminado es cruzado y simétrico se denomina laminado ortótropo, ya que su comportamiento es idéntico al de una lámina ortótropa. También es posible conseguir un comportamiento cuasiisótropo si el laminado cumple las siguientes condiciones: es simétrico y equilibrado, todas las láminas tienen el mismo espesor y composición y sus orientaciones vienen dadas por $180^\circ/N + \theta_0$ con $N \geq 3$, por ejemplo $[0/60/-60]_S$.

2.2.2 Propagación de ondas en laminados

El movimiento ondulatorio es un fenómeno en el cual los movimientos de las partículas son transferidos dinámicamente a partículas adyacentes. Una partícula solo vibra en su propia posición y no se traslada. Sin embargo, el movimiento ondulatorio en sí se propaga con su velocidad característica. Se pueden distinguir distintos tipos de onda en base a las orientaciones de los movimientos de partículas y las direcciones de propagación [18]. En la Figura 2.2 se ilustra diferentes tipos de onda, se indica el movimiento de las partículas (flechas negras) y la dirección de propagación (flechas rojas).

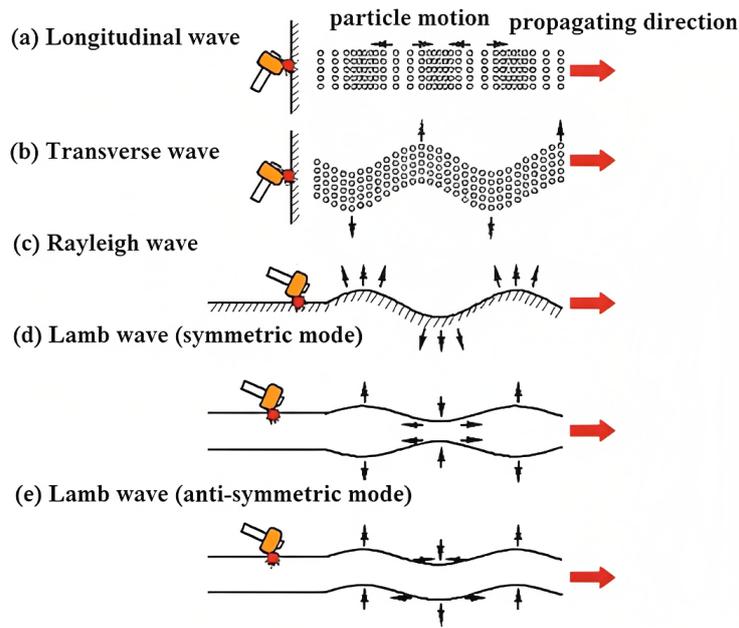


Figura 2.2: Tipos de movimiento ondulatorio [18].

- **Ondas longitudinales:** En este tipo de onda las partículas vibran a lo largo de la dirección de propagación (Figura 2.2 a). Esta onda también es llamada onda de dilatación, ya que está asociada con cambios de volumen. La onda longitudinal puede propagarse a través de todos los tipos de medios, ya sean sólidos, líquidos o gases, y es la más rápida de las ondas elásticas.
- **Ondas transversales:** Aquí las partículas vibran perpendicularmente a la dirección de propagación (Figura 2.2 b). La onda transversal también se llama onda de corte y puede propagarse a través de sólidos pero no a través de líquidos y gases.
- **Ondas Rayleigh:** En este caso las partículas cercanas a la superficie se mueven elípticamente, y el movimiento disminuye con la profundidad (Figura 2.2 c). Es denominada como una onda de superficie.
- **Ondas Lamb:** Este tipo de ondas se propagan en materiales tipo placa de pared delgada, por lo que se las conoce como ondas de placa. Se producen cuando la longitud de onda es mayor que el espesor del material. A causa de la reflexión y superposición de ondas tiene dos modos de vibración. Uno simétrico (S_0) o de extensión, como se muestra en la Figura 2.2 (d), y un modo antisimétrico (A_0) también llamado de flexión, como se muestra en la Figura 2.2 (e) [18].

Debido a que los laminados son elementos de pared delgada o de tipo placa las ondas que se propagan a través de su superficie son de tipo Lamb, tanto en su modo simétrico como antisimétrico.

En un medio infinito e isotrópico la propagación de ondas no presentaría pérdidas de energía. Sin embargo, en materiales reales, las ondas elásticas experimentan varios efectos de atenuación. El principal motivo para la atenuación es la propagación geométrica, que se refiere a la disminución de la energía de una onda a medida que se propaga desde su fuente. Esta pérdida se debe a

que la energía se distribuye en un área cada vez mayor a medida que la onda se aleja de su punto de origen. En otras palabras, la energía se esparce a medida que se propaga en el espacio tridimensional [19]. Las ondas de altas frecuencias sufren una mayor atenuación, por lo tanto la atenuación de los modos antisimétricos es mayor que la atenuación en los modos simétricos.

Para materiales compuestos, como los laminados de fibras de carbono, esta atenuación es aún más pronunciada debido a la anisotropía que presentan este tipo de materiales. Además, existen otros aspectos que pueden causar atenuación o distorsión de las ondas como los aspectos geométricos, presencia de defectos, secuencia de apilado, entre otros. Primero la velocidad de propagación depende tanto del espesor de la placa como de la frecuencia y modo de propagación de la onda [18].

En la Figura 2.3 se ilustra el efecto que tiene el espesor de la placa en la forma de la onda que se propaga a través de una placa unidireccional de material T800/913. En ella se comparan las señales acústicas generadas por la misma fuente en tres espesores diferentes de placa. En esta figura se puede diferenciar dos regiones, la parte inicial del transitorio, y las reflexiones de la señal. No se observa una diferencia significativa en el tiempo en el que inician de las reflexiones para los tres casos. Esto se debe a que en todos los ensayos, la longitud y el ancho de la placa son idénticos, y solo ha variado su espesor. La principal diferencia se encuentra en la parte inicial de la señal, donde el espesor de la placa más delgada presenta un mayor número de ondas en comparación con las placas más gruesas. A medida que aumenta el espesor de la placa, se reduce la cantidad de ondas en este intervalo inicial. Debido a la naturaleza de las ondas de placa, su contenido de frecuencia está implícitamente relacionado con el espesor del laminado, lo que provoca un cambio sustancial en la frecuencia de la onda. Por ejemplo, la placa de 1 mm exhibe un mayor número de ondas en el inicio de la señal, lo que se traduce en una frecuencia más alta. Por otro lado, el espécimen de 3 mm de espesor muestra menos ondas en el mismo período de tiempo, lo que resulta en una frecuencia más baja [19].

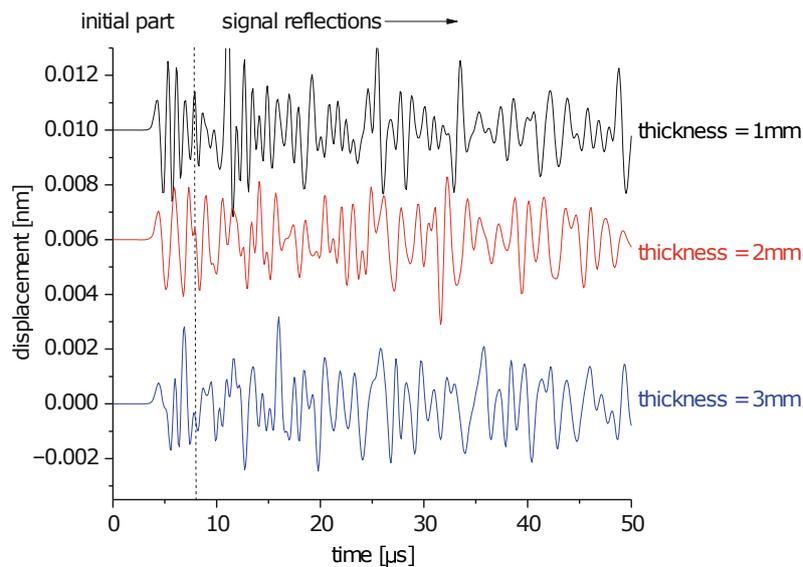


Figura 2.3: Influencia del espesor de placa en la propagación de una onda en un laminado de T800/913 [19].

La propagación de una onda depende también de la orientación que tengan las fibras. Esto indica que dependiendo de la secuencia de laminado una onda puede propagarse de distinta manera y sufrir mayor o menor atenuación. En la Figura 2.4 se observa la influencia de la secuencia de apilado sobre la forma de la onda. La figura compara tres tipos de laminados: una lámina unidireccional, un laminado cruzado $[0/90/90/0]_S$, y un laminado cuasiisótropo $[90/-45/45/0]_S$, todos con dimensiones idénticas.

De forma similar al caso anterior se presentan cambios en la frecuencia de la onda, así como también en su velocidad de propagación. En concreto se observa la diferencia en el tiempo en el que inicia las reflexiones de la onda y el tiempo de subida de la señal, ligado directamente con la velocidad de propagación. En el caso de la lámina unidireccional, la velocidad de propagación es más alta que en los otros casos, por lo que las reflexiones aparecen antes. Además de las diferencias en la velocidad de propagación, también se aprecia un mayor número de ondas en los casos de lámina unidireccional y laminado cruzado en comparación con el caso cuasiisótropo. Esto se traduce en una frecuencia más alta en los dos primeros casos.

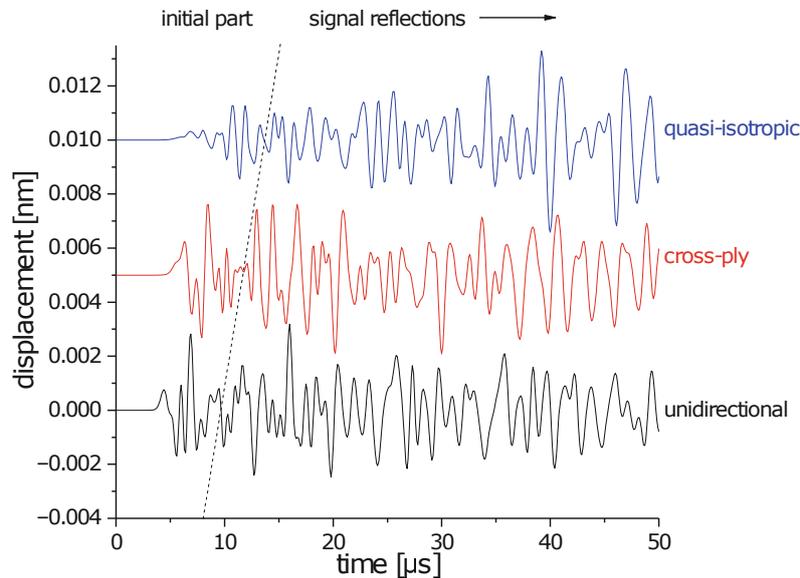


Figura 2.4: Influencia de la secuencia de apilado en la propagación de una onda en un laminado de T800/913 [19].

Además existen otros factores que pueden influir en el modo de propagación de una onda en laminados de fibras de carbono. Por ejemplo defectos en la composición, como vacíos u ondulaciones, grietas en la matriz o interfaz, fibras rotas, delaminaciones, discontinuidades en la geometría, como agujeros, e incluso los elementos de unión como pernos, pueden afectar su propagación.

2.3 Emisiones acústicas

Se entiende como emisión acústica a una onda transitoria de tensión elástica generada por la energía liberada cuando se producen cambios estructurales en un material. Esta energía liberada proviene del campo de tensión elástico, que puede ser producido por esfuerzos de tipo mecánico, térmico o químico [20].

Cuando una onda de emisión acústica alcanza la superficie del material causa que esta vibre, y dicha vibración puede ser medida. Los pequeños desplazamientos de la superficie (en el orden de picómetros - pm) pueden excitar a transductores que registran y convierten este movimiento en una señal eléctrica que ya puede ser utilizada para el análisis de la onda. Pero existe un inconveniente, las características de la señal eléctrica registrada son muy distintas a las que originalmente se producen por la onda de AE. Conforme una onda de emisión acústica se propaga desde su fuente a través del material es influenciada por una variedad de factores, como por ejemplo, cambios en la velocidad de propagación, atenuación, reflexión, refracción, discontinuidades en el material, etc.

Otros factores que pueden influir en este tipo de ondas son las propiedades del material, la geometría del componente, e incluso el tipo de sensor que se utiliza para detectarlas. Todos ellos afectan las características de la señal detectada y estudiar su contribución es importante para realizar una correcta interpretación de las señales de emisión acústica [21].

En la Figura 2.5 se muestra una configuración típica de un transductor piezoeléctrico resonante y como convierte una señal de emisión acústica, que es generada en el material y que se propaga hasta la superficie, en una señal eléctrica.

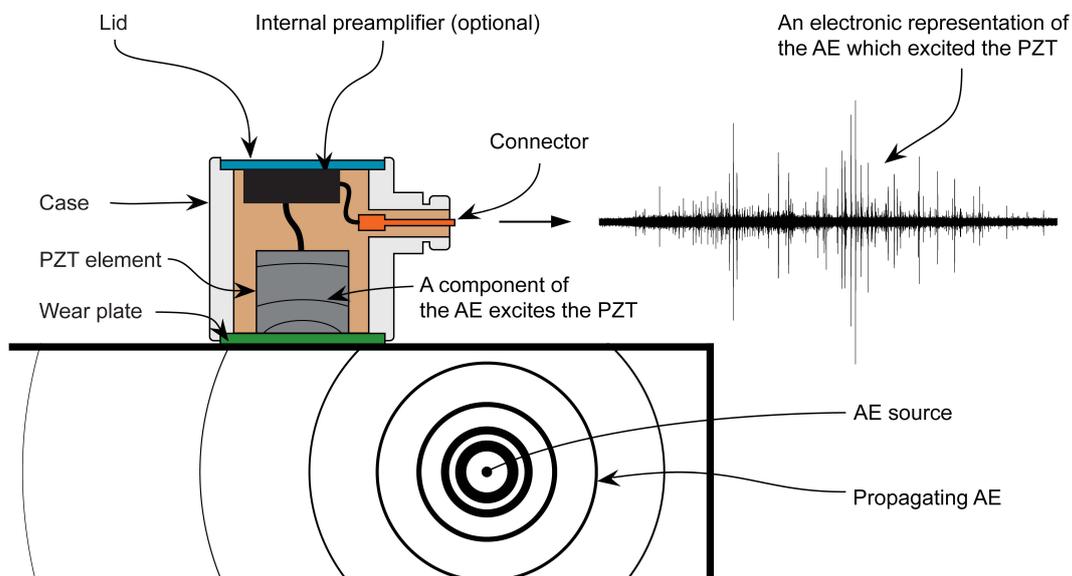


Figura 2.5: Ilustración de un transductor piezoeléctrico resonante y cómo se transforma una señal de AE en una señal eléctrica. [22].

A pesar de que los sensores piezoeléctricos son muy sensibles a la detección de desplazamientos en la superficie, la mayoría de ellos muestran un comportamiento intrínsecamente resonante. Esta respuesta resonante en frecuencia se debe a las propiedades de los materiales piezoeléctricos y a las

dimensiones finitas del sensor. Estos efectos superponen la característica de frecuencia de la onda elástica detectada. Por lo tanto, para interpretar adecuadamente la distribución de frecuencias de las señales de AE, es necesario tener en cuenta el efecto del sensor. Esto se ejemplifica en la Figura 2.6 que señala la influencia de factores como el material, el camino de propagación y la característica del sensor sobre el espectro de frecuencia de una señal de emisión acústica.

En ella se representa el espectro de frecuencia de la señal original (en negro), que muestra una magnitud decreciente de aproximadamente un orden de magnitud a medida que aumenta la frecuencia y no presenta fluctuaciones. Se muestra cómo el material y el camino de propagación de la onda afectarán a la señal original a medida que se propaga a través de este medio. La influencia en la señal depende de la geometría, las propiedades del material y la presencia de defectos en el medio. En azul, se muestra la curva característica del sensor, que está definida por sus propiedades y dimensiones específicas y que varía según el tipo de sensor. Es notable cómo ciertas frecuencias son amplificadas en los picos y atenuadas en los valles de esta curva. Finalmente, en verde se presenta el espectrograma de la señal registrada después de haber sido influenciada por todos estos factores. Se observa una marcada diferencia en comparación con la señal original, con un mayor número de fluctuaciones y donde algunas frecuencias han sido amplificadas mientras que otras han sido atenuadas.

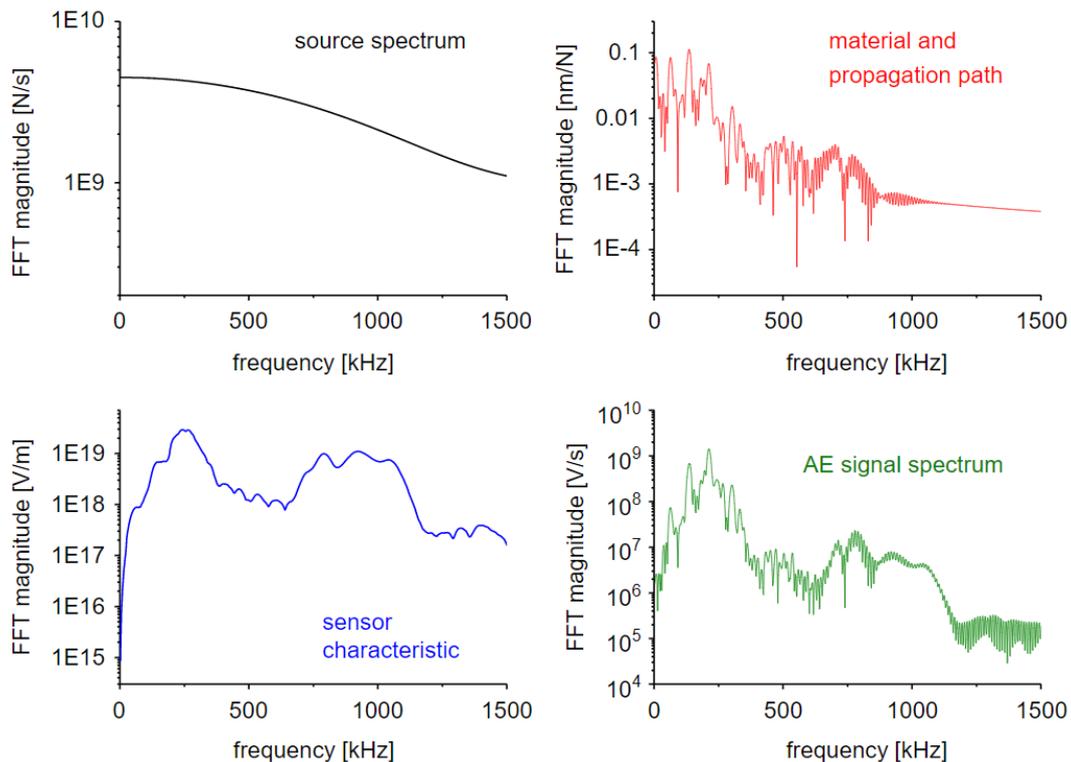


Figura 2.6: Contribución individual del tipo de material y geometría, características del sensor en el espectro de frecuencia de una señal de emisión acústica [23].

2.3.1 Fuentes de emisión acústica en laminados de fibras de carbono

En general las señales de emisión acústica se originan por desplazamientos microscópicos repentinos ya sea en el volumen o en la superficie de medios sólidos. La aplicación de esfuerzos mecánicos como tracción, compresión, impactos, etc., pueden causar cambios internos del material que liberan energía en forma de ondas. En el contexto de materiales compuestos y en laminados de fibras de carbono las señales de AE que generalmente se producen provienen de daños internos del material, como por ejemplo:

- Generación y propagación de grietas en la matriz y en la interfaz fibra-matriz.
- Rotura de fibras.
- Delaminación
- Fricción entre las paredes de grieta existentes (comúnmente en cargas variables).

Además pueden existir otras fuentes de emisión que no estén relacionadas a daños internos, como por ejemplo impactos en el material y vibraciones de alta frecuencia, pero también otras fuentes que no son deseables para el análisis y pueden ser consideradas como ruido por su interferencia con las señales de interés. Entre estas fuentes de ruido están:

- Los movimientos relativos en las conexiones del componente con la estructura que causan movimientos de fricción de tipo *stick-slip*.
- Electrónica de alta potencia que produce inducción electromagnética en los cables del sensor generan señales transitorias que no están relacionados con ningún origen acústico.
- Actuadores mecánicos que comúnmente tienen fricción interna.
- En máquinas servo-hidráulicas, el funcionamiento de la servo-válvula puede provocar un flujo constante de baja actividad de emisiones acústicas durante su funcionamiento.

En contraste a todas las fuentes mencionadas, cualquier fuente de emisión audible no interfiere en la medición de las señales de emisión acústica debido a que estas se producen en una banda de frecuencia baja, mientras que las mediciones de AE empiezan entre 10 i 20 kHz hasta 1 MHz [23].

2.3.2 Parámetros de adquisición y características de las señales de emisión acústica

Debido a todos los factores listados anteriormente, la representación digital de una señal de emisión acústica será diferente a la señal original. Pese a esto estas señales registradas se han utilizado con éxito en la detección, monitorización y reconocimiento entre varios tipos de daño en laminados de fibras de carbono, como delaminación, agrietamiento de la matriz, rotura de fibra [24]. Con el fin de distinguir entre las fuentes que producen las señales es necesario conocer cuáles son sus características y qué parámetros son comúnmente utilizados para su adquisición.

Las señales de emisión acústica se pueden dividir en tres tipos: transitorias, continuas y mixtas. Las señales transitorias están generadas por la formación de daño o por impactos sobre el material, se caracterizan por tener un claro inicio hasta alcanzar la amplitud pico seguido de un decaimiento antes de desaparecer en el ruido de fondo. Las señales continuas son generadas cuando múltiples señales transitorias se solapan y no pueden distinguirse unas de otras, haciendo que

la envolvente de la amplitud de la señal sea constante en el tiempo. Son producidas por fuentes de fricción o por ruido eléctrico. Por último, las señales de tipo mixto son una combinación de las dos anteriores y es el tipo que se encuentra normalmente en servicio. En la Figura 2.7 se presentan una señal transitoria y una señal continua de emisión acústica.

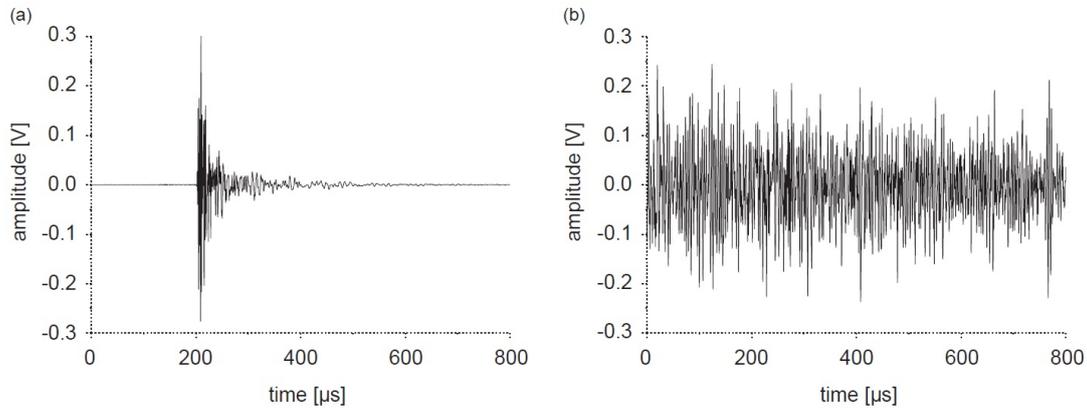


Figura 2.7: Ejemplo de una señal transitoria de AE (a) y un segmento de señal continua de AE (b). [23].

El método más utilizado para extraer información de una señal de emisión acústica consiste en identificar las ondas transitorias contenidas dentro de la señal y posteriormente extraer las características relevantes ya sea en el dominio del tiempo o frecuencia. Estas señales transitorias se denominan *hits*, que son porciones de la señal original que satisfacen un criterio de detección dado y tienen una duración definida. El propósito de este criterio de detección es identificar la presencia de una señal transitoria y discriminarla del ruido de fondo o de una señal continua.

Una técnica generalmente utilizada consiste en establecer como criterio de detección un valor umbral (*threshold*) con el cual se compara la señal. Si la amplitud de la señal supera el umbral entonces se registra un hit. Este parámetro comúnmente se establece 6 dB por encima del ruido de fondo, el cual se determina con una medición previa.

Además existen otros parámetros de adquisición que son útiles al momento de establecer la duración de un hit como el tiempo de definición (*hit definition time - HDT*), tiempo de bloqueo (*hit lockout time - HLT*) y tiempo de definición de pico (*peak definition time - PDT*). Estos parámetros se ilustran en la Figura 2.8.

El tiempo de definición (HDT) especifica el tiempo máximo entre dos cruces por el umbral de un mismo hit, es decir, si no ocurren cruces del umbral dentro de este tiempo, el hit ha terminado. Es uno de los parámetros más importantes ya que si se establece un valor muy alto el sistema de adquisición puede interpretar a dos o más hits como uno solo, mientras que si el valor establecido es muy bajo detectará múltiples hits cuando en realidad solo se ha producido uno.

El tiempo de bloqueo (HLT) es el tiempo que debe transcurrir después de detectar un hit antes de que se pueda registrar otro. Si su valor es muy alto puede que el sistema no sea capaz de capturar el siguiente hit y, por el contrario, si se ha establecido un valor bajo se pueden capturar los reflejos de la señal como un hit.

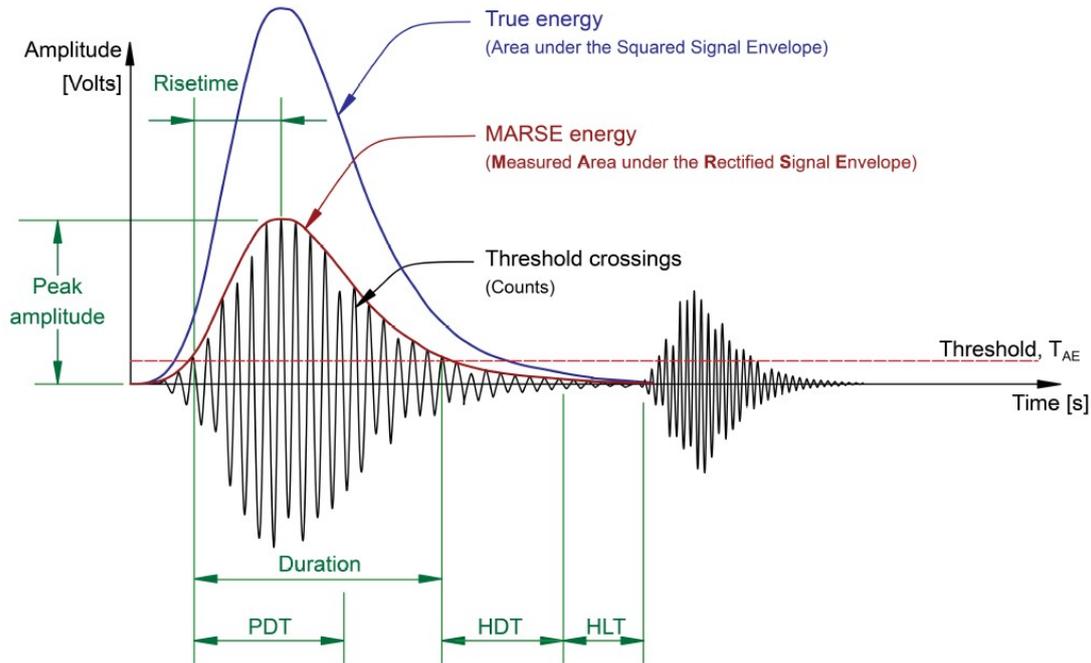


Figura 2.8: Parámetros de adquisición y características de un hit de emisión acústica [21].

Por último, el tiempo de definición de pico (PDT) especifica el tiempo, después del primer cruce por el umbral, para determinar la amplitud pico. Igual que los anteriores parámetros no deben establecerse valores muy altos, que causarían falsas medidas de la amplitud pico. Lo recomendable es elegir un valor bajo, pero no excesivamente bajo pues el verdadero valor de la amplitud pico no sería identificado [21].

En la Figura 2.8 también se ilustra algunas de las características que se pueden extraer para el análisis de un hit de señal acústica. Entre ellas se incluyen:

- **Amplitud pico:** Es la amplitud máxima que alcanza la señal dentro de su tiempo de duración. Generalmente viene expresado en dB o mV dependiendo del sistema de adquisición.
- **Duración:** Es el tiempo definido entre el primer y último cruce de la señal por encima del valor umbral.
- **Energía:** Aquí se puede diferenciar entre la energía real (*True energy*) y la energía MARSE (*Measured Area under the Rectified Signal Envelope*). La primera se calcula como el área bajo la envolvente de la señal elevada al cuadrado. Mientras que la segunda, como su nombre lo indica, es el área bajo la envolvente.
- **Tiempo de subida:** También conocido como *rise-time* es el tiempo que transcurre desde el primer cruce de la señal por el umbral hasta que alcanza la amplitud pico. Esta característica es muy utilizada cuando se busca determinar la localización de la fuente que generó la señal.
- **Conteo:** Se trata del número de veces que la señal ha cruzado el valor umbral. En general los sistemas de adquisición establecen como *counts* solo aquellos cruces en la parte positiva de la señal.

2.3.3 Tipos de sensores

Los sensores de tipo piezoeléctrico son los más utilizados para captar las señales de emisión acústica, pero dentro de este grupo existen diferentes tipos con sus respectivas propiedades. Dentro de las propiedades que más destacan están el ancho de banda y la planitud de la respuesta de frecuencia. Por ejemplo, para ciertas aplicaciones solo es interesante detectar las señales acústicas y características básicas como la amplitud, duración, conteo, etc. Otras aplicaciones en cambio requieren información del espectro en frecuencia de la señal, como en tareas de reconocimiento de fuentes de emisión, donde es necesario contar con un sensor que posea un amplio ancho de banda y que en lo posible presente una respuesta de frecuencia plana. Con estas consideraciones se puede clasificar en tres tipos de sensores: resonante, multi-resonante y de banda ancha [19].

Los sensores piezoeléctricos resonantes, como su nombre lo indica, se basan en la propiedad de resonancia mecánica. Están diseñados para operar en un rango de frecuencias corto y presentan mayor sensibilidad cuando operan cerca de la frecuencia de resonancia. Son útiles cuando se requiere registrar las señales y que se conoce que el rango de frecuencias a analizar caen dentro del rango de sensibilidad del sensor.

Los sensores multi-resonantes están diseñados para operar en varios modos de resonancia, lo que les permite capturar información en un amplio rango de frecuencias. Resultan muy útiles en entornos ruidosos o en situaciones donde existen diversas fuentes de emisión superpuestas.

Por último, los sensores de banda ancha permiten obtener respuestas en un espectro más amplio y generalmente tienen una respuesta de frecuencia más plana en comparación con el comportamiento presentado por los sensores resonantes y multi-resonantes. Son muy utilizados en aplicaciones donde se requiere extraer información relevante en el dominio de la frecuencia y cuando no se conoce el rango de registro de las fuentes de emisión acústica.

En la Figura 2.9 se pueden observar los distintos tipos de sensores de la marca Vallen Systeme, incluyendo las especificaciones del fabricante como el tamaño, las características de resonancia y rango de frecuencias de funcionamiento. Mientras que en la Figura 2.10 se muestra una comparación en las curvas de respuesta de frecuencia de los mismos sensores. Para los sensores resonante y multi-resonante, Figura 2.10 (a) y (b) respectivamente, se observan claramente los picos en las frecuencias de resonancia. En el caso del sensor de banda ancha en la Figura 2.10 (c) se aprecia una respuesta de frecuencia más plana y un rango de funcionamiento más amplio.

2.4 Análisis en frecuencia de las señales

Una señal de emisión acústica puede analizarse de distintas formas. Existen principalmente tres maneras de hacerlo: en el dominio del tiempo, de la frecuencia o en tiempo-frecuencia.



Figura 2.9: Tipos de sensores piezoeléctricos incluyendo especificaciones del fabricante [25].

2.4.1 Dominio del tiempo

El análisis en el dominio de tiempo implica extraer directamente la información capturada por los sensores piezoeléctricos para su posterior análisis. Se pueden registrar varias características en el tiempo, como la amplitud pico, el tiempo de subida, la duración y la energía, entre otras. Este enfoque tiene ventajas, como la facilidad para obtener información, la sencillez en su interpretación y la necesidad de poca intervención en el procesamiento posterior de la señal. Sin embargo, una limitación importante es que todas sus características dependen de la posición relativa entre la fuente emisión y el sensor. Es decir, si la fuente de emisión está muy cerca del sensor las señales registradas tendrán mayor amplitud, energía y duración. En cambio, si la fuente está muy distante del sensor la señal recibida presentará atenuación con valores más bajos de amplitud, energía, etc. Esto puede dificultar el análisis de reconocimiento de fuentes de emisión, ya que una misma fuente puede generar diferentes características.

2.4.2 Dominio de la frecuencia

Las desventajas presentadas por las características extraídas en el dominio del tiempo pueden superarse al utilizar un análisis en frecuencia. Se puede hacer uso de la transformada de Fourier para descomponer la señal en sus componentes de frecuencia, lo que resulta útil para estudiar la composición espectral de la señal.

En la práctica se utiliza la transformada rápida de Fourier (*Fast Fourier Transform - FFT*) que es un algoritmo que computa de manera eficiente la transformada de una señal discreta. Existen dos aspectos a tener en cuenta al utilizar la FFT. El primero es la resolución en frecuencia, que es igual al inverso del tiempo de adquisición de la señal. El segundo es el rango de frecuencia que se puede analizar, que queda determinado por la frecuencia de muestreo. De acuerdo con el teorema de muestreo de Nyquist-Shannon, para evitar el fenómeno de aliasing, la frecuencia

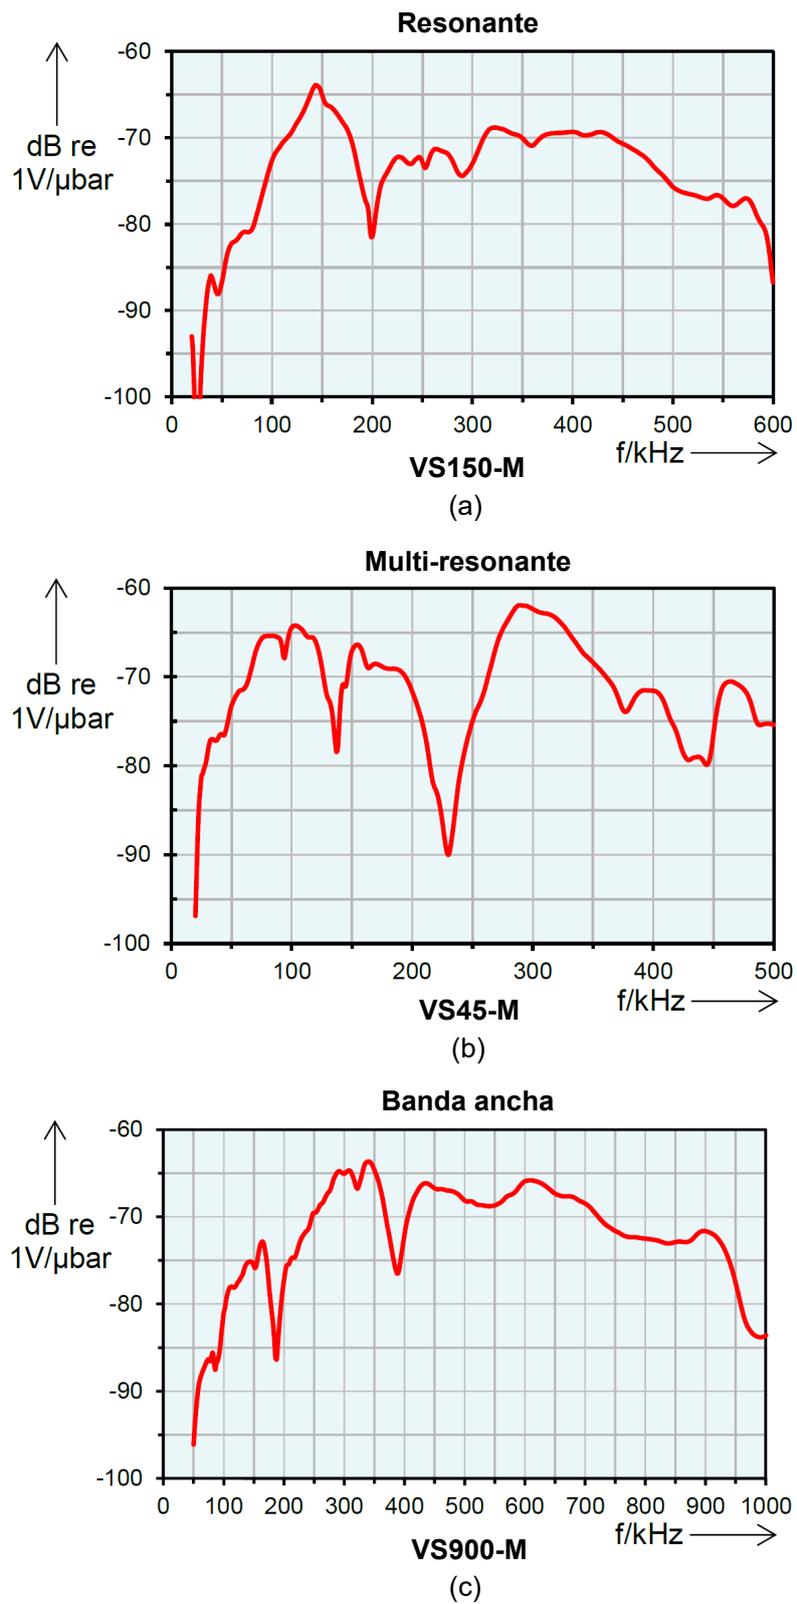


Figura 2.10: Curvas de respuesta en frecuencia para el sensor resonante (a), multi-resonante (b) y de banda ancha (c) [25].

de muestreo debe ser al menos el doble de la frecuencia más alta presente en la señal. Por lo tanto, el rango de frecuencias analizado por la FFT se extiende desde cero hasta la mitad de la frecuencia de muestreo [26].

Este análisis permite extraer características independientes de la amplitud de la señal registrada, sino que son propias de la fuente. Sin embargo, los efectos de atenuación pueden influir en la velocidad de propagación de la onda, que causa distorsión en el contenido en frecuencia de la señal. Pese a esto varias investigaciones [5], [27]-[32] han demostrado que es posible discriminar el tipo de fuente que ocasionó la señal de EA utilizando este método.

2.4.3 Dominio tiempo-frecuencia

Por último, el análisis en tiempo-frecuencia combina la información de los dominios de tiempo y frecuencia, lo que lo hace especialmente útil para analizar señales transitorias, donde la señal varía en función del tiempo y se busca analizar su evolución. Entre las técnicas más utilizadas se encuentran la transformada de Fourier de tiempo reducido o STFT, las transformadas continuas de wavelet (CWT) y los análisis de espectrogramas.

La STFT permite descomponer la señal en sus componentes de frecuencia para intervalos de tiempo específicos. Esto significa que es posible obtener información sobre cómo varían las frecuencias a lo largo del tiempo en una señal dada. Por otro lado, las transformadas continuas de wavelet también brindan una representación similar en tiempo-frecuencia y permiten analizar señales con contenido no estacionario en el tiempo.

Además, los espectrogramas son representaciones gráficas que muestran la energía de la señal en función del tiempo y la frecuencia. Proporcionan una visión más intuitiva de cómo se distribuye la energía espectral en diferentes momentos temporales. Estas técnicas ofrecen una mayor capacidad para identificar cambios en el espectro de frecuencia de una señal a medida que avanza el tiempo, lo que es especialmente valioso para analizar señales transitorias [33].

2.4.4 Transformada de Fourier de tiempo reducido - STFT

La transformada de Fourier de tiempo reducido es una extensión natural de la transformada de Fourier. Permite obtener información de frecuencia localizada en el tiempo para situaciones en las que los componentes de frecuencia de una señal varían a lo largo del tiempo, mientras que la Transformada de Fourier estándar proporciona información de frecuencia promediada sobre todo el intervalo de tiempo de la señal [34].

La STFT considera solo segmentos de corta duración y computa sobre ellos la transformada de Fourier. Normalmente se lleva a cabo multiplicando la señal en función del tiempo $x[k]$ por una función de ventana $w[k]$ de corta duración. Dos ventanas de duración finita comúnmente utilizadas son la ventana rectangular, que extrae un segmento de la señal sin modificaciones adicionales, y la ventana de Hamming, que aplica una atenuación en los extremos para mejorar la representación en el dominio de frecuencia.

Es muy común utilizar solapamiento entre los segmentos, comúnmente de un 50%, para evitar los efectos de borde, es decir, que los valores de los extremos se atenúen debido a la presencia de la ventana. Además mejora la resolución temporal y por ende también se consigue una mejora en la representación espectral.

La STFT se puede utilizar tanto para funciones continuas como discretas, aunque en la práctica lo más común es utilizar señales discretas debido a los métodos de adquisición de señal. La versión discreta de la STFT se presenta en la Ecuación 2.1:

$$X[m, n] = \sum_{k=0}^{L-1} x[k]w[k-n]e^{-j2\pi mk/L} \quad (2.1)$$

Se puede descomponer la ecuación para entenderla de mejor manera:

- $X[m, n]$ es la representación de la STFT de la señal discreta $x[k]$ en un tiempo discreto n y una frecuencia discreta m .
- La variable n denota la localización de la ventana de análisis a lo largo del eje temporal.
- La variable m es un índice de frecuencia, y es en algunas ocasiones definido como banda de frecuencia.
- $x[k]$ son las muestras discretas de la señal de entrada.
- $w[k-n]$ es la ventana discreta que generalmente tiene un soporte finito y se centra en torno a n para analizar un segmento de la señal de entrada.
- L es la longitud de la función ventana.
- $e^{-j2\pi mk/L}$ es la función exponencial compleja discreta que codifica la información de frecuencia en la transformada de Fourier.

La función exponencial de la Ecuación 2.1 representa una onda sinusoidal compleja en el dominio de la frecuencia. La frecuencia está determinada por el valor de m . A medida que m varía, la frecuencia de la onda sinusoidal cambia. Cuanto mayor sea el valor de m , mayor será la frecuencia. En cambio la fase está determinada por el valor de k . La fase de la onda sinusoidal se relaciona con el desplazamiento en el tiempo.

Se puede entender a la STFT como una aplicación de la transformada de Fourier discreta sobre el producto $x[k]w[k-n]$ donde la variable n identifica la ubicación del segmento que se extrae utilizando la ventana $w[k-n]$, la cual se desplaza a lo largo del eje temporal [35].

El uso de una ventana temporal $w[k]$ más corta nos permitirá obtener una alta resolución temporal, sin embargo, esto resultará en una amplia dispersión en el dominio de frecuencia, lo que puede ocasionar que las frecuencias sean menos distintivas entre sí y más difusas. Por el contrario si la ventana temporal es más ancha obtendremos una alta resolución espectral, pero a costo de una pérdida en los detalles temporales. En general, la elección de la longitud de la ventana de análisis es un compromiso entre la resolución temporal y la resolución espectral [36].

En la Figura 2.11 se presenta un esquema del proceso de la STFT. Como resultado de aplicar la STFT se puede obtener un espectrograma (Figura 2.11 c), que se trata de un gráfico de intensidad en donde el eje horizontal representa el tiempo y el eje vertical la frecuencia. Cada punto del espectrograma muestra la intensidad de la componente de frecuencia correspondiente en ese momento específico de tiempo. Los colores o tonalidades se utilizan para indicar la intensidad, donde colores más brillantes representan mayor intensidad.

Aunque también existe la posibilidad de obtener las características espectrales de cada uno de los segmentos analizados por separado después de realizar la transformada de Fourier (Figura 2.11 b).

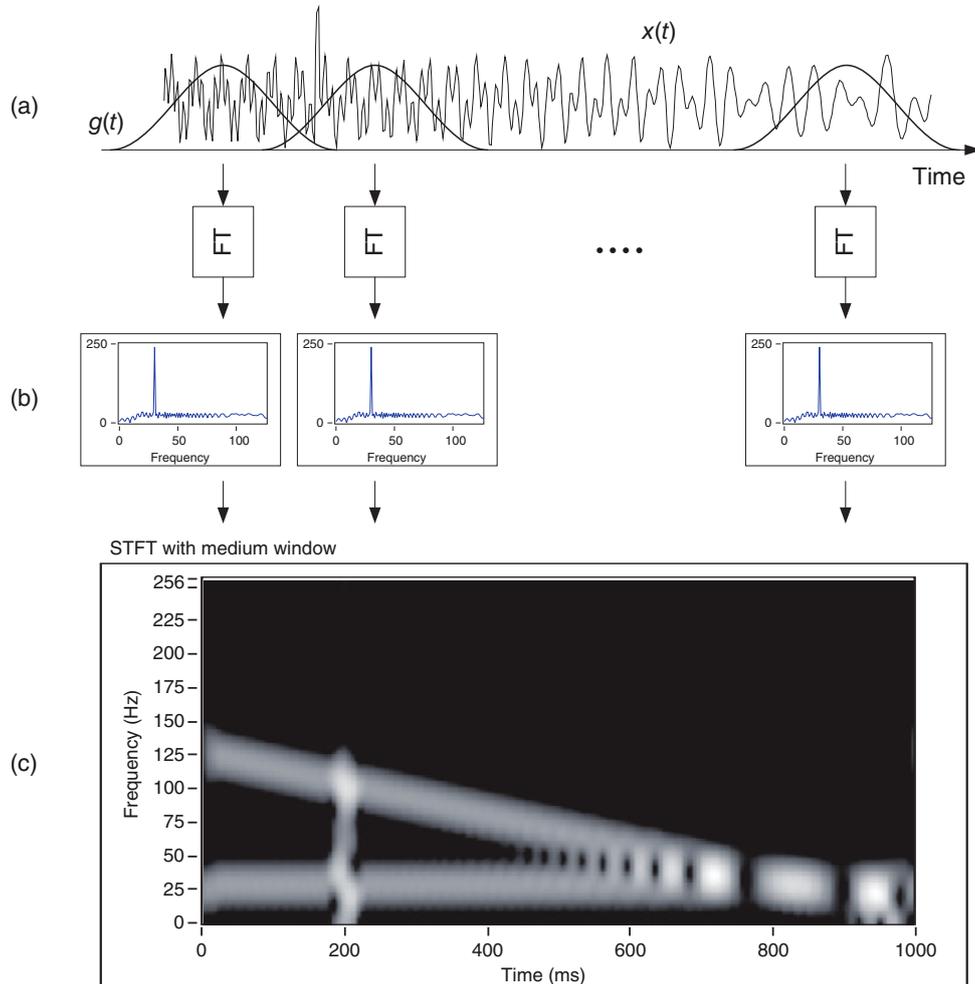


Figura 2.11: Esquema de proceso de la transformada de Fourier de tiempo reducido - STFT [34].

2.4.5 Características en frecuencia

Una vez analizada la señal en uno de los dominios antes mencionados se procede a extraer información relevante que permita caracterizar la señal. A continuación, se establece qué características en frecuencia pueden ser de utilidad para el análisis de señales una vez aplicada la STFT.

En la Tabla 2.1 se presentan características básicas de adquisición que serán útiles para definir las características en frecuencia que se pueden extraer de una señal. Estas últimas se presentan en la Tabla 2.2 donde f representa a la frecuencia y $\tilde{U}(f)$ es el espectro de amplitud de la señal en función de la frecuencia f . Mientras que en la Figura 2.12 se observa una señal de emisión acústica en el dominio del tiempo y la frecuencia con algunas de estas características.

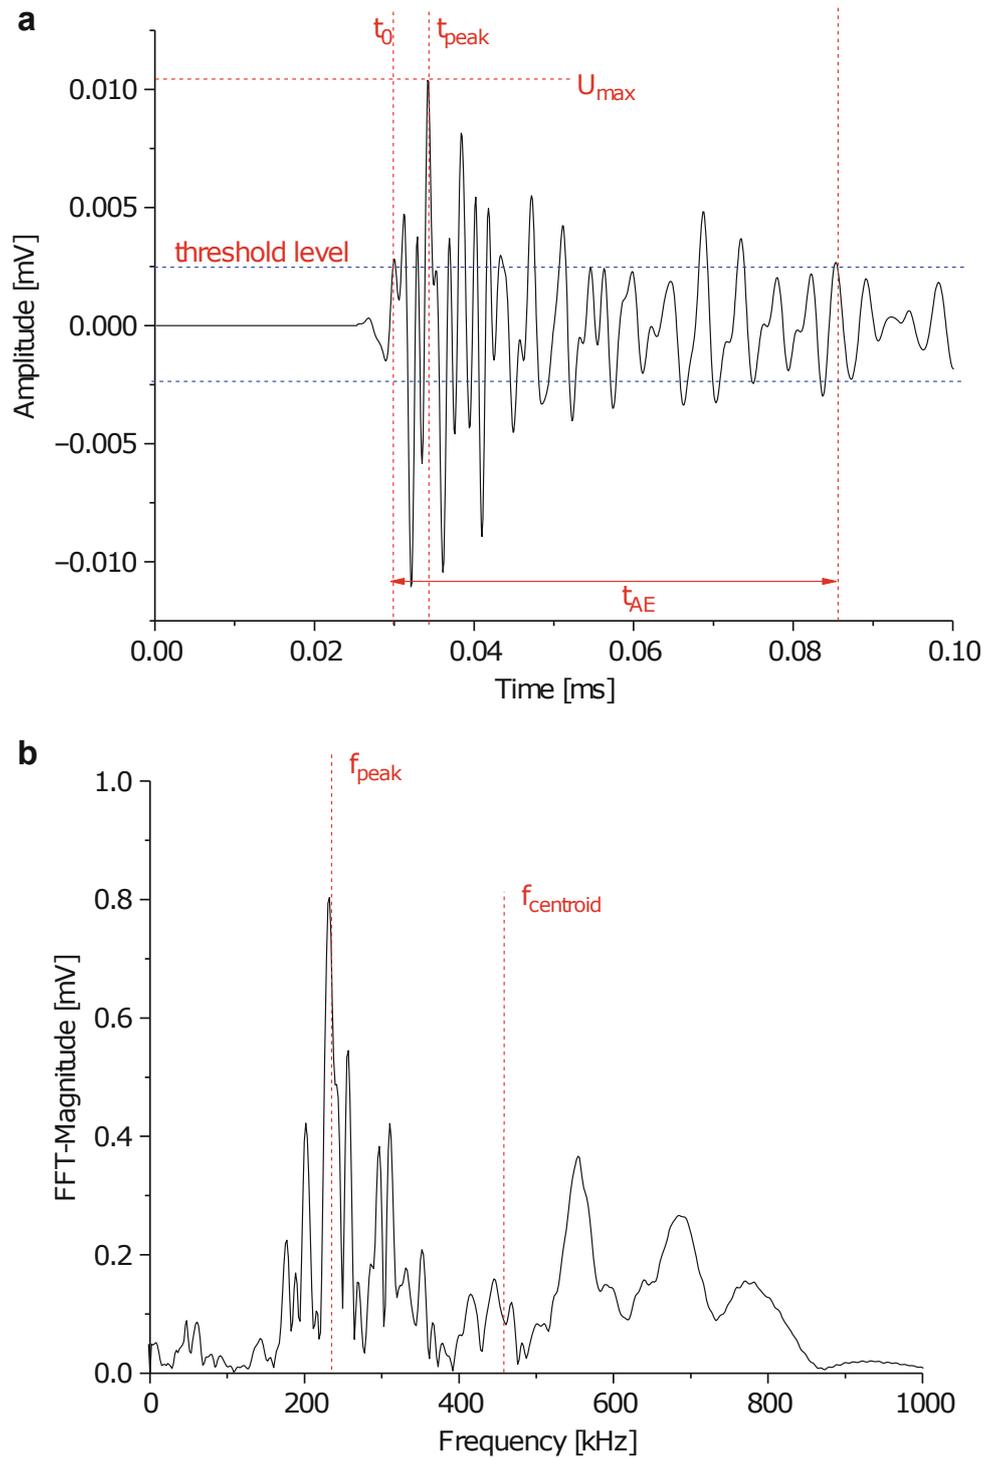


Figura 2.12: Ejemplo de una señal de emisión acústica en el dominio del tiempo (a) y de frecuencia (b) [19].

A continuación, se definen cada una de las características de frecuencia presentadas en la Tabla 2.2:

Tabla 2.1: Características de señal básicos utilizados para la definición de características en frecuencia.

Característica	Definición	Unidad
Tiempo de llegada	t_0	[s]
Conteo	N_{AE}	[-]
Duración	t_{AE}	[s]
Amplitud pico	U_{max}	[mV]
Tiempo hasta la amplitud pico	t_{peak}	[μ s]
Número de cruces entre t_0 y t_{peak}	N_{peak}	[-]

Tabla 2.2: Características en frecuencia de una señal de emisión acústica.

Característica	Definición	Unidad
Frecuencia promedio	$\langle f \rangle = \frac{N_{AE}}{t_{AE}}$	[Hz]
Frecuencia de reverberación	$f_{rev} = \frac{N_{AE} - N_{peak}}{t_{AE} - t_{peak}}$	[Hz]
Frecuencia de iniciación	$f_{init} = \frac{N_{peak}}{t_{peak}}$	[Hz]
Frecuencia pico	f_{peak}	[mV]
Frecuencia centroide	$f_{centroid} = \frac{\int f \cdot \tilde{U}(f) df}{\int \tilde{U}(f) df}$	[μ s]
Frecuencia pico ponderada	$\langle f_{peak} \rangle = \sqrt{f_{peak} \cdot f_{centroid}}$	[-]
Potencia parcial	$\frac{\int_{f_1}^{f_2} \tilde{U}^2(f) df}{\int_{f_{start}}^{f_{end}} \tilde{U}^2(f) df}$	[%]

- **Frecuencia promedio, de reverberación y de iniciación:** Se utilizan como una estimación para la frecuencia característica antes y después del pico máximo y de la señal completa. Estas frecuencias no deben entenderse como un análisis de frecuencia exacto, ya que el número de cruces de umbral suele ser muy bajo y, por lo tanto, arroja resultados inexactos.
- **Frecuencia pico:** Como su nombre lo indica es la frecuencia específica de una señal donde se encuentra el valor más alto o pico de amplitud. En otras palabras, se refiere a la frecuencia a la cual la señal tiene la mayor intensidad o energía. Proporciona información sobre la componente dominante o más relevante de una señal.

- **Frecuencia centroide:** Se utiliza para caracterizar el contenido promedio de frecuencia de una señal de emisión acústica de manera similar al centro de masa que describe las propiedades de un objeto geométrico con densidad uniforme. En general esta característica difiere de la frecuencia pico y resulta muy útil para discriminar señales de emisión acústica debido a su naturaleza discreta.
- **Frecuencia pico ponderada:** Es una característica que combina la eficiencia discriminativa de la frecuencia pico con la información sobre el contenido de frecuencia promedio de la señal expresada por la frecuencia centroide. Mejora la representación de una frecuencia característica asociada a una señal de emisión acústica.
- **Potencia parcial:** Se tratan de niveles de potencia que miden la contribución de la frecuencia de las señales dentro de un intervalo específico y, por lo tanto, se utilizan para capturar la composición de frecuencia de señal en más de un valor característico. En lugar de evaluar solo la potencia total de la señal, esta se descompone en intervalos para obtener una imagen más detallada de la contribución de cada frecuencia en la señal completa. Esto permite obtener información más específica sobre la composición espectral de la señal y sus características frecuenciales distintivas [19]. En la Tabla 2.3 se presenta un ejemplo de los intervalos de frecuencia para cada uno de los niveles de potencia parcial para un rango de frecuencia total entre $f_{start} = 0$ kHz y $f_{end} = 1\ 200$ kHz.

Tabla 2.3: Ejemplo de intervalos de frecuencia para los niveles de potencia parcial.

Característica	Definición	Unidad
Potencia parcial 1	$f_{start} = f_1 = 0$ kHz; $f_2 = 150$ kHz	[%]
Potencia parcial 2	$f_1 = 150$ kHz; $f_2 = 300$ kHz	[%]
Potencia parcial 3	$f_1 = 300$ kHz; $f_2 = 450$ kHz	[%]
Potencia parcial 4	$f_1 = 450$ kHz; $f_2 = 600$ kHz	[%]
Potencia parcial 5	$f_1 = 600$ kHz; $f_2 = 900$ kHz	[%]
Potencia parcial 6	$f_1 = 900$ kHz; $f_2 = f_{end} = 1\ 200$ kHz	[%]

2.5 Aprendizaje automático

El aprendizaje automático (*Machine Learning*) es una rama de la inteligencia artificial basada en el desarrollo de algoritmos y modelos que usan datos de entrada para aprender una tarea determinada sin ser explícitamente programado para ello. Esa es su principal diferencia con la programación clásica donde el programador escribe las entradas y las reglas para obtener una respuesta, mientras que en el aprendizaje automático se ingresan los datos y las respuestas para que el modelo sea quien escriba las reglas Figura 2.13.

Estos algoritmos adaptan automáticamente su arquitectura a través de repeticiones donde mejora cada vez para realizar la tarea para la que fue desarrollada. El proceso de adaptación se denomina entrenamiento, donde se proporciona los datos de entrada junto con los resultados deseados. Luego el algoritmo configura de manera óptima los parámetros de decisión para no solo producir el resultado deseado sino también para generalizar hacia nuevos datos no vistos previamente [37].

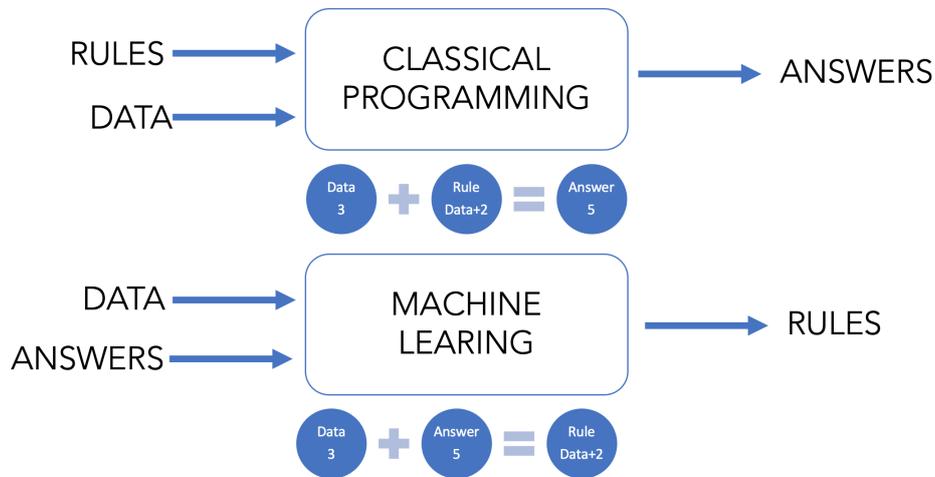


Figura 2.13: Comparación entre la programación clásica y el aprendizaje automático [38].

2.5.1 Tipos de aprendizaje automático

Los modelos de aprendizaje automático pueden ser clasificados de acuerdo al tipo de supervisión que estos tengan durante su fase de entrenamiento. Entre las principales categorías se encuentran: aprendizaje supervisado, no supervisado, semi-supervisado, auto supervisado y aprendizaje por refuerzo.

- **Aprendizaje supervisado:** En este tipo de modelo los datos de entrenamiento con los que se entrena al algoritmo incluyen la solución deseada que se denomina etiqueta (*label*). Dentro de este tipo de aprendizaje se pueden distinguir principalmente dos tareas: una de clasificación y otra de regresión. En la primera el objetivo es diferenciar entre distintas clases o categorías como por ejemplo, identificar el tipo de fuente que ha emitido una señal acústica. Para el caso de la regresión el objetivo es predecir un valor numérico basado en las características, también llamadas *features*, con las que se ha entrenado el modelo. Dentro de los principales algoritmos de aprendizaje supervisado tanto para tareas de clasificación como de regresión se encuentran: regresión lineal, regresión logística, KNN (*k-Nearest Neighbor*), árboles de decisión, máquinas de soporte de vectores, entre otros.
- **Aprendizaje no supervisado:** Para este tipo de aprendizaje las etiquetas no son proporcionadas al modelo. Es decir, el algoritmo debe ser capaz de encontrar patrones entre los datos proporcionados, por ejemplo para agruparlos en grupos de características similares lo que se denomina *clustering*. Otra aplicación de este tipo de aprendizaje es la reducción de la dimensionalidad donde el objetivo es simplificar el conjunto de datos sin perder mucha información, esto se logra combinando varias características que se relaciona entre ellas en una sola y se realiza como fase previa al entrenamiento con un algoritmo supervisado. Esta técnica también puede ser útil para la visualización de datos, donde se puede reducir la complejidad del conjunto de datos para poder representarlos gráficamente.
- **Aprendizaje semi-supervisado:** Etiquetar los datos puede llegar a ser una tarea costosa y que requiere mucho tiempo especialmente cuando el conjunto de datos es extremadamente grande. Si se tiene un conjunto de datos que está parcialmente etiquetado se puede utilizar

una combinación de algoritmos supervisados y no supervisados. Por ejemplo un algoritmo de *clustering* para agrupar los datos similares y luego etiquetar cada instancia con la etiqueta más común de cada agrupación. Una vez que el conjunto de datos está etiquetado ya es posible utilizar un algoritmo supervisado.

- **Aprendizaje auto supervisado:** Este tipo de aprendizaje involucra generar un conjunto de datos completamente etiquetado a partir de uno sin ninguna etiqueta. Por ejemplo, para un gran conjunto de imágenes sin etiquetar, se puede utilizar una máscara pequeña en una parte de la imagen y luego el modelo se entrena para recuperar la imagen original. Durante el entrenamiento, las imágenes enmascaradas se utilizan como entradas al modelo y las imágenes originales se utilizan como etiquetas.
- **Aprendizaje por refuerzo:** Este tipo de aprendizaje es completamente diferente a los anteriores. En este caso el sistema puede observar el entorno, seleccionar y llevar a cabo acciones, y recibir recompensas o penalizaciones a cambio. Luego, debe aprender por sí mismo cuál es la mejor estrategia, llamada política, para obtener la mayor recompensa a lo largo del tiempo. Una política define qué acción debe elegir el agente cuando se encuentra en una situación dada. [39].

2.5.2 Árboles de decisión y bosques aleatorios

Los árboles de decisión son algoritmos de aprendizaje automático versátiles que pueden realizar tanto tareas de clasificación como de regresión, incluso tareas multi-salida. Son algoritmos potentes capaces de ajustar conjuntos de datos completos. Son también los componentes fundamentales de los bosques aleatorios, que son uno de los algoritmos de aprendizaje automático más potentes que existen en la actualidad [39].

Para realizar una clasificación un árbol de decisión formula una serie de preguntas sobre las características asociadas con los elementos. Cada pregunta se encuentra en un nodo, y cada nodo interno apunta a un nodo hijo para cada posible respuesta a su pregunta. De esta manera, las preguntas forman una jerarquía, codificada en forma de un árbol Figura 2.14. Un elemento se clasifica en una clase siguiendo el camino desde el nodo superior, la raíz (*root node*), hasta un nodo sin hijos, una hoja (*leaf node*), de acuerdo con las respuestas que aplican al elemento en consideración. El elemento se asigna a la clase asociada a la hoja a la que llega [40].

Por ejemplo en la Figura 2.14 se presenta un árbol de decisión para el conjunto de datos *Iris* donde se pretende clasificar tres tipos de flor iris (setosa, versicolor y virginica) en base a las dimensiones de sus pétalos. En este caso el nodo raíz (profundidad 0) pregunta si la longitud del pétalo es menor a 2,45 cm. Si es verdad se baja por el nodo hijo de la izquierda (profundidad 1) que se trata de una hoja o un nodo terminal, es decir, que no formula ninguna pregunta y simplemente asigna una clase a las instancias que pasen por él, en este caso “setosa”. Si en cambio la longitud del pétalo es mayor el algoritmo baja por el nodo hijo de la derecha (también profundidad 1) que como no se trata de un nodo terminal formula otra pregunta, en este caso si el ancho del pétalo es menor que 1,75 cm. Si esto es verdad es muy probable que la flor sea de la clase “versicolor” (profundidad 2, izquierda), y si no es verdad la flor será de la clase “virginica” (profundidad 2, derecha).

Dentro de cada nodo existen algunos atributos que cabe mencionar:

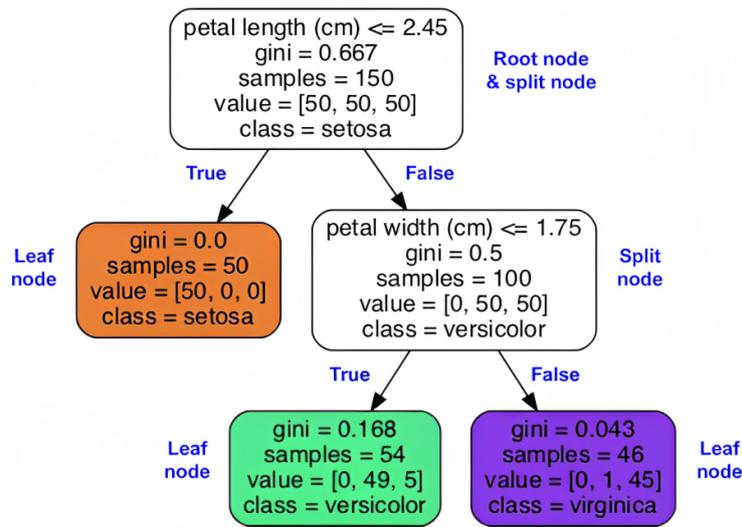


Figura 2.14: Árbol de decisión para el conjunto de datos *Iris* [39].

- *Samples*: Cuenta cuantas instancias de entrenamiento se aplican a un nodo, por ejemplo en el nodo raíz ingresan 150 instancias.
- *Value*: Indica a cuantas instancias de entrenamiento de cada clase se aplica el nodo, por ejemplo en el nodo raíz se aplican a 50 de cada clase.
- *Gini*: Mide la impureza de un nodo. Un nodo es “puro” ($gini = 0$) si todas las instancias de entrenamiento a las que se aplica pertenecen a la misma clase, como es el caso de la hoja en la profundidad 1 para la clase “setosa”. La Ecuación 2.2 muestra cómo el algoritmo computa la puntuación *gini* G_i del nodo i . El algoritmo entonces busca, en cada nodo, dividir el conjunto de datos en dos subconjuntos mediante una única característica y un valor umbral que minimicen el valor de impureza de un nodo [39].

$$G_i = 1 - \sum_{k=1}^n p_{i,k}^2 \quad (2.2)$$

En esta ecuación $p_{i,k}^2$ es el ratio de instancias de clase k entre las instancias de entrenamiento del nodo i .

En la Figura 2.15 se muestran los límites de decisión de este árbol. La línea vertical gruesa representa el límite de decisión del nodo raíz: longitud de pétalo = 2,45 cm. Como el área de la izquierda es pura ya no puede dividirse más. Pasa lo contrario con el área de la izquierda, donde se puede dividir con el nodo derecho de profundidad 1, es decir con anchura de pétalo = 1,75 cm (línea de guiones). En este caso el árbol estaba limitado a una profundidad máxima de 2 (en este caso la profundidad 0 y 1). Pero si se configurase a una profundidad máxima de 3, los dos nodos de profundidad 2 añadirían cada uno otro límite de decisión (línea de puntos).

Si bien los árboles de decisión son sencillos de interpretar, fáciles de usar, versátiles y potentes también tienen sus limitaciones. Por lo general, su principal problema es que son muy sensibles a pequeñas variaciones en los datos de entrenamiento. Por ejemplo, para el caso anterior si

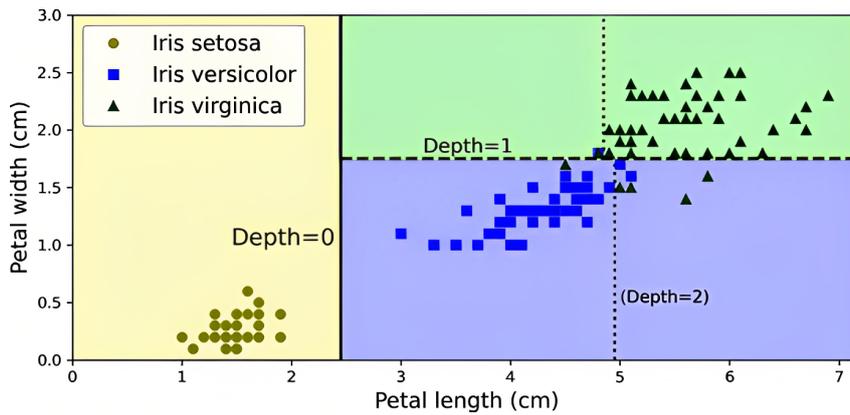


Figura 2.15: Límites de decisión del árbol para el conjunto de datos *Iris* [39].

eliminamos la instancia de flor “versicolor” más ancha, que tiene los pétalos de 4,8 cm de largo y 1,8 cm de ancho, los límites de decisión del nuevo árbol tendrán un aspecto muy diferente al original, como se puede ver en la Figura 2.16. Para limitar esta inestabilidad se puede hacer uso de los bosques aleatorios (*random forests*).

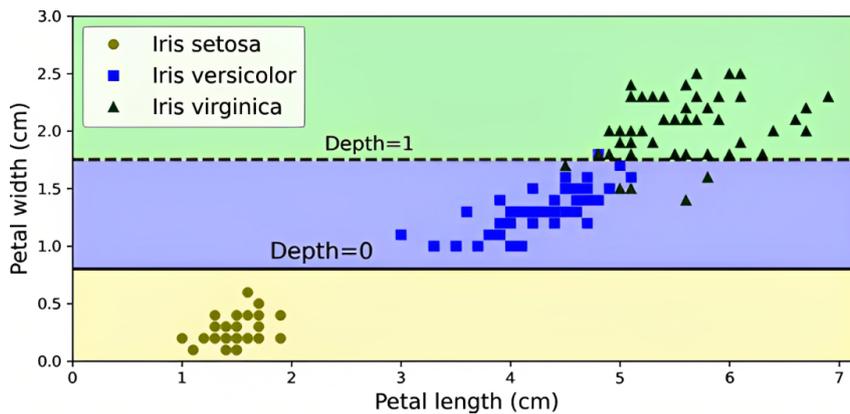


Figura 2.16: Límites de decisión del árbol para el conjunto de datos *Iris* modificado [39].

Un bosque aleatorio es un ensamblaje de árboles de decisión. Un ensamblaje se trata de un conjunto de predictores (por ejemplo de árboles de decisión) en donde se entrena a cada uno de estos predictores con un subconjunto aleatorio del conjunto de entrenamiento diferente. Para predecir una clase, el ensamblaje evalúa las predicciones de cada árbol individualmente y luego asigna la instancia a la clase que ha conseguido más votos, es decir aquella que la mayoría de árboles ha predicho (Figura 2.17).

El algoritmo de bosques aleatorios introduce una aleatoriedad cuando hace crecer los árboles, en lugar de buscar la mejor característica global al dividir un nodo, busca la mejor característica solo dentro de un subconjunto aleatorio de características. Esto otorga al algoritmo una diversidad de árboles mayor, que compensa un sesgo más alto por una varianza más baja, produciendo un modelo capaz de generalizar mejor.

Además este algoritmo permite medir la importancia relativa de cada característica, centrándose en cuánto reduce la impureza, en promedio, los nodos que utilizan esa característica [39]. En otras

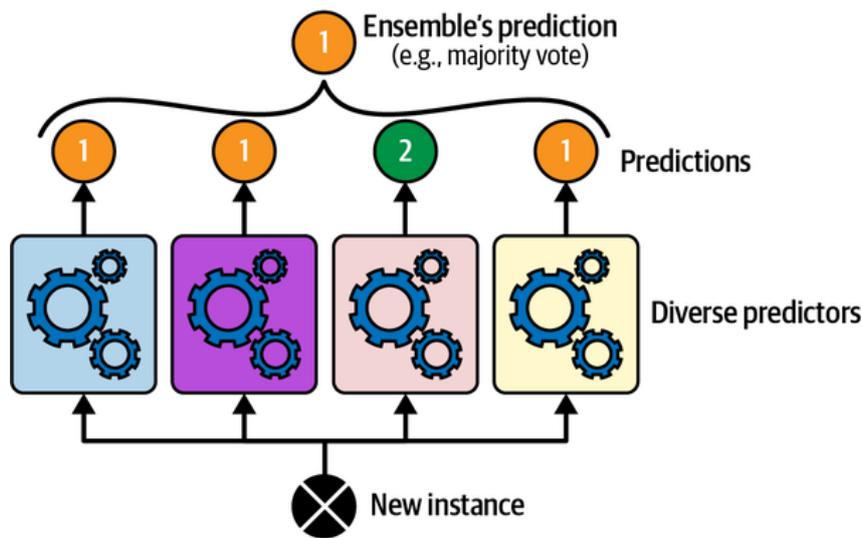


Figura 2.17: Predicciones de un bosque aleatorio con varios árboles de decisión [39].

palabras, es una medida que indica qué características permiten al modelo distinguir de mejor manera entre cada una de las clases o categorías. Esto resulta de mucha utilidad al momento de escoger las características significativas para entrenar al modelo y deshacerse de aquellas que pueden reducir su rendimiento.

2.5.3 Procedimiento para generar un modelo

Para generar un modelo de aprendizaje automático eficaz en tareas de clasificación es fundamental seguir un proceso bien definido el cual proporciona una visión general de las tareas y pasos que se deben llevar a cabo para el manejo de datos, el entrenamiento y la implementación del modelo. En la Figura 2.18 se presenta un diagrama de flujo con los principales pasos para el entrenamiento de un modelo de clasificación.

A continuación se describe cada uno de los pasos del diagrama de flujo.

- **Recolección de datos:** Este es el primer paso de todo modelo de aprendizaje automático. Los datos que se recolecten deben ser representativos con respecto a la tarea que se quiere realizar. Las características que se registren durante la recolección de datos deben ser relevantes, por ejemplo para el caso de clasificación, deben ser aquellas que permitan distinguir una clase de otra. Finalmente es necesario que todos los datos estén etiquetados, es decir, que se conozca la clase a la que cada instancia pertenece.
- **Tratamiento de datos:** Una vez recolectados los datos estos deben ser preprocesados antes de entrenar el modelo. Este es uno de los pasos más importantes ya que la calidad de los datos de entrenamiento es el factor más influyente en el rendimiento final del modelo. Generalmente este paso consiste en la eliminación de datos anómalos, eliminación de características linealmente dependientes, combinación de características o lo que se conoce como *feature engineering* en donde se puede mejorar el rendimiento del modelo con la creación de nuevas características que contengan información más relevante o condensada.

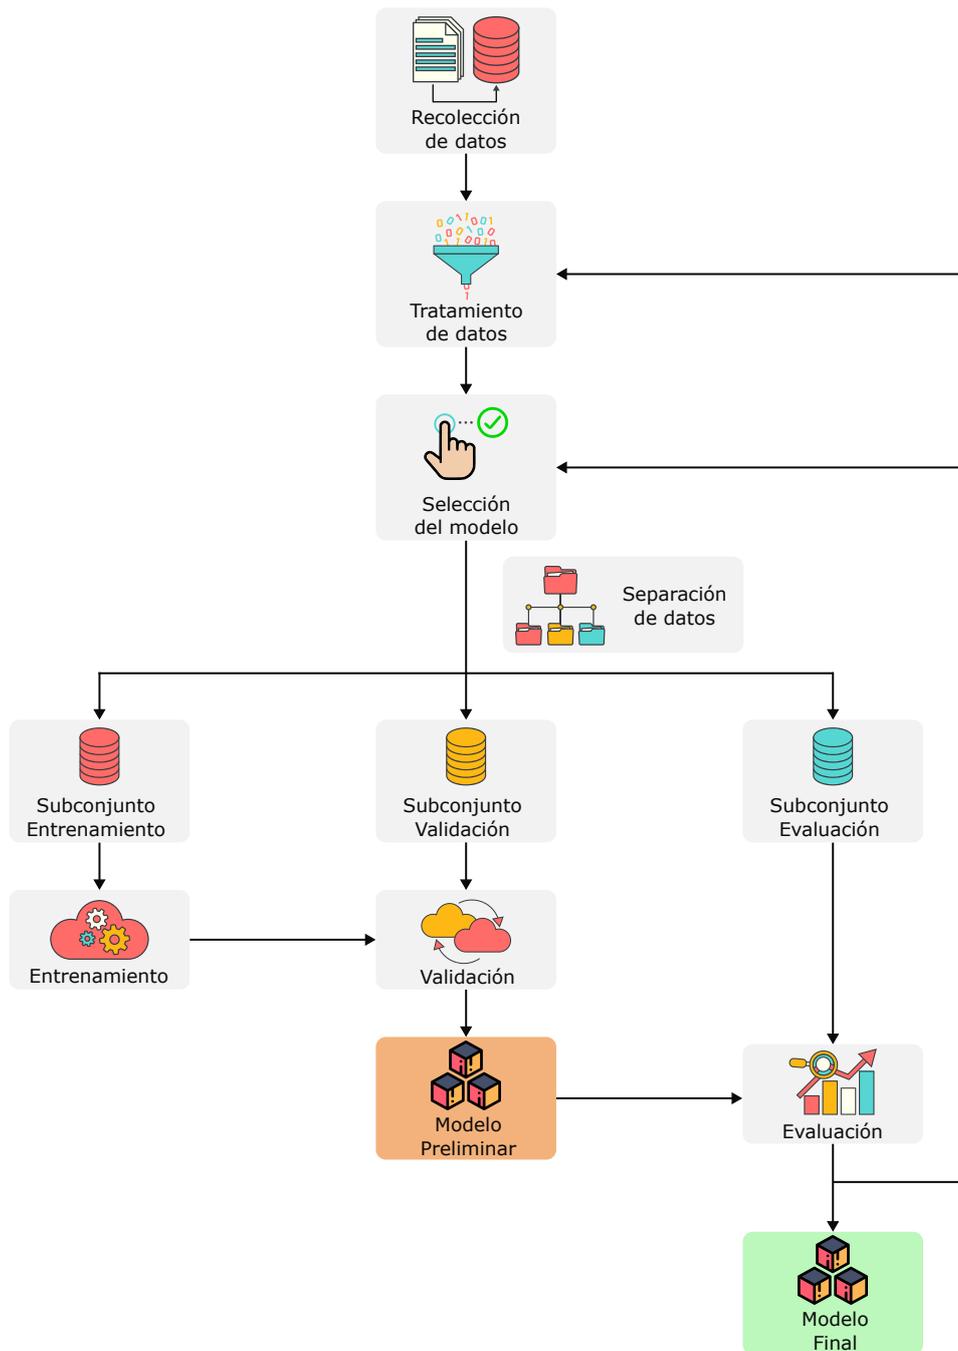


Figura 2.18: Diagrama de flujo para un modelo de aprendizaje automático.

Además, la normalización o escalado es una técnica muy utilizada cuyo objetivo es llevar todas las características del conjunto de datos a una escala común para evitar que aquellas con valores más grandes pueden dominar y tener un impacto desproporcionado en el modelo durante el proceso de entrenamiento.

- **Selección del modelo:** Es necesario considerar que modelo o algoritmo se va a utilizar en función de las necesidades y datos disponibles. Primero se decide en base a la tarea que se va a efectuar, ya sea de regresión o clasificación, ya que existen algoritmos diseñados

específicamente para cada una de estas tareas. Además, es necesario considerar el tipo de datos con los que se cuenta, su tamaño y distribución. Algunos algoritmos pueden ser más adecuados para datos numéricos, mientras que otros pueden manejar de manera eficiente características categóricas o de texto. El tamaño del conjunto de datos puede influir en la elección del modelo, ya que algunos algoritmos pueden requerir grandes cantidades de datos para un buen rendimiento. Adicionalmente considerar su distribución o desequilibrio de clases, si el conjunto de datos presenta clases desequilibradas, es decir, algunas clases tienen muchas más muestras que otras, se debe prestar especial atención a técnicas de muestreo o ajuste de pesos para evitar sesgos en el modelo hacia las clases mayoritarias.

- **Separación del conjunto de datos:** Una vez seleccionado todas las características, con los datos etiquetados y definido el modelo se procede a hacer una separación del conjunto de datos. Existen dos formas de separarlos según la cantidad de datos que se disponga. Si el conjunto de datos es grande se suele dividir en tres subconjuntos: uno para entrenamiento (*training set*) que se trata del 80 %, de este subconjunto se separa otro 20 % para validación (*validation set*), y uno para evaluación (*test set*) que es el 20 % restante del conjunto original. Por otro lado, si el conjunto de datos es pequeño se omite el subconjunto de validación pero en cambio se utiliza la estrategia de validación cruzada. Esta estrategia consiste en primero dividir el subconjunto de entrenamiento en K subconjuntos de aproximadamente el mismo tamaño, luego el modelo se entrena K veces, cada vez utilizando $K - 1$ subconjuntos como datos de entrenamiento y uno de los subconjuntos restantes para validación.
- **Entrenamiento:** Durante el entrenamiento, el algoritmo ajusta sus parámetros para encontrar la mejor forma de predecir las etiquetas de clase a partir de las características. El objetivo es minimizar una métrica de rendimiento específica, como la función de pérdida, para obtener el modelo más adecuado a los datos de entrenamiento.
- **Evaluación:** Después de entrenar el modelo, es fundamental evaluar su rendimiento utilizando el conjunto de datos para evaluación independiente separado previamente. Para ello se hace uso de distintas métricas de evaluación como la exactitud y la puntuación $F1$ para medir el rendimiento del modelo. Esta evaluación proporciona información sobre la capacidad del modelo para generalizar y predecir correctamente ante instancias nuevas con las que no fue entrenado, lo que es esencial para asegurar su posterior aplicabilidad.
- **Iterar y refinar:** Una vez evaluado el modelo es necesario considerar si su rendimiento es el esperado. Generalmente se deben realizar algunas iteraciones hasta conseguir el desempeño deseado. Entre los principales ajustes están modificar los hiperparámetros del algoritmo, probar diferentes técnicas de preprocesamiento, cambiar el algoritmo o realizar una nueva selección de características. Es probable que se repita el proceso de entrenamiento y evaluación varias veces hasta alcanzar un modelo con un rendimiento satisfactorio.
- **Implementación:** Una vez se ha conseguido un rendimiento aceptable del modelo, este se puede implementar en un entorno de producción para su uso aplicación. El modelo entrenado se utiliza para hacer predicciones sobre nuevos datos no vistos y tomar decisiones basadas en las clases predichas. Es importante monitorizar el rendimiento del modelo con el tiempo y actualizarlo según sea necesario para mantener su precisión y utilidad en un entorno cambiante.

2.5.4 Métricas de evaluación

Así como existen diferentes algoritmos dependiendo si se trata de una tarea de regresión o clasificación, asimismo existen diferentes métricas de evaluación dependiendo de ello. Para las tareas de regresión se encuentran: el error cuadrático medio, error absoluto medio, la raíz del error cuadrático medio, entre los principales. En cuanto a los modelos de clasificación son muy utilizadas la exactitud (*accuracy*), la precisión, la sensibilidad o *recall* y la puntuación *F1*. Además se utiliza la denominada matriz de confusión como una representación visual y muy intuitiva del rendimiento del modelo, donde se puede observar tanto aquellas instancias que el modelo ha predicho correctamente como aquellas en las que no.

La idea general de la matriz de confusión es contar el número de veces que las instancias de la clase *A* se clasifican como clase *B*. Cada fila de la matriz de confusión representa una clase real, es decir, la categoría con la que fue etiquetada una instancia, mientras que cada columna representa una clase predicha por el modelo [39]. En la Figura 2.19 se muestra una matriz de confusión ilustrada para un clasificador binario (positivo o negativo) para el conjunto de datos *MNIST*. En ella se presenta los conceptos de verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos, además de las métricas de precisión y sensibilidad.

- **Verdaderos positivos (*TP*):** Son aquellas instancias que fueron etiquetadas como positivas y el modelo predijo como positivas. Es decir, aquellas que el modelo clasificó correctamente.
- **Verdaderos negativos (*TN*):** Se trata de las instancias que fueron etiquetadas como negativas y el modelo predijo como negativas. De igual forma aquellas que el modelo clasificó correctamente.
- **Falsos positivos (*FP*):** En este caso son aquellas instancias que fueron etiquetadas como negativas pero el modelo predijo como positivas. Serían instancias clasificadas erróneamente.
- **Falsos negativos (*FN*):** En cambio se trata de las instancias etiquetadas como positivas pero predichas como negativas. De igual forma clasificadas incorrectamente.

Un clasificador perfecto tendría solo verdaderos positivos y verdaderos negativos, es decir, valores distintos de cero solo en la diagonal principal.

La exactitud se calcula como la razón entre los valores correctamente predichos y el número total de datos (Ecuación 2.3), es decir, mide el porcentaje de casos que el modelo ha acertado [41]. Aunque es una métrica intuitiva no es recomendable utilizarla porque puede dar lugar a considerar que un modelo tiene un buen rendimiento cuando en realidad no.

$$\text{exactitud} = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.3)$$

Es por ello que es muy común utilizar otras métricas como la precisión, la sensibilidad y la puntuación *F1*. La precisión representa la proporción de verdaderos positivos entre todas las instancias clasificadas como positivas, es decir, se centra en las predicciones positivas y se calcula como indica la Ecuación 2.4.

$$\text{precisión} = \frac{TP}{TP + FP} \quad (2.4)$$

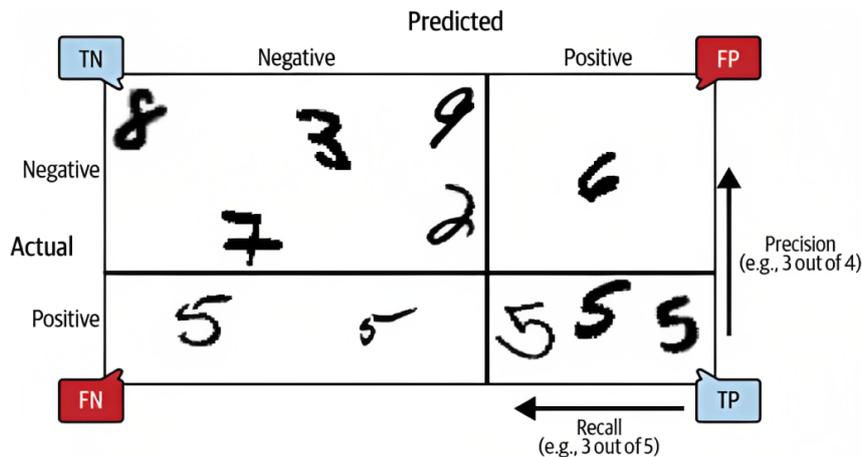


Figura 2.19: Matriz de confusión ilustrada para el conjunto de datos *MNIST* [39].

La sensibilidad o *recall* es en cambio la proporción de verdaderos positivos entre todas las instancias positivas en el conjunto de datos. Se centra en la capacidad del modelo para detectar correctamente las muestras positivas. Se calcula mediante la Ecuación 2.5.

$$\text{sensibilidad} = \frac{TP}{TP + FN} \quad (2.5)$$

La puntuación *F1* es una métrica que combina la precisión y la sensibilidad para obtener un balance entre ambas. Es útil cuando hay un desequilibrio entre las clases en el conjunto de datos. Se puede calcular mediante la Ecuación 2.6.

$$F1 = 2 \times \frac{\text{precisión} \times \text{sensibilidad}}{\text{precisión} + \text{sensibilidad}} \quad (2.6)$$

De forma general, si en lugar de un clasificador binario se trata de un clasificador multi-clase, es decir con más de dos clases, las métricas de evaluación deben involucrar a todas las clases. En este caso las métricas toman el nombre de *precisión macro*, *sensibilidad macro* y *F1 macro*. Para su cálculo se hace uso de la matriz de confusión centrándose en una clase a la vez y etiquetando las posiciones de la siguiente manera:

- Se consideran verdaderos positivos *TP* solo a las instancias correctamente clasificadas en su clase.
- Los falsos positivos y falsos negativos son las instancias mal clasificadas en la columna y fila de la clase respectivamente.
- Los verdaderos negativos son todas las demás posiciones, como se muestra en la Figura 2.20, donde se considera la clase “b” como enfoque de referencia.

Se trata de un proceso secuencial, cuando cambiamos de una clase a otra, se calculan las métricas nuevamente y las etiquetas de las posiciones para la matriz de confusión se cambian en consecuencia. La precisión y la sensibilidad para cada clase se calculan de la misma manera que para el caso de un clasificador binario. En la Ecuación 2.7 y Ecuación 2.8 se indica como calcularlas para una clase genérica *n*.

		PREDICTED classification			
		Classes	a	b	c
ACTUAL classification	a	TN	FP	TN	TN
	b	FN	TP	FN	FN
	c	TN	FP	TN	TN
	d	TN	FP	TN	TN

Figura 2.20: Etiquetado de la matriz de confusión multi-clase en referencia a la clase “b” [41].

$$\text{precisión}_j = \frac{TP_j}{TP_j + FP_j} \quad (2.7)$$

$$\text{sensibilidad}_j = \frac{TP_j}{TP_j + FN_j} \quad (2.8)$$

La *precisión macro* y la *sensibilidad macro* simplemente se calculan como el promedio aritmético de las métricas para clases individuales como se indica en la Ecuación 2.9 y Ecuación 2.10.

$$\text{precisión}_M = \frac{\sum_{j=1}^N \text{precisión}_j}{N} \quad (2.9)$$

$$\text{sensibilidad}_M = \frac{\sum_{j=1}^N \text{sensibilidad}_j}{N} \quad (2.10)$$

Finalmente *F1 macro* se determina con la Ecuación 2.11.

$$F1_M = 2 \times \frac{\text{precisión}_M \times \text{sensibilidad}_M}{\text{precisión}_M + \text{sensibilidad}_M} \quad (2.11)$$

Diseño experimental y recogida de datos

3.1 Ensayo experimental

Los ensayos de impacto se realizaron sobre una placa de fibra de carbono unidireccional de dimensiones $300\text{ mm} \times 50\text{ mm} \times 1,2\text{ mm}$ donde la orientación de la fibras está a lo largo de la dimensión de mayor longitud. Se utilizó la configuración de laminado unidireccional para simplificar la propagación de la onda y evitar que los cambios de orientación entre láminas distorsionen la forma de la onda. Además, esta configuración ayuda a mitigar algunos de los efectos de atenuación que se pueden producir con otro tipo de laminados con disposiciones más complejas. Al mantener todas las fibras alineadas en la misma dirección, se reduce la complejidad del análisis y se facilita la interpretación de las señales acústicas emitidas. En la Figura 3.1 se muestra un esquema de experimento donde se observa las dimensiones de la placa, la ubicación de los sensores de emisión acústica y la zona de impacto.

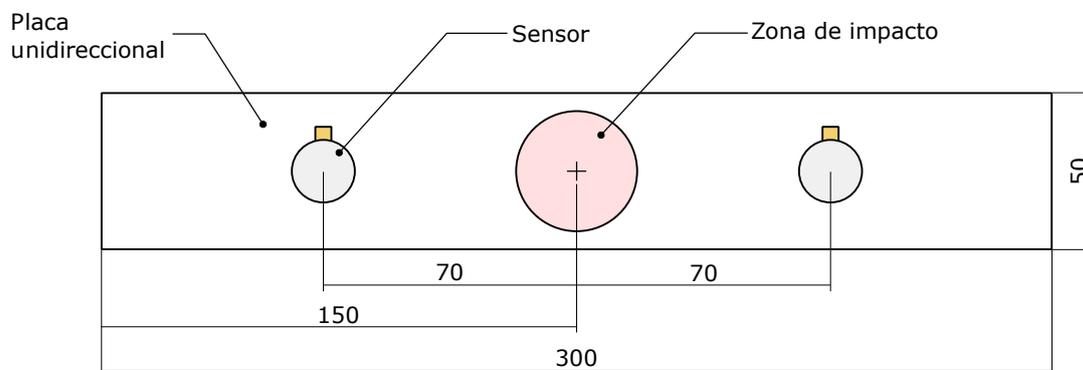


Figura 3.1: Esquema de la ubicación de los sensores y la zona de impacto.

Para realizar los ensayos, se utilizaron tres fuentes de impacto diferentes: una esfera metálica de 6 mm de diámetro, trozos de hielo de entre 6 i 8 mm de diámetro, y granos de arena. Estos materiales fueron seleccionados por dos razones principales. En primer lugar, presentan propiedades distintas, especialmente en términos de rigidez y densidad, lo que permitió generar diferentes tipos de ondas que fueran fácilmente distinguibles entre sí. En segundo lugar, la elección de estos materiales se basó en la intención de simular situaciones de impacto realistas que podrían ocurrir en aplicaciones prácticas de laminados de fibras de carbono, como en aeronaves.

Por ejemplo, se buscó replicar situaciones como el desprendimiento de hielo formado durante el vuelo, la presencia de arena en la pista o el impacto de elementos metálicos de unión, como pernos o tornillos, que podrían causar daños en la superficie del laminado. La Figura 3.2 ilustra las tres fuentes de impacto colocados sobre la placa unidireccional.



Figura 3.2: Fuentes de impacto para el ensayo.

El ensayo de impacto siguió el siguiente procedimiento:

1. Ubicación de los sensores en las posiciones predefinidas. Se utilizaron sensores piezoeléctricos de la marca *Vallen Systeme* modelo VS150-M que se trata de un sensor resonante con una frecuencia característica de 150 kHz y un rango de operación entre 100 i 450 kHz. Se utilizó grasa sintética *Loctite SuperLube* como acoplante para facilitar la transmisión de energía entre la superficie del laminado y la del transductor. Para fijar los sensores a la placa se utilizaron pinzas de compresión, como se indica en la Figura 3.3.
2. Se colocó la placa sobre soportes flexibles para no restringir su movimiento al momento de los impactos (Figura 3.3). Esto permite que las ondas se propaguen principalmente por la placa y que no estén influenciadas por las condiciones de contorno.



Figura 3.3: Sujeción de los sensores con pinzas de compresión.

3. Una vez ubicada la placa y colocados los sensores estos se conectaron al sistema de adquisición para posteriormente registrar las señales como se puede observar en la Figura 3.4.

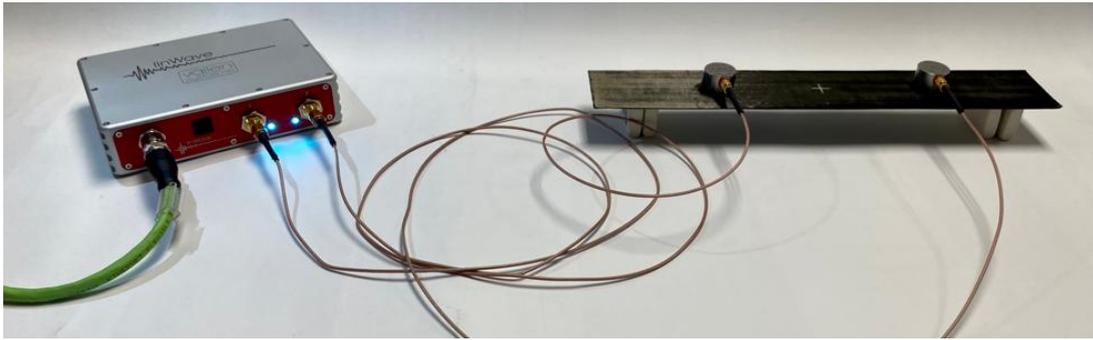


Figura 3.4: Montaje del sistema de adquisición de datos.

- Se realizó la prueba de Hsu-Nielsen o *Pencil lead break AE test*. Esta prueba consiste en la rotura de mina de lápiz a 30° con el objetivo generar ondas que exciten los sensores a todas las frecuencias. Con esto se comprueba que los sensores están colocados correctamente y que están registrando las señales con normalidad. Un esquema de esto se observa en la Figura 3.5.

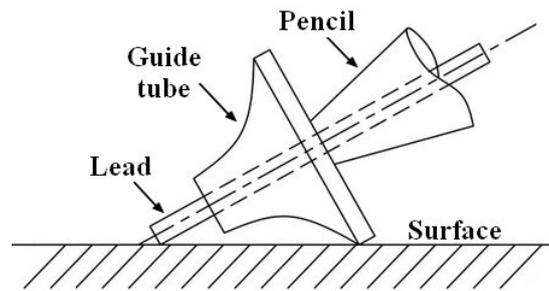


Figura 3.5: Esquema de la prueba de Hsu-Nielsen [42].

- Posteriormente se realizó uno a uno los impactos sobre la placa con cada una de las fuentes por separado. Es decir, primero se lanzó la esfera metálica, cuyo impacto se registra, luego se volvió a repetir el lanzamiento y registro hasta alcanzar el número de hits deseados. Se repitió el mismo proceso para el caso de los trozos de hielo y los granos de arena. Todos los impactos se realizaron desde la misma altura, prestando atención a que golpeen la placa en la zona de impacto. Al final se generaron tres archivos diferentes, uno para cada clase, con los hits registrados para su posterior análisis.

3.2 Adquisición de datos

Para registrar los hits generados durante los ensayos de impacto se utilizó la unidad de adquisición de datos *linWave 1002*, la cual posee dos canales para la conexión de los sensores. Para ello primero los parámetros de adquisición que se utilizaron se muestran en la Tabla 3.1.

La frecuencia de muestreo indica el número de datos por segundo que el sistema registra, en este caso se toman dos millones de muestras por segundo para cada señal. Con este valor se logra que

el rango analizado en el dominio de la frecuencia sea de 0 i 1 000 kHz o que es lo mismo que la mitad de la frecuencia de muestreo.

Para determinar el valor del umbral primero se realiza una prueba del ruido de fondo, con los sensores colocados sobre la placa y sin realizar ningún impacto sobre ella. Una vez la medición fue efectuada se establece el valor umbral 6 dB por encima del valor máximo de amplitud del ruido de fondo.

El término *Duration discrimination time* es utilizado por *Vallen Systeme* para referirse al tiempo de definición (HDT) que especifica el tiempo para distinguir un hit de otro. En los ensayos de rotura de mina o prueba de Hsu-Nielsen se determinó el valor de este tiempo de definición en 250 μ s. En cuanto a los parámetros *Pre-trigger* como *Post-duration* son los valores de tiempo en donde el sistema registra información de la señal antes de que el hit comience y después de que este haya finalizado. Es necesario que la señal registrada tenga la duración suficiente para poder realizar su posterior procesamiento con la transformada rápida de Fourier.

Tabla 3.1: Parámetros de adquisición de datos para el ensayo.

Parámetro	Valor	Unidad
Frecuencia de muestreo	2	[MHz]
Umbral	50	[dB]
Duration discrimination time	250	[μ s]
Pre-trigger	100	[μ s]
Post-duration	700	[μ s]

Con esta configuración y con todos los ensayos de impacto realizados se obtuvieron en total 12 034 datos registrados, de los cuales 504 pertenecen a la clase “esfera metálica”, 10 916 a la clase “arena” y 614 a la clase “hielo”. Se obtuvo un mayor volumen de datos para la clase “arena” debido a la naturaleza de la fuente. En cada lanzamiento, numerosos granos de arena impactaban la placa, a diferencia del hielo o la esfera metálica, que generaban solo un impacto por lanzamiento. En la Figura 3.6 se muestra un hit registrado de uno de los impactos con esfera metálica.

3.3 Procesamiento de datos y extracción de características

Una vez registradas las señales de emisión acústica es necesario realizar un procesamiento a esos datos antes de extraer las características relevantes que van a utilizarse para el entrenamiento del modelo de aprendizaje automático. Los archivos que se generan con el software de *Vallen Systeme* tras la adquisición de datos son de tres tipos: un archivo con extensión *.pridb* que contiene las características de la señal; uno con extensión *.tradb* almacena los datos de tiempo y amplitud de la señal transitoria, es decir la señal en sí; y por último uno con extensión *.vaex* que se utiliza para la visualización de datos.

Del archivo primario *.pridb* se pueden extraer las características en el dominio del tiempo de cada una de las señales registradas. Estas características pueden se utilizadas para realizar un filtrado previo en base a la amplitud, tiempo de llegada, energía, conteo, etc. En la Tabla 3.2 se indica toda la información que se obtiene de este archivo primario.

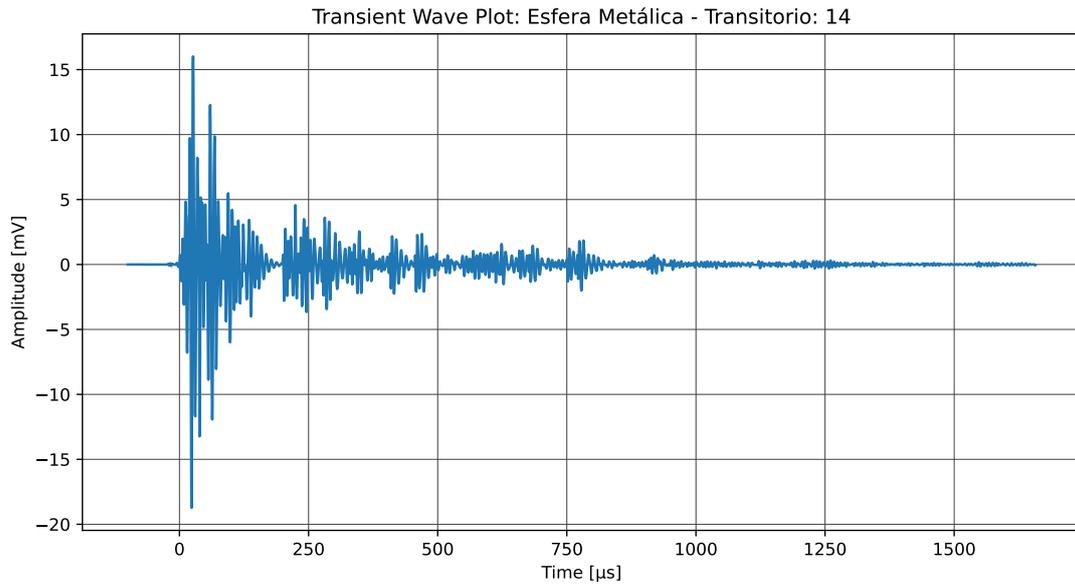


Figura 3.6: Señal transitoria para un impacto de esfera metálica.

En cuanto al archivo del transitorio *.tradb* es el que contiene la información completa de la señal, es un registro del cambio de amplitud en función del tiempo, como se muestra en la Figura 3.6. A partir de la señal en el dominio temporal, es posible aplicar técnicas de transformación para obtener información en el dominio de la frecuencia.

Tabla 3.2: Características extraídas del archivo primario *.pridb*.

Característica	Descripción
time	Tiempo transcurrido desde el inicio del ensayo en segundos
channel	Número de canal que detecta el hit
amplitude	Amplitud pico en voltios
energy	Energía en eu
rms	Valor cuadrático medio del ruido de fondo al inicio del hit en voltios
rise time	Tiempo desde el primer cruce de umbral hasta la amplitud pico en segundos
counts	Número de veces que la señal cruza el umbral en dirección positiva
trai	Índice del transitorio

3.3.1 Filtrado de datos

No todos los hits registrados resultan útiles para el entrenamiento del modelo, debido a la forma de operar del sistema de adquisición de datos para la detección de este tipo de señal acústica. Muchas de las señales no son generadas por las fuentes de impacto en sí, sino que pueden ser causadas por reflejos de la onda debido a la geometría de la placa o por impactos de menor amplitud, resultado del rebote de las mismas fuentes sobre la superficie de la placa.

Además del filtro inicial de umbral de 50 dB para eliminar el ruido de fondo, fue necesario implementar dos filtros adicionales. El primer filtro se utiliza para identificar los transitorios con índice inválido, como por ejemplo aquellos con índice 0. Estas son señales que el sistema de adquisición de datos ha registrado pero que no los considera como hits y por ende no posee información en el archivo *.tradb*. El segundo filtro tiene la función de descartar los impactos de baja amplitud que han cruzado el umbral solo unas pocas veces. Para ello, se consideran únicamente las señales con al menos 12 conteos o *counts*, ya que aquellas que tienen menos cruces tienden a perderse en el ruido de fondo después de la fase inicial.

En la Figura 3.7 se observa la diferencia entre una señal de emisión acústica producto de un impacto con la esfera metálica con la placa (a), y una señal resultante de un rebote de la misma esfera (b), la cual exhibe un número de conteos igual a 1. Las líneas rojas horizontales representan el umbral que se ha establecido en el proceso de adquisición de datos. Se observa claramente la diferencia en la amplitud de ambas señales, siendo notable que la señal proveniente del rebote está mayormente compuesta por ruido de fondo.

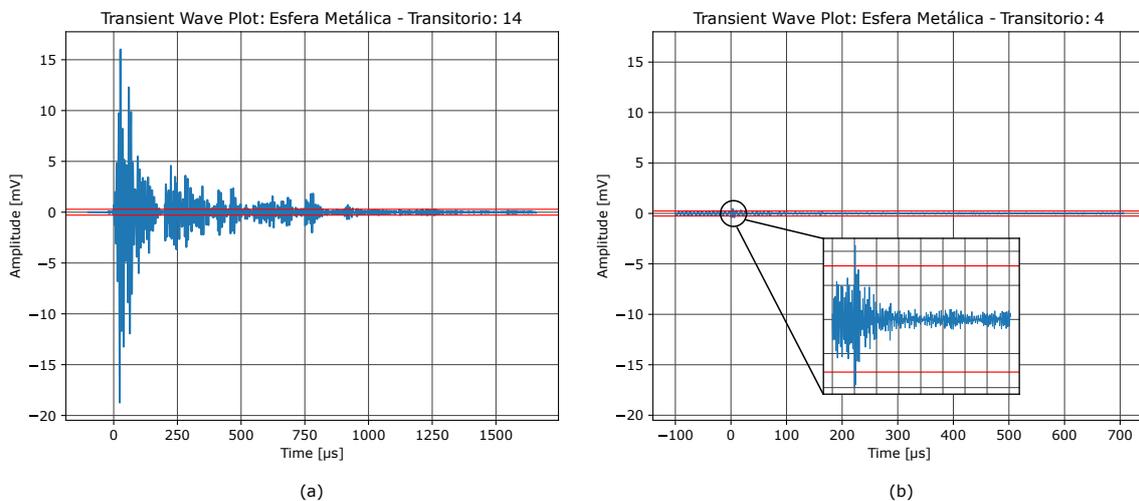


Figura 3.7: Comparación entre una señal de impacto de esfera metálica (a) y una señal resultante de un rebote de esfera metálica (b).

Después de haber aplicado los filtros se obtuvieron un total 4360 señales de emisión acústica válidas, distribuidas en 273 para la clase “esfera metálica”, 3729 para la clase “arena” y 358 para la clase “hielo”. Para garantizar un buen rendimiento del modelo de clasificación, es esencial que todas las clases cuenten con un número similar de instancias. Por lo tanto, se procedió a reducir aleatoriamente el número de instancias en la clase “arena” a un total de 300, equiparando así las cantidades de datos entre las distintas clases. Al final el conjunto de datos constaba de 931 señales.

3.3.2 Aplicación de la transformada de Fourier de tiempo reducido

Para la extracción de características de frecuencia de las señales se utilizó la transformada de Fourier de tiempo reducido o STFT. Esta técnica evalúa el contenido de frecuencia en segmentos temporales de la señal, en lugar de analizarla en su totalidad. Esto permite solventar dos problemas. En primer lugar, dado que las señales no tienen la misma duración, al utilizar un número constante de segmentos de longitud definida se recortan todas a la misma duración. En segundo lugar, al trabajar con segmentos temporales, se posibilita el análisis de la señal en diferentes instantes de tiempo, permitiendo captar la evolución de la señal, desde que se produce el impacto hasta su atenuación.

El procedimiento que se llevó a cabo para la aplicación de la STFT fue el siguiente:

1. Definir el número de segmentos, su duración y el porcentaje de solapamiento. Generalmente se utiliza un número impar de segmentos con un solapamiento del 50% para asegurar que no se pierda la información al inicio y al final de un segmento, especialmente al utilizar ventanas que evitan las discontinuidades de la señal. La duración del segmento se establece en el número de muestras que este contiene. Se recomienda que este valor sea una potencia de 2, ya que la transformada rápida de Fourier para señales discretas está optimizada para trabajar con estas potencias. Esto resulta en un procesamiento más rápido y eficiente en términos de tiempo de ejecución y uso de recursos computacionales.

Estos parámetros fueron seleccionados a través de múltiples iteraciones hasta llegar a la configuración que mejor se ajustara al modelo de aprendizaje automático. Esta configuración final consistió en utilizar 3 segmentos con 512 muestras por segmento y un solapamiento del 50%. Además, el punto de inicio del primer segmento se estableció en 25 μ s antes del primer cruce por el umbral, valor al cual se puede acceder con la ayuda del parámetro *pretrigger* establecido previamente.

2. Aplicación de una ventana a cada segmento. Las ventanas son funciones matemáticas que se multiplican con la señal original previo a una operación de transformación. Se utilizan para reducir los efectos de las discontinuidades en los bordes de la señal. Se atenúa gradualmente la amplitud de las muestras cercanas a los bordes de la señal, permitiendo trabajar con señales finitas y no periódicas. La ventana con mejor rendimiento en el modelo fue la ventana *Hanning* cuya fórmula está expresada en la Ecuación 3.1.

$$w[n] = 0,54 - 0,46 \cos \frac{2\pi n}{N-1} \quad (3.1)$$

Donde $w[n]$ es el valor de la ventana en la muestra y N es el número total de muestras en la ventana.

3. Transformada rápida de Fourier. Una vez que la ventana fue aplicada a cada segmento, se procedió a efectuar la transformada rápida de Fourier para obtener el espectro de frecuencia de la señal en distintos intervalos de tiempo. A partir de este espectro, se pudieron extraer las características en frecuencia luego fueron utilizadas para el entrenamiento del modelo de aprendizaje automático. En la Figura 3.8 se presenta un ejemplo de aplicación de este procedimiento sobre una señal producida por el impacto de la esfera metálica. En la fila superior de la figura, se pueden observar tres segmentos de la señal en el dominio del

tiempo, los cuales han sido procesados utilizando la ventana Hamming. Es importante destacar que el segundo segmento se superpone parcialmente con los segmentos uno y tres, como se puede apreciar en los valores del eje horizontal del tiempo. En la segunda fila, se muestra la aplicación de la transformada de Fourier a cada uno de estos segmentos. Se aprecia claramente que el primer segmento presenta una amplitudes mayores que los demás segmentos. Además, lo más destacado es cómo cambian los valores de la frecuencia pico y frecuencia centroide para cada uno de los segmentos.

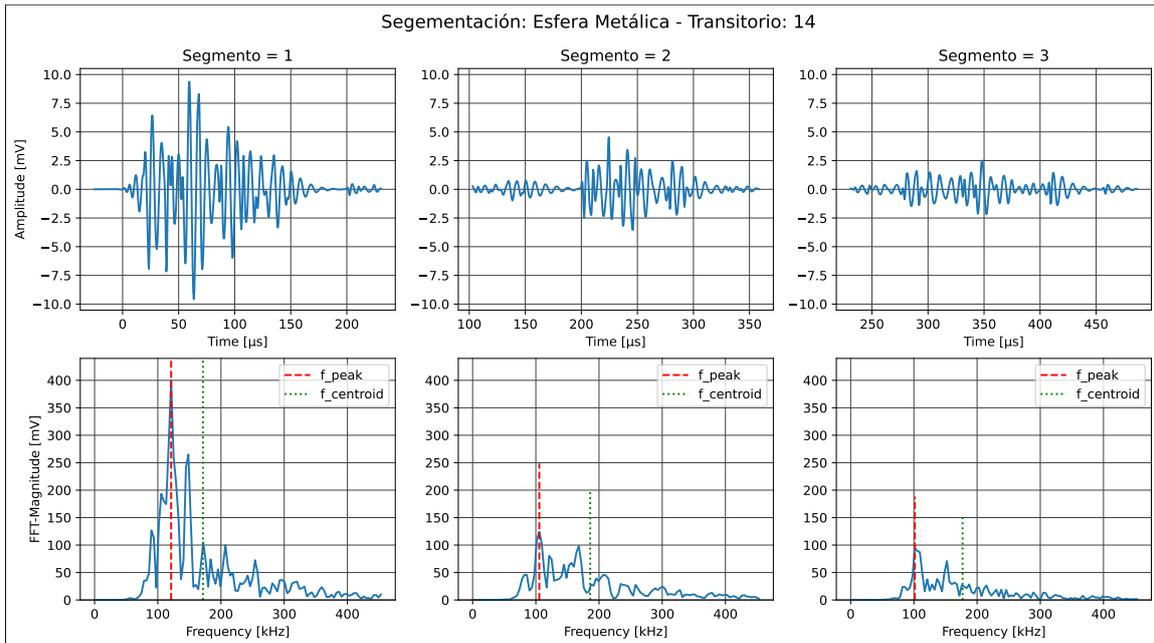


Figura 3.8: Segmentación para un impacto de esfera metálica.

3.3.3 Extracción de características

Una vez obtenidos los espectros de frecuencia de cada uno de los segmentos se procedió a realizar la extracción de características para el entrenamiento del modelo. En la Subsección 2.4.5 se mencionaron cuáles eran las principales características que se pueden extraer de una señal en el dominio de la frecuencia. Tras varias iteraciones se comprobó que las características más relevantes son: la frecuencia pico, la frecuencia centroide, la frecuencia pico ponderada y la potencia parcial.

En la Tabla 2.2 se presentaron las ecuaciones para calcular cada una de estas características para una señal continua. Debido a que en la práctica se trabaja con señales discretas las integrales pueden expresarse en forma de sumatorios obteniendo las expresiones que se presentan en la Tabla 3.3. En esta versión discreta, f_i representa las frecuencias discretas en las que se ha muestreado el espectro de amplitud, y $\tilde{U}(f_i)$ es la amplitud correspondiente en esa frecuencia discreta.

Debido al rango de funcionamiento de los sensores, el intervalo de frecuencia para los niveles de potencia se establece entre $f_{start} = 0$ kHz y $f_{end} = 450$ kHz, dividiendo el análisis en tres

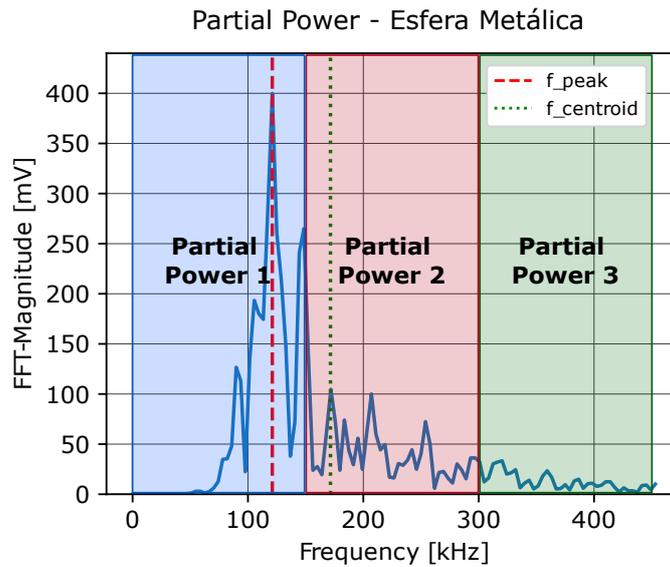
Tabla 3.3: Características en frecuencia para una señal discreta.

Característica	Definición	Unidad
Frecuencia pico	f_{peak}	[mV]
Frecuencia centroide	$f_{centroid} = \frac{\sum_i f_i \cdot \tilde{U}(f_i)}{\sum_i \tilde{U}(f_i)}$	[μs]
Frecuencia pico ponderada	$\langle f_{peak} \rangle = \sqrt{f_{peak} \cdot f_{centroid}}$	[-]
Potencia parcial	$\frac{\sum_{i=f_1}^{f_2} \tilde{U}^2(f_i)}{\sum_{i=f_{start}}^{f_{end}} \tilde{U}^2(f_i)}$	[%]

potencias parciales como se indica en la Tabla 3.4. En la Figura 3.9 se observa un ejemplo de los intervalos de la potencia parcial.

Tabla 3.4: Intervalos de frecuencia para los niveles de potencia parcial.

Característica	Definición	Unidad
Potencia parcial 1	$f_{start} = f_1 = 0 \text{ kHz}; f_2 = 150 \text{ kHz}$	[%]
Potencia parcial 2	$f_1 = 150 \text{ kHz}; f_2 = 300 \text{ kHz}$	[%]
Potencia parcial 3	$f_1 = 300 \text{ kHz}; f_2 = f_{end} = 450 \text{ kHz}$	[%]


Figura 3.9: Intervalos de potencia parcial 1, 2 y 3.

Además de las características en frecuencia, se demostró la utilidad del tiempo de subida, también conocido como *rise-time*, en la clasificación de señales de emisión acústica. Por lo tanto, se incorporó esta característica en el proceso de entrenamiento del modelo. En resumen, se extrajeron 6 características por cada segmento, que incluyen la frecuencia pico, frecuencia centroide, frecuencia pico ponderada y la potencia parcial 1, 2 y 3. En total, se obtienen 18 características. Sumado a esto, la inclusión del tiempo de subida resulta en un conjunto total de 19 características que se utilizaron en el proceso de entrenamiento del modelo.

3.4 Entrenamiento del modelo de aprendizaje automático

Para el entrenamiento del modelo de clasificación se utilizó el flujograma propuesto en la Figura 2.18. Una vez realizado la recolección y el tratamiento de los datos se procedió a elegir el tipo de algoritmo a utilizar. En este caso se escogió el algoritmo de bosques aleatorios que es el uno de los más utilizados para tareas de clasificación gracias a su buen rendimiento.

Se utilizó la biblioteca de *scikit-learn*, que es una herramienta de aprendizaje automático de código abierto y de uso libre. Además, se utilizó el lenguaje de programación *Python*, que también es de código abierto y tiene compatibilidad con las librerías existentes para el tratamiento de datos. En el Anexo A se detalla el código utilizado para la importación de datos, extracción de características, así como también el entrenamiento, validación y evaluación del modelo.

3.4.1 Separación del conjunto de datos

Una vez creado el conjunto de datos, que se trata de una matriz que contiene las características en las columnas para cada una de las señales o instancias, ubicadas en las filas, se procedió a realizar la separación en subconjuntos. En este caso solo se dividió en dos subconjuntos, uno de entrenamiento y uno de evaluación en proporción 80/20, omitiendo el subconjunto de validación debido a la poca cantidad relativa de datos que se ha recogido de los ensayos. Sin embargo la validación del modelo se realizó mediante la técnica de validación cruzada con un valor de $K = 5$. En la Figura 3.10 se observa una ilustración de la separación del conjunto de datos.

3.4.2 Entrenamiento y validación

El algoritmo utilizado para el proceso de clasificación fue el *RandomForestClassifier*, disponible en la librería *scikit-learn*. En este enfoque, cada clasificador se configura con el propósito de encontrar los parámetros que minimizan la función de costo o pérdida. Esta función de costo compara las predicciones realizadas por el modelo con las etiquetas reales correspondientes a cada instancia del conjunto de datos.

El ajuste de estos parámetros se lleva a cabo durante la fase de entrenamiento del modelo. En el caso específico del algoritmo de bosque aleatorio, estos parámetros corresponden a los umbrales utilizados en cada nodo del árbol de decisión para separar las diferentes clases. Los árboles de decisión que componen el bosque aleatorio se construyen mediante la selección aleatoria de características y subconjuntos de datos, lo que proporciona una diversidad en la generación de múltiples árboles.

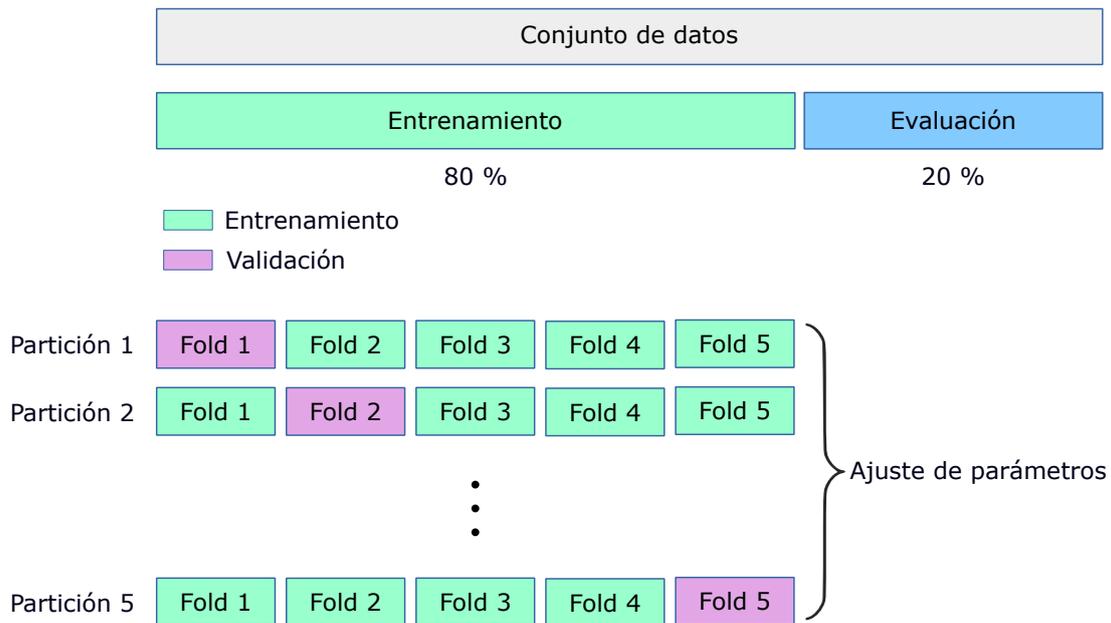


Figura 3.10: División del conjunto de datos utilizando la técnica de validación cruzada.

La estrategia detrás del ajuste de parámetros de un bosque aleatorio implica la exploración de diferentes combinaciones de umbrales en cada nodo de cada árbol en el bosque. Esto se realiza mediante técnicas como la búsqueda en cuadrícula (*grid search*) o la optimización bayesiana, con el objetivo de encontrar la configuración que resulte en la mejor precisión y generalización del modelo en datos no vistos. El proceso de ajuste se basa en evaluar cómo las decisiones tomadas en cada nodo afectan la calidad de las predicciones y se orienta a evitar el sobreajuste y mejorar el rendimiento en situaciones reales.

Además de los parámetros que debe ajustar el modelo existe también otros que son propios del algoritmo y que se denominan hiperparámetros. Estos son valores configurables que no se determinan directamente a partir de los datos de entrenamiento, sino que deben ser ajustados antes del proceso de entrenamiento para obtener un mejor rendimiento del modelo. Estos hiperparámetros guían el comportamiento y la complejidad del algoritmo, influyendo en su capacidad para aprender patrones y generalizar a datos nuevos.

En el caso del algoritmo *RandomForestClassifier*, existen varios hiperparámetros que pueden ajustarse para optimizar su rendimiento. Algunos de los más relevantes son:

- ***n_estimators***: Representa la cantidad de árboles de decisión que se construirán en el bosque aleatorio. Un valor mayor puede mejorar la precisión, pero también aumenta el costo computacional.
- ***max_depth***: Indica la profundidad máxima que pueden tener los árboles de decisión individuales. Un valor más alto puede permitir un mejor ajuste a los datos de entrenamiento, pero puede conducir a un sobreajuste del modelo.
- ***min_samples_split***: Especifica el número mínimo de muestras requeridas para dividir un nodo interno en un árbol. Controla la prevención de divisiones que pueden resultar en nodos con muy pocas muestras.

- ***min_samples_leaf***: Establece el número mínimo de muestras requeridas en un nodo hoja. Esto evita la creación de hojas con muy pocas instancias, lo que puede conducir al sobreajuste.
- ***max_features***: Determina la cantidad máxima de características consideradas en cada división de un nodo. Un valor más bajo puede aumentar la aleatoriedad y la diversidad entre los árboles.

3.4.3 Evaluación del modelo

Una vez que el clasificador ha sido entrenado, con todos sus parámetros ajustados para optimizar su rendimiento, se procede a evaluarlo. Esta evaluación se lleva a cabo utilizando un subconjunto de datos independientes llamado conjunto de evaluación. Este conjunto contiene ejemplos que el modelo no ha visto durante su entrenamiento, lo que permite poner a prueba su capacidad de generalización a nuevas instancias. En esta etapa, el modelo realiza predicciones sobre los datos de evaluación y las compara con las etiquetas reales correspondientes. Las métricas de evaluación utilizadas son la exactitud (*accuracy*) y la puntuación F1.

Si el rendimiento del modelo no cumple con los estándares establecidos, se inicia un proceso iterativo de mejora. Durante esta iteración, se pueden ajustar diversos aspectos del modelo, incluidos los hiperparámetros, las características utilizadas e incluso los métodos de estandarización de los datos. Estas iteraciones se repiten hasta que el rendimiento del modelo alcance los niveles deseados y cumpla con los requisitos previamente definidos.

Primero se estudió la posibilidad de incluir o no la estandarización de las características. Aunque su utilización no es necesariamente requerida en un bosque aleatorio debido a la naturaleza de funcionamiento del modelo, donde las decisiones se basan en comparaciones de características individuales en cada nodo. Esto los hace menos sensibles a las diferencias de escala. Entre las opciones de estandarización que se utilizaron están la normalización, el escalamiento “Mín-Máx” y la transformación logarítmica.

También se hizo uso de la técnica *backward elimination* para la selección de características relevantes y la simplificación del modelo. Esta técnica consiste en entrenar el modelo con el conjunto completo de características e ir eliminando de forma iterativa aquellas que tienen el menor impacto en el rendimiento del clasificador basado en las métricas de evaluación. El proceso iterativo de eliminación se repite hasta cumplir con un criterio de rendimiento predefinido, o una vez que ya no se observa una mejora significativa al eliminar más características. Esta técnica además de reducir la complejidad puede mejorar la interpretabilidad y la generalización del modelo.

Además, se utilizó la función *feature_importances_* disponible en las librerías del clasificador *RandomForestClassifier* que permite evaluar la importancia relativa de cada característica en el proceso de toma de decisiones del modelo. En esencia, esta función ayuda a determinar qué características tienen un impacto más significativo en la capacidad del modelo para hacer predicciones precisas. Si bien proporciona una guía valiosa sobre la importancia de las características, no necesariamente indica causalidad ni establece relaciones directas entre características y resultados.

Por último, para el ajuste de los hiperparámetros se utilizó la técnica *RandomizedSearchCV* para realizar una búsqueda exhaustiva entre diferentes combinaciones. Esta técnica consiste en

definir un conjunto de posibles valores para cada hiperparámetro que se desea ajustar y luego selecciona un subconjunto de combinaciones de manera aleatoria para evaluarlas. Cada combinación de hiperparámetros se evalúa mediante las métricas de rendimiento. El parámetro “n_iter” permite definir cuántas combinaciones se evaluarán, en este caso se ha fijado en un total de 10 combinaciones.

En la Tabla 3.5 se muestran los hiperparámetros que se ajustaron y el rango de valores evaluado.

Tabla 3.5: Valores para el ajuste de hiperparámetros.

Hiperparámetro	Rango	Paso
n_estimators	100 a 1 000	100
max_depth	5 a 30 + [None]	5
min_samples_split	2 a 11	1
min_samples_leaf	1 a 5	1
max_features	“sqrt”, “log2”	-

Por ejemplo, para el caso del número de estimadores ($n_estimators$), este puede tomar los valores 100, 200, 300, ..., o 1 000. En el caso de la profundidad máxima (max_depth) la opción [None] indica que los nodos se pueden expandir hasta que todas las hojas no tengan impureza, o hasta que contengan un número de instancias menor al establecido en el hiperparámetro $min_samples_split$.

Por último para la cantidad máxima de características para cada división ($max_features$) no se ha establecido un rango sino dos opciones que este hiperparámetro posee. La opción “sqrt”, que es la que está establecida por defecto, considera $max_features = \sqrt{n_features}$ donde $n_features$ es el número total de características. La opción “log2” en cambio establece al número máximo de características como $max_features = \log_2 n_features$.

Resultados

4.1 Optimización del modelo de clasificación

En esta sección, se presentan los resultados obtenidos a través del análisis del modelo de clasificación. Se exploran las diversas iteraciones detalladas en la metodología, evaluando la influencia de factores como la normalización, la selección de características y los hiperparámetros del modelo en su rendimiento. Estos resultados proporcionan una comprensión más profunda de cómo estas variables impactan en la capacidad del modelo para realizar predicciones precisas y su generalización.

4.1.1 Configuración base del modelo

Esta configuración sirve como punto de referencia preliminar a partir del cual se puede evaluar el rendimiento de las combinaciones posteriores. En esta configuración se utilizan los valores por defecto de los hiperparámetros y se consideran todas las características sin ningún tipo de normalización. Para la comparación entre las distintas combinaciones, se utilizan métricas de evaluación como la exactitud y la puntuación F1. Primero se calcula la exactitud y la puntuación F1 para el subconjunto de evaluación que funcionarán como un valor base. Además, se emplea la técnica de validación cruzada para comprobar la generalización del modelo, obteniendo la exactitud y puntuación F1 de validación cruzada.

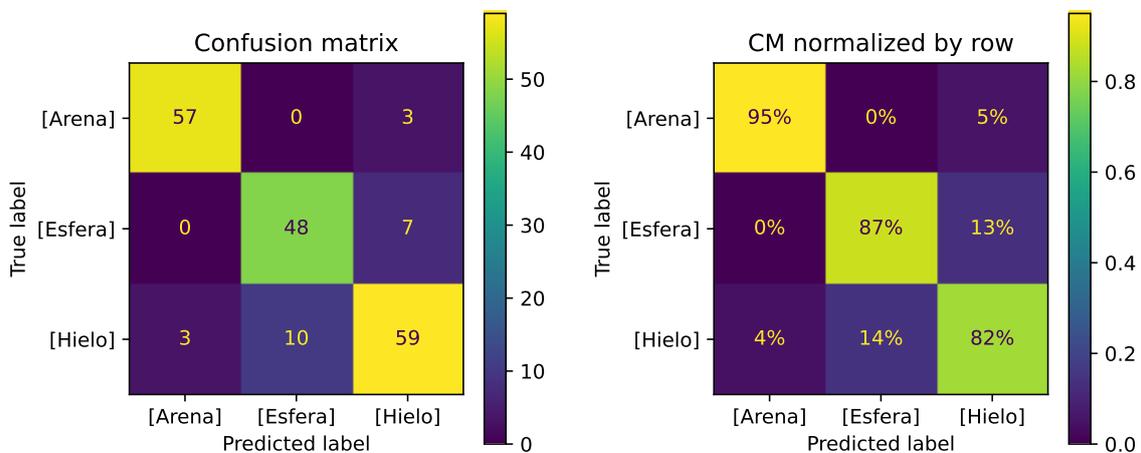
Se complementa la evaluación con la matriz de confusión en el conjunto de evaluación, tanto en términos de instancias totales como presentado como porcentaje con normalización por filas. La matriz de confusión ofrece una representación visual detallada de los resultados. En la Tabla 4.1 se presenta la configuración base mientras que en la Figura 4.1 se presenta su matriz de confusión.

Se han cambiado los nombres de los hiperparámetros para su mejor comprensión, donde $estim = n_estimators$, $depth = max_depth$, $split = min_samples_split$, $leaf = min_samples_leaf$ y $feat = max_features$.

Tabla 4.1: Configuración base del modelo de clasificación.

Características	Normalización	Hiperparámetros	Métricas
Todas	Ninguna	estim = 100	Evaluación
		depth = None	Exactitud = 87,7%
		split = 2	F1 = 87,9%
		leaf = 1	Val. Cruzada
		feat = "sqrt"	Exactitud = 88,6%
			F1 = 88,8%

En la matriz de confusión el eje horizontal son las predicciones que ha realizado el modelo, mientras que el eje vertical indica la clase real a la que pertenece cada instancia. Un modelo ideal tendría valores únicamente en la diagonal principal de esta matriz. Se puede observar que el modelo logra distinguir con mayor precisión las instancias pertenecientes a la clase "arena". Además, el modelo distingue perfectamente entre los impactos de arena y esfera metálica. Sin embargo, se observa un menor rendimiento cuando el modelo intenta distinguir entre impactos de hielo y esfera metálica. Esto puede deberse a la similitud existente entre estas dos fuentes de impacto, especialmente en sus dimensiones, que para el caso de la arena es muy diferente.

**Figura 4.1:** Matriz de confusión para la configuración base del modelo.

4.1.2 Importancia del filtrado de datos

Para demostrar la importancia del filtrado de los datos se comparan los resultados de la configuración base con los resultados obtenidos de un modelo en el que no se aplicó el filtro de conteo de datos. En este último caso, se emplearon 500 para la clase "arena", 504 para la "esfera metálica" y 614 para la clase "arena". Se utilizó la misma configuración que en el caso base, y su matriz de confusión se presenta en la Figura 4.2. Sin embargo, en este escenario, la exactitud se reduce al 79,6% y la puntuación F1 al 79,7%. Se puede comprobar cómo la introducción de datos que no corresponden directamente a impactos, sino a reflexiones de ondas o rebotes de las fuentes, ha disminuido el rendimiento del modelo hasta en 8 puntos.

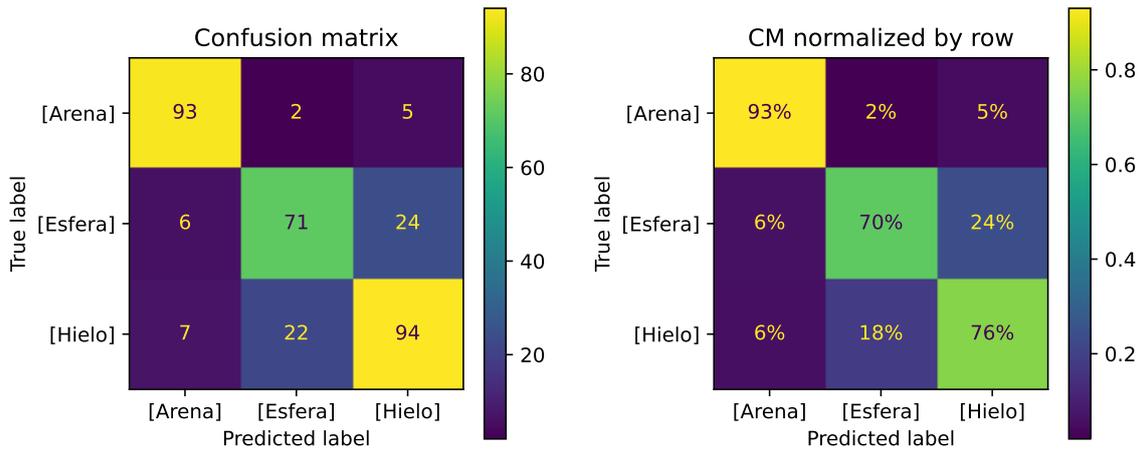


Figura 4.2: Matriz de confusión para datos sin filtro de conteo.

Cabe recalcar que también se produce el mismo patrón que en el caso base donde las instancias de arena son las que mejor clasifica el modelo, y se observa una menor exactitud para los impactos de esfera metálica y hielo.

4.1.3 Normalización de características

Primero se analiza el caso de la normalización por estandarización, un proceso mediante el cual cada característica es dividida por el valor de su desviación estándar. La estandarización es una técnica que busca transformar las características para que tengan una media de cero y una desviación estándar de uno. Esto permite que las características estén en la misma escala y ayuda a los algoritmos de aprendizaje automático a converger más rápido y a trabajar de manera más eficiente, ya que reduce el impacto de características con escalas muy diferentes. Si bien los bosques aleatorios son menos susceptibles a diferentes escalas se ha evaluado su inclusión.

El segundo tipo de normalización es el de tipo “Mín-Máx” donde se transforman las características de tal manera que queden dentro de un rango específico, en este caso entre 0 y 1. Para ello cada valor de la característica se transforma restando el valor mínimo de la característica y dividiendo por la diferencia entre el valor máximo y el valor mínimo.

Por último, se utilizó una transformación logarítmica en las siguientes características: la potencia parcial 3 de todos los segmentos y el tiempo de subida. Esta elección se fundamenta en el hecho de que sus histogramas de frecuencia exhibían un sesgo positivo o asimetría hacia la derecha. Es decir, la mayoría de los valores se concentran en el extremo inferior del rango, mientras que solo unos pocos valores se encuentran en el extremo superior.

En la Figura 4.3 (a) se presenta el histograma de frecuencias para el caso de la frecuencia centroide del segmento 1, en ella se observa una distribución más cercana a la normal. Sin embargo, en el caso de la potencia parcial 3 del segmento 1, representado en la Figura 4.3 (b) el sesgo positivo es evidente. La transformación logarítmica se aplicó con el propósito de mitigar esta asimetría. Esta transformación utiliza calcula el logaritmo natural de cada característica. Comprime los valores más grandes y expande los valores más pequeños, lo que conduce a una distribución

más simétrica mejorando las propiedades estadísticas de los datos. En la Figura 4.4 se ilustra la transformación logarítmica para la potencia parcial 3 del segmento 1.

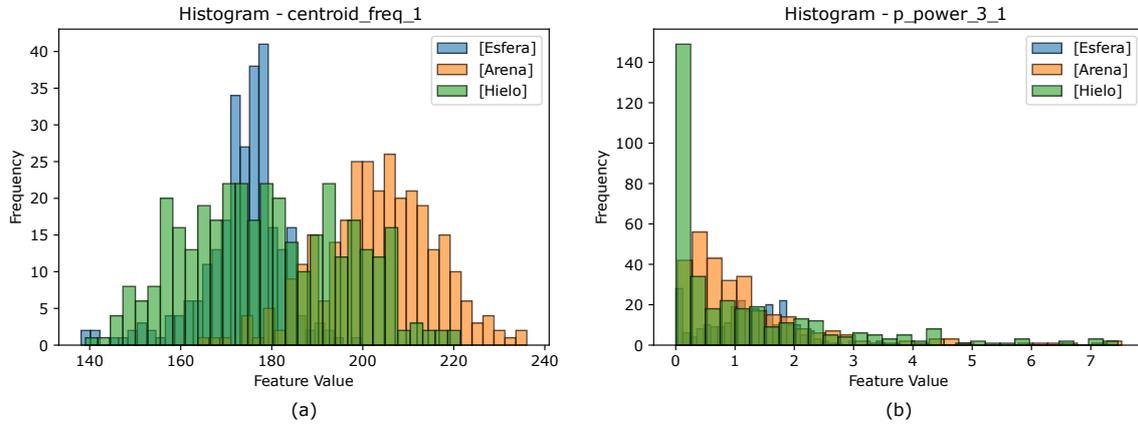


Figura 4.3: Histograma de la frecuencia centroide (a), y potencia parcial 3 (b) del segmento 1.

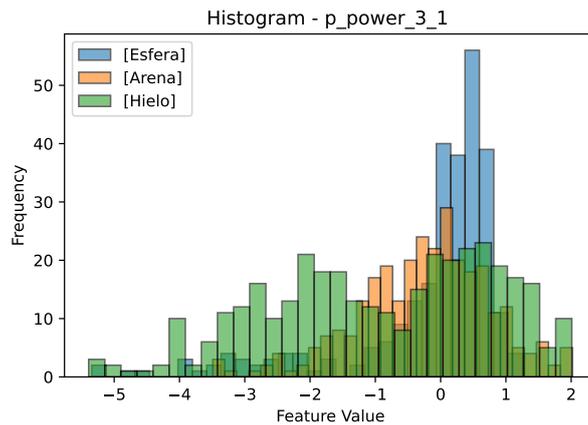


Figura 4.4: Histograma de la potencia parcial 3 del segmento 1 con la transformación logarítmica.

En la Tabla 4.2 se presentan las métricas de evaluación correspondientes a los tres tipos de normalización. Aunque se observa una ligera mejora en la exactitud y la puntuación F1 en el subconjunto de evaluación para los casos de estandarización y la técnica "Mín-Máx", también se registra una pequeña disminución en estas métricas durante la validación cruzada. Sin embargo, es importante destacar que no se observa una diferencia significativa en comparación con la configuración base, evidenciando que las técnicas de normalización no son necesarias para el caso de modelos que utilizan los bosques aleatorios.

Tabla 4.2: Métricas para los casos de normalización.

Métricas	Estandarización	“Mín-Máx”	Logarítmica
Evaluación:	Exactitud = 88,2 % F1 = 88,4 %	Exactitud = 88,2 % F1 = 87,4 %	Exactitud = 87,7 % F1 = 87,9 %
Val. Cruzada:	Exactitud = 88,3 % F1 = 88,5 %	Exactitud = 88,3 % F1 = 88,5 %	Exactitud = 88,3 % F1 = 88,5 %

4.1.4 Selección de características

Debido a que la normalización por sí sola no demostró una mejora significativa en el rendimiento del modelo, se ha combinado su uso con el de la técnica de selección de características. En este caso se utilizó la técnica de eliminación hacia atrás o *backward elimination*, explicada en la Subsección 3.4.3. Esta técnica se aplicó en conjunto con las tres estrategias de normalización, una a una. La combinación de la transformación logarítmica con la eliminación hacia atrás presentó el mejor rendimiento.

Del conjunto inicial de 19 características utilizadas en la configuración base, se han seleccionado solo 13 que conforman el subconjunto de características relevantes. Este subconjunto se presenta en la Tabla 4.3 donde se han separado las características por el segmento al que pertenece. Mientras que en la Tabla 4.4 se presentan en orden descendente las características seleccionadas, considerando su importancia relativa en el proceso de toma de decisiones del modelo.

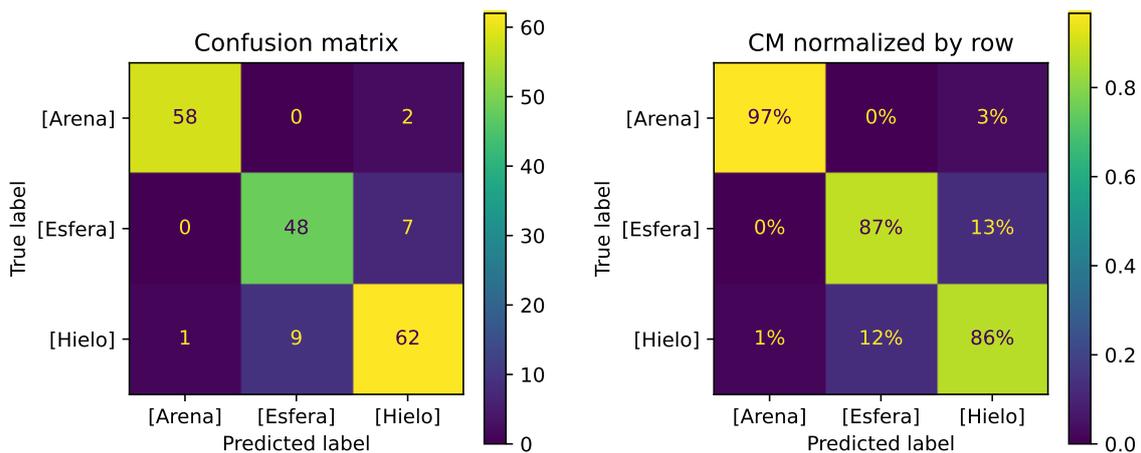
Tabla 4.3: Características seleccionadas con la técnica de eliminación hacia atrás.

Tiempo	Segmento 1	Segmento 2	Segmento 3
Tiempo de subida	Frecuencia pico	Frecuencia pico	Frec. pico ponderada
	Frec. pico ponderada	Frec. pico ponderada	Frecuencia centroide
	Frecuencia centroide	Potencia parcial 3	Potencia parcial 3
	Potencia parcial 1		
	Potencia parcial 2		
	Potencia parcial 3		

En esta iteración se obtuvo una exactitud del 89,8 % y una puntuación F1 del 90,0 % en el caso del subconjunto de evaluación. En cuanto a la validación cruzada se obtuvo una exactitud del 88,7 % y una puntuación F1 del 88,9 %. Estos resultados indican una mejora de hasta 2 puntos en comparación con la configuración base en el subconjunto de evaluación, además de una ligera mejora para el caso de la validación cruzada. En la Figura 4.5 se presenta la matriz de confusión para esta iteración.

Tabla 4.4: Importancia relativa de las características.

Característica	Segmento	Importancia relativa
Frecuencia centroide	3	15,98 %
Potencia parcial 2	1	10,28 %
Potencia parcial 3	2	10,14 %
Frecuencia pico ponderada	1	8,93 %
Tiempo de subida	3	8,57 %
Potencia parcial 1	1	7,88 %
Frecuencia centroide	1	7,82 %
Frecuencia pico ponderada	3	7,76 %
Potencia parcial 3	3	5,73 %
Potencia parcial 3	1	4,63 %
Frecuencia pico ponderada	2	4,37 %
Frecuencia pico	2	4,16 %
Frecuencia pico	1	3,73 %

**Figura 4.5:** Matriz de confusión con la técnica de eliminación hacia atrás y transformación logarítmica.

4.1.5 Ajuste de hiperparámetros

El ajuste de los hiperparámetros se ha realizado mediante una búsqueda aleatoria considerando los valores indicados en la Tabla 3.5. Como resultado de este análisis, se ha observado una ligera mejora en el rendimiento del modelo. Esta última iteración se considera como la configuración final del modelo, ya que ha evidenciando una mejora de hasta 0,6 puntos en la exactitud y 0,4 puntos en la puntuación F1. Este ajuste a parte de mejorar la precisión también ayuda a evitar el sobreajuste, mejorar la generalización, adaptar el algoritmo al conjunto de datos y mejorar la interpretación de los resultados.

La Tabla 4.5 muestra la configuración final del modelo, mientras que en la Figura 4.6 se presenta la matriz de confusión correspondiente. Se puede observar que el modelo ha mejorado sus predicciones para los impactos de hielo, reduciendo las confusiones de 10 a solo 8 instancias. Sin

embargo, en la clase “arena” el modelo ha confundido una instancia con un impacto de esfera metálica. Las predicciones para las instancias de esfera metálica no han sufrido cambios.

Tabla 4.5: Configuración final del modelo de clasificación.

Características	Normalización	Hiperparámetros	Métricas
Subconjunto de características relevantes	Transformación logarítmica	estim = 200 depth = 25 split = 7 leaf = 3 feat = “log2”	Evaluación Exactitud = 90,4 % F1 = 90,4 % Val. Cruzada Exactitud = 88,3 % F1 = 88,6 %

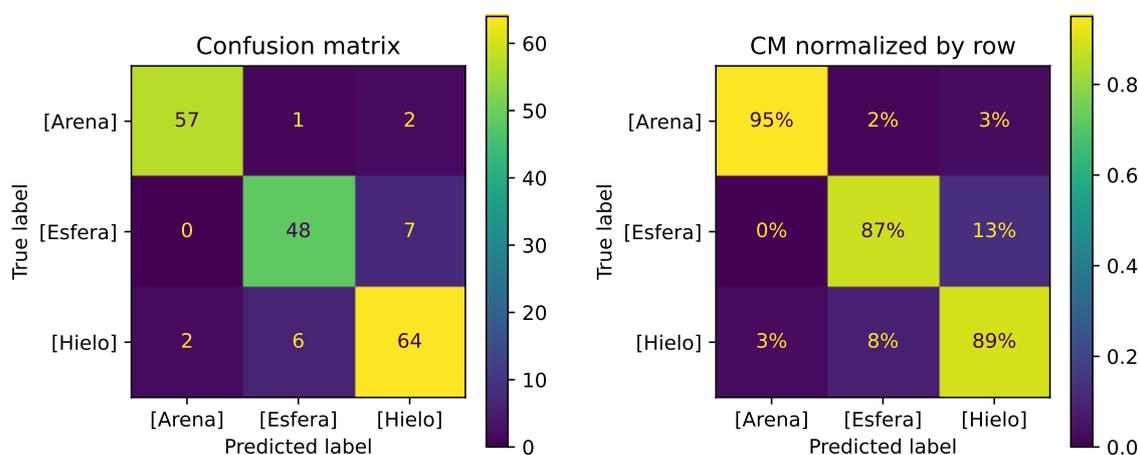


Figura 4.6: Matriz de confusión para la configuración final del modelo.

Por último para visualizar los agrupamientos de los datos se ha utilizado la técnica t-SNE (*t-distributed stochastic neighbor embedding*). Esta es una técnica de reducción de dimensionalidad que toma un conjunto de datos de alta dimensión, que en este caso son las 13 características extraídas de las señales, en un espacio bidimensional de manera que los grupos de señales similares se manifiesten como cúmulos o regiones densas en el espacio proyectado.

En la Figura 4.7 se muestra el diagrama de dispersión, donde se ha utilizado todo el conjunto de datos. En él se puede apreciar claramente los cúmulos correspondientes a cada una de las fuentes de impacto. Se observa también cierto solapamiento, es decir, que algunas instancias se encuentran dentro de cúmulos de agrupación incorrectos, o que las fronteras no están bien definidas. En especial para el caso de los impactos de hielo, que son los que más dispersión tienen. Este solapamiento puede deberse a la similitud en las características de las señales de emisión acústica. En otras palabras, algunas señales generadas por distintas fuentes pueden compartir características similares, lo que hace que el algoritmo de agrupación las coloque en el mismo grupo, aunque en realidad pertenezcan a grupos diferentes. Esto explica el rendimiento del modelo de clasificación, el cual tenía aproximadamente un 10 % de error en sus predicciones.

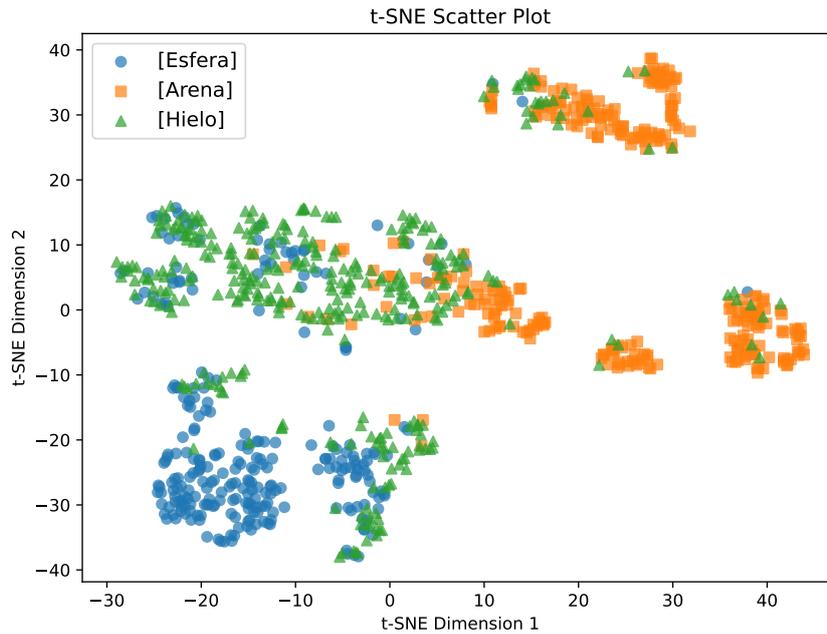


Figura 4.7: Diagrama de dispersión t-SNE para el subconjunto de características relevantes.

4.2 Correspondencia entre características de frecuencia y fuentes de impacto

En varias investigaciones [5], [27]-[32] se ha utilizado el enfoque de contenido en frecuencia para la clasificación de mecanismos de fallos en materiales compuestos, y en ellas se ha demostrado el poder discriminatorio de estas características. El rendimiento del modelo de clasificación indica que las características seleccionadas permiten distinguir entre las fuentes de impacto con bastante precisión. Estas reflejan aspectos específicos para cada una de las fuentes de impacto y cómo se han propagado estas ondas por el laminado de material compuesto.

La gráfica de una señal acústica en el dominio del tiempo puede parecer idéntica para las diferentes fuentes de impacto, como se observa en la Figura 4.8, pero en el espectro de frecuencia se pueden notar las diferencias que existen para cada una de ellas. En la Figura 4.9 se presenta una comparación del espectro en frecuencia entre las distintas clases.

En la Tabla 4.4 se presentaba la importancia relativa de las características en las decisiones que tomó el modelo para la clasificación. Si bien brinda una idea de cuáles son las más relevantes, no indican una correspondencia física por lo que se requiere un análisis posterior.

Por ejemplo, en la Tabla 4.3 se muestran las características utilizadas para el entrenamiento del modelo. Cabe destacar que debido a la naturaleza de una señal transitoria la mayor cantidad de información de esta se encuentra al inicio, o en otras palabras en el primer segmento. Es por ello que las seis características del primer segmento han sido escogidas por el propio modelo para el entrenamiento. Mientras que para los otros dos segmentos fueron escogidas solo tres, destacando las frecuencias pico, centroide y pico ponderada, además la potencia parcial 3. La frecuencia

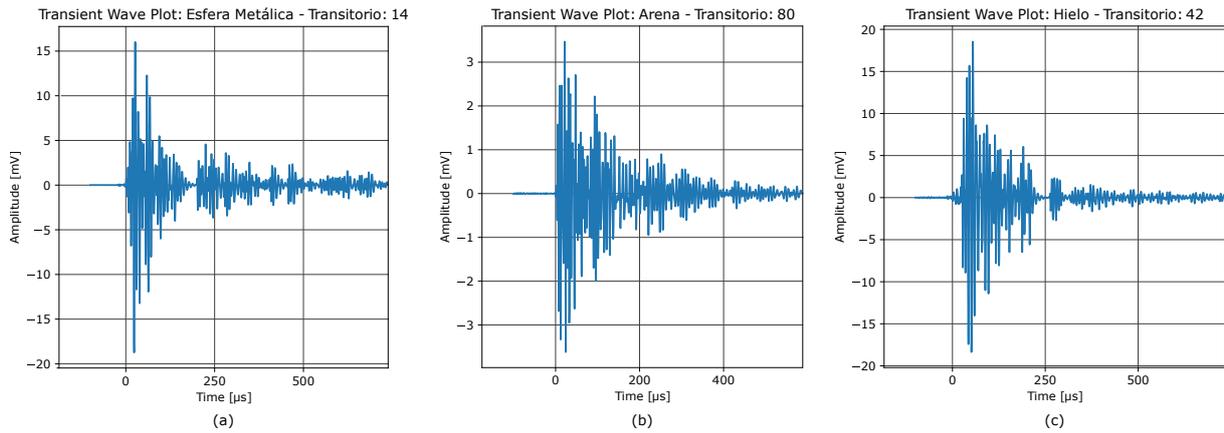


Figura 4.8: Comparación de señales transitorias de impactos de esfera metálica (a), arena (b) y hielo (c).

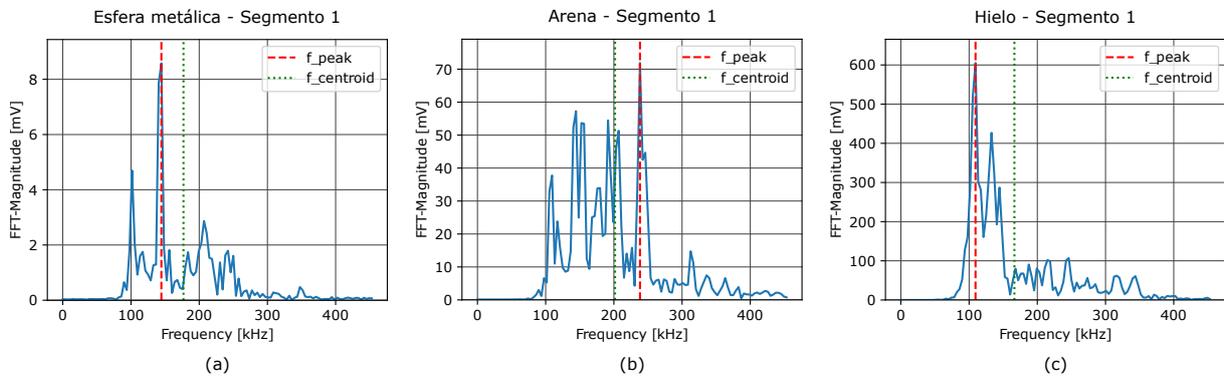


Figura 4.9: Comparación del espectrograma para los impactos de esfera metálica (a), arena (b) y hielo (c).

pico dominante de una señal está directamente relacionada con la fuente de impacto. Además, la distribución de energía en diferentes bandas de frecuencia proporciona información relevante.

Para visualizar la distribución de los valores de cada característica en relación a su fuente de origen, se han utilizados gráficas de dispersión. En ellas se grafica una característica frente a otra en cada eje coordenado, diferenciando cada clase con un marcador distinto. Se pueden observar los agrupamientos que forma cada clase. Esta representación permite observar claramente los agrupamientos que se forman para cada clase y sirve como indicador de si una característica en particular es relevante o no.

En la Figura 4.10 se presenta el diagrama de dispersión para la frecuencia pico ponderada y la potencia parcial 2, ambas correspondientes al segmento 1. Mientras que en la Figura 4.11 se enfrentan la frecuencia centroide del segmento 1 y la potencia parcial 3 correspondiente al segmento 2. En ellas se observa como las instancias para las diferentes clases forman pequeñas agrupaciones, aunque con cierto solapamiento entre ellas que explica el error de clasificación del modelo.

En la Figura 4.10 los impactos correspondientes a la esfera metálica se agrupan en la esquina inferior izquierda, lo que indica valores bajos tanto para la frecuencia pico ponderada, que va desde 120 a 140 kHz, como para la potencia parcial 2, con valores de 10 a 45%. Todo lo contrario

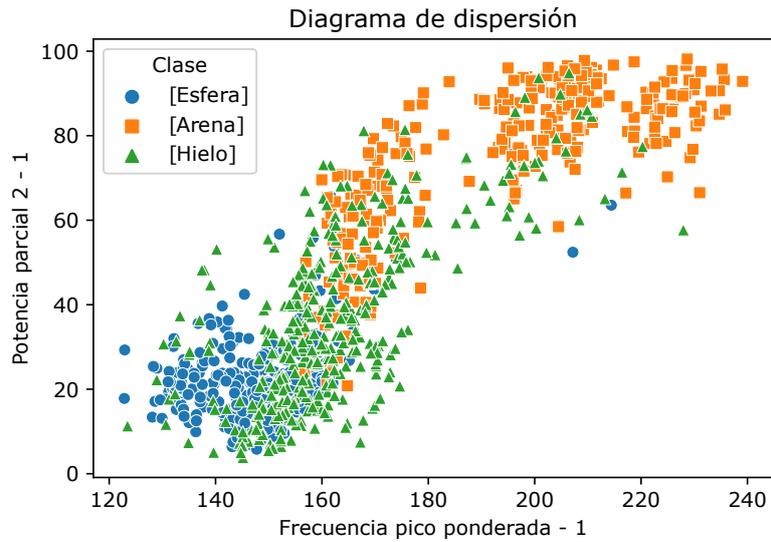


Figura 4.10: Diagrama de dispersión de la frecuencia pico ponderada - 1 vs la potencia parcial 2 - 1.

para los impactos de arena, que en su mayoría se agrupan en la esquina superior derecha, con valores para la frecuencia pico ponderada de 155 a 240 kHz y para la potencia parcial 2, un pocos más dispersos, en un rango de 20 a 100 %. Los impactos de hielo son los que más dispersión presentan, pero se puede observar una mayor agrupación en la zona media del diagrama, con valores para la frecuencia pico ponderada de 140 a 180 kHz y una potencia parcial 2 de 10 a 60 %.

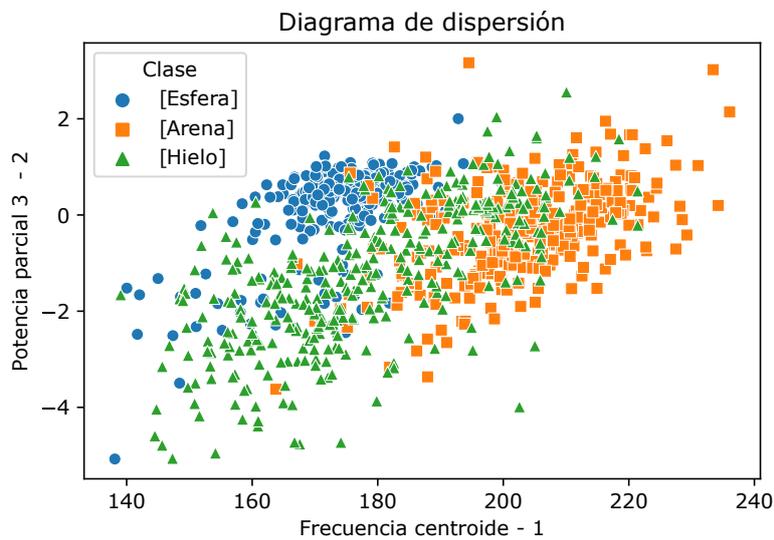


Figura 4.11: Diagrama de dispersión de la frecuencia centroide - 1 vs la potencia parcial 3 - 2.

En la Figura 4.11 en cambio se observa una correspondencia aparentemente lineal positiva entre ambas características para cada una de las clases. En otras palabras, para una fuente de impacto,

al aumentar la frecuencia centroide también aumenta la potencia parcial. Se mantiene la tendencia del caso anterior, donde los impactos de esfera metálica se encuentran en la zona de valores más bajos, los de hielo en la zona media, y los de arena en la zona de valores altos. Estos diagramas además evidencian que se podrían obtener mejores resultados si se utilizaran sensores de banda ancha, con un rango de frecuencia mayor y una respuesta más plana. A pesar de esto, es importante destacar que los resultados obtenidos hasta el momento son altamente satisfactorios.

4.3 Discusión

En esta sección de discusión se destacan las similitudes y deferencias del presente trabajo con las investigaciones mencionadas en la Sección 1.1. Los estudios realizados pueden clasificarse en dos grandes grupos: aquellos que se centran en la detección, clasificación y localización de impactos, y los que asignan los grupos de emisión acústica a mecanismo de fallo que se pueden producir en los plásticos reforzados con fibras de carbono.

El primer grupo es el que tiene más relación con la presente investigación. Además del uso de los laminados de fibras de carbono y la utilización de las señales provenientes de emisión acústica, es la extracción de características del contenido en frecuencia. Por ejemplo, en el estudio realizado por Damm, Andreas M., et al. [2] utiliza la misma segmentación, que se obtiene con la STFT. La principal diferencia es que en lugar de características numéricas utiliza los espectrogramas como imágenes para entrenar una red neuronal. Si bien una red neuronal tienen una capacidad de aprender de manera profunda y encontrar patrones complejos, sobresalen especialmente cuando se dispone de grandes cantidades de datos con una amplia variedad de ejemplos. Sin embargo, en situaciones con conjuntos de datos más pequeños, las técnicas convencionales de aprendizaje automático pueden ofrecer ventajas significativas.

Otras investigaciones [1], [3] también utilizan redes neuronales convoluciones para la clasificación y localización de impactos de emisión acústica. En la primera no utiliza características frecuenciales sino que construye mapas de superficie con el voltaje registrado con los sensores en función del tiempo y del número de sensor. La principal ventaja de esta investigación es que los impactos lo realiza en una estructura compleja, tanto en su geometría curva como en la disposición de las láminas, en concreto $[45/-45/90/0/90]_S$. Si bien la construcción de los mapas de superficie es más rápida y sencilla que la segmentación y extracción de características, depende del número de sensores que se utilice y de su ubicación relativa a la fuente de impacto, ya que el voltaje registrado depende directamente la distancia fuente-sensor. Esa característica resulta útil para la localización de los impactos pero no tan relevante para su clasificación.

En la investigación realizada por Zhao, Zhimin, and Nian-Zhong Chen [1] propone un método basado en redes de convolucionales espacial-temporal (STGCN) que utiliza representaciones de grafos para la localización de fuentes de emisión acústica en paneles compuestos. Su método se puede implementar si el principal objetivo es la localización de la fuente o zona de impacto, además es propicia si los ensayos se realizan en estructuras complejas, con distintas disposiciones de capas y con un conjunto de datos elevado.

El trabajo de Karimian y Modarres [4] resalta la importancia del ancho de la ventana temporal en la extracción de características de las señales de emisión acústica. Esta consideración es relevante ya que puede afectar significativamente la capacidad de clasificación de los modelos. Una ventana

muy pequeña podría resultar en una menor resolución en frecuencia, lo que podría implicar una pérdida de información importante. Por otro lado, una ventana excesivamente grande correría el riesgo de no captar las variaciones temporales que suceden en una señal de tipo transitorio. Se debe buscar un equilibrio entre el tamaño de la ventana y la resolución temporal. Además, el uso de ventanas pequeñas requeriría la implementación de más segmentos para cubrir toda la duración de la señal, esto provocaría la extracción de un mayor número de características, lo que podría dificultar la interpretación de los resultados y de su correspondencia con las diferentes fuentes de emisión. En definitiva, la selección del tamaño de ventana depende de la aplicación y lo recomendable es probar distintos valores dependiendo de la duración de la señal y del compromiso entre resolución en frecuencia y temporal.

Entre las características más utilizadas están las frecuencia pico y frecuencia pico ponderada, además de la potencia parcial, utilizadas en varios trabajos [5], [27]-[32] no solo para la clasificación de impactos sino también para la asignación de mecanismos de fallo. Además en otros trabajos se maneja una combinación de características temporales y del contenido en frecuencia [7], [10], [11]. Los estudios se han centrado en la asignación de las señales a fallos de matriz, interfaz, delaminación y rotura de fibras. En cuanto a impactos los estudios buscan determinar su localización, y la energía que estos producen y cuanto daño puede causar y no tanto a la fuente de emisión, clasificándolos por ejemplo, en niveles alto, medio o bajo. Esto argumenta el uso de características temporales como la energía, la amplitud pico, los conteos y el tiempo de llegada y de subida.

Se ha analizado mucho la utilización de técnicas de inteligencia artificial conjuntamente con las señales de emisión acústica para la identificación de mecanismos de fallo para cumplir con uno de los objetivos de investigación. Entre las principales investigaciones [5]-[11], [27]-[32] se usa principalmente técnicas de algoritmos no supervisados y de reconocimiento de patrones, puesto que al comienzo las instancias no están asociadas a ninguna clase. A diferencia de las fuentes de impacto, cuya procedencia y localización son conocidas, los mecanismos de fallo ocurren internamente en el material, lo que imposibilita conocer de antemano si una señal resultante provino de uno u otro tipo de fallo.

Como solución a este inconveniente se podrían utilizar técnicas de aprendizaje automático semi-supervisado [39], conjuntamente con ensayos donde un tipo de fallo sea preferente a otro, o donde se conozcan claramente las etapas donde estos se producen. La técnica consiste en utilizar etiquetar parcialmente los datos con la realización de pocos ensayos donde se controla la aparición de los mecanismos de fallo. Luego en los ensayos restantes, utilizar un algoritmo de *clustering* para agrupar las señales de emisión acústica similares y extender las etiquetas generadas previamente en estos grupos.

Otro enfoque que se puede utilizar es basarse en trabajos como [27]-[30] donde se ha demostrado que los fallos y agrietamiento de matriz corresponden principalmente a frecuencias bajas, que va desde los 90 a 250 kHz, el fallo de la interfaz en un rango 200 a 500 kHz, y que la rotura de fibras corresponde a las frecuencias altas en un rango de 400 a 800 kHz. Aunque en el trabajo realizado por Fatih E. Oz, et al. [9] demuestra que el fallo de las fibras no siempre está relacionado con altas frecuencias. Lo que indica que dependiendo de la configuración del ensayo, geometría del material, presencia de defectos y atenuación de la señal influyen en la señal registrada.

Un aspecto importante en el análisis del contenido en frecuencia de estas señales es la limitación de los sensores resonantes que generalmente tienden a aumentar las amplitudes de aquellas señales que están cerca de su frecuencia de resonancia. En los estudios realizados por Markus G. R. Sause [5], [19], [23], [27]-[29] siempre se recomienda el uso de sensores de banda ancha con respuesta plana para este tipo de aplicaciones. En concreto en [19] compara el uso de tres tipos de sensores, resonantes, multiresonantes y de banda ancha. En él obtiene que el error cometido en la clasificación de mecanismos de fallo fue del 1,2% para el caso de los sensores de banda ancha, 8,3% para el multiresonante y del 19,6% para el sensor resonante. No descarta la posibilidad de usar este tipo de sensores pero sí advierte de sus limitaciones.

En resumen, aunque el campo de investigación relacionado con la detección y clasificación de impactos, así como la identificación de los mecanismos de fallo en plásticos reforzados con fibras de carbono utilizando señales de emisión acústica ha experimentado un notable avance, aún persisten desafíos significativos, especialmente cuando se trata de abordar estructuras complejas, presencia de defectos, cargas variables e impactos de alta energía. El avance en las técnicas de inteligencia artificial en los últimos años ha permitido analizar una mayor cantidad de datos de manera más rápida y eficiente, y supone una herramienta importante para la identificación de patrones relacionando los modelos matemáticos con los ensayos experimentales. Cada enfoque y metodología presentada en los estudios mencionados aporta sus propias ventajas y, al mismo tiempo, enfrenta ciertas limitaciones intrínsecas. Por lo tanto, la elección de la técnica adecuada para abordar un problema particular depende en última instancia de las necesidades específicas de la aplicación y de la naturaleza de los datos disponibles. Estos desafíos ofrecen un amplio espacio para futuras investigaciones con el objetivo de lograr un monitoreo más preciso y confiable de la integridad estructural en diversas aplicaciones industriales y de ingeniería.

Conclusiones

Después del proceso de revisión de la literatura, la recopilación y análisis de datos experimentales, el desarrollo y evaluación de modelos de clasificación, así como la comparación y discusión con otros trabajos similares, se resumen a continuación las principales conclusiones de este estudio:

- Se ha desarrollado un modelo de clasificación de fuentes de impacto en laminados uni-direccionales reforzados con fibras de carbono, en base a las características extraídas del contenido en frecuencia de las señales de emisión acústica generadas. El modelo, en el cual se ha utilizado el algoritmo de bosques aleatorios, presenta tanto una buena precisión como capacidad para generalizar sus predicciones. En este aspecto se obtuvo una exactitud y puntuación F1 ambas del 90,4%. Este enfoque sienta las bases para futuros trabajos en la construcción de modelos de identificación de mecanismos de fallo en laminados de fibras de carbono, utilizando el marco de características y algoritmos de aprendizaje automático establecido en este estudio.
- En base a los resultados obtenidos en este estudio y la comparación con otras investigaciones, se ha comprobado la relevancia del contenido en frecuencia de las señales como características fundamentales para la clasificación de las fuentes de emisión acústica que las generaron. Aunque la obtención de características temporales es más directa, su utilidad en tareas de clasificación se ve limitada por factores como la atenuación de la señal debido al medio en el que se propaga, o los defectos presentes en el material. Además, características como amplitud, tiempo de llegada y subida o la energía dependen de la distancia relativa entre sensor y fuente. Esto implica que estas características pueden variar significativamente según si la onda se originó en proximidad o lejanía al sensor, incluso cuando provienen de la misma fuente de emisión.
- El uso de la transformada de Fourier de tiempo reducido (STFT) ha permitido extraer las características del contenido en frecuencia de las señales, pero también utilizar diferentes ventanas temporales, especialmente útil para este tipo de señales de clase transitoria. Se ha utilizado una ventana temporal de 126 μ s, o 512 muestras con una frecuencia de muestreo de 2 MHz. Se concluye que es recomendable utilizar un número de muestras que sea potencia

de 2 para mejorar la eficiencia computacional. Además un número reducido de segmentos, entre 3 y 5, son suficientes para capturar la información principal de la señal, sin incurrir en demasiadas características que puedan dificultar su interpretabilidad.

- Se determinó que las principales características para esta aplicación son la frecuencia pico ponderada y la potencia parcial 2, ambas del primer segmento, así como también la frecuencia centroide del tercer segmento y la potencia parcial 3 del segundo segmento. Además al realizar el proceso de selección de características el modelo escogió todas aquellas correspondientes al primer segmento, y tan solo tres para los segmentos 1 y 2. Esto indica que la mayor cantidad de información en este tipo de señales transitorias se encuentra en el inicio, que es lógico debido a la atenuación y dispersión de la onda, pero que también existen características relevantes en los demás segmentos que pueden usarse para diferenciar las fuentes de impacto.
- De forma general, los impactos de esfera metálica se encontraban en una banda de frecuencia baja entre 120 i 140 kHz y potencia parcial 2 del 10 al 45 %. Muy bien diferenciadas de los impactos de arena que se manejan con altas frecuencias de entre 155 i 240 kHz, y potencias parciales en su mayoría altas, del 60 al 100 % pero con algo de dispersión llegando a valores de hasta el 20 %. Los impactos de hielo ocupan una zona intermedia pero con un pequeño solapamiento con las otras agrupaciones, pero apracen principalmente con frecuencias comprendidas entre 140 i 180 kHz.
- Si bien las técnicas de normalización y de ajuste de hiperparámetros pueden contribuir a la mejora del rendimiento del modelo de clasificación, los aspectos más críticos en el entrenamiento de un modelo son el filtrado de datos y la selección de características. En relación al filtrado de datos, se ha demostrado que el uso de señales válidas y aquellas provenientes de ruido puede tener un impacto drástico en el rendimiento de un modelo, convirtiéndolo en el paso más crucial antes de aplicar cualquier algoritmo de aprendizaje automático. Aunque no siempre garantiza una mejora significativa en la precisión del modelo, mantener el conjunto de características lo más reducido posible siempre beneficia su interpretabilidad y correlación con el fenómeno estudiado.
- Finalmente, este trabajo ha logrado establecer un marco sólido de características y algoritmos de aprendizaje automático que pueden ser aplicados en futuras investigaciones y desarrollos relacionados con la identificación de mecanismos de fallo en laminados de fibras de carbono. Además, se ha demostrado que estas características resultan altamente relevantes y discriminativas para este tipo de aplicaciones.

Bibliografía

- [1] Z. Zhao y N.-Z. Chen, “Spatial-temporal graph convolutional networks (STGCN) based method for localizing acoustic emission sources in composite panels”, *Composite Structures*, pág. 117496, 2023 (vid. págs. 5, 67).
- [2] A. M. Damm, C. Spitzmüller, A. T. Raichle, A. Bühler, P. Weißgraeber y P. Middendorf, “Deep learning for impact detection in composite plates with sparsely integrated sensors”, *Smart Materials and Structures*, vol. 29, n.º 12, pág. 125014, 2020 (vid. págs. 5, 67).
- [3] I. Tabian, H. Fu y Z. Sharif Khodaei, “A convolutional neural network for impact detection and characterization of complex composite structures”, *Sensors*, vol. 19, n.º 22, pág. 4933, 2019 (vid. págs. 5, 67).
- [4] S. F. Karimian y M. Modarres, “Acoustic emission signal clustering in CFRP laminates using a new feature set based on waveform analysis and information entropy analysis”, *Composite Structures*, vol. 268, pág. 113987, 2021 (vid. págs. 6, 67).
- [5] M. G. Sause, A. Gribov, A. R. Unwin y S. Horn, “Pattern recognition approach to identify natural clusters of acoustic emission signals”, *Pattern Recognition Letters*, vol. 33, n.º 1, págs. 17-23, 2012 (vid. págs. 6, 26, 64, 68, 69).
- [6] J. Wang, W. Zhou, X.-y. Ren, M.-m. Su y J. Liu, “A waveform-based clustering and machine learning method for damage mode identification in CFRP laminates”, *Composite Structures*, vol. 312, pág. 116875, 2023 (vid. págs. 6, 68).
- [7] C. Muir, B. Swaminathan, A. Almansour et al., “Damage mechanism identification in composites via machine learning and acoustic emission”, *npj Computational Materials*, vol. 7, n.º 1, pág. 95, 2021 (vid. págs. 6, 68).

-
- [8] M. Šofer, J. Cienciala, M. Fusek, P. Pavlíček y R. Moravec, “Damage analysis of composite CFRP tubes using acoustic emission monitoring and pattern recognition approach”, *Materials*, vol. 14, n.º 4, pág. 786, 2021 (vid. págs. 6, 68).
- [9] F. E. Oz, N. Ersoy y S. V. Lomov, “Do high frequency acoustic emission events always represent fibre failure in CFRP laminates?”, *Composites Part A: Applied Science and Manufacturing*, vol. 103, págs. 230-235, 2017 (vid. págs. 7, 68).
- [10] H. A. Sawan, M. E. Walter y B. Marquette, “Unsupervised learning for classification of acoustic emission events from tensile and bending experiments with open-hole carbon fiber composite samples”, *Composites Science and Technology*, vol. 107, págs. 89-97, 2015 (vid. págs. 7, 68).
- [11] D. Aljets, A. Chong, S. Wilcox, K. Holford, R. Pullin y M. Eaton, “Classification of delamination and matrix cracking in carbon fibre composite plates using Acoustic Emission (AE)”, en *International Design Engineering Technical Conferences and Computers and Information in Engineering Conference*, vol. 48982, 2009, págs. 29-36 (vid. págs. 7, 68).
- [12] X.-S. Yi, S. Du y L. Zhang, *Composite Materials Engineering, Volume 2*. Springer, 2018 (vid. pág. 11).
- [13] E. Giner y J. Albelda, “Análisis y diseño con materiales compuestos”, *Valencia: Universidad Politécnica de Valencia, Servicio de Publicaciones*, 1998 (vid. págs. 11-13).
- [14] A. A. Baker, *Composite materials for aircraft structures*. AIAA, 2004 (vid. pág. 12).
- [15] K. K. Chawla, *Composite materials: science and engineering*. Springer Science & Business Media, 2012 (vid. pág. 12).
- [16] D. Chung, *Carbon fiber composites*. Elsevier, 2012 (vid. pág. 13).
- [17] V. V. Vasiliev y E. V. Morozov, *Mechanics and analysis of composite materials*. Elsevier, 2001 (vid. pág. 13).
- [18] M. Ohtsu, M. Enoki, Y. Mizutani et al., “Principles of the acoustic emission (AE) method and signal processing”, en *Practical acoustic emission Testing*, Springer, 2016, págs. 5-34 (vid. págs. 14-16).
- [19] M. G. Sause, *In situ monitoring of fiber-reinforced composites: theory, basic concepts, methods, and applications*. Springer, 2016, vol. 242 (vid. págs. 16, 17, 23, 29, 31, 69).

-
- [20] A. Mouritz, “Non-destructive evaluation of damage accumulation AP Mouritz, RMIT University, Australia”, *Fatigue in Composites: Science and Technology of the Fatigue Response of Fibre-Reinforced Plastics*, pág. 242, 2003 (vid. pág. 18).
- [21] W. Sikorski, *Acoustic Emission: Research and Applications*. BoD–Books on Demand, 2013 (vid. págs. 18, 22).
- [22] R. Unnþórsson, “Hit detection and determination in AE bursts”, *Acoustic emission-research and applications*, págs. 1-20, 2013 (vid. pág. 18).
- [23] M. G. Sause y M. Hamstadt, “Acoustic emission analysis”, 2018 (vid. págs. 19-21, 69).
- [24] R. Unnþórsson, “Identifying and Monitoring Evolving AE Sources”, en *Acoustic Emission*, IntechOpen, 2012 (vid. pág. 20).
- [25] *Vallen Systeme*. <https://www.vallen.de/> (vid. págs. 24, 25).
- [26] R. Carmona, W.-L. Hwang y B. Torresani, *Practical Time-Frequency Analysis: Gabor and wavelet transforms, with an implementation in S*. Academic Press, 1998 (vid. pág. 26).
- [27] M. G. Sause y S. Horn, “Simulation of acoustic emission in planar carbon fiber reinforced plastic specimens”, *Journal of Nondestructive Evaluation*, vol. 29, págs. 123-142, 2010 (vid. págs. 26, 64, 68, 69).
- [28] M. G. Sause, F. Haider y S. Horn, “Quantification of metallic coating failure on carbon fiber reinforced plastics using acoustic emission”, *Surface and Coatings Technology*, vol. 204, n.º 3, págs. 300-308, 2009 (vid. págs. 26, 64, 68, 69).
- [29] M. G. Sause, D. Schultheiß y S. R. Horn, “Acoustic emission investigation of coating fracture and delamination in hybrid carbon fiber reinforced plastic structures”, 2008 (vid. págs. 26, 64, 68, 69).
- [30] E. Njuhovic, M. Bräu, F. Wolff-Fabris, K. Starzynski y V. Altstädt, “Identification of interface failure mechanisms of metallized glass fibre reinforced composites using acoustic emission analysis”, *Composites Part B: Engineering*, vol. 66, págs. 443-452, 2014 (vid. págs. 26, 64, 68).
- [31] M. Kempf, O. Skrabala y V. Altstädt, “Acoustic emission analysis for characterisation of damage mechanisms in fibre reinforced thermosetting polyurethane and epoxy”, *Composites Part B: Engineering*, vol. 56, págs. 477-483, 2014 (vid. págs. 26, 64, 68).

-
- [32] T. Prieß, M. G. Sause, D. Fischer y P. Middendorf, “Detection of delamination onset in laser-cut carbon fiber transverse crack tension specimens using acoustic emission”, *Journal of Composite Materials*, vol. 49, n.º 21, págs. 2639-2647, 2015 (vid. págs. 26, 64, 68).
- [33] G. Bachman, L. Narici y E. Beckenstein, *Fourier and wavelet analysis*. Springer, 2000, vol. 586 (vid. pág. 26).
- [34] N. Kehtarnavaz, “Frequency domain processing”, *Digital signal processing system design*, vol. 1, págs. 175-196, 2008 (vid. págs. 26, 28).
- [35] S. Okumura, “The short time Fourier transform and local signals”, Tesis doct., Carnegie Mellon University, 2011 (vid. pág. 27).
- [36] K. Sri, “Advanced analysis of biomedical signals”, *Biomedical Signal Analysis for Connected Healthcare; Academic Press: Cambridge, MA, USA*, págs. 157-222, 2021 (vid. pág. 27).
- [37] I. El Naqa y M. J. Murphy, *What is machine learning?* Springer, 2015 (vid. pág. 31).
- [38] F. Chollet y J. J. Allaire, “Deep learning with R. Shelter island”, *Manning Publications Co. Biometrics*, vol. 76, págs. 361-362, 2018 (vid. pág. 32).
- [39] A. Géron, *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow*. O'Reilly Media, Inc.", 2022 (vid. págs. 33-36, 39, 40, 68).
- [40] C. Kingsford y S. L. Salzberg, “What are decision trees?”, *Nature biotechnology*, vol. 26, n.º 9, págs. 1011-1013, 2008 (vid. pág. 33).
- [41] M. Grandini, E. Bagli y G. Visani, “Metrics for multi-class classification: an overview”, *arXiv preprint arXiv:2008.05756*, 2020 (vid. págs. 39, 41).
- [42] M. Teodorczyk, “Influence of Aggregate Gradation on the Longitudinal Wave Velocity Changes in Unloaded Concrete”, en *IOP Conference Series: Materials Science and Engineering*, IOP Publishing, vol. 245, 2017, pág. 032084 (vid. pág. 45).

Parte II

Anexos

Anexo A

Código fuente

A.1 Librerías y directorio

```
# -*- coding: utf-8 -*-
"""
Created on Thu Jun 15 12:32:48 2023

@author: Byron Barriga Machado
"""

# =====
# Clasicacion de impactos sobre placa unidireccional de fibra de carbono
# =====

#%%
# =====
# Importamos las librerias necesarias
# =====

# Librerias principales
from pathlib import Path
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
import valleng as vae

# Librerias para el tratamiento de senales
from scipy.fft import fft, fftfreq
from scipy.signal import hamming

# Tratamiento de datos y normalizacion
from sklearn.utils import shuffle
from sklearn.preprocessing import StandardScaler
```

```

from sklearn.preprocessing import FunctionTransformer
from sklearn.preprocessing import MinMaxScaler
from sklearn.preprocessing import LabelEncoder

# Entrenamiento del modelo
from sklearn.model_selection import train_test_split
from sklearn.ensemble import RandomForestClassifier
from sklearn.feature_selection import RFECV

# Librerías para métricas y evaluación del modelo
from sklearn.model_selection import cross_val_predict
from sklearn.metrics import ConfusionMatrixDisplay, f1_score, accuracy_score,
    make_scorer

# Librerías para optimizar los hiperparámetros
from sklearn.model_selection import RandomizedSearchCV

# =====
# Establecemos el directorio
# =====

HERE = Path(__file__).parent if "__file__" in locals() else Path.cwd()

#%%
# =====
# Definios las variabls globales que se van a utilizar durante la función
# =====

lower_freq = 0 # Limite inferior de frecuencia en kHz
upper_freq = 450 # Limite superior de frecuencia en kHz
sampling_rate = 2.0 # Frecuencia de adquisición de datos por segundo en MHz
N_samp = 512 # Numero de muestras (datos) en cada segmento
res_freq = sampling_rate * 1000 / N_samp # Resolución en frecuencia en kHz
time_samp = 1 / sampling_rate # Tiempo de muestreo en us (microsegundos)
time_seg = time_samp * N_samp # Tiempo de cada segmento en us
N_seg = 3 # Numero de segmentos
desfase = 150 # Desfase va de [0 a 200]

```

A.2 Segmentación y extracción de características

```

#%%
# =====
# Extracción de features
# =====
def feature_extr(name, clase):

    # Necesitamos calcular los índices de este rango
    lower_freq_index = int(lower_freq // res_freq) # Índice de la frecuencia
        inferior
    upper_freq_index = int(upper_freq // res_freq + 1) # Índice de la frecuencia
        superior

```

```

N_freq_seg = upper_freq_index + 1 - lower_freq_index # Numero de bandas de
    frecuencia por segmento
N_feat_seg = 6 # Numero de features por segmento

# Cargamos los directorios de los archivos
folder = 'Datos_TFM'
name_tra = name + ".tradb"
name_pri = name + ".pridb"
TRADB = HERE / folder / name / name_tra # Archivo de transitorio
PRIDB = HERE / folder / name / name_pri # Archivo primario

# Leemos los archivos
pridb = vae.io.PriDatabase(PRIDB)
tradb = vae.io.TraDatabase(TRADB)
df_hits = pridb.read_hits() # Leemos los hits que se han producido

# Filtro de trai y counts
umbral = 50 # Umbral en dB
counts = 12 # Numero minimo de counts
umbral_V = 10 ** (umbral/20 - 6) # Umbral en Voltios

df_hits_filtro = df_hits[(df_hits["amplitude"] >= umbral_V) & (df_hits["trai
    "] != 0) & (df_hits["counts"] >= counts)] # Seleccionamos solo los
    valores cumplen las condiciones
trai = df_hits_filtro["trai"].to_numpy() # Extraemos la columna con los
    valores TRAI (indices de transitorio)
N_trai = trai.size # Numero de transitorios totales

# Creacion de matriz para almacenar features
v_features_total = np.zeros((N_trai , N_seg * N_feat_seg)) # Array que
    almacenara los features en cada iteracion

x = np.arange(0, N_seg) # Vector con factores para la segmentacion
N_iter = 0 # Esto va a contar las iteraciones si por alguna razon los trai
    no siguen la secuencia de 1 en 1 (e.g uso de filtro)

# Valores para la FFT que solo se calculan una vez
window = hamming(N_samp) # Creamos la ventana Hamming
freq_fft = (fftfreq(N_samp, time_samp*1e-6)/1000)[:N_samp//2] # Valores
    positivos de frecuencias de la FFT en kHz
freq_fft_rango = freq_fft[lower_freq_index:upper_freq_index + 1] #
    Secciona los valores de frecuencia

for trans in trai:
    amp, tiempo = tradb.read_wave(trans, time_axis=False) # Leemos el
        transitorio i-esimo

    amp *= 1e3 # in mV # El operador *= esta actualizando el valor de
        amplitud -- amplitud = amplitud * 1e3
        # La senal estaba en voltios y la representa en mV

```

```

# Esta es la amplitud
time = tiempo * 1e6 # for us # Lo mismo la señal se almacena en
segundos y se representa en us
# Este es el tiempo

# Creacion de los segmentos
seg_total = np.zeros((N_seg, N_samp)) # Array que almacenara los
valores de las amplitudes en cada segmento

for i in x:
    seg_total[i] = amp[int(i * N_samp / 2) + desfase : int((i/2 + 1) *
N_samp) + desfase]

# Aplicar ventanas Hamming a cada segmento
seg_t_window = seg_total * window # Aplicamos la ventana a la matriz de
segmentos

# Calcular FFT la matriz de segmento
amp_fft = fft(seg_t_window) # Calcula la transformada de Fourier de la
matriz de segmentos
amp_fft = np.abs(amp_fft) # Calcula el modulo de la amplitud para no
representar con su fase (Parte real e imaginaria)

# Escoger el rango de frecuencias de interes
amp_fft_rango = amp_fft[:,lower_freq_index:upper_freq_index + 1] #
Secciona los valores de amplitud en el rango de frecuencias
establecido

# Calculo de features en frecuencia para cada segmento
peak_freq = np.zeros(N_seg) # Almacena los peak freq de cada segmento
centroid_freq = np.zeros(N_seg) # Almacena el centroide de frecuencia de
cada segmento
part_power_1 = np.zeros(N_seg) # Almacena la potencia parcial 1 total de
cada segmento
part_power_2 = np.zeros(N_seg) # Almacena la potencia parcial 2 total de
cada segmento
part_power_3 = np.zeros(N_seg) # Almacena la potencia parcial 3 total de
cada segmento

for i in x:
    # Peak frequency
    peak_index = np.argmax(amp_fft_rango[i])
    peak_freq[i] = freq_fft_rango[peak_index]

    # Centroid frequency
    centroid_freq[i] = np.sum(amp_fft_rango[i] * freq_fft_rango) / np.
sum(amp_fft_rango[i])

    # Partial Power 1 y 2
    part_power_1[i] = np.sum((amp_fft_rango[i, 0:int(len(freq_fft_rango)
/3)]) ** 2) * 100 / np.sum((amp_fft_rango[i]) ** 2)

```

```

part_power_2[i] = np.sum((amp_fft_rango[i, int(len(freq_fft_rango)
/3):int(len(freq_fft_rango)*2/3)]) ** 2) *100 / np.sum((
amp_fft_rango[i]) ** 2)
part_power_3[i] = np.sum((amp_fft_rango[i, int(len(freq_fft_rango)
*2/3):]) ** 2) *100 / np.sum((amp_fft_rango[i]) ** 2)

w_peak_freq = (peak_freq * centroid_freq) ** 0.5

# Vector de features
v_features = np.hstack((peak_freq, w_peak_freq, centroid_freq,
part_power_1, part_power_2, part_power_3)) # Agrupamos los features
v_features = v_features.reshape(1, N_feat_seg * N_seg) # Reshape de la
matriz de features a un vector de una sola fila
v_features_total[N_iter] = v_features # Encadenamos los valores a cada
fila de la matriz para crear la matriz de features

N_iter += 1 # Actualizamos el contador

# Nombre de los features
name_feature = ['peak_freq_1', 'peak_freq_2', 'peak_freq_3',
'w_peak_freq_1', 'w_peak_freq_2', 'w_peak_freq_3',
'centroid_freq_1', 'centroid_freq_2', 'centroid_freq_3',
'p_power_1_1', 'p_power_1_2', 'p_power_1_3',
'p_power_2_1', 'p_power_2_2', 'p_power_2_3',
'p_power_3_1', 'p_power_3_2', 'p_power_3_3'] # Array que
almacenara los nombres de los features por segmento

# Dataframe de features
df_features = pd.DataFrame(v_features_total,
columns = name_feature)

# Dataframe de traits
df_trait = pd.DataFrame(trai, columns = ['trait'])

# Dataframe de time features
df_time = df_hits_filtro[['rise_time']].reset_index().drop(['set_id'], axis
=1)

# Dataframe de clases
df_clase = pd.DataFrame({'Clase' : [clase] * N_trait})

# DataFrame total
# df_total = pd.concat([df_features, df_clase], axis=1)
df_total = pd.concat([df_features, df_time, df_clase, df_trait], axis=1)
# La funcion regresa el DataFrame total
return (df_total)

```

A.3 División en subconjuntos y normalización

```

%%
# =====
# Preprocesamiento de datos para clasificacion
# =====
def train_test_set(data, normalization='none'):
    train_set = data
    # Separamos los features de las clases
    X = train_set.drop(["Clase", 'traí'], axis=1) # Elimina la columna de clases
        y traís

    # Feature names
    feature_names = X.columns.tolist()

    if normalization == 'log':
        log_transformer = FunctionTransformer(np.log, feature_names_out="one-to-
            one")
        columns_to_transform = ['p_power_3_1', 'p_power_3_2', 'p_power_3_3', '
            rise_time']
        X[columns_to_transform] = log_transformer.transform(X[
            columns_to_transform]) # Aplicamos el logaritmo a los features

    if normalization == 'standard':
        standardize = StandardScaler()
        X = standardize.fit_transform(X) # Aplicamos la estandarizacion a los
            features

    if normalization == 'min_max':
        min_max = MinMaxScaler()
        X = min_max.fit_transform(X) # Aplicamos la estandarizacion a los
            features

    y = train_set["Clase"].copy() # Creamos una copia solo de la columna clase

    # Convert string class labels to numeric labels
    label_encoder = LabelEncoder()
    y = label_encoder.fit_transform(y)
    classes = label_encoder.classes_

    # Split the dataset into training and testing sets
    X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2,
        stratify=train_set["Clase"], random_state=0, shuffle=True)

    return X_train, X_test, y_train, y_test, classes, feature_names

```

A.4 Modelo de bosques aleatorios

```

%%
# =====
# Random Forest Classifier - Funcion
# =====
def forest_clf(data, feature_indices, normalization='none', hiperparametros=
False):
    X_train, X_test, y_train, y_test, classes, feat_names = train_test_set(data,
normalization)

    if isinstance(X_train, pd.DataFrame):
        X_train = X_train.iloc[:, feature_indices]
        X_test = X_test.iloc[:, feature_indices]

    else:
        X_train = X_train[:, feature_indices]
        X_test = X_test[:, feature_indices]

    feature_names = [feat_names[index] for index in feature_indices]

    # Devuelve los nombres originales de las clases
    y_train_1 = [classes[element] for element in y_train]
    y_test_1 = [classes[element] for element in y_test]

    # Seccion de ajuste de hiperparametros
    # -----
    # Define the hyperparameters to tune
    if hiperparametros:
        param_grid = {'max_features': ['sqrt', 'log2'], # Maximum number of
features to consider at each split
'n_estimators': np.arange(100, 1000, 100), # Number of
trees in the forest
'max_depth': [None] + list(np.arange(5, 30, 5)), # Maximum
depth of each tree
'min_samples_split': np.arange(2, 11), # Minimum number of
samples required to split an internal node
'min_samples_leaf': np.arange(1, 5), # Minimum number of
samples required to be at a leaf node
}

    # Define the scoring metric
    scorer = make_scorer(f1_score, average="macro")

    classifier = RandomForestClassifier(random_state=42) # Nombre del
modelo

    # Perform randomized search
    random_search_forest = RandomizedSearchCV(classifier,
param_distributions=param_grid, scoring=scorer, cv=5, n_iter=10,
random_state=42) # Optimizador

```

```

random_search_forest.fit(X_train, y_train) # Entrenamiento del
    optimizador
best_params_forest = random_search_forest.best_params_ # Obtiene los
    parametros optimizados
best_score_forest = random_search_forest.best_score_ # Obtiene la
    exactitud del entrenamiento del optimizador

print(f"Best parameters - forest = {best_params_forest}")
print(f"Optimized F1 - forest = {best_score_forest:.1%}")

# Entrenando el modelo con el mejor estimador
final_forest_clf = random_search_forest.best_estimator_ # Almacena
    el mejor estimador (mejor modelo)
final_forest_clf.fit(X_train, y_train) # Entrena la
    maquina con el mejor estimador

# cross-validation que nos devuelve la precision del modelo (scores) y
    los valores predichos (predict)
# Evaluamos el f1_score
y_train_pred_forest = cross_val_predict(final_forest_clf, X_train,
    y_train, cv=5) # Valores predichos en el training set con
    validacion cruzada
cross_accuracy = accuracy_score(y_train, y_train_pred_forest)
f1_score_forest = f1_score(y_train, y_train_pred_forest, average="macro"
    ) # Calcula el F1 score
print(f"Cross-val accuracy = {cross_accuracy:.1%}")
print(f"F1 score - training = {f1_score_forest:.1%}")

final_pred_forest = final_forest_clf.predict(X_test) # Predicciones
    realizadas con el modelo optimizado sobre el test set
baseline_accuracy_forest = accuracy_score(y_test, final_pred_forest)
final_f1_score_forest = f1_score(y_test, final_pred_forest, average="
    macro") # Calcula el F1 score
print(f"Baseline Accuracy - forest = {baseline_accuracy_forest:.1%}") #
    Imprime el accuracy del modelo en formato % con 1 decimal
print(f"Final F1 score - test = {final_f1_score_forest:.1%}")

modelo = final_forest_clf
# -----

# Seccion sin ajuste de hiperparametros
# -----
else:
    # Entrenar el modelo
    forest_clf = RandomForestClassifier(random_state=42) # Nombre del
        modelo
    forest_clf.fit(X_train, y_train) # Entrenamiento del modelo
    baseline_accuracy_forest = forest_clf.score(X_test, y_test) # Accuracy
        del modelo en el test_set
    print(f"Baseline Accuracy - forest = {baseline_accuracy_forest:.1%}") #
        Imprime el accuracy del modelo en formato % con 1 decimal

```

```

# cross-validation que nos devuelve la precision del modelo (scores) y
# los valores predichos (predict)
# Evaluamos el f1_score
y_train_pred_forest = cross_val_predict(forest_clf, X_train, y_train, cv
=5) # Valores predichos en el training set con validacion cruzada
cross_accuracy = accuracy_score(y_train, y_train_pred_forest)
f1_score_forest = f1_score(y_train, y_train_pred_forest, average="macro"
) # Calcula el F1 score
print(f"Cross-val accuracy = {cross_accuracy:.1%}")
print(f"F1 score - training = {f1_score_forest:.1%}")

final_pred_forest = forest_clf.predict(X_test)
final_f1_score_forest = f1_score(y_test, final_pred_forest, average="
macro") # Calcula el F1 score
print(f"Final F1 score - test = {final_f1_score_forest:.1%}")

modelo = forest_clf
# -----

y_train_pred = [classes[element] for element in y_train_pred_forest]
y_test_pred = [classes[element] for element in final_pred_forest]

feature_importances = modelo.feature_importances_
best_features = pd.DataFrame(sorted(zip(feature_importances,
feature_names),
reverse=True),
columns = ["Importances", "Features"]
)
# best_features.to_csv("best_features_final.csv", index=False)

return y_train_1, y_test_1, y_train_pred, y_test_pred, best_features, modelo

```

A.5 Selección de características

```

#%%
# =====
# Backward Elimination
# =====
def backward_elimination(data, classifier, normalization='none'):

    X_train, X_test, y_train, y_test, classes, feature_names = train_test_set(
        data, normalization)

    # Perform backward elimination with cross-validation
    selector = RFECV(estimator=classifier, step=1, cv=5, scoring='f1_macro')
    selector.fit(X_train, y_train)

    # Get the selected feature indices
    best_subset = np.where(selector.support_)[0]

```

```

# Get the best score
best_f1_score = selector.cv_results_['mean_test_score'][selector.n_features_
    - 1]

return best_subset, best_f1_score

```

A.6 Importación de datos y entrenamiento del modelo

```

#%%
# =====
# Lectura de archivos y extraccion de features
# =====
esfera = feature_extr('Canica', '[Esfera]')

arena = feature_extr('Arena', '[Arena]')
arena = shuffle(arena, random_state=0)
arena = arena[0:300]

hielo = feature_extr('Hielo2', '[Hielo]')

datos = pd.concat([esfera, arena, hielo], ignore_index = True)

# =====
# Entrenamiento del modelo
# =====
#%%
best_subset = [ 0, 1, 3, 4, 5, 6, 8, 9, 12, 15, 16, 17, 18] # Backward
    elimination
# best_subset = np.arange(0,19) # Configuracion base

y_train, y_test, y_train_pred, y_test_pred, best_features, modelo = forest_clf(
    datos, best_subset, normalization='log', hiperparametros=True)

#%%
# =====
# Backward elimination
# =====
classifier = RandomForestClassifier()
# Perform backward elimination
best_subset, best_f1_score = backward_elimantion(datos, classifier,
    normalization='log')

# Print the best feature subset and its performance
print("Best Feature Subset:", best_subset)
print("Best F1 Score:", best_f1_score)

```

Anexo B

ODS Agenda 2030

B.1 Objetivos de desarrollo sostenible de la agenda 2030

Se incluye a continuación, una tabla que recoge la relación del trabajo con los Objetivos de Desarrollo Sostenible (ODS).

Tabla B.1: Relación de la investigación con los ODS.

Objetivos de desarrollo sostenibles	Alto	Medio	Bajo	No procede
ODS 1. Fin de la pobreza.				X
ODS 2. Hambre cero.				X
ODS 3. Salud y bienestar.				X
ODS 4. Educación de calidad.				X
ODS 5. Igualdad de género.				X
ODS 6. Agua limpia y saneamiento.				X
ODS 7. Energía asequible y no contaminante.				X
ODS 8. Trabajo decente y crecimiento económico.				X
ODS 9. Industria, innovación e infraestructuras.	X			
ODS 10. Reducción de las desigualdades.				X
ODS 11. Ciudades y comunidades sostenibles.				X
ODS 12. Producción y consumo responsables.			X	
ODS 13. Acción por el clima.				X
ODS 14. Vida submarina.				X
ODS 15. Vida de ecosistemas terrestres.				X
ODS 16. Paz, justicia e instituciones sólidas.				X
ODS 17. Alianzas para lograr objetivos.				X

Se determina que el presente trabajo tiene alta relación con el objetivo 9 de industria, innovación e infraestructuras. La investigación abarca temas como emisiones acústicas, su caracterización mediante técnicas de inteligencia artificial y su aplicación en materiales compuestos. Tal como se mencionó en el apartado de introducción, el uso de materiales compuestos está en auge en industrias potentes como son la automovilística y aeronáutica. Además, el uso de inteligencia artificial para el tratamiento de datos y su capacidad de encontrar patrones complejos en ellos, es sin duda una innovación.

Por otro lado, se determina que tiene una relación baja con el objetivo 12 de producción y consumos responsables. El proyecto, no tiene una relación directa, pero puede sentar las bases de una producción responsable de materiales compuestos. Técnicas de caracterización como las utilizadas en este estudio podrían emplearse en la monitorización de la salud estructural de componentes fabricados con este tipo de material. Esto conllevaría a un aumento en su vida útil y reducción de la frecuencia de producción.

Finalmente, el trabajo no se presenta relación alguna con los demás de objetivos de desarrollo sostenible de la agenda 2030.

Parte III

Pliego de condiciones

Pliego de condiciones

El desarrollo de todo proyecto esta obligado a cumplir con la regulación vigente. En este apartado, se habla sobre el marco legal y las especificaciones técnicas que tienen relación con este trabajo.

El objetivo del pliego de condiciones es comprobar que se cumplen las especificaciones técnicas y legales a la hora de ejecutar el trabajo fin de máster, como si de un contrato entre propiedad y contratista se tratase.

C.1 Obligaciones y derechos de los trabajadores

La Ley del estatuto de los trabajadores recogida en el Real Decreto 2/2025 del 23 de octubre recoge las obligaciones y derechos de los trabajadores. Se incluyen los requisitos que deben cumplir tanto los empleados como sus responsables.

C.2 Condiciones del puesto de trabajo

Por una parte, se deben cumplir las disposiciones que establece el BOE-A-1971-380 sobre seguridad e higiene en el trabajo, a fin de prevenir accidentes y enfermedades profesionales además de lograr las mejores condiciones de higiene y bienestar en los centros y puestos de trabajo.

En este decreto se incluyen diversos aspectos, como:

- Seguridad estructural de los edificios en los que se lleva a cabo el trabajo.
- Condiciones mínimas del área de trabajo en cuanto a dimensiones.
- Iluminación adecuada del entorno de trabajo, a ser posible natural.
- Condiciones mínimas y máximas de ventilación, temperatura y humedad.
- Eliminación de ruidos, vibraciones y trepidaciones.
- Abastecimiento de agua potable.

- Requisitos relativos a las instalaciones eléctricas.
- Condiciones relativas al almacenamiento, manipulación y transporte de materias inflamables.
- Medidas de protección contra incendios.
- Medidas de emergencia e información sobre vías y salidas de evacuación.

En cuanto al desarrollo de actividades, la gran mayoría del tiempo se invierte en trabajo con equipos informáticos y redacción. Por ello, se debe cumplir con el Real Decreto 488/1997 de 14 de abril que establece las disposiciones mínimas de seguridad y de salud para la utilización por los trabajadores de equipos que incluyan pantallas de visualización. También se incluye una parte de ensayos experimentales, regulada por la Ley 31/1995, de 8 de noviembre, de prevención de riesgos laborales y el Real Decreto 1215/1997, de 18 de julio, por el que se establecen las disposiciones mínimas de seguridad y salud para la utilización por los trabajadores de los equipos de trabajo.

En cuanto a las condiciones del puesto de trabajo que establece el Real Decreto 488/1997, se proporciona información relativa a los siguientes aspectos:

- Ergonomía del puesto de trabajo.
- Equipo de trabajo (Pantalla, teclado, superficie de trabajo y asiento).
- Entorno (Espacio, iluminación, reflejos y deslumbramientos, ruido, calor, emisiones y humedad).
- Interconexión ordenador/persona.
- Existen aspectos en los que se solapan ambas normativas, en esos casos se debe cumplir con lo establecido en ambas.

C.3 Condiciones del teletrabajo

La aparición de la COVID-19 y la pandemia que causó en 2020 potenció el trabajo a distancia. Esta situación se regula por el Real Decreto-Ley 28/2020 de 22 de septiembre, de trabajo a distancia.

Los aspectos más importantes que incluye son: la igualdad de derechos y condiciones entre empleados a distancia y en el lugar de trabajo; el derecho a la desconexión digital para garantizar el equilibrio entre vida laboral y personal; la obligación del empleador de cubrir los gastos relacionados con el trabajo remoto; la necesidad de un acuerdo escrito para establecer el trabajo a distancia y también se promueve la formación adecuada para empleados y empleadores sobre el uso de tecnologías de la información.

C.4 Condiciones y especificaciones técnicas

Conocimientos requeridos

El presente trabajo, en cuanto al ámbito académico, requiere de los conocimientos técnicos adquiridos durante el grado y máster en materias como: análisis, diseño y fabricación con materiales compuestos; informática; ciencia de materiales; resistencia de materiales y mecánica entre otras. Además se ha requerido formación adicional en el campo de emisiones acústicas, procesamiento de señales, inteligencia artificial y programación.

Equipo informático

En cuanto a condiciones técnicas de hardware y software, al ser un trabajo académico no se ha requerido más de lo que se detalla a continuación. Sin embargo, en el caso de continuar con el ámbito de la inteligencia artificial profunda, se requerirían condiciones técnicas de hardware y software más potentes capaces de albergar un gran número de datos y de entrenar modelos complejos.

El equipo informático empleado para la elaboración del proyecto ha sido un ordenador de escritorio proporcionado en el puesto de trabajo, cuyas especificaciones son:

Tabla C.1: Especificaciones del equipo informático.

Características	Descripción
Modelo	ASUS All series
Procesador	Intel® Core i7-4790 @ 3,60 GHz
Almacenamiento	Seagate ST2000DM001 - 2 TB
Memoria	32 GB (1 600 MHz)
Tarjeta gráfica	GeForce® GTX 750 Ti
Sistema operativo	Windows 10 Enterprise©

En cuanto al software, para llevar a cabo el trabajo se han utilizado los programas necesarios para realizar cada una de las tareas involucradas en el desarrollo del proyecto. Entre ellos se encuentran:

- LinWave acquisition: software de la empresa Vallen Systeme GmbH para la interacción con el equipo de emisiones acústicas y toma de datos.
- Vallen VisualAE: software de la empresa Vallen Systeme GmbH para la visualización de los datos de emisiones acústicas recogidos.
- Spyder: se trata de un entorno de desarrollo integrado diseñado específicamente para la programación en Python. En él se ha realizado tanto el tratamiento de datos, como el entrenamiento del modelo de clasificación y la generación de gráficas e imágenes.
- Inkscape: software de edición de gráficos vectoriales de código abierto y gratuito. Utilizado para crear y editar imágenes vectoriales que son escalables sin pérdida de calidad.

- Overleaf: es una plataforma en línea para la edición y colaboración en documentos LaTeX. En él se ha desarrollado la redacción del trabajo.
- Otros: Se han utilizado diversos navegadores para la búsqueda de información y lectores como Adobe Acrobat Reader para el análisis de textos.

Para el empleo de aquellos *softwares* que no son de código abierto se ha hecho uso de las licencias institucionales con las que cuenta la UPV.

Conexión a internet

El desarrollo del trabajo, ha implicado la búsqueda de información acerca de técnicas de inteligencia artificial y tratamiento de señales, procesos que se realizan mayoritariamente en línea. Para ello, se ha utilizado la red disponible en la UPV y la conexión a escritorio remoto por VPN para la modalidad de teletrabajo.

C.5 Control de calidad

Los materiales empleados para la realización de los ensayos deben cumplir las especificaciones dadas por el fabricante y satisfacer los mínimos de calidad requeridos por las normas UNE (Una Norma Española) para cada uno de los componentes.

C.6 Supervisión

El trabajo se realiza bajo la supervisión de dos profesores tutores de la UPV. Expertos en la ejecución de proyectos y trabajos de investigación de diversa temática similares al realizado. Su supervisión sirve de gran ayuda a la hora de realizar el seguimiento del trabajo, de resolver dudas y de proponer mejoras.

Parte IV

Presupuesto

Anexo D

Presupuesto

En esta sección, se realiza una estimación de los costes involucrados en el desarrollo del proyecto. En el presupuesto se incluye tanto los costes del personal como el uso de hardware y software necesarios. A esto se añade el 21 % de IVA (Impuesto sobre el Valor Añadido) vigente en España.

D.1 Desglose de costes

Coste de personal

Los costes de personal incluyen los gastos del estudiante que está completando sus estudios llevando a cabo el presente proyecto y de los profesores que lo tutorizan. Se considera que los tutores dedican parte de sus horas de trabajo al proyecto y por tanto, este forma parte de su sueldo.

Para asignar las retribuciones de cada uno de los miembros involucrados se considera lo siguiente: al alumno se asigna el sueldo correspondiente a un técnico superior de investigación; a uno de los tutores, el salario de un profesor ayudante doctor y al otro la de un catedrático. En cuanto a las horas, se estiman en función de las horas de dedicación que requieren los 15 créditos ECTS que se otorgan al proyecto.

Tabla D.1: Desglose de costes de personal.

Concepto	Tiempo [h]	Coste unitario [€/h]	Importe [€]
Autor	375	10,17	3 813,75
Tutor Profesor	25	14,63	365,75
Tutor Catedrático	15	24,16	362,40
		Total	4 541,90

Coste de equipo de emisiones acústicas

Para la adquisición de las emisiones acústicas se ha hecho uso de hardware y software específicos adquiridos para tal fin. Se estima su vida útil de 5 años, por lo que se calcula la amortización equivalente.

Tabla D.2: Desglose de costes de equipo de emisiones acústicas.

Concepto	Periodo de amortización [meses]	Coste total [€]	Importe [€]
Linwave 1002	6	9 513,00	951,30
PoE	6	328,00	32,80
Cable Ethernet	6	112,00	11,20
2 Sensores VS150M	6	572,00	57,20
2 Cables de sensor	6	112,00	11,20
Software de adquisición	6	3 109,00	31,09
Formación	-	225,00	225,00
Total			1 622,10

Coste de equipo informático y licencias

En cuanto a hardware, se especifica el coste de los equipos utilizados teniendo en cuenta al igual que en caso anterior una vida útil de 5 años. De la parte de software, se detallan los programas utilizados que no son de código abierto. Existen diversos tipos de licencia, en función del desarrollador, por lo que se utiliza el coste equivalente mensual de cada una de ellas.

Tabla D.3: Desglose de costes de hardware.

Equipo	Periodo de amortización [meses]	Coste total [€]	Importe [€]
ASUS All series	6	778,85	77,89
Pantalla BenQ GW2475H	6	140,00	14,00
Pantalla LG IPS Full HD	6	126,00	12,60
Teclado	6	20,00	2,20
Ratón	6	10,00	1,00
Total			107,69

Tabla D.4: Desglose de costes de software.

Programa	Tiempo [meses]	Coste unitario [€/mes]	Importe [€]
Windows 10 ©	6	12,08	72,50
Adobe Acrobat Pro ©	6	24,19	145,14
Total			217,64

D.2 Coste total

Realizando la suma de todos los costes parciales, se establece el presupuesto global del proyecto.

Tabla D.5: Presupuesto global.

Concepto	Importe [€]
Personal	4 541,90
Equipo emisiones acústicas	1 622,10
Equipo informático	107,69
Software	217,64
Subtotal	6 489,33
IVA (21 %)	1 362,76
Total	7 852,09

Por tanto, el coste global del proyecto asciende a un total de:

**SIETE MIL OCHOCIENTOS CINCUENTA Y DOS EUROS CON NUEVE
CÉNTIMOS**

