



UNIVERSIDAD DE GUANAJUATO

CAMPUS IRAPUATO - SALAMANCA
DIVISIÓN DE INGENIERÍAS

“Análisis de señales de vibración mediante un arreglo reflectivo de fibra óptica empleando técnicas de aprendizaje automático”

TESIS

QUE PARA OBTENER EL GRADO DE:

MAESTRÍA EN INGENIERÍA ELÉCTRICA

PRESENTA:

Ing. Kristy Carolina Escalante Sánchez

DIRECTORES:

Dr. Juan Manuel Sierra Hernández

M.I. Daniel Fernando Zambrano Gutiérrez

Salamanca, Gto., a 03 de junio del 2024

M. en I. HERIBERTO GUTIÉRREZ MARTIN
COORDINADOR DE ASUNTOS ESCOLARES
PRESENTE.-

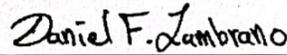
Por medio de la presente, se otorga autorización para proceder a los trámites de impresión, empastado de tesis y titulación al alumno(a) **Kristy Carolina Escalante Sánchez** del **Programa de Maestría en Ingeniería Eléctrica (Instrumentación y Sistemas Digitales)** y cuyo número de **NUA** es:148144 del cual soy director. El título de la tesis es: **Análisis de señales de vibración mediante un arreglo reflectivo de fibra óptica empleando técnicas de aprendizaje automático.**

Hago constar que he revisado dicho trabajo y he tenido comunicación con los sinodales asignados para la revisión de la tesis, por lo que no hay impedimento alguno para fijar la fecha de examen de titulación.

ATENTAMENTE



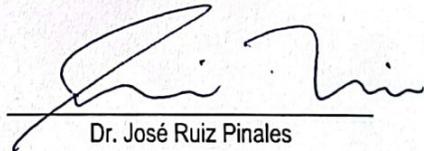
Dr. Juan Manuel Sifra Hernández
DIRECTOR DE TESIS
SECRETARIO



M.I. Daniel Fernando Zambrano Gutiérrez
DIRECTOR DE TESIS



Dr. Julián Moisés Estudillo Ayala
PRESIDENTE



Dr. José Ruiz Pinales
VOCAL

Dedicatoria

A mis amados padres:

José Elías Escalante Belandria

Nelly Del Carmen Sánchez de Escalante

Agradecimientos

A mis padres por todo su esfuerzo y sacrificio, junto con ellos a mis hermanos por brindarme un apoyo incondicional en el camino hacia mis metas.

Al Dr. Daniel Jáuregui y el M.I Daniel Zambrano por su confianza, paciencia, apoyo y amistad durante el desarrollo de este trabajo.

Al Dr. Juan Manuel Sierra por el apoyo y respaldo brindado en momentos difíciles.

Al cuerpo académico de Telecomunicaciones y Fotónica, especialmente al Dr. Julián Estudillo y el Dr. Roberto Rojas, por la confianza y ayuda brindada en todo momento.

Al Dr. José Ruiz Pinales, revisor de mi tesis por sus comentarios y sugerencias fundamentales para mejorar la calidad de mi trabajo.

A las amistades que construí durante la maestría, espero siempre formen parte de mi vida.

Agradecimientos Institucionales

A la Universidad de Guanajuato, especialmente a la División de Ingenierías del Campus Irapuato-Salamanca (DICIS) por proporcionar los recursos y medios necesarios para continuar con mi formación académica y desarrollar este trabajo de tesis.



Al Consejo Nacional de Humanidades, Ciencias y Tecnologías CONACHCYT de México, por el apoyo financiero recibido bajo el número de becario CVU 1193144.



Resumen

Este proyecto presenta una metodología que combina un arreglo reflectivo de fibra óptica con técnicas de aprendizaje automático para analizar y clasificar señales de vibración en sistemas de vigas cantiléver. Este enfoque consta de dos etapas principales, el sistema de adquisición de datos y la metodología para la clasificación de fallas. Como primer punto, se implementa y valida el arreglo modulado por la reflexión de luz producto del desplazamiento entre la fibra y la superficie de la viga. A partir de las señales de vibración capturadas con el arreglo se construye una base de datos con múltiples escenarios, que dan lugar a los subconjuntos de datos BD1, BD2 y BD3. En la segunda etapa del proyecto se propone y evalúa la metodología de clasificación compuesta por una técnica de reducción de dimensionalidad (Análisis de componentes principales (PCA), Análisis discriminante lineal (LDA)), y un algoritmo de aprendizaje supervisado (k-Vecinos cercanos (KNN), Máquina de soporte vectorial (SVM), Árboles de decisión (DT)). Los resultados obtenidos de la evaluación preliminar para determinar la presencia y nivel de daños en una viga, alcanza una exactitud superior al 96 % para tres de las cuatro técnicas utilizadas. La prueba DB1 centrada en la presencia de daños y no en las condiciones del sistema, obtiene un 80.24 % con la combinación PCA+KNN. Por su parte, los mejores resultados para las pruebas BD2 y BD3 que contemplan clases específicas, surgen producto de LDA+SVM. La prueba BD2 que clasifica los 63 posibles casos de fallos, consigue un 80.25 % de exactitud; mientras que BD3 logra 78.41 % luego de agregar el estado sano y crear un desbalance para las 64 clases. La integración del arreglo óptico con la combinación correcta de técnicas de aprendizaje automático, puede ofrecer un rendimiento eficiente en el análisis y clasificación de señales de vibración en diversos contextos, esto demuestra un gran potencial para aplicaciones de monitoreo estructural y mecánico.

Abstract

This work presents a methodology that combines a reflective fiber optic array with machine learning techniques to analyze and classify vibration signals in cantilever beam systems. This approach consists of two main stages: the data acquisition system and the fault classification methodology. Initially, the reflective array modulated by light reflection due to the displacement between the fiber and the beam surface is implemented and validated. A database is constructed with multiple scenarios from vibration signals captured with the array, resulting in data subsets BD1, BD2, and BD3. In the project's second stage, a classification methodology is proposed and evaluated, combining a dimensionality reduction technique (Principal Component Analysis (PCA), Linear Discriminate Analysis (LDA)) with a supervised learning algorithm (k-Nearest Neighbors (KNN), Support Vector Machine (SVM), Decision Trees (DT)). The results from the preliminary evaluation to determine the presence and level of damage in a beam achieve an accuracy higher than 96 % for three of the four techniques used. The DB1 test, which focuses on the presence of damage rather than system conditions, achieves an accuracy of 80.24 % using PCA+KNN. Meanwhile, the best results for the BD2 and BD3 tests, which consider specific classes, emerge from the combination of LDA+SVM. The BD2 test, classifying the 63 possible failure cases, achieves an accuracy of 80.25 %, whereas BD3 attains 78.41 % accuracy after adding the healthy state and creating an imbalance for the 64 classes. Integrating the optical array with the correct combination of machine learning techniques can efficiently analyze and classify vibration signals in various contexts, demonstrating significant potential for structural and mechanical monitoring applications.

Índice General

Resumen	iv
Abstract	v
Índice de Figuras	ix
Índice de Tablas	xiii
1 Introducción	1
1.1 Introducción	1
1.2 Planteamiento general del problema	3
1.3 Objetivos	4
1.3.1 Objetivo general	4
1.3.2 Objetivos específicos	4
1.4 Justificación	5
1.5 Antecedentes	6
1.6 Estructura del trabajo	8
2 Marco teórico	10
2.1 Fundamentos ópticos	10
2.1.1 Láser	12
2.1.2 Haz gaussiano	13
2.1.3 Índice de refracción	14
2.1.4 Reflexión y refracción de la luz	15

2.1.5	Reflexión especular	17
2.1.6	Fibras Ópticas	18
2.1.7	Arreglos de fibra óptica modulados por reflexión	21
2.2	Sistema y parámetro analizar	22
2.2.1	Viga cantiléver	22
2.2.2	Modelado matemático del cantiléver	23
2.3	Aprendizaje automático	27
2.3.1	k-Vecinos más cercanos	29
2.3.2	Máquina de vectores de soporte	31
2.3.3	Árboles de decisión	33
2.3.4	Técnicas de reducción de dimensionalidad	34
2.3.5	Métricas de evaluación para los modelos de clasificación	37
3	Metodología del arreglo óptico	40
3.1	Configuración experimental	40
3.2	Descripción de elementos empleados	41
3.2.1	Acoplador 1x2 Multimodo	42
3.2.2	Fuente de Luz	43
3.2.3	Fotodetector	44
3.3	Análisis del sistema reflectivo	46
3.4	Validación del arreglo	48
4	Procesamiento y análisis de datos	53
4.1	Base de datos	54
4.1.1	Subconjuntos de la base de datos	58
4.2	Extracción de características	60
4.2.1	Comportamiento de las características	64
4.3	Adimensionalización	66
4.4	Reducción de dimensionalidad	66

4.4.1	Análisis de componentes principales (PCA)	67
4.4.2	Análisis discriminaste lineal (LDA)	69
4.5	Clasificación e identificación de fallas	70
4.5.1	División de los Datos	71
4.5.2	Algoritmos de aprendizaje	72
5	Resultados	74
5.1	Prueba BD1	78
5.2	Prueba BD2	84
5.3	Prueba BD3	88
6	Conclusiones	93
	Referencias	96

Índice de Figuras

2.1	Espectro electromagnético.	11
2.2	Onda electromagnética.	12
2.3	Una onda gaussiana en forma de haz que se propaga en la dirección z	14
2.4	Refracción y reflexión en una superficie dieléctrica para los materiales n_1 y n_2	16
2.5	Reflexión especular en un espejo plano. n_1 y n_2	17
2.6	Esquema de una estructura convencional de fibra con núcleo sólido circular de índice de refracción n_1 , rodeado por un revestimiento con un índice de refracción n_2 y un recubrimiento encapsulado de plástico.	18
2.7	Diversos tipos de fibras ópticas de índice escalonado y gradual, tanto monomodo como multimodo.	19
2.8	Cono de aceptación para una fibra óptica.	20
2.9	Disposiciones utilizadas para los sensores de fibra óptica modulados por reflexión. (a) Arreglo con fibras ópticas independientes para la alimentación y detección. (b) Arreglo con una sola fibra óptica y una derivación en Y para separar la alimentación y detección.	21
2.10	Viga tipo cantiléver en flexión.	23
2.11	Características principales de una viga tipo cantiléver.	24
2.12	Evolución de la inteligencia artificial.	28
2.13	Clasificación de KNN para diferentes valores de k ; la muestra de ensayo se clasifica como “estrella” cuando $k=5$ o $k=13$ y se clasifica como “cuadrado” cuando $k=13$	30

2.14 (a) Transformación del espacio de entrada a uno de mayor dimensión. (b) Separación de dos clases de datos en el espacio de características mediante una máquina de vectores de soporte de margen suave.	32
2.15 Estructura general de un árbol de decisión.	34
2.16 Ilustración de las proyecciones de los datos con los algoritmos de reducción de dimensionalidad utilizados. (a) PCA: representación de los ejes de componentes que maximizan la varianza. (b) LDA: maximización de los ejes de componentes para la separación de clases.	35
2.17 Proceso de interacción entre los datos y los algoritmos ML.	38
2.18 Matriz de confusión binaria.	38
3.1 Esquema de adquisición, configuración experimental.	41
3.2 Representación del uso del Acoplador en la configuración experimental.	42
3.3 Espectro típico de la fuente de luz centrado en 655mm.	44
3.4 Curva de responsividad del fotodetector DET025AFC de Thorlabs.	45
3.5 Transmisión y recepción del haz gaussiano.	46
3.6 Montaje experimental del arreglo óptico. (a) Vista superior del montaje. (b) Vista lateral del montaje. (c) Sistema en funcionamiento, emisión-recepción de luz sobre la viga cantiléver. (d) Señal de vibración obtenida por el arreglo.	49
3.7 Señal de vibración obtenida mediante el arreglo experimental.	50
3.8 Transformada rápida de Fourier para diferentes longitudes de la viga cantiléver.	51
3.9 Variaciones de frecuencia teórica y experimental según la longitud de la viga.	52
4.1 Metodología propuesta para la clasificación de daños.	53
4.2 Estructura de la base de datos.	55
4.3 Localización de daños por vigas (viga 1, viga 2 y viga 3).	56
4.4 Niveles de daños ocasionados a las vigas (leve, moderado y severo).	56
4.5 Señales obtenidas según los niveles de daños (leve, moderado y severo).	57
4.6 Transformada rápida de Fourier para las distintas condiciones de la viga.	57
4.7 Diagramas de caja del comportamiento del conjunto de características original.	64

4.8	Diagramas de caja que ilustran el comportamiento de las características finales.	65
4.9	Representaciones de los datos en 2D y 3D mediante PCA, para cada una de las bases de datos (BD1, BD2 y BD3).	68
4.9	Visualización de los datos en 2D y 3D a través de LDA, para cada una de las bases de datos (BD1, BD2 y BD3).	70
4.10	Diagrama de flujo general para la clasificación de fallas.	71
5.1	Comportamiento de los datos reagrupados mediante los algoritmos de reducción de dimensionalidad. (a) Representación a partir de PCA. (b) Representación según LDA	75
5.2	Pruebas preliminares con el modelo SVM: (a) Matriz de confusión del modelo. (b) Regiones de clasificación con kernel gaussiano	77
5.3	Pruebas para BD1 con PCA. (a) Estudio de número de componentes en función de la varianza de los datos. (b) Evolución de la exactitud para diferentes números de vecinos.	79
5.4	Pruebas para BD1 con LDA. (a) Estudio del número de componentes en función de la varianza de los datos. (b) Evolución de la exactitud para diferentes números de vecinos	81
5.5	(a) Gráfica Anova de los mejores resultados para BD1. (b) Matriz de confusión generada con el modelo PCA+KNN.	83
5.6	Pruebas para BD2 con PCA. (a) Estudio de número de componentes en función de la varianza de los datos. (b) Evolución de la exactitud para diferentes números de vecinos.	85
5.7	Pruebas para BD2 con LDA. (a) Estudio del número de componentes en función de la varianza de los datos. (b) Evolución de la exactitud para diferentes números de vecinos.	86
5.8	(a) Gráfica Anova de los resultados más destacados para BD2.	88

5.9	Pruebas para BD3 con PCA. (a) Estudio de número de componentes en función de la varianza de los datos. (b) Evolución de la exactitud para diferentes números de vecinos.	89
5.10	Pruebas para BD3 con LDA. (a) Estudio del número de componentes en función de la varianza de los datos. (b) Evolución de la exactitud para diferentes números de vecinos.	91
5.11	(a) Gráfico Anova de los resultados más sobresalientes para BD3.	92

Índice de Tablas

2.1	Valores de λL para viga cantiléver	26
2.2	Métricas de distancia comúnmente utilizadas en KNN	30
2.3	Funciones de Kernel empleadas en SVM	33
3.1	Características del acoplador TM105R5F1A de Thorlabs.	43
3.2	Características de la fuente de luz.	44
3.3	Características del fotodetector DET025AFC de Thorlabs.	45
3.4	Características de la viga cantiléver.	49
3.5	Resultados de los valores reales y experimentales de la frecuencia.	51
4.1	Distribución de la base de datos de prueba BD1.	59
4.2	Distribución de la base de datos de prueba BD2.	59
4.3	Distribución de la base de datos de prueba BD3.	59
4.4	Características estadísticas en el dominio del tiempo	62
4.5	Características estadísticas en el dominio de la frecuencia	63
4.6	Características de dimensión fractal	63
5.1	Resultados de pruebas preliminares.	76
5.2	Resultados de PCA con algoritmos de aprendizaje para BD1.	80
5.3	Resultados de LDA con algoritmos de aprendizaje para BD1.	82
5.4	Resultados de PCA con algoritmos de aprendizaje para BD2.	85
5.5	Resultados de LDA con algoritmos de aprendizaje para BD2.	87
5.6	Resultados de PCA con algoritmos de aprendizaje para BD3.	90

5.7 Resultados de LDA con algoritmos de aprendizaje para BD3. 91

Capítulo 1

Introducción

1.1. Introducción

Las necesidades tecnológicas modernas exigen un monitoreo continuo de los sistemas para mejorar la seguridad general. En este contexto, conceptos como el monitoreo de salud estructural han ganado relevancia en distintos campos de la ingeniería [1]. El objetivo principal de estos procesos es identificar cuándo un sistema comienza a presentar comportamientos diferentes a su estado normal [1, 2], convirtiéndose en una medida de salvaguardia extremadamente eficaz. Las técnicas de supervisión dependen en gran medida de los parámetros seleccionados para representar los cambios del sistema. Los procesos de monitoreo basados en vibraciones han demostrado ser particularmente adecuados en la identificación, clasificación y evaluación progresiva de fallos [3, 4]. Las señales de vibración ofrecen una respuesta altamente correlacionada con las propiedades físicas y geométricas de diversos sistemas. Se pueden describir como la oscilación o el movimiento repetitivo de un objeto alrededor de una posición de equilibrio[5].

Tradicionalmente, las señales de vibración se han obtenido mediante transductores, dispositivos que generan una señal eléctrica análoga al movimiento vibratorio al que están sometidos [6]. Entre los más conocidos, destacan los acelerómetros capacitivos y piezoeléctricos. Aunque la tecnología de transductores eléctricos se ha implementado con éxito en innumerables apli-

caciones [7, 5], la incorporación de la detección óptica ha permitido realizar mediciones que antes eran poco prácticas o, en algunos casos, imposibles con sensores eléctricos convencionales [8, 9]. Los sensores de fibra óptica se utilizan en una amplia gama de variables, como la curvatura [10], deformación [11], vibración [12], temperatura [13], torsión [14] y otros factores. Esto se debe en parte a su naturaleza no eléctrica, que aprovecha la alta sensibilidad y las pocas pérdidas de la fibra óptica para percibir cambios de intensidad, fase, estado de polarización o longitud de onda generados por perturbaciones externas.

Las tecnologías ópticas aportan múltiples de sus beneficios al campo del monitoreo y la supervisión, en especial los sensores de vibración de fibra óptica son objeto de continuas investigaciones [2, 15]. Los sensores de fibra sensibles a vibraciones suelen dividirse en sensores puntuales y distribuidos. Entre los esquemas de sensores puntuales se tiene subdivisiones según sus principios de funcionamiento [16]; los basados en intensidad, como los arreglos reflectivos, son aquellos en los que la intensidad de la luz es modulada por un parámetro externo [17]; las estructuras interferométricas entre ellas la Fabry-Pérot, utilizan la interferencia de haces múltiples en una cavidad entre dos superficies semirreflectantes [18]; otro enfoque ampliamente utilizado en el monitoreo estructural es el ofrecido por las rejillas de fibra de Bragg (*fiber Bragg grating*, FBG), dispositivos que consisten en una perturbación periódica longitudinal del índice de refracción del núcleo de una fibra óptica [19].

En el actual surgimiento de dispositivos inteligentes, las tecnologías de medición óptica son un método prometedor a formar parte de las nuevas plataformas de detección inteligente, caso de estudio de la presente investigación. El progreso simultáneo en ambas áreas ha ampliado las aplicaciones a nuevos contextos que antes eran inimaginables [20]. Las técnicas de inteligencia artificial buscan simular el razonamiento humano a través de agentes capaces de tomar decisiones en función de un objetivo determinado [21, 22]. Entre los enfoques particulares para el diseño de sistemas inteligentes, el aprendizaje automático adapta su comportamiento en función de los datos que consume, utilizando algoritmos y modelos estadísticos para realizar tareas específicas para las que no fueron programadas explícitamente.

La integración de métodos de aprendizaje automático y sistemas ópticos representa una unión poderosa que impulsa avances significativos en una amplia gama de campos. Entre estos, destaca la monitorización de la salud estructural como una de las principales áreas de investigación, mayormente reportadas con la combinación de estas dos disciplinas de estudio [20]. Al combinar la capacidad de los sistemas ópticos para capturar y procesar datos con la sofisticación de los algoritmos de aprendizaje automático, se abre la puerta a nuevas oportunidades para la detección, análisis y toma de decisiones en tiempo real [23]. Esto promete mejorar la eficiencia, la precisión y la versatilidad de los sistemas de monitoreo y control, generando un camino de oportunidades para futuros avances tecnológicos.

1.2. Planteamiento general del problema

En la actualidad, el monitoreo de la condición estructural es de vital importancia tanto para empresas como para los ciudadanos en general. Esto debido a las prácticas de construcción deficientes, que pueden resultar en fallos que se amplifican con el paso del tiempo, o por la inducción de acontecimientos imprevistos [1]. Tales fallos pueden ocasionar pérdidas económicas significativas o incluso poner en riesgo vidas humanas. Entiéndase por daño estructural al cambio de parámetros geométricos de una estructura civil o mecánica. Generalmente, ocasionados por grietas, corrosión, pernos sueltos, fatiga o soldaduras rotas que causan desplazamientos, vibraciones o tensiones no deseadas [24, 25].

Las técnicas de monitoreo generalmente emplean análisis de vibraciones y dispositivos del tipo transductores eléctricos, los cuales suelen ser vulnerables a las condiciones ambientales adversas y a las interferencias electromagnéticas a las que están expuestos [26]. Para solventar este tipo de problemas y sumar los múltiples beneficios de la detección óptica, el presente trabajo plantea una metodología compuesta por un arreglo reflectivo de fibra óptica sensible a vibración, conjunto con métodos de aprendizaje automático para el análisis y la clasificación de las señales de vibración. Aunque existen múltiples trabajos que exploran la supervisión

mediante sensores de fibra [27, 2, 28, 15, 29], así como también el acoplamiento de los datos de estos dispositivos con modelos inteligencia artificial[30, 31], es importante destacar que no se cuenta con disponibilidad de bases de datos provenientes de sensores ópticos. La dificultad para replicar las metodologías propuestas en la literatura limita las innovaciones y la exploración abierta en este tipo de datos, lo que ha resultado en un desconocimiento sobre los alcances y los beneficios reales de la intersección entre sensores ópticos y aprendizaje automático.

1.3. Objetivos

1.3.1. Objetivo general

Desarrollar una metodología basada en la combinación de un arreglo reflectivo de fibra óptica y aprendizaje automático que permita clasificar señales de vibración acorde a las necesidades del sistema.

1.3.2. Objetivos específicos

1. Realizar una revisión bibliográfica de los arreglos ópticos reflectivos y el estado actual de las técnicas de aprendizaje automático utilizadas en la clasificación de vibraciones.
2. Implementar y validar de manera experimental un arreglo reflectivo de fibra óptica que permita la detección de señales de vibración.
3. Generar una base de datos a partir del arreglo implementado, con el fin de realizar un posterior análisis de vibración.
4. Emplear y comparar diferentes algoritmos de aprendizaje automático en la tarea de clasificar las señales de vibración provenientes de la base de datos.

1.4. Justificación

El análisis de vibraciones ha demostrado ser una herramienta fundamental en los procesos asociados con el mantenimiento preventivo. Dado que brinda la posibilidad de identificar la presencia, la ubicación y la gravedad de posibles anomalías en una etapa temprana, optimizando la productividad, rentabilidad, seguridad y durabilidad de sistemas de diversas índoles [32]. Además de contar con la ventaja de ser un tipo de medición no invasiva. En el caso del monitoreo estructural, las señales de vibración dan una respuesta global del sistema, lo que hace posible evaluar el desarrollo progresivo de una estructura [3]. Asimismo, el comportamiento vibratorio en los motores de inducción posibilita el diagnóstico de fallas mecánicas, holguras o simplemente deterioro.

Un enfoque moderno para la medición de vibración, que supera los desafíos de interferencia electromagnética y de radiofrecuencia presentes en los sensores electrónicos convencionales, son los sensores compuestos de fibra óptica [16]. Este tipo de sensores ofrecen múltiples ventajas en cuanto a estabilidad, inmunidad electromagnética, alta sensibilidad, capacidad de multiplexación, amplio ancho de banda, además de contar con la cualidad de soportar condiciones adversas [8]. Por su parte, los arreglos reflectivos de fibra óptica modulados por intensidad presentan ventajas distintivas, ya que suelen ser más económicos y menos complejos que su contraparte los interferométricos y las FBG [33]. Este tipo de arreglos puede realizar una detección precisa sin contacto, a la vez que tienen un tamaño reducido y un amplio rango dinámico.

En años recientes, el desarrollo de software y la inteligencia artificial han transformado tanto aplicaciones existentes como el proceso de creación de nuevas [20]. Esta evolución ha fomentado una mayor sinergia entre la inteligencia artificial y disciplinas como la óptica, marcando el comienzo de una nueva era en la medición de parámetros físicos y dando lugar al surgimiento de sensores con capacidades mejoradas [34]. Esto ha ocasionado un cambio significativo en la investigación de sensores de fibra óptica, pasando de enfoques centrados en diseño y multiplexación a un énfasis en el reconocimiento de patrones para mejorar el rendimiento

de las aplicaciones [20]. Esta unión interdisciplinaria presenta un potencial considerable para mejorar la precisión, sensibilidad, robustez, inseparabilidad y adaptabilidad de los sensores en diversos entornos y condiciones.

Aunque se han logrado avances significativos, aún se requiere una mayor investigación para comprender completamente cómo las técnicas de aprendizaje automático pueden optimizar la detección y seguimiento de parámetros físicos a través de sensores ópticos [23, 20]. Por estas razones, el desarrollo de una metodología que integre un arreglo reflectivo de fibra óptica y aprendizaje automático no solo se presenta como una solución práctica y novedosa para el monitoreo de daños tanto en estructuras civiles como en dispositivos mecánicos, sino que también ofrece múltiples beneficios en la detección y análisis de señales de vibración. Este trabajo contribuye a la continuidad de la investigación interdisciplinaria entre la óptica y el aprendizaje automático.

1.5. Antecedentes

En las últimas dos décadas, los sistemas de monitoreo se han convertido en una herramienta primordial para que los ingenieros puedan garantizar la seguridad y la mantenibilidad en diversas áreas, como civil, energética, aeroespacial y mecánica, entre otras. Los procesos de supervisión comúnmente implican tres etapas: monitoreo, procesamiento e interpretación de señal [2]. De esta manera se puede evaluar la salud, capacidad operativa y el desempeño de sistemas mediante la clasificación de daños.

En la etapa de monitoreo se han utilizado un número significativo de tecnologías para la localización y cuantificación de fallas, prestando particular atención al análisis y recolección de señales de vibración. Este tipo de señales se encuentran directamente relacionadas con los parámetros físicos de las estructuras [4], además su naturaleza no destructiva y no invasiva, permite estudiar con relativa facilidad gran variedad de sistemas [3]. Para la detección de las

señales de vibración se han implementado diversos dispositivos, entre los cuales destacan los sensores compuestos por fibras ópticas en vista de las múltiples ventajas que ofrecen.

En las aplicaciones de monitoreo de salud estructural con sensores ópticos de vibración, resaltan los sistemas de tipo distribuido y los que emplean FBG [2, 35]. Sin embargo, los arreglos basados en el uso de elementos ópticos-electrónicos ofrecen la capacidad de recolectar información del comportamiento vibratorio de un elemento estructural, sin ningún tipo de contacto. Esto se logra mediante el uso de un láser emisor, un fotodiodo comercial y una película reflejante. La capacidad de detección de este tipo de arreglos es comparable con un acelerómetro en una variedad de sistemas y materiales [36]. De igual manera, otros estudios han diseñado y desarrollado arreglos similares, compuestos por un conjunto resistencias dependientes de la luz (LDR), dispuestas en una placa con un microcontrolador y una superficie reflejante sujeta al objeto vibrante [37]. Este tipo de arreglos son dependientes de la distancia entre el cabezal sensor y el objetivo.

Los sensores de fibra óptica por sí solos no están en capacidad de medir los daños a los cuales están respondiendo, para obtener esa información es necesario implementar estrategias adicionales, lo que nos lleva a las etapas de procesamiento e interpretación. Entre las alternativas que se han ganado gradualmente la atención de los investigadores, se encuentra el análisis de datos avanzados mediante aprendizaje automático [30], subcampo de la inteligencia artificial. Un caso significativo de su aplicación es en el monitoreo de deformación estructural con sistemas de fibra distribuidos, en donde el uso de la herramienta de análisis multivariable de PCA (*Principal component analysis*, PCA) permitió amplificar el área de exploración, identificando consistentemente la estructura dañada, no obstante es necesario mejorar la brecha de identificación para daños mínimos [38].

Metodologías distintas de monitoreo con sensores ópticos y aprendizaje automático han sido implementadas en la revisión del estado y el diagnóstico de fallos mecánicos. Tal es el caso del trabajo realizado por los autores [39], donde se propuso un sistema de monitorización de alta frecuencia para detectar fallos en motores de combustión interna, utilizando un sensor

compuesto por una FBG adherida a una viga cantiléver. Se identificaron señales de vibración estructural relacionadas con fallos en las válvulas y el ángulo de avance de la inyección de combustible, posteriormente se preprocesaron los datos mediante descomposición y reconstrucción wavelet, y se utilizó un modelo de clasificación multiclase máquinas de vectores soporte para identificar los fallos. Las pruebas experimentales confirmaron la eficacia del enfoque propuesto al mostrar un excelente rendimiento y una mayor precisión en la identificación de fallos, en comparación con otros métodos.

Otro estudio orientado al diagnóstico de fallas en motores, hace uso de dispositivo captador de vibraciones óptico sin contacto [37], junto con un entorno de aprendizaje automático para el monitoreo del estado de salud de los rodamientos de un motor bajo carga y variación de velocidad [40]. Tras la adquisición de datos de vibración, se lleva a cabo una fase de preprocesamiento que incluye la eliminación de ruido mediante una transformada de Hilbert y la reducción de la dimensionalidad de las características mediante PCA. Además, se emplea un algoritmo de selección de características para determinar el conjunto más óptimo. En la etapa de clasificación, se compara el rendimiento de modelos de vectores de soporte y redes neuronales artificiales para identificar y clasificar los defectos en los rodamientos. Los resultados destacan que la precisión de clasificación obtenida utilizando la metodología propuesta y los datos capturados por el dispositivo captador de vibraciones es comparable a la de otros sensores mencionados en la literatura. Esta estrategia ofrece la posibilidad de detectar tempranamente fallos en los rodamientos, ayudando a evitar paradas no planificadas.

1.6. Estructura del trabajo

Este trabajo de tesis está dividido en 6 capítulos, que se detallan brevemente a continuación:

- **Capítulo 1. Introducción:** Presenta una descripción general del problema a tratar, seguido de los objetivos propuestos para resolverlo, junto con los motivos que impulsan el estudio.

Finalmente, se hace un recuento de trabajos previos relacionados con la unión interdisciplinaria propuesta.

- **Capítulo 2. Marco teórico:** Se especifican los fundamentos ópticos relacionados con los arreglos reflectivos de fibra óptica y aprendizaje automático. A su vez, se realiza una breve descripción de los términos correspondientes a las señales de vibración y el modelado del sistema viga tipo cantiléver.
- **Capítulo 3. Metodología del arreglo óptico:** Se describen cada uno de los elementos que componen el arreglo óptico empleado en el trabajo, así como la descripción de su funcionamiento y validación de las mediciones obtenidas.
- **Capítulo 4. Procesamiento y análisis de datos:** Se especifica el procedimiento y las técnicas que componen la metodología para el análisis y clasificación de los datos de vibración, así como la construcción de la base de datos.
- **Capítulo 5. Resultados:** Se exponen los resultados obtenidos del procedimiento propuesto.
- **Capítulo 6. Conclusiones:** Finalmente, este apartado presenta las conclusiones resultantes del presente trabajo de investigación.

Capítulo 2

Marco teórico

Este capítulo proporciona el marco teórico necesario para comprender el trabajo de investigación presentado en este documento. En primer lugar, se revisan los fundamentos ópticos relacionados con los arreglos reflectivos de fibra óptica. Seguido de una breve descripción de los términos pertinentes a las señales de vibración y al modelado del sistema a analizar (viga tipo cantiléver). Finalmente, se discuten las técnicas de aprendizaje automático empleadas en el procedimiento propuesto para el análisis de las señales de vibración, así como las métricas de evaluación asociadas a los modelos de aprendizaje.

2.1. Fundamentos ópticos

Comúnmente se describe la luz desde el sentido de la visión como la energía radiante que estimula la vista y permite percibir el mundo. Sin embargo, la naturaleza de la luz no es tan sencilla de comprender a lo largo de la historia el concepto de luz ha evolucionado [41]. Una de las primeras explicaciones fue la de Isaac Newton en su tratado de óptica, donde describió los rayos de luz como corpúsculos (pequeñas estructuras de materia) emitidos por sustancias brillantes. Paralelo a esta investigación, Christiaan Huygens presentó una idea diferente al inferir que la luz es una onda que se propaga desde la fuente en todas direcciones; este comporta-

miento ondulatorio da explicación a fenómenos como la interferencia y fundamenta de manera sólida las leyes elementales de la reflexión y la refracción [42]. No fue hasta 1873 que James Clerk Maxwell estableció las reglas universales de electricidad y magnetismo, lo que llevó a la confirmación de que la naturaleza de la luz tiene forma ondulatoria con energía electromagnética [43], cuyo espectro varía conforme la longitud de las ondas o la velocidad de las mismas en términos de frecuencia, como se muestra en la Figura 2.1.

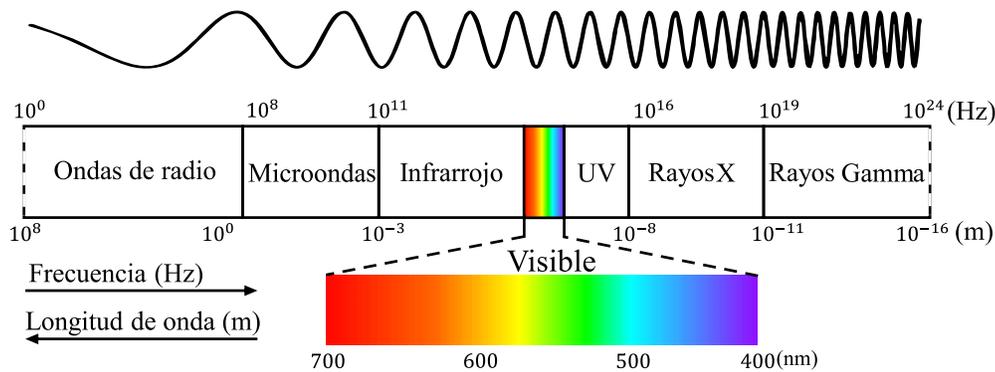


Figura 2.1: Espectro electromagnético.

El siguiente gran avance en la comprensión de la luz tuvo lugar durante las primeras décadas del siglo XX, cuando Planck, Einstein y Bohr desarrollaron la teoría cuántica de la luz. [44]. Esta teoría evidencia que la energía electromagnética está cuantizada, es decir, sólo puede tomar valores discretos (partículas) denominados fotones; lo cual proporciona un razonamiento coherente e inequívoco a otro tipo de fenómenos ópticos en donde la luz muestra un aspecto de partícula, tal es el caso del efecto fotoeléctrico [44]. Es así como nace el concepto moderno de que la luz tiene un comportamiento dual, dando paso a la electrodinámica cuántica, que combina las leyes electromagnéticas de Maxwell y la teoría cuántica [41]. En resumen y para fines ópticos, la luz se puede definir como la radiación electromagnética, un flujo de energía en forma de campos eléctricos y magnéticos conectados entre sí formando ángulos rectos y perpendiculares a la dirección de propagación (Figura 2.2). Las ondas electromagnéticas tienen como componentes principales la intensidad, relacionada con la distancia entre un máximo y el eje central de la onda; y la longitud de onda compuesta por dos máximos consecutivos.

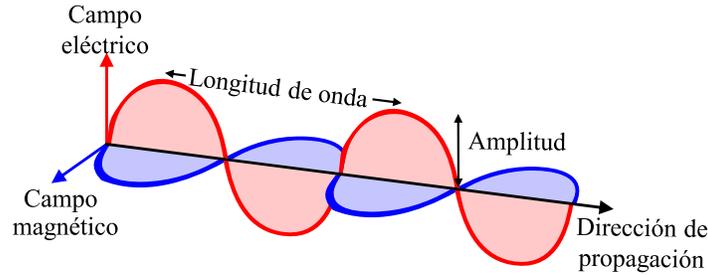


Figura 2.2: Onda electromagnética.

Por otra parte, la dirección de propagación de la luz se representa a menudo como un rayo luminoso, término usado en óptica geométrica para asumir que la luz proveniente de una fuente puntual que viaja en línea recta a través de medios homogéneos e isótropos, como el aire o el agua. [42]. Normalmente, la mayoría de las fuentes luminosas no logran un equilibrio ideal entre intensidad y paralelismo, lo que produce haces con cierta divergencia. Esto nos lleva al concepto de luz láser, donde el haz óptico es intenso y casi perfectamente paralelo.

2.1.1. Láser

El láser (acrónimo de *light amplification by stimulated emission of radiation*) debe contarse entre los inventos más significativos del siglo XX, convirtiéndose en un instrumento importante no solo para la investigación física, sino también para casi todos los ámbitos de la vida cotidiana [42]. Esencialmente, un láser es una fuente de luz que produce campos luminosos intensos, coherentes y monocromáticos (o para una sola longitud de onda). Se basa en el fenómeno de emisión estimulada de radiación, propuesto por Einstein, y en el bombeo óptico, estudiado por Alfred Kastler. [41]. La amplificación de la luz por emisión estimulada se genera al pasar luz a través de un cuerpo transparente que tiene una resonancia con la frecuencia del haz luminoso. En este proceso, los átomos de un material se excitan al darles una energía adicional, por medio de un procedimiento de bombeo. Cuando los átomos regresan a su estado fundamental, emiten fotones con la misma energía que recibieron. Estos fotones se propagan de forma coherente, es decir, con la misma dirección y fase, creando así la luz láser.

Los dispositivos láser están disponibles en una amplia gama de formas, tamaños y rangos de funcionamiento en el espectro electromagnético. Se componen generalmente de tres componentes principales: una cavidad resonante, un medio de ganancia y una fuente de bombeo. Por otra parte, cabe destacar que el funcionamiento de los láseres y los amplificadores electrónicos es similar, ya que ambos se excitan a través de oscilaciones ocasionadas por la realimentación positiva [42, 45]. En el caso de los láseres la realimentación luminosa se obtiene formando una cavidad resonante compuesta por espejos; dentro de esta cavidad se tiene un medio activo o de ganancia (por ejemplo un cristal láser), que amplifica la luz gradualmente después de que comienza la oscilación y hasta que toda la energía de bombeo sea utilizada sólo en la compensación de las pérdidas y el desacoplamiento del circuito oscilador o del láser, respectivamente. El bombeo de energía se puede realizar de manera óptica al inyectar luz al medio de ganancia o de manera eléctrica con una corriente eléctrica en el caso de los láseres semiconductores.

2.1.2. Haz gaussiano

Las posibles formas en que la luz puede propagarse están definidas por los modos transversales (TEM por las siglas en inglés de *Transverse electromagnetic*), el modo principal o de orden más bajo (TEM_{00}) tiene un perfil de distribución cuya intensidad transversal y longitudinal está descrita por una función gaussiana. [41]. Un haz de luz gaussiano se caracteriza por tener un pico central intenso que decae transversalmente, siguiendo una curva en forma de campana que es simétrica alrededor del eje central, como se muestra en la Figura 2.3.

El haz gaussiano se comporta de manera muy similar a una onda plana con amplitud constante a lo largo de la dirección de propagación (z), sin cambios de fase en el campo eléctrico. Esto da a los haces gaussianos características distintivas y de gran interés en óptica como alta coherencia, direccionalidad y enfoque, lo que los convierte en el modo de propagación más utilizado. La irradiancia del haz gaussiano se representa por la ecuación [43]:

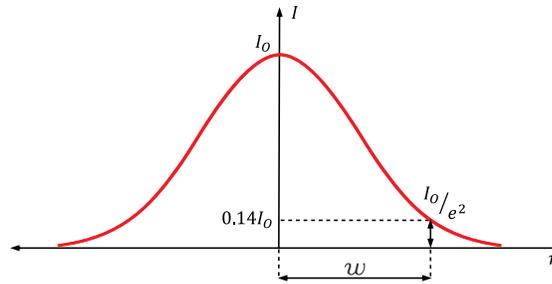


Figura 2.3: Una onda gaussiana en forma de haz que se propaga en la dirección z .

$$I(r) = I_0 e^{-2r^2/w^2} \quad (2.1)$$

El haz se desplaza radialmente con r como la distancia medida en un plano transversal desde el eje central de propagación z . Por su parte, w es el valor del radio que define un límite arbitrario a la anchura del haz en el que la distancia es r y la irradiancia es inferior a $1/e^2$ de su valor axial, es decir solo el 14 % de I_0 permanece dentro del cilindro de radio imaginario de w por donde se propaga la luz.

2.1.3. Índice de refracción

El índice de refracción es una medida utilizada para identificar los medios por donde se propaga la luz. Generalmente, es denotado por la letra n , define el factor en el que la velocidad de fase (v) disminuye en relación con la velocidad de la luz (c) en el vacío [43, 46]; al transmitirse luz en un medio homogéneo ocurren eventos continuos y repetitivos que introducen desplazamientos de fase en el campo luminoso, que finalmente se manifiesta como un desplazamiento o decaimiento de la velocidad de fase.

$$n = \frac{c}{v}, \quad (2.2)$$

La ecuación 2.2 posee una magnitud adimensional al ser una relación entre dos velocidades, suponiendo una propagación lineal de ondas planas que genera intensidades ópticas bajas [46]. Por otra parte, es importante destacar, que el índice de reflexión también se puede definir a través de las propiedades de los materiales ópticos.

$$n = \sqrt{\varepsilon\mu} \quad (2.3)$$

Donde ε es la permitividad eléctrica, representa la oposición del campo eléctrico en el material, y (μ) la permeabilidad magnética describe el cambio en el campo magnético dentro de un material [43]. En términos de propagación de la luz, el índice de refracción de los materiales junto con la velocidad de fase determinan los distintos fenómenos de las interfaces ópticas como la refracción, la reflexión y la difracción [46], los cuales son estudiados en la siguiente sección.

2.1.4. Reflexión y refracción de la luz

La reflexión y la refracción de la luz son los dos fenómenos naturales, que ocurren cuando un haz de luz incide sobre una frontera plana que separa dos medios ópticos diferentes[44]. La reflexión se produce cuando el rayo de luz incidente llega a la superficie de separación y parte de la luz se dispersa hacia atrás, generando el rayo reflejado. La luz que logra transmitirse por el nuevo medio experimenta un cambio en la dirección de propagación, a esto se le conoce como refracción y da lugar al rayo refractado [43], tal y como se aprecia en la Figura 2.4.

Las primeras leyes de refracción y reflexión se pueden deducir fácilmente utilizando el principio de Fermat, el cual establece que la luz elige el camino más corto y directo en su propagación a través de un medio [43]. Según la primera ley de reflexión, el rayo incidente, el rayo reflejado y la normal a la superficie reflectora (línea punteada de la 2.4) están en un plano común. Por otra parte, la segunda ley establece que la magnitud del ángulo de incidencia es igual a la magnitud del ángulo de reflexión [41], como se indica en la siguiente ecuación:

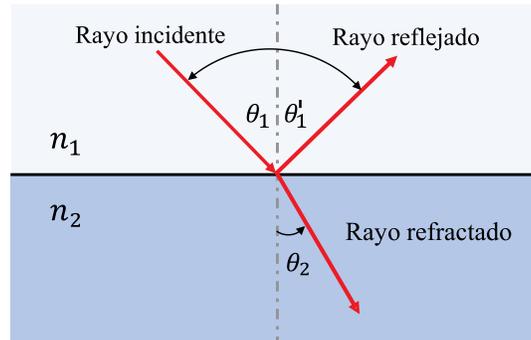


Figura 2.4: Refracción y reflexión en una superficie dieléctrica para los materiales n_1 y n_2 .

$$\theta_1 = -\theta'_1 \quad (2.4)$$

En el caso de la primera ley de refracción, el rayo incidente, el rayo refractado y la normal a la superficie que separa los medios ópticos (línea punteada de la 2.4) se encuentran en un plano común. La segunda ley de refracción, también conocida como ley de Snell, se puede deducir a partir del camino óptico generado, relacionando el seno del ángulo de incidencia θ_1 y el seno ángulo de refractado θ_2 con los valores constantes de los índices de refracción de ambos medios (n_1 y n_2) [41], como se muestra a continuación:

$$n_1 \sin \theta_1 = n_2 \sin \theta_2 \quad (2.5)$$

Cuando se tiene un rayo incidente con ángulo de 90° , la luz refractada tendrá un ángulo llamado ángulo crítico (θ_L), ángulo límite o ángulo de reflexión total, el cual está únicamente en función de los índices de refracción de los materiales involucrados, y se puede obtener mediante la ley de Snell [42]. La misma ley de donde se deduce que θ_L es el máximo valor de ángulo que existirá para los rayos refractados. Sin embargo, siempre que el rayo de luz provenga de un medio óptico más denso, es decir ($n_1 > n_2$), con un ángulo de incidencia mayor que el ángulo crítico, no existirá refracción. Este fenómeno se conoce como reflexión total interna y es el principio por el que funcionan los prismas y las fibras ópticas [47], que se explicarán más adelante, ya que confina la luz al reflejarla completamente en la interfaz entre dos medios.

2.1.5. Reflexión especular

El tipo de reflexión óptica dependerá de las condiciones de la superficie del material en donde incida la luz. Para el caso de superficies irregulares o rugosas, la luz se reflejará en todas direcciones, a esto se le conoce como reflexión difusa [43]. Por el contrario, cuando se tiene una superficie lisa y pulida, el rayo de luz incidente se reflejará en una sola dirección, formando una imagen especular del objeto que la emite, tal y como se observa en la Figura 2.5.

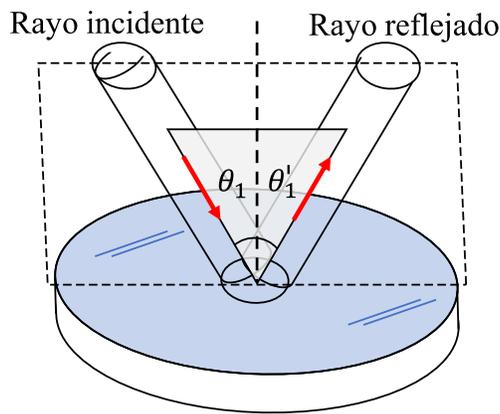


Figura 2.5: Reflexión especular en un espejo plano. n_1 y n_2 .

El término reflexión especular proviene de la palabra en latín *speculum* (espejo), es el tipo clásico de reflexión de la luz, en donde el ángulo del rayo luz reflejada es igual al ángulo del rayo de luz incidente, pero en el lado opuesto de la normal a la superficie, cumpliendo con la segunda ley de reflexión [48]. Este tipo de reflexión se produce en superficies lisas como piezas de metal o de vidrio pulidas, incluidos los casos con reflexión total interna, inclusive en superficies líquidas, esta situación suele encontrarse con gran precisión en varios tipos de espejos planos [42]. Es importante señalar que para longitudes de onda menores como las de la luz visible, se requiere un alto grado de planitud y superficies bien pulidas para obtener una reflexión especular casi perfecta.

2.1.6. Fibras Ópticas

Las fibras ópticas desempeñan un papel particularmente importante en la fotónica en general, se describen como guías de ondas dieléctricas que funciona a frecuencias ópticas [49]. Estas guías de ondas generalmente tienen una forma cilíndrica y están hechas de algún tipo de vidrio. Gracias al fenómeno de reflexión total interna y con base en múltiples reflexiones, esta estructura confina la energía electromagnética en forma de luz en sus superficies y la conduce en dirección paralela a su eje [41, 50]. La propagación de la luz en la fibra se describe de manera discreta en términos de los modos o conjunto de ondas electromagnéticas que son guiadas. Cada modo guiado es un patrón de distribución de campo eléctrico y magnético que se repite en intervalos iguales a lo largo de la fibra.

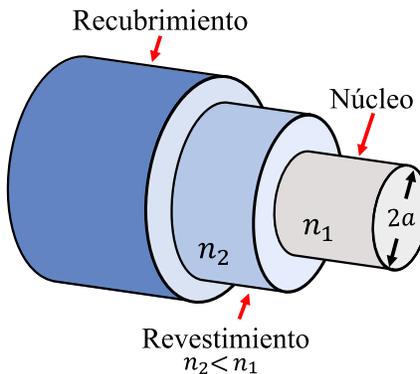


Figura 2.6: Esquema de una estructura convencional de fibra con núcleo sólido circular de índice de refracción n_1 , rodeado por un revestimiento con un índice de refracción n_2 y un recubrimiento encapsulado de plástico.

La estructura más común entre las fibras ópticas es el cilindro dieléctrico sólido simple de radio a e índice de refracción n_1 , conocido como núcleo, tal y como se muestra en la Figura 2.6. De manera estándar, el material del núcleo está formado por un compuesto de vidrio de sílice (SiO_2) de alta pureza, rodeado por un revestimiento dieléctrico sólido [50]. Este revestimiento tiene un índice de refracción n_2 inferior al del núcleo n_1 . Aunque el revestimiento no es necesario

para que la luz se propague a lo largo del núcleo de la fibra, reduce las pérdidas por dispersión y protege el núcleo al agregar resistencia mecánica a la fibra[50]. Por último, la mayoría de las fibras tienen un recubrimiento plástico elástico que aumenta la resistencia a las abrasiones o rugosidades de las superficies adyacentes.

Las características estructurales y la composición del material del núcleo de la fibra determinan sus capacidades de transmisión, principalmente existen dos tipos de fibra. En el caso de fibra de índice escalonado, el índice de refracción del núcleo es uniforme en todo su espesor con un cambio brusco (escalón) en el límite del revestimiento [50]. Por su parte, en la fibra de índice graduado, el índice de refracción del núcleo varía en función de la distancia radial desde el centro de la fibra [43]. Todos los tipos de fibras pueden dividirse a su vez en términos de los modos que transmiten (Figura 2.7). Las fibras monomodos transmiten sólo un modo de propagación, mientras que las multimodos transmiten múltiples modos.

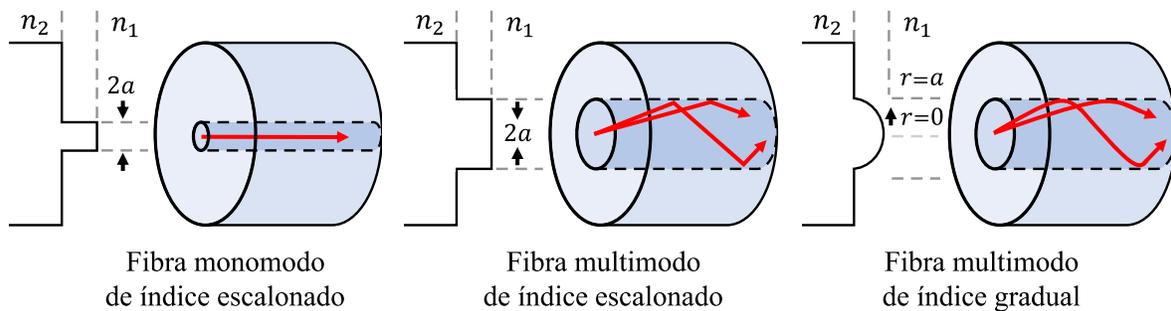


Figura 2.7: Diversos tipos de fibras ópticas de índice escalonado y gradual, tanto monomodo como multimodo.

En comparación con las fibras monomodo, las fibras multimodo ofrecen una serie de ventajas. Como núcleos más amplios que facilitan el tránsito de altas potencias ópticas por la fibra, así como la conexión de fibras similares, en nuestro caso se aprovecha el amplio radio de la fibra multimodo para acoplar de señales lumínicas externas [50]. Para que la luz de entrada a una fibra sea captada y propagada con éxito en su interior, el rayo de luz incidente o de entrada debe reflejarse en el revestimiento con un ángulo mayor al crítico, para lo cual existe

un valor de ángulo límite, conocido como ángulo de aceptación (θ_A), parámetro que define el semiángulo del cono de aceptación de la fibra, como se aprecia en la Figura 2.8.

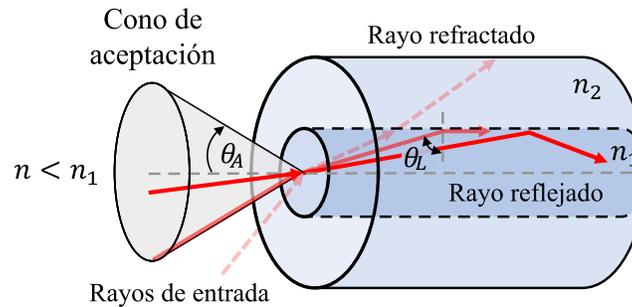


Figura 2.8: Cono de aceptación para una fibra óptica.

El ángulo de aceptación se encuentra influenciado tanto por los índices de refracción de la fibra, como por el material donde incida la fuente de luz (generalmente aire $n = 1$). La capacidad de captar luz de una fibra viene determinada por la apertura numérica (*Numerical Aperture, NA*) que se define en función del seno del ángulo de aceptación con respecto al eje de la fibra, es decir:

$$NA = \sin \theta_A \quad (2.6)$$

También se puede calcular a partir de la diferencia de los índices de refracción de la fibra, más precisamente con la siguiente relación:

$$NA = \sqrt{n_1^2 - n_2^2} \quad (2.7)$$

Las fibras ópticas revolucionaron las telecomunicaciones y la tecnología, las aplicaciones asociadas con ellas han avanzado rápidamente en los últimos años. Como medio físico, la fibra puede experimentar cambios en su geometría (tamaño, forma) o propiedades ópticas (índice de refracción, conversión de modo) cuando está expuesta a perturbaciones. Estos cambios se utilizan para detectar una variedad de fenómenos ambientales [26]. En general, los sensores de fibra óptica tienen una sensibilidad superior en comparación con otros tipos de sensores,

además su estructura dieléctrica los protege contra interferencias electromagnéticas y los hace resistentes a entornos difíciles. Existen diferentes clasificaciones para los sensores de fibra óptica, en el caso de los que detectan una perturbación de interés mediante la modulación de la señal que pasa por la fibra [51], se dividen en subclases, modulación de fase, modulación de polarización, o modulación de amplitud (intensidad), principio que da lugar a los arreglos reflectivos de fibra óptica.

2.1.7. Arreglos de fibra óptica modulados por reflexión

Los sistemas de fibra óptica por amplitud modulada funcionan como transductores, convirtiendo los datos de medición en un cambio en la radiación óptica correspondiente. Este tipo de sistemas utiliza componentes multimodo y son relativamente económicos [52]. Una de las técnicas conceptualmente más simples para la detección por amplitud modulada, son los arreglos de fibra óptica modulados por reflexión. En este tipo de sistemas la modulación tiene lugar fuera de la fibra, la luz sale de una o varias fibras orientadas perpendicularmente a la superficie reflectante, separadas con una pequeña distancia. Parte de la luz reflejada es recapturada por la misma fibra o por otra diferente, tal y como en las configuraciones de la Figura 2.9.

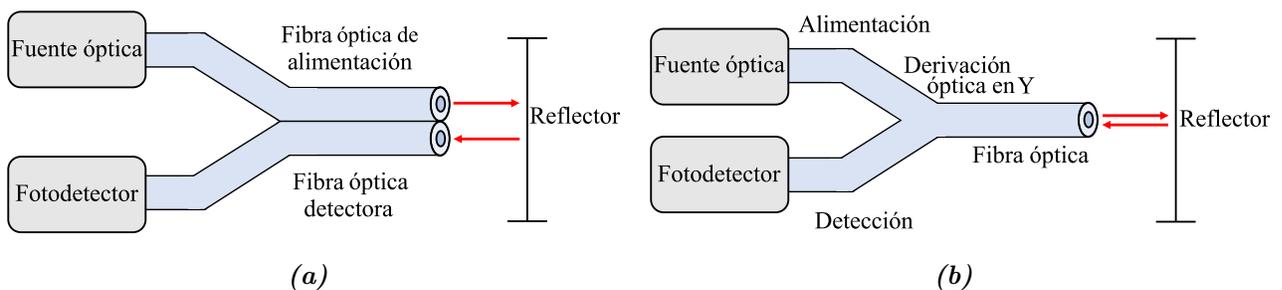


Figura 2.9: Disposiciones utilizadas para los sensores de fibra óptica modulados por reflexión. (a) Arreglo con fibras ópticas independientes para la alimentación y detección. (b) Arreglo con una sola fibra óptica y una derivación en Y para separar la alimentación y detección.

La distancia entre el extremo de la fibra y la superficie reflectante determinará la fracción de luz recapturada, lo que implica que los movimientos en la superficie reflectante (por ejemplo, un

diafragma, o un cantiléver) son proporcionales a la luz captada por la fibra óptica colectora [52]. Este es un principio a partir del cual se pueden fabricar sensores de posición, desplazamiento, vibración, presión, nivel de líquidos, entre otros. Sin embargo, también es importante destacar que este tipo de sistemas, presentan una serie de limitaciones ligadas a las pérdidas de la señal recuperada [17]. Las posibles fuentes de error incluyen pérdidas causadas por variables externas, conectores y empalmes, así como las pequeñas pérdidas causadas por la flexión o desalineación de la fuente de luz o el detector.

2.2. Sistema y parámetro analizar

El sistema elegido para generar las señales de vibración que se detectarán y recolectarán mediante el arreglo reflectivo de fibra óptica, es en una estructura de viga cantiléver. Este tipo de sistema es imprescindible en cualquier estructura, por lo cual es un sistema ampliamente estudiado y modelado [53]. Por otro lado, el comportamiento de vibración de los sistemas, tanto mecánicos como estructurales, se evalúan principalmente mediante parámetros como la frecuencia natural, el factor de amortiguación y la forma del modo [54].

Los conceptos esenciales para comprender los parámetros asociados el comportamiento vibratorio en los sistemas de viga cantiléver se explicarán a continuación.

2.2.1. Viga cantiléver

Las vigas son elementos estructurales que soportan cargas a lo largo de un eje longitudinal. Existen muchos tipos de vigas, clasificadas según su tamaño, ubicación en un sistema estructural y la forma en que se apoyan [53]. Esta última categoría incluye las vigas tipo cantiléver, sistemas fundamentales de cualquier estructura desde hace décadas. La Figura 2.10 muestra una viga cantiléver con sección transversal rectangular.

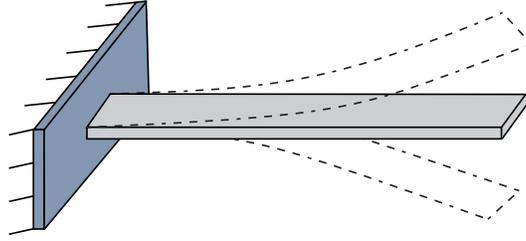


Figura 2.10: Viga tipo cantiléver en flexión.

Una viga cantiléver, también conocida como viga en voladizo, tiene un extremo fijo y otro libre. Se caracterizan por tener una longitud mucho mayor que su anchura y profundidad, pueden ser rectas o curvas, de sección rectangular o circular [55]. Cuando una viga cantiléver horizontal se somete a una fuerza de flexión debido a su propio peso o una carga externa, se genera un momento de flexión donde la viga se doblará hacia abajo y vibrará a su frecuencia natural hasta que vuelve a su forma original debido a la inercia.

2.2.2. Modelado matemático del cantiléver

Existen diversas alternativas para desarrollar el modelo matemático de una viga cantiléver, cada una con sus propias ventajas y desventajas. Entre ellas, se incluyen métodos analíticos como Euler-Bernoulli o Timoshenko [56]. Sin embargo, uno de los más usados es el desarrollado mediante la teoría de vigas de Euler-Bernoulli es una simplificación de la teoría de la elasticidad lineal que brinda una forma sencilla de calcular la relación entre la carga y la deformación para pequeñas deflexiones en una viga [57]. La expresión que describe el momento flector de la viga está dada por la ecuación:

$$EI \frac{\partial^2 M}{\partial x^2} + \rho A \frac{\partial^2 v}{\partial t^2} = 0 \quad (2.8)$$

El momento flector de la fuerza resultante de una distribución de tensiones sobre la sección transversal del cantiléver según la teoría de Euler-Bernoulli, es representado por la función:

$$M(x) \approx EI \frac{\partial^2 v}{\partial x^2} \quad (2.9)$$

La expresión 2.10 describe la vibración libre de la viga con respecto a su posición de equilibrio [57], se obtiene reemplazando la ecuación 2.9 en la ecuación 2.8.

$$EI \frac{\partial^4 v}{\partial x^4} + \rho A \frac{\partial^2 v}{\partial t^2} = 0 \quad (2.10)$$

La rigidez de flexión de la viga EI , depende de las propiedades elásticas del material y de la geometría del cantiléver. Donde E es el módulo de elasticidad lineal (o módulo de Young) e I es el momento de inercia de la sección transversal, rectangular para el caso de estudio. Por su parte, ρ es la densidad del material en flexión y A es el área $A = h * b$, descrita por la forma del cantiléver en la Figura 2.11.

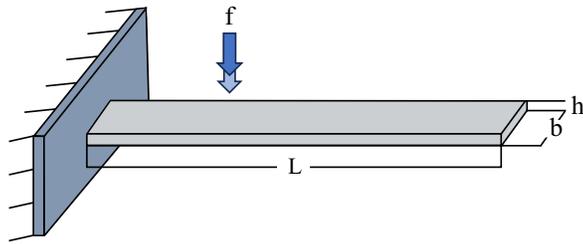


Figura 2.11: Características principales de una viga tipo cantiléver.

La ecuación 2.10 que gobierna las vibraciones transversales libres de la viga es una ecuación diferencial en derivadas parciales de cuarto orden, homogénea y lineal, cuya solución se puede encontrar utilizando la técnica de separación de variables.

$$v(x, t) = V(x, t) \quad (2.11)$$

$$V(x, t) = V(x)P(t) \quad (2.12)$$

Donde $V(x)$ representa una función dependiente de la variable espacial x y la función $P(t)$ depende exclusivamente de la variable temporal t . Esta solución implica que todos los puntos de la viga tienen la misma dependencia del tiempo. En consecuencia, la ecuación 2.10 se describe de la siguiente manera:

$$\frac{1}{P(t)} \frac{\partial^2 P(t)}{\partial T^2} = -\frac{EI}{\rho AV(x)} \frac{\partial^4 V(x)}{\partial X^4} = \varphi \quad (2.13)$$

Las oscilaciones libres en los sistemas vibratorios se expresan mediante funciones armónicas seno o coseno, donde φ es una constante que por lo general la literatura establece como la expresión 2.14, siendo ω la frecuencia natural de vibración del sistema [56].

$$\varphi = -\omega^2 \quad (2.14)$$

Utilizando las ecuaciones 2.13 y 2.14, se obtienen las expresiones temporal 2.15 y espacial 2.16 de valores característicos.

$$\frac{\partial^2 P}{\partial T^2} + \omega^2 P = 0 \quad (2.15)$$

$$EI \frac{\partial^4 V}{\partial X^4} - \rho A \omega^2 V = 0 \quad (2.16)$$

Al despejar la ecuación 2.16 y hacer un cambio de variable se consigue:

$$\frac{\partial^4 V}{\partial X^4} = \frac{\rho A \omega^2}{EI} V \quad (2.17)$$

$$\lambda^4 = \frac{\rho A \omega^2}{EI} \quad (2.18)$$

La solución general de la ecuación 2.16 se puede escribir como:

$$V(x) = C_1 \cosh(\lambda x) + C_2 \sinh(\lambda x) + C_3 \cos(\lambda x) + C_4 \sin(\lambda x) \quad (2.19)$$

Las condiciones de frontera asumidas para el sistema viga cantiléver vienen definidas por su geometría. Las dos primeras representan la imposibilidad de desplazamiento y giro en el extremo sujeto. Mientras que las dos restantes son de tipo natural, dadas por el extremo libre y equivalentes al momento flector y esfuerzo cortante nulos [58].

$$V(0) = 0, \quad V'(0) = 0, \quad V''(L) = 0, \quad V'''(L) = 0 \quad (2.20)$$

Al considerar las condiciones de contorno 2.20 se tiene:

$$\begin{bmatrix} \cosh(\lambda L) + \cos(\lambda L) & \sinh(\lambda L) + \sin(\lambda L) \\ \sinh(\lambda L) - \sin(\lambda L) & \cosh(\lambda L) - \cos(\lambda L) \end{bmatrix} \begin{bmatrix} C_1 \\ C_2 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \quad (2.21)$$

La solución de la ecuación 2.21 ofrece una variedad de soluciones a partir de las cuales se obtienen los valores λL , dados por la ecuación característica a continuación:

$$\cosh(\lambda L) \cos(\lambda L) = -1 \quad (2.22)$$

Las raíces (2.22) pueden ser determinadas numéricamente, siendo las primeras cuatro:

Tabla 2.1: Valores de λL para viga cantiléver

n	1	2	3	4
$\lambda_n \mathbf{L}$	1.8751	4.694	7.854	10.9955

Finalmente, las frecuencias naturales de los modos vibracionales del sistema se obtienen utilizando la expresión 2.23 al reemplazar los eigen valores dados por la Tabla 2.1, en donde el valor de $\lambda_1 L$ determina la frecuencia fundamental del sistema.

$$\omega_n = (\lambda_n L)^2 \sqrt{\frac{EI}{\rho AL^4}} \quad (2.23)$$

Los modos de vibración natural obtenidos a partir de los eigen valores de la Tabla 2.1 y la ecuación 2.23 son parámetros clave para analizar el comportamiento del sistema, representan los patrones característicos del movimiento armónico que adopta el sistema viga cantiléver al oscilar libremente. Para lograr un análisis eficiente, se considerarán los primeros eigen valores y sus modos asociados correspondientes a las frecuencias más bajas, debido a que a menudo capturan la mayoría de las características dinámicas del sistema.

2.3. Aprendizaje automático

Los sistemas inteligentes modernos, que han revolucionado y cambiado radicalmente nuestras vidas, suelen depender del aprendizaje automático (*machine learning, ML*). Al hablar de ML, es fundamental partir del concepto de inteligencia artificial (*Artificial intelligence, IA*); en términos generales, la IA comprende cualquier técnica que permite imitar el comportamiento cognitivo humano y reproducir la toma de decisiones en tareas complejas de forma autónoma o con una mínima intervención [59]. La evolución de la IA representada en la Figura 2.12, inició en la década de los 50, cuando el enfoque estaba en el razonamiento lógico, pero pronto se descubrió que para lograr inteligencia, las máquinas debían aprender como los humanos y otros animales [60]. Este cambio dio inicio a la era del conocimiento; sin embargo, el ML no ganó popularidad hasta mediados de los años 80, cuando se convirtió en un campo propio. En la actualidad, el aprendizaje profundo (*deep learning*) ha ampliado las posibilidades de la IA.

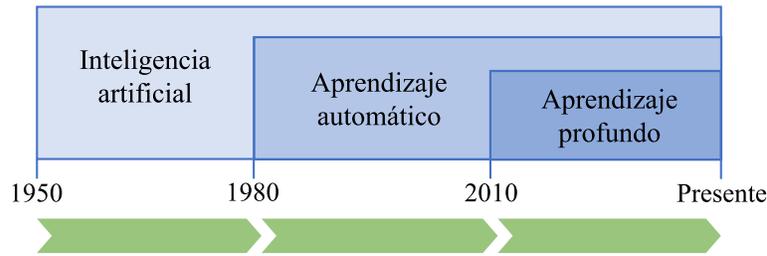


Figura 2.12: Evolución de la inteligencia artificial.

El ML y el DL son dos enfoques de la IA con diferentes ventajas. El ML tiende a ser más sencillo, necesita menos datos para funcionar y es más rápido de implementar, este enfoque emplea técnicas computacionales para mejorar o aumentar la propensión de los sistemas, a cambiar de manera adaptativa por medio de la experiencia que se presenta en forma de datos [60]. El objetivo principal del ML es estudiar, desarrollar y mejorar algoritmos que construyan modelos matemáticos capaces de entrenarse (una vez o continuamente) con datos relacionados con un contexto específico, para así inferir el futuro y tomar decisiones sin un conocimiento completo de todos los factores que puedan influir (elementos externos). Dependiendo del problema planteado y de los datos disponibles, ML puede tomar diferentes direcciones de aprendizaje, distinguiéndose tres tipos [61]:

- **Aprendizaje Supervisado:** un escenario supervisado se caracteriza por contar con un maestro o supervisor (etiquetas), cuya tarea principal es suministrar a los algoritmos una medida directamente comparable a los valores de salida, haciendo posible determinar el valor preciso de error. Se necesita de un conjunto de datos, conformando los datos de entrada y las salidas esperadas. Con base en esta información, los algoritmos pueden corregir sus parámetros para reducir la magnitud de una función de pérdida global.
- **Aprendizaje no supervisado:** este método se basa en la ausencia de un supervisor (etiquetas) y, como resultado, no es posible realizar comparaciones directas. Sin embargo, este tipo de algoritmos aprendizaje son de gran utilidad, cuando se desea hacer agrupar un conjunto de elementos en función de las similitudes que poseen.

- **Aprendizaje por refuerzo:** este enfoque de aprendizaje no cuenta con supervisores reales, aún cuando es un método basado en información proporcionada por el entorno. En este caso, la información es más cualitativa y no permite determinar una medida precisa de su error, pero sí una retroalimentación que suele designar recompensas y penalizaciones al perseguir un objetivo.

Entre las tareas de ML que se emplearán en esta investigación destaca principalmente la clasificación en escenarios supervisados, donde el objetivo particular es analizar los patrones de las señales de vibración en el sistema viga cantiléver para predecir el estado discreto (categorías o clases) de muestras nunca vistas. Algunos de los enfoques utilizados en este proyecto destacan por ser algoritmos clásicos con una eficiencia altamente probada, cuyos parámetros específicos se encuentran especificados en el capítulo 4. A continuación, en las siguientes subsecciones se da a conocer de manera general cada uno de los clasificadores implementados, además de algunas técnicas reducción de dimensionalidad empleadas en el proceso previo a la clasificación.

2.3.1. k-Vecinos más cercanos

La clasificación por vecinos más cercanos (*k-Nearest Neighbors*, KNN) es un método de aprendizaje supervisado basado en instancias que cataloga los datos según la clase a la que pertenecen sus iguales más próximos [62]. En lugar de crear un modelo KNN almacenan instancias (conocidas como vecinos), cuya información permite la clasificación durante la fase de pruebas. En términos más precisos, una instancia arbitraria se describe mediante el vector de características que conforma una muestra del conjunto de entrenamiento. En un espacio de n -dimensiones el algoritmo supone que todos los vectores de datos x_i corresponden a puntos del espacio de características con categorías y , en el cual los k -vecinos más cercanos se definen en términos de alguna una medida de similitud (métrica de distancia).

La Figura 2.13 ilustra la importancia de seleccionar adecuadamente el parámetro k (valor normalmente suministrado por el usuario), componente principal del método que indica el

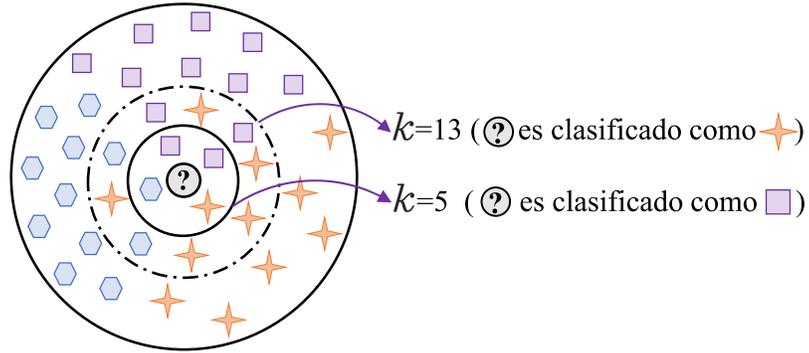


Figura 2.13: Clasificación de KNN para diferentes valores de k ; la muestra de ensayo se clasifica como “estrella” cuando $k=5$ o $k=13$ y se clasifica como “cuadrado” cuando $k=13$.

número de datos más cercanos a considerar en la votación por pluralidad que determina la etiqueta de una muestra desconocida [60]. El valor de k tiene un gran impacto en los resultados de clasificación, suele depender de los datos y puede determinarse mediante validación cruzada; una regla empírica típica es que $k \leq \sqrt{L}$, donde L es la cantidad de los datos observados [63]. De igual manera, la función de distancia también es esencial para el éxito de KNN, debido a que diferentes métricas de distancia (tales como las de la Tabla 2.2 para dos puntos (x_i, y_i)) producen “vecindades” significativamente distintas y, en consecuencia, resultados de clasificación distintos para un mismo problema.

Tabla 2.2: Métricas de distancia comúnmente utilizadas en KNN

Nombre	Expresión
Distancia Euclídeana	$d(x, y) = \sqrt{\sum_{i=1}^d (x_i - y_i)^2}$
Distancia Manhattan	$d(x, y) = \sum_{i=1}^d x_i - y_i $
Distancia Mahalanobis	$d(x, y) = \sqrt{(x - y)^T \Sigma^{-1} (x - y)}$
Distancia Coseno	$d = x \cdot y / (\ x\ _2 \ y\ _2)$

2.3.2. Máquina de vectores de soporte

Una Máquina de Vectores de Soporte (*Support vector machine, SVM*) es un algoritmo de aprendizaje supervisado que procura encontrar el mejor hiperplano de separación entre los datos según su clase o categoría [64]. Esta técnica se basa principalmente en un preprocesamiento de datos que de ser necesario transforma los patrones a un nuevo espacio de características en donde las dimensiones son generalmente mucho mayores a la que originalmente tenían (Figura 2.14a). De esta manera, los datos pueden separarse fácilmente mediante un simple límite de decisión plano o hiperplano [65]. En otras palabras, SVM utiliza el conjunto de datos de entrenamiento para encontrar en el espacio muestral de n -dimensiones un hiperplano de separación que divida los datos en subespacios, de tal forma que en cada subespacio creado domine una única categoría, lo cual permite la predicción de un dato desconocido [60]. Un hiperplano se describe por la ecuación 2.24, donde $\varphi(x_i)$ denota la función transformación del espacio de características aplicado a los datos de entrada x_i .

$$W^T \varphi(x_i) + b = 1 \quad (2.24)$$

Los parámetros W y b son parte del modelo; W es el vector normal que controla la dirección del hiperplano y la variable b conocida como sesgo o bias, representa la distancia entre el hiperplano y el origen [63]. Al tratarse de una clasificación binaria que utiliza la estrategia de uno contra todos, el hiperplano puede clasificar nuevas muestras en una de las dos categorías $y \in \{1, -1\}$ definidas por el valor del signo, la ecuación 2.24, tal y como se muestra en la Figura 2.14b. Los vectores de soporte (círculos punteados) son los patrones de entrenamiento transformados que definen el hiperplano de separación óptimo, representan los datos más difíciles de clasificar y por ende los que aportan más información a la tarea de clasificación [65].

El objetivo del entrenamiento de SVM es encontrar el hiperplano con el margen más grande (γ), entre los hiperplanos límites compuestos por los vectores de soporte; se espera que

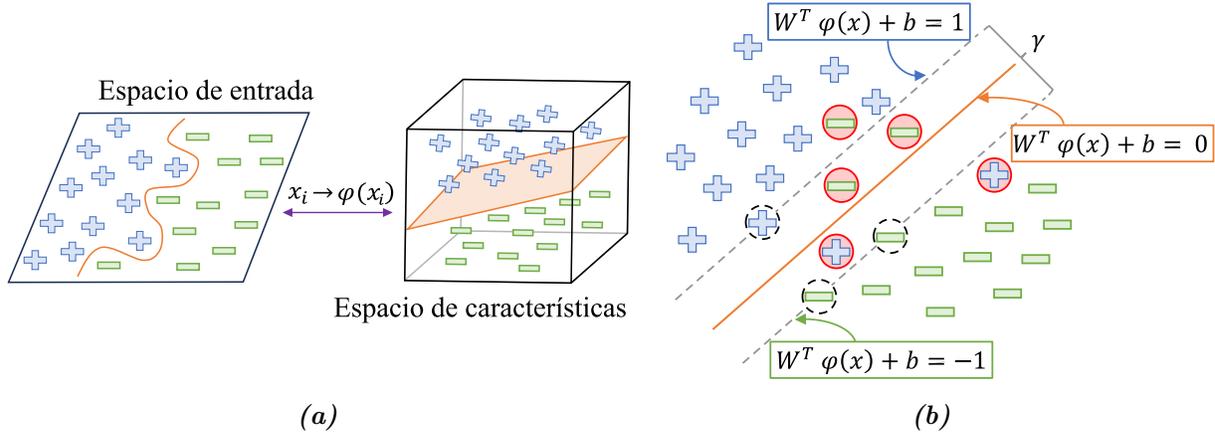


Figura 2.14: (a) Transformación del espacio de entrada a uno de mayor dimensión. (b) Separación de dos clases de datos en el espacio de características mediante una máquina de vectores de soporte de margen suave.

cuanto mayor sea el margen, mayor será poder de generalización, lo que significa que la probabilidad de una clasificación errónea disminuirá. Sin embargo, conseguir el mínimo error de generalización entre todos los hiperplanos posibles conlleva un problema de optimización de los parámetros (W, b) , es posible resolver este inconveniente en su forma original (2.25) o dual (2.26), mediante [60]:

$$\min_{W, b} \frac{1}{2} \|W\|^2 \quad (2.25)$$

Teniendo en consideración: $y_i(W^T \varphi(x_i) + b) \geq 1, \quad i = 1, 2, \dots, m.$

$$\max_{\alpha} \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j \nu_i \nu_j \varphi(x_i)^T \varphi(x_j) \quad (2.26)$$

La formulación dual se encuentra sujeta a: $\sum_{i=1}^m \alpha_i \nu_i = 0, \quad \alpha_i \geq 0, \quad i = 1, 2, \dots, m.$

En el caso de que los datos no sean linealmente separables, se requiere de una función no lineal $\varphi(\cdot)$ que transforme el espacio original a un espacio nuevo [63]. En su lugar se busca una función denominada kernel que corresponda al producto interno $K(x_i, x_j) = \varphi(x_i)^T \varphi(x_j)$,

algunas funciones de kernel típicas se incluyen en la Tabla 2.3. Aun así, cuando no se consigue separar perfectamente los subespacios de categorías, SVM puede permitirse cometer algunos errores mínimos (círculos rojos de la Figura 2.14b) que además ayudan a evitar el ajuste excesivo del modelo (*overfitting*), esta técnica se conoce como margen suave [60].

Tabla 2.3: Funciones de Kernel empleadas en SVM

Nombre	Expresión	Parámetros
Kernel lineal	$\kappa(x_i, x_j) = x_i^\top x_j$	
Kernel Polinomial	$\kappa(x_i, x_j) = (x_i^\top, x_j)^d$	$d \geq 1$ es el grado del polinomio
Kernel Gaussiano	$\kappa(x_i, x_j) = \exp\left(-\frac{ x_i - x_j ^2}{2\sigma^2}\right)$	$\sigma > 0$ es la anchura del núcleo gaussiano
Kernel Laplaciano	$\kappa(x_i, x_j) = \exp\left(-\frac{ x_i - x_j }{\sigma}\right)$	$\sigma > 0$
Kernel Sigmoide	$\kappa(x_i, x_j) = \tanh(\beta x_i^\top x_j + \theta)$	\tanh es la función tangente hiperbólica $\beta > 0, \theta < 0$

2.3.3. Árboles de decisión

Un árbol de decisión (*Decision Tree*, DT) es un algoritmo de aprendizaje supervisado que estratifica o segmenta el espacio predictor en una serie de regiones más simples; se utiliza tanto para tareas de clasificación como de regresión [66]. Este algoritmo representa las elecciones y los resultados en forma de un árbol con nodos y ramas; cada nodo representa una elección o un suceso, y cada rama representa las reglas o condiciones de la elección [60]. La configuración general de un DT se muestra en la Figura 2.15, compuesta por un nodo raíz que desciende por las ramas del árbol, proporcionando información a los nodos internos o de decisión y a los nodos terminales, también conocidos como hojas del árbol [66]. Los nodos raíz y de decisión realizan evaluaciones para formar subconjuntos homogéneos (sub-árboles), mientras que los nodos hojas representan las categorías o clases posibles del conjunto de datos.

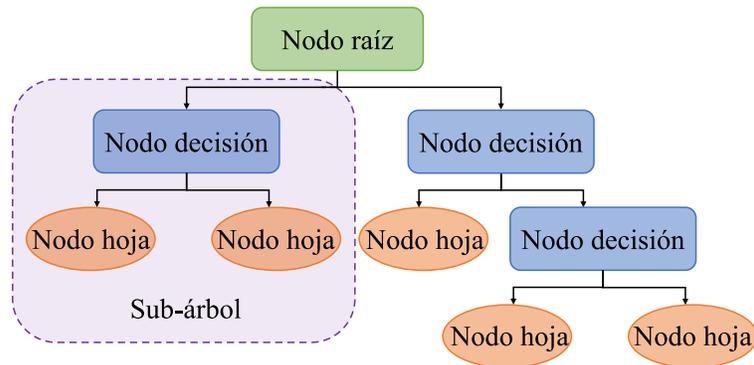


Figura 2.15: Estructura general de un árbol de decisión.

El proceso de clasificación de DT se lleva a cabo de manera segmentada, con etapas de preclasificación en las que se verifican primero el nodo raíz y luego los de decisión. Estos nodos están definidos por un subconjunto de categorías, un subconjunto de características y una regla de decisión, propias al nodo y basadas en el conjunto de entrenamiento [61]. El número de subcategorías disminuye a medida que avanza por las ramas hasta el nodo terminal al que pertenece un dato x_i de una categoría y_i . Para la división de subcategorías en DT, los criterios más populares son la entropía, ganancia de información y la impureza de Gini [67]. Los métodos basados en árboles son simples y fáciles de interpretar. Sin embargo, en algunos casos se puede acabar con estructuras muy complejas que no permiten una buena generalización.

2.3.4. Técnicas de reducción de dimensionalidad

En el proceso de entrenamiento de modelos de clasificación, es esencial disponer de datos de alta calidad para lograr resultados óptimos con un menor costo computacional. En este contexto, las técnicas de reducción de dimensionalidad ofrecen enfoques que garantizan una representación eficiente de los datos, permitiendo a los modelos de ML un mayor poder de generalización en el proceso de clasificación. La reducción dimensional implica la proyección de los datos originales a un espacio de menor dimensión, eliminando la varianza no informativa, o identificando un subespacio donde residan de mejor manera los datos [68]. A continuación,

se exploran dos técnicas clásicas de transformación lineal (Figura 2.16a), utilizadas para la reducción de atributos en etapas posteriores del proyecto:

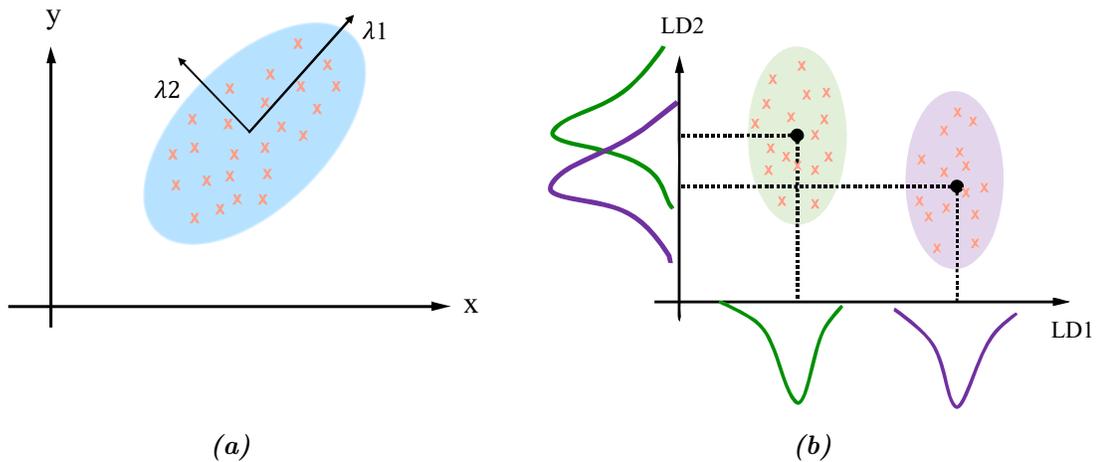


Figura 2.16: Ilustración de las proyecciones de los datos con los algoritmos de reducción de dimensionalidad utilizados. (a) PCA: representación de los ejes de componentes que maximizan la varianza. (b) LDA: maximización de los ejes de componentes para la separación de clases.

Análisis de componentes principales

El análisis de componentes principales (*Principal Components Analysis*, PCA) es un algoritmo no supervisado de reducción dimensionalidad lineal, que utiliza técnicas de proyección estadísticas para transformar los datos a un nuevo subespacio de menor dimensionalidad [69, 70]. Este proceso implica la generación de variables denominadas componentes principales, las cuales son combinaciones lineales de las características originales; estos componentes se organizan de tal manera que reflejen la mayor cantidad de variabilidad presente en los datos, sin correlacionar la información entre ellos [71]. En otras palabras, el objetivo principal de PCA es la maximización de la varianza, a la vez que se reduce la covarianza entre variables. El mapeo lineal de los datos que realiza PCA se obtiene a partir de la eige-descomposición de la matriz de covarianza C .

$$C = V\Lambda V^T \quad (2.27)$$

El parámetro V corresponde a la matriz de vectores propios, para el cual cada columna es un vector propio, y Λ es una matriz diagonal con los valores propios en orden descendente [72]. Para seleccionar de componentes que denotarán la nueva dimensionalidad de los datos, se toman en cuenta los k vectores propios correspondientes a los k valores propios más significativos. Finalmente, en términos matemáticos, la transformación de PCA al espacio objetivo se realiza multiplicando los puntos originales X por la matriz de vectores propios truncada V_k , como se muestra en la ecuación siguiente:

$$\text{PCA}(X) = XV_k \quad (2.28)$$

Este proceso crea un conjunto de componentes que son ortogonales entre sí y capturan la mayor parte de la variabilidad en los datos originales. PCA puede ser utilizado en la visualización de datos, la reducción de dimensionalidad previo al entrenamiento de los modelos de ML, asegurando una representación precisa de los datos [71]. Sin embargo, es importante destacar que para datos no correlacionados, esta estrategia no es muy precisa.

Análisis discriminante lineal

Otro enfoque popular en la reducción de la dimensionalidad, es el análisis discriminante lineal (*Linear Discriminant Analysis*, LDA). Este algoritmo estadístico de aprendizaje supervisado genera una proyección lineal que maximiza la separación entre las medias de las clases, a la vez que minimiza la varianza en torno a esas medias [71]. LDA proyecta los datos de entrada a un subespacio de menor dimensión, formado por la combinación lineal de las variables que resulten en las direcciones más discriminantes. La formulación original del LDA esta basada en el criterio discriminante de Fisher [69], para un arreglo de variables independientes X y múltiples grupos con k clases, se calculan las siguientes medidas de dispersión:

$$S_B = \sum_{i=1}^k (\mu_i - \bar{x})(\mu_i - \bar{x})^T \quad (2.29)$$

$$S_W = \sum_{i=1}^k \sum_{x \in C_i} (x - \mu_i)(x - \mu_i)^T \quad (2.30)$$

Las ecuaciones 2.30 definen la dispersión entre clases S_B y dispersión dentro de clases S_W . Por su parte la variable \bar{x} representa la media global de los puntos de datos X , mientras que μ_i es la media de los puntos de datos (x) que pertenecen a la clase C_i [68]. Con el objetivo de encontrar la proyección de las características óptima, LDA hace uso de la eigen-descomposición de $S_W^{-1} S_B$, seleccionando los vectores propios asociados a los valores propios más grandes (direcciones discriminantes), los cuales transmiten la información más significativa sobre la distribución de los datos [73]. Finalmente, los datos originales \mathbf{x} se proyectan en el espacio de las direcciones discriminantes W para obtener las características transformadas:

$$\text{LDA}(x) = W^T x \quad (2.31)$$

Las características transformadas resultantes son versátiles y encuentran aplicaciones tanto en la clasificación de datos como en la visualización de la distribución de las clases. Al igual que PCA estas nuevas características proporcionan una representación intuitiva y detallada de la estructura y la separabilidad de los datos, lo que simplifica significativamente la interpretación de los patrones inherentes en el conjunto de datos.

2.3.5. Métricas de evaluación para los modelos de clasificación

Evaluar la eficacia de un modelo de aprendizaje requiere mediciones de desempeño que puedan cuantificar la capacidad de generalización. En otras palabras, la capacidad de un modelo ante nuevas situaciones y datos que no fueron incluidos en el proceso de aprendizaje [60]. Además de eso, las métricas de evaluación son de gran utilidad en la comparación del rendi-

miento entre distintos modelos de clasificación o técnicas de aprendizaje automático [74]. La calidad del modelo es un concepto relativo que depende del algoritmo, sus parámetros, los datos utilizados para el entrenamiento y los requisitos de la tarea.

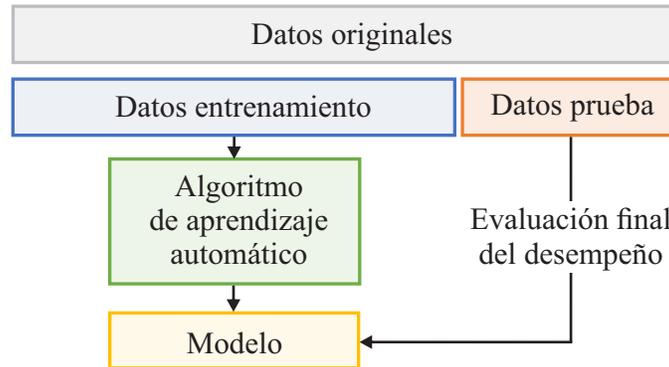


Figura 2.17: Proceso de interacción entre los datos y los algoritmos ML.

En el proceso de evaluación del rendimiento de un modelo se emplean diferentes estrategias de validación. Cada estrategia implica dos conjuntos de datos diferentes, tal y como se muestra la Figura 2.17, datos de entrenamiento y el de datos de prueba. El primero, como su nombre lo indica, se utiliza para construir o entrenar el modelo; este conjunto de datos debe ser lo suficientemente grande para cubrir todos los patrones de muestras, garantizando la estabilidad y confiabilidad del aprendizaje [74]. El conjunto de prueba, por otro lado, se utiliza para verificar la eficacia del modelo creado ante casos desconocidos, requiere de datos suficientes para producir resultados estadísticamente representativos del conjunto de datos global [75].

		Valores del modelo	
		Positivo	Negativo
Valores del verdaderos	Positivo	TP	FP
	Negativo	FN	TN

Figura 2.18: Matriz de confusión binaria.

Los resultados de un modelo de aprendizaje supervisado normalmente se representan mediante una matriz de confusión, ya que contiene los datos necesarios sobre el rendimiento del modelo. Como se muestra en la Figura 2.18 de referencia, la matriz de confusión se representa como una tabla que registra el número de ocurrencias entre la clasificación real (filas de la matriz) y la clasificación prevista (columnas de la matriz). Los elementos en la diagonal principal, verdaderos positivos (TP) y falsos positivos (TN) se consideran correctamente clasificados. Mientras que los elementos fuera de la diagonal principal representan los casos incorrectamente clasificados, que se dividen en falsos positivos (FP) y falsos negativos (FN). A partir de los elementos de la matriz de confusión derivan una serie de métricas, entre las que destaca la exactitud (*Accuracy, Acc*):

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.32)$$

La exactitud es una medida general de cuánto predice correctamente el modelo sobre un conjunto completo de datos, en el que cada dato contribuye de igual forma. Como se muestra la ecuación 2.32, la exactitud considera la suma de elementos verdaderos (diagonal principal) en el numerador y la suma de todas las entradas de la matriz de confusión en el denominador [75]. Para casos multiclase el cálculo de la exactitud utiliza del mismo razonamiento de la matriz binaria. Adicionalmente, es conveniente evaluar el comportamiento estadístico de las métricas en múltiples ejecuciones del algoritmo que, bajo las mismas premisas, construye los diferentes modelos a calificar. Para interpretar las tendencias a lo largo de las ejecuciones se implementan las herramientas estadísticas clásicas de medida de ubicación (media) [76, 77], medidas de dispersión (desviación estándar, coeficiente de variación) [77, 78], medidas de ubicación relativa (rango intercuartílico) [78], y diagnóstico de gráficos (gráficos de caja) [76, 78].

Capítulo 3

Metodología del arreglo óptico

Este capítulo presenta la metodología para detectar y recopilar las señales de vibración obtenidas por un sistema de fibra óptica, las cuales se utilizarán para construir la base de datos que alimentará los algoritmos de aprendizaje automático. Para comenzar, se proporciona una descripción detallada de la configuración experimental y de cada uno de los componentes involucrados. Posteriormente, se analiza el funcionamiento del sistema reflectivo y, por último, se presenta la validación de las mediciones experimentales obtenidas a través del arreglo óptico.

3.1. Configuración experimental

El arreglo fibra óptica empleado para la adquisición de las señales de vibración es el mostrado en la Figura 3.1. Al aplicar un estímulo externo a la viga de aluminio tipo cantiléver, se genera un movimiento oscilatorio que es captado por una fibra óptica multimodo (FG105UCA). Mediante un acoplador de tres puertos (TM105R5F1A) es posible colectar parte de la luz que sale de la fibra en dirección a la viga. La luz emitida desde el puerto se propaga a través del medio externo hacia la superficie reflectante, luego de reflejarse en la superficie, parte de la luz emitida regresa a la fibra. Dependiendo de la separación con la viga, será la intensidad de la luz reflejada; por lo tanto, la luz colectada estará en función del desplazamiento vibratorio.

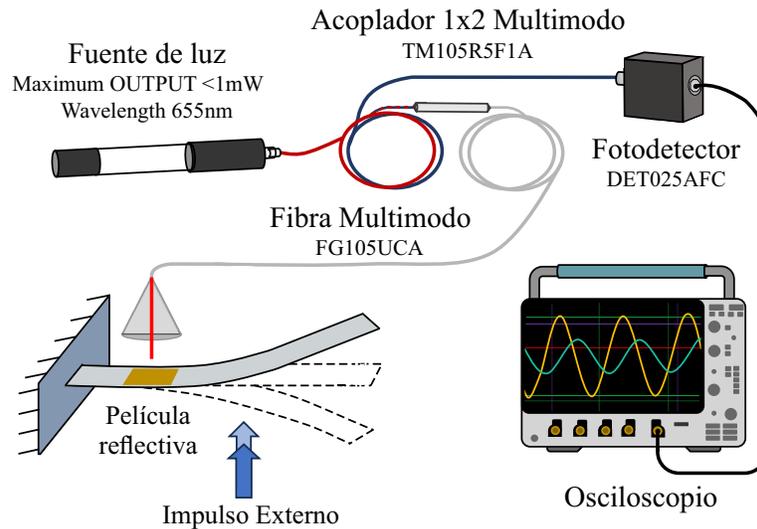


Figura 3.1: Esquema de adquisición, configuración experimental.

El acoplador de fibra multimodo (1x2), permite direccionar en partes iguales, la emisión y recepción de las señales que viajan simultáneamente por la fibra. Un extremo del dispositivo está conectado a una fuente de luz láser con emisión centrada en 655nm, encargada de suministrar la intensidad lumínica que se refleja sobre la cinta de cobre dispuesta en la superficie de la viga. Al mismo tiempo, en el otro puerto del acoplador se lleva a cabo el registro e interpretación de los cambios de intensidad luminosa provocados por el movimiento de la viga. La adquisición de datos se realizó utilizando un osciloscopio Tektronix modelo DPO5054B, con un ancho de banda de 500MHz y una velocidad de muestreo de 5GS/s, el cual se encarga de trazar y almacenar las señales de intensidad luminosa que el fotodetector (DET025AFC) transforma a señal eléctrica (voltaje).

3.2. Descripción de elementos empleados

A continuación, se describen en detalle los componentes del arreglo de fibra óptica reflectivo utilizado en el proyecto. Se abordará cada elemento individualmente, profundizando en sus características y funciones específicas.

3.2.1. Acoplador 1x2 Multimodo

El acoplador multimodo TM105R5F1A de la marca Thorlabs, empleado en el arreglo, presenta una configuración en forma de derivación en Y (1×2), lo que permite la emisión y recepción simultánea de señales a través de una sola fibra óptica. Este componente esencial del esquema de configuración asegura un direccionamiento equitativo de las señales, con una distribución de proporciones iguales (50 : 50) para los puertos de entrada de luz y salida de intensidad de luz colectada, identificados como puertos 1 y 2 respectivamente, tal y como se muestra en la Figura 3.2.

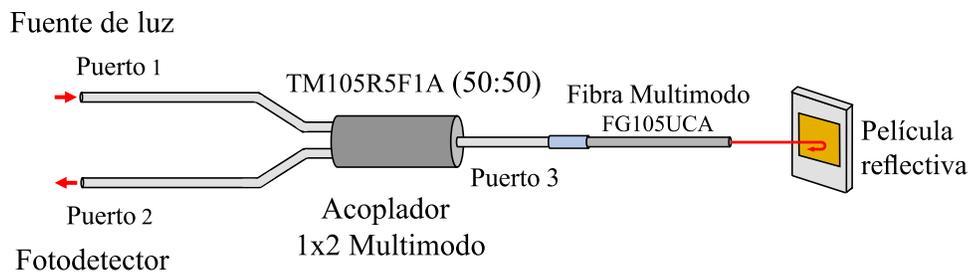


Figura 3.2: Representación del uso del Acoplador en la configuración experimental.

La fibra óptica multimodo utilizada en el diseño acoplador tiene un núcleo de sílice de $105\mu\text{m}$ de diámetro y una apertura numérica de 0.22 NA. Esta fibra tiene características idénticas a la fibra FG105UCA que se empalma en el tercer puerto del dispositivo [79], permitiendo aumentar la distancia de maniobra y posibilitando la exposición de la punta de la fibra que emitirá y recopilará la luz. La Tabla 3.1 muestra las características del acoplador y la fibra utilizada [80, 79]. Para la mitad del rango de funcionamiento del dispositivo a 650nm se presenta una respuesta con longitud de onda muy plana y bajas pérdidas.

Tabla 3.1: Características del acoplador TM105R5F1A de Thorlabs.

Especificaciones	Valor
Rango de longitud de onda	400-900 nm
Relación de acoplamiento	50:50
Tolerancia de relación de acoplamiento	$\pm 5.0\%$
Exceso de pérdida	< 0.6 dB (Typ.)
Pérdida óptica de retorno	≤ 4.2 dB / ≤ 4.2 dB
Temperatura de funcionamiento	-45°C a 85°C
Temperatura de almacenamiento	-45°C a 85°C
Dimensiones	56.1 x 35x 20.3mm
Especificaciones de la fibra	
Diámetro del núcleo	$105\mu\text{m}$
Diámetro del revestimiento	$125\mu\text{m}$
Material del núcleo	Sílice puro
Material de revestimiento	Sílice dopada con flúor

3.2.2. Fuente de Luz

Como fuente emisora de luz se utilizó un localizador visual de fallas (*Visual Fault Locator*, *VFL*) de la marca Cruiser, herramienta compacta y económica, diseñada originalmente para diagnosticar problemas de conectividad en cables de fibra óptica [81]. Sin embargo, en la configuración experimental se le dio un uso diferente, aprovechando la reflexión de luz coherente altamente visible para inferir los desplazamientos que se producen en la viga cantiléver. El dispositivo VFL cuenta con un diodo láser de larga duración, que emite un haz de luz roja en el espectro visible a una longitud de onda constante de 655nm y una potencia de salida máxima de 1mW. La salida del dispositivo se aprecia en la Figura 3.3, respuesta capturada mediante un analizador de espectros ópticos. Otras propiedades se especifican en la tabla 3.2.

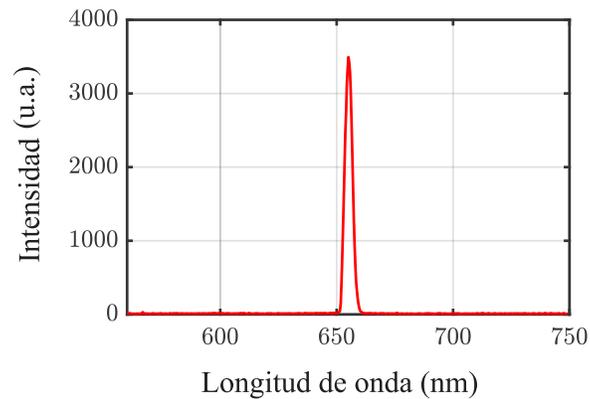


Figura 3.3: Espectro típico de la fuente de luz centrado en 655nm.

Tabla 3.2: Características de la fuente de luz.

Especificaciones	Valor
Longitud de onda nominal	$650 \pm 10\text{nm}$
Potencia máxima de salida	1mW
Temperatura de funcionamiento	-10°C a 60°C
Temperatura de almacenamiento	-20°C a 70°C
Modo de operación	Pulsado (2Hz) y onda continua
Tipo de conector	Universal de 2.5mm
Tipo de batería	2 AA
Dimensiones	175 x 26x 26mm

3.2.3. Fotodetector

Para convertir la señal óptica en una señal eléctrica, se emplea un fotodiodo DET025AFC(/M) de la marca Thorlab. Los fotodetectores del tipo fotodiodos son dispositivos semiconductores, que aprovechan la fotoexcitación de portadores eléctricos para producir una fotocorriente proporcional a la intensidad de la luz absorbida (o incidente).

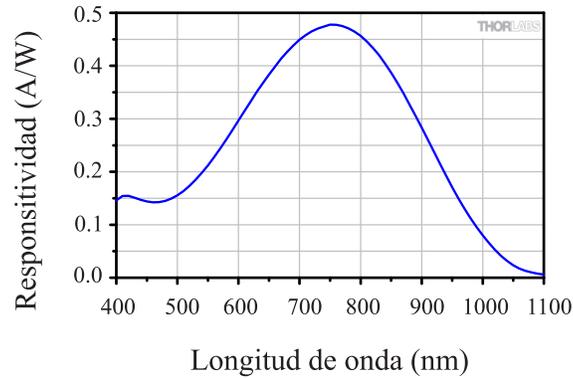


Figura 3.4: Curva de responsividad del fotodetector DET025AFC de Thorlabs.

La capacidad de respuesta (responsividad) entre la fotocorriente generada y la potencia óptica incidente, para el rango espectral de funcionamiento (400 – 1100nm), se muestra en la figura 3.4. Este componente, cuenta con una alta velocidad de respuesta y un ancho de banda máximo de 2GHz, especificaciones adicionales del fotodetector [82], se plasman en la Tabla 3.3.

Tabla 3.3: Características del fotodetector DET025AFC de Thorlabs.

Especificaciones	Valor
Longitud de onda	400 – 1100 nm
Ancho de banda	2 GHz
Responsividad Máxima	0.46 A/W
Tensión de salida	2 V (Max)
Umbral Daños	18 mW
Temperatura de funcionamiento	0°C a 40°C
Temperatura de almacenamiento	0°C a 40°C
Tipo de batería	A23, 12V _{DC} , 40mAh
Dimensiones	56.1 x 35x 20.3mm

3.3. Análisis del sistema reflectivo

El esquema de modulación de intensidad de luz por reflexión mediante una sola fibra óptica encargada de la Trasmisión-Recepción de señales, se presenta en la Figura 3.5. El comportamiento del perfil de distribución de intensidad de la luz transmitido se propaga de manera cónica según una función de haz gaussiano, desde la punta expuesta de la fibra hasta la superficie reflectante y viceversa. En una primera fase, el haz de luz sale de la fibra con intensidad luminosa máxima de la fuente (I_0), un radio inicial del campo modal (ω_0) y ángulo de divergencia (γ) (Transmisión virtual), viajando con dirección a la película reflectiva a lo largo del eje principal de la fibra a una distancia d . Seguidamente, el haz de luz es reflejado especularmente, regresa a la fibra de manera perpendicular y simétrica a su eje, recorriendo nuevamente la distancia inicial ($2d$).

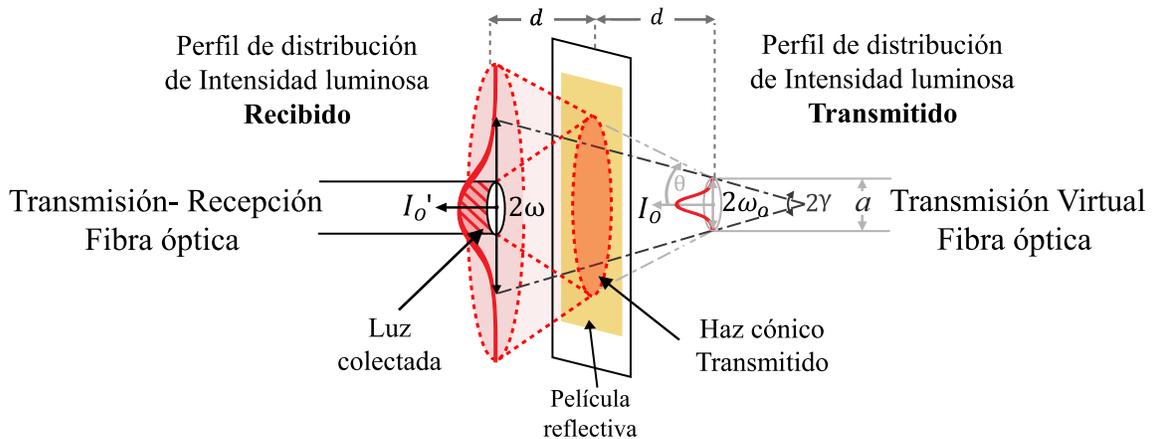


Figura 3.5: Transmisión y recepción del haz gaussiano.

En la segunda etapa del sistema se colecta parte de la intensidad luminosa proyectada por la superficie reflectiva; en parte, gracias al amplio valor de apertura numérica de la fibra utilizada (FG105UCA) que genera un mayor cono de aceptación a la entrada del arreglo ($2 \cdot \theta$). Independientemente de las características de la fibra, la intensidad luminosa colectada varía en función de la distancia al reflector. A medida que aumenta la distancia, el radio del haz gaussiano se va tornando más amplio (ω), mientras que la irradiancia del mismo disminuye

(I'_0); conforme crece la distancia, el haz se vuelve más difuso, lo que ocasiona mayores pérdidas. Sin embargo, cuando las variaciones de distancia son pequeñas, se supone que habrá un cambio lineal tanto en la intensidad como en la amplitud del haz gaussiano [83]. Por esta razón, se ubica la superficie reflectante cerca del extremo fijo de la viga, donde los cambios de distancia son mínimos, tal y como se aprecia en la Figura 3.1 del esquema del arreglo.

En términos matemáticos, para determinar la intensidad luminosa $I(r)$ transmitida se puede hacer uso de las características geométricas del sistema [83, 84]. El perfil de distribución de la irradiancia de un haz gaussiano se presenta según la ecuación polar 2.1 del Capítulo 2.

$$I(r) = I_0 e^{-\frac{2r^2}{\omega^2}} \quad (3.1)$$

El nuevo valor de anchura gaussiana ω se determina a partir de trigonometría del sistema, plasmada en la Figura 3.5. Donde d como se ha mencionado anteriormente, es la distancia de separación entre la fibra óptica y la película reflectiva. Para nuestro arreglo experimental, luego de múltiples ensayos se estableció un valor de 5 mm de distancia fija.

$$\omega = 2 \cdot d \cdot \tan(\gamma) + \omega_o \quad (3.2)$$

Por consiguiente, la intensidad luminosa transmitida I'_0 se puede calcular sustituyendo el nuevo valor de ω en la ecuación 3.1. No obstante, la intensidad luminosa recibida por la fibra es considerablemente menor (como se muestra en la sección con franjas rojas en la Figura 3.5), dado que solamente una pequeña cantidad de la luz puede retornar a través de la fibra debido a las limitaciones impuestas por su diámetro (a). Por lo tanto, el flujo luminoso recibido se puede definir mediante la ecuación 3.3, como el flujo de luz de transmitido, según los límites determinados por el diámetro de la fibra.

$$\Phi_{col} = \int_0^{\frac{a}{2}} I'_0 \cdot e^{-\frac{2r^2}{\omega^2}} \cdot 2\pi \cdot r dr = \frac{\pi}{2} \cdot \omega^2 \cdot I'_0 \left(1 - e^{-\frac{a^2}{2\omega^2}} \right). \quad (3.3)$$

En consecuencia, el flujo de luz recibido se ve reflejado en la salida de tensión del fotodetector V_{out} , el cual se encuentra en función de los valores I'_0 y ω , lo que implícitamente lo hace dependiente de la distancia entre la superficie reflectiva y el extremo de la fibra (d). La salida de tensión teórica que puede detectarse a partir de un circuito optoelectrónico ideal viene dada por la siguiente expresión [83]:

$$V_{out} = \frac{\pi}{2} \cdot k_v \cdot \sigma_r \cdot \omega^2 \cdot I'_0 \left(1 - e^{-\frac{a^2}{2 \cdot \omega^2}} \right) \quad (3.4)$$

Donde k_v es un factor de conversión que relaciona el flujo luminoso con la salida de tensión, y σ_r es un parámetro que representa las pérdidas de luz de la fibra debidas a la flexión y a la desalineación de la fibra en la fibra óptica receptora.

3.4. Validación del arreglo

El arreglo óptico, constituido por la configuración experimental mostrada en la Figura 3.1, es capaz de capturar las señales de vibración provenientes de la viga cantiléver por medio de la modulación de intensidad. La prueba de validación del sistema implica la exposición del cantiléver a una perturbación mediante la aplicación de una fuerza externa. La viga que inicialmente estaba en reposo experimentará oscilaciones amortiguadas alrededor de su punto de equilibrio. En este sentido nos interesa comprobar la frecuencia fundamental o del primer modo de vibración del sistema viga cantiléver, para ello se emplea la ecuación 2.23 con las características estructurales plasmadas en la Tabla 3.4 presentada a continuación:

Según las características de la viga se obtiene un valor específico de frecuencia fundamental teórico asociado al sistema (Tabla 3.5). A modo de validación se varía la longitud de la viga en siete ocasiones desde 160mm hasta 220mm con paso de 10mm, al modificar el área transversal rectangular de la viga se generan diferentes valores de frecuencia que posibilitan

Tabla 3.4: Características de la viga cantiléver.

Dimensiones geométricas	Símbolo	Valor
Ancho	b	18.4 mm
Alto	h	2.72 mm
Longitud	L	160-220 mm
Propiedades del Aluminio 6061	Símbolo	Valor
Módulo elástico	E	$6.9 \times 10^{10} \text{ Nw/m}^2$
Densidad	ρ	2700 Kg/m^3

una comparación más amplia entre el comportamiento teórico y el experimental en diferentes configuraciones. La Figura 3.6 muestra las fotografías del montaje experimental; en los anexos se suministra el plano bajo el cual fueron modeladas las vigas utilizadas a lo largo del proyecto.

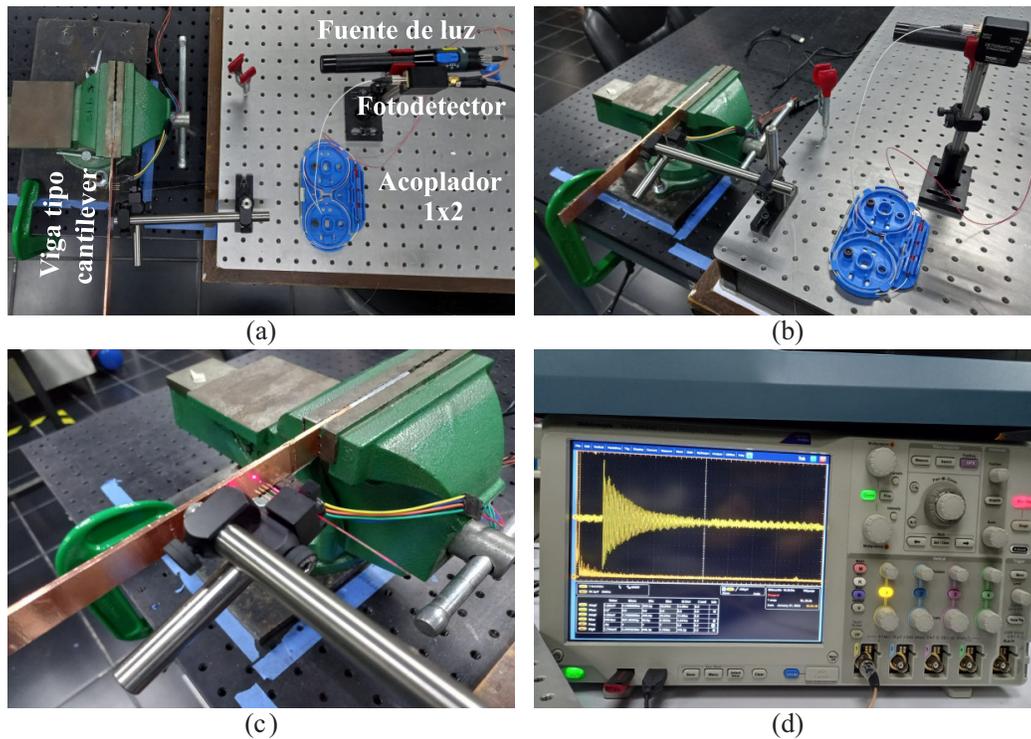


Figura 3.6: Montaje experimental del arreglo óptico. (a) Vista superior del montaje. (b) Vista lateral del montaje. (c) Sistema en funcionamiento, emisión-recepción de luz sobre la viga cantiléver. (d) Señal de vibración obtenida por el arreglo.

Las señales registradas en el arreglo experimental provienen del voltaje de salida del fotodetector, el cual oscila entre valores positivos y negativos, reflejando fielmente el fenómeno vibratorio que experimenta el sistema. Como se puede observar en la Figura 3.7, estas señales se encuentran en el dominio del tiempo, en ellas se aprecia el instante donde el cantiléver experimenta la perturbación, seguido por el retorno de la viga a su estado de reposo.

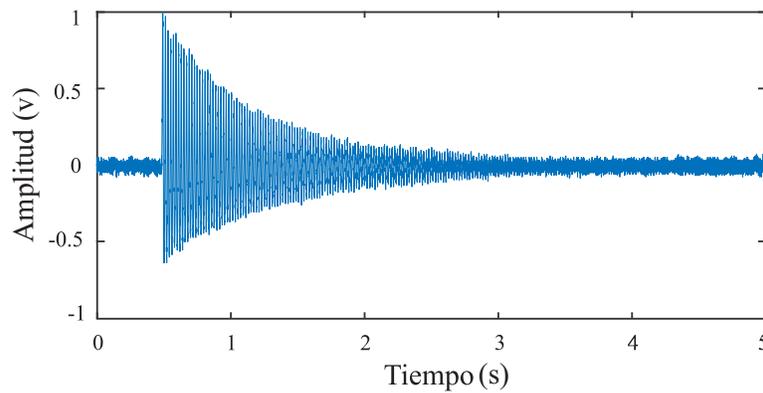


Figura 3.7: Señal de vibración obtenida mediante el arreglo experimental.

Para verificar la frecuencia fundamental experimental se aplica la transformada rápida de Fourier (*Fast Fourier Transform, FFT*) a los datos recolectados. La FFT es un algoritmo diseñado para calcular de forma eficiente la Transformada de Fourier Discreta de una señal digital, para una descomposición de la señal en sus componentes de frecuencia, permitiendo analizar su contenido frecuencial. Para obtener una explicación más detallada sobre el funcionamiento y la teoría subyacente de la FFT, consulte [85].

Los resultados gráficos de las FFT para las señales de vibración normalizadas, al aumentar la longitud del cantiléver se muestran en la Figura 3.8, donde los valores picos indican las frecuencias fundamentales, y el cómo se desplazan gradualmente hacia la izquierda conforme aumenta la longitud de la viga. Resultados más concretos de aplicar la FFT a las señales capturadas con el arreglo óptico se presentan en la Tabla 3.5. Esta Tabla proporciona tanto los valores teóricos como los experimentales de frecuencia correspondientes a las longitudes estudiadas para el sistema. Los valores experimentales se derivan del promedio de las FFT calculadas a partir de 50 señales de vibración recolectadas en cada caso de estudio.

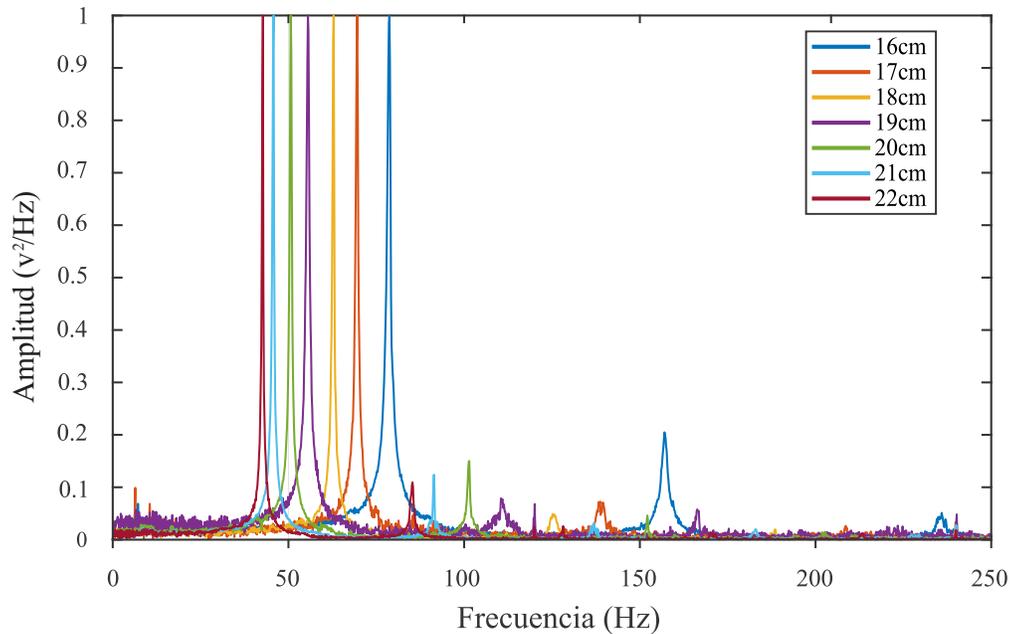


Figura 3.8: Transformada rápida de Fourier para diferentes longitudes de la viga cantiléver.

Tabla 3.5: Resultados de los valores reales y experimentales de la frecuencia.

Longitud del cantiléver	Valor teórico	Valor experimental	Error relativo
160 mm	78.8544 Hz	82.4413 Hz	4.5488 %
170 mm	71.3959 Hz	73.0276 Hz	2.2855 %
180 mm	62.0422 Hz	65.1388 Hz	4.9911 %
190 mm	55.5511 Hz	58.4625 Hz	5.2409 %
200 mm	52.4902 Hz	52.7624 Hz	0.5186 %
210 mm	47.2717 Hz	47.8571 Hz	1.2383 %
220 mm	44.0979 Hz	43.6053 Hz	1.1170 %

El valor experimental de frecuencia para las señales de vibración capturadas por el arreglo reflectivo es similar al valor teórico derivado de las propiedades de la viga, presentando un error relativo inferior al 5 %. Para el intervalo de longitudes de prueba, la frecuencia del sistema decae casi a la mitad de su valor inicial, presentando resultados experimentales más próximos al valor teórico en las últimas tres variaciones con un error cercano al 1 %.

La Figura 3.9 ilustra gráficamente el comportamiento de las frecuencias, tanto teóricas como experimentales, mostradas en la Tabla 3.5.

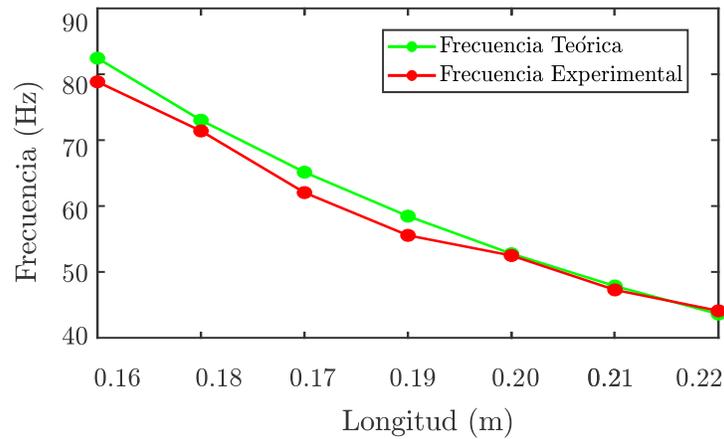


Figura 3.9: Variaciones de frecuencia teórica y experimental según la longitud de la viga.

Los resultados de la validación demuestran la capacidad del arreglo óptico en la adquisición de señales de vibración. La calidad de las aproximaciones obtenidas proporcionan una base sólida para la siguiente fase del proyecto, donde se extraerán patrones de información de las señales capturadas, con el fin de conocer el estado del sistema viga cantiléver.

Capítulo 4

Procesamiento y análisis de datos

En este capítulo se describe todo lo relacionado con el procesamiento y análisis de las señales de vibración adquiridas por el arreglo óptico. A partir de esta etapa, las señales se convierten en datos con información del comportamiento del sistema viga cantiléver. En primer lugar, se describe el problema a estudiar y se detalla la metodología utilizada para recopilar y organizar los datos. Posteriormente, se detallan cada uno de los procesos involucrados en la estrategia de trabajo propuesta en la Figura 4.1. Esto abarca los conjuntos de características utilizados para representar las señales, las etapas de preprocesamiento y, finalmente, se exponen los aspectos clave de los algoritmos de aprendizaje empleados en la clasificación de fallas.

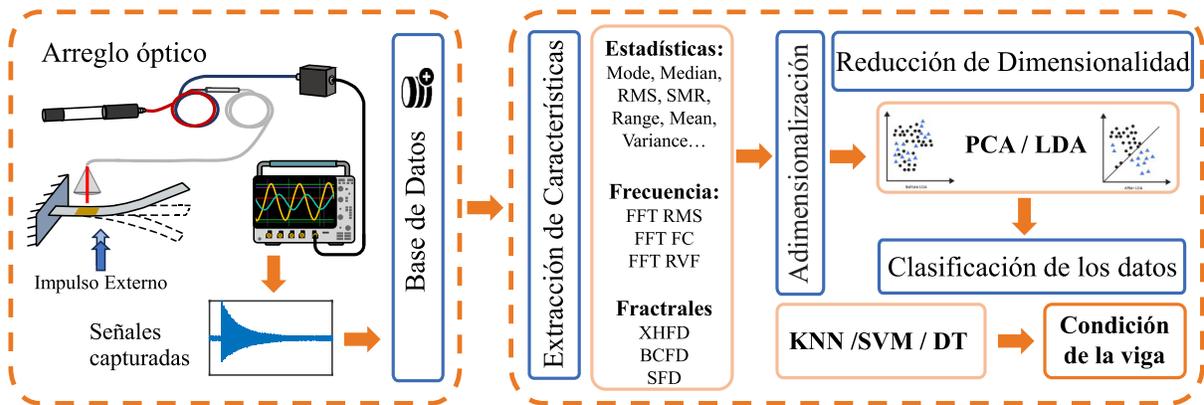


Figura 4.1: Metodología propuesta para la clasificación de daños.

En cuanto a las especificaciones del entorno de ejecución, todos los análisis realizados durante este proyecto se llevaron a cabo utilizando Matlab R2022b en una computadora ASUS Vivobook 15K513 equipada con un procesador Intel(R) Core(TM) i5-1135G7 @2.40GHz de 11^a generación, 16 GB de RAM y sistema operativo Windows 10 Home de 64 bits.

4.1. Base de datos

En el presente proyecto se plantea la creación de una base de datos a partir las señales de vibración adquiridas por el arreglo reflectivo de fibra óptica descrito en el Capítulo 3. Con la validación del comportamiento de frecuencia de las señales detectadas por el sistema óptico, se comprueba la veracidad de la información contenida en las señales. Fundamentado en este hecho, se procede a recolectar nuevos datos (señales de vibración) para diferentes configuraciones y condiciones del sistema viga cantiléver que no tienen una respuesta previamente analizada.

Basándose en la revisión de investigaciones del comportamiento vibratorio de daños en vigas cantiléver [86, 87], se propone someter el sistema de estudio a fisuras o grietas (*cracks*). Está demostrado que la presencia de grietas altera significativamente la respuesta dinámica de los sistemas y hace que cualquier tipo de estructura se aleje del correcto funcionamiento. Reproduciendo de manera general y bajo nuestros propios criterios lo realizado por los autores [86, 87], se generan grietas artificiales en las tres vigas modeladas para esta investigación. Siguiendo la estructura de la Figura 4.2 se contemplan en una primera fase variaciones en la localización de la grieta y posteriormente su profundidad, imitando así el impacto que tiene el paso del tiempo en la condición de los daños.

El proceso de adquisición de las señales que componen la base de datos comienza con la exposición de la viga a una perturbación externa, lo que provoca una respuesta vibratoria que es detectada por el arreglo óptico y capturada por el osciloscopio. La recopilación de datos inicia con el estado sano de las vigas (1, 2, 3), al igual que en la validación del arreglo

se registran datos con diferentes proporciones de área transversal, con el objetivo de obtener datos de sistemas ligeramente diferentes. Con este fin, la longitud de la viga se varía de 160 mm a 220 mm, aumentado en pasos de 10 mm después de capturar 50 señales correspondientes a cada longitud. El proceso se repite hasta llegar al final del rango de prueba con un total de 350 datos recolectados.

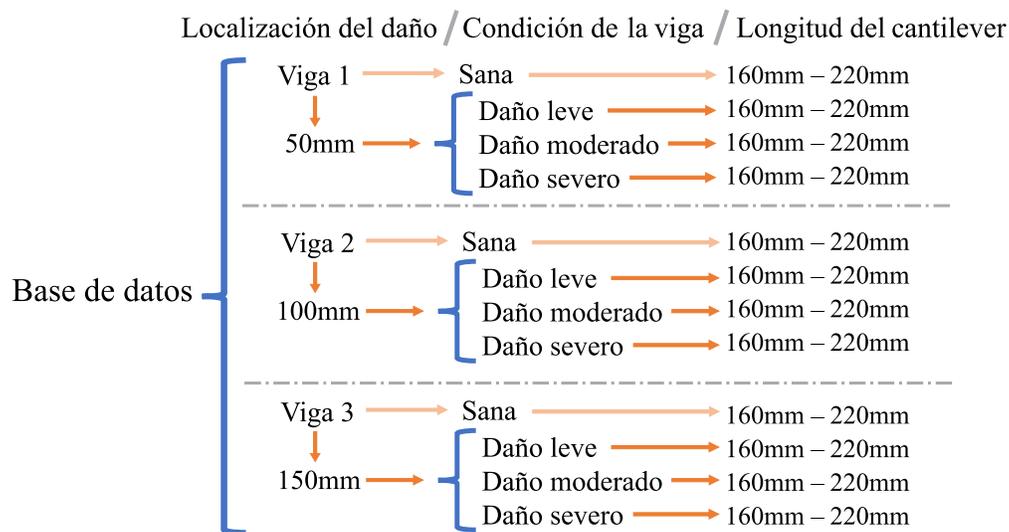


Figura 4.2: Estructura de la base de datos.

Luego de almacenar los datos del estado sano se procede a efectuar una grieta de aproximadamente 4.5 mm de profundidad en cada una de las vigas, este primer daño lo denominaremos para efectos de la tesis como “daño leve” y equivale a una afectación del 25 % del ancho total de la viga. La localización de la grieta cambia para cada viga, en la primera se ubica a 50mm del extremo fijo del cantiléver, la segunda a 100mm y la tercera a 150mm, tal y como se aprecia en las fotografías de la Figura 4.3.

Con la intención de simular la evolución de una grieta, se aumenta la profundidad de la hendidura en dos ocasiones más. De esta manera, se crean los estados de “daño moderado” con un 50 % de afectación y “daño severo” con el 75 % del ancho de la viga comprometido, conforme a la Figura 4.4. Posterior a cada uno de los daños se efectúa la captura de datos siguiendo el mismo procedimiento de variación de longitud realizado para los estados sanos de las vigas.

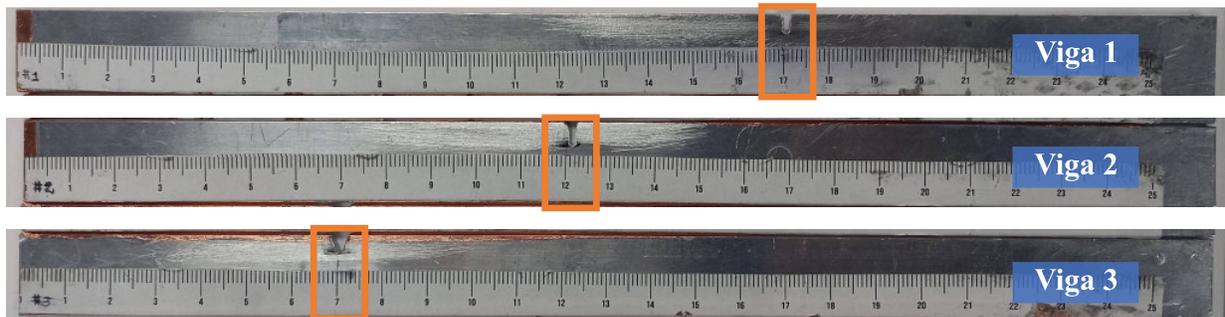


Figura 4.3: Localización de daños por vigas (viga 1, viga 2 y viga 3).

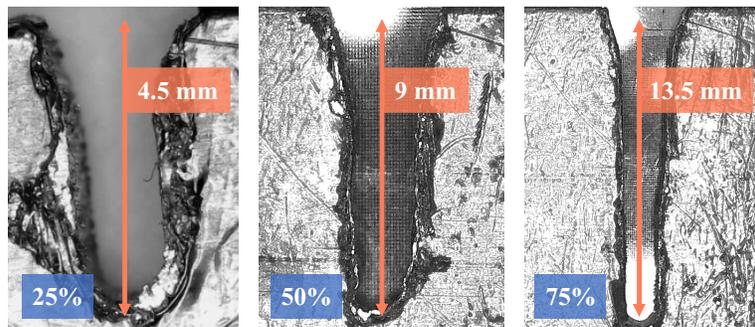


Figura 4.4: Niveles de daños ocasionados a las vigas (leve, moderado y severo).

Las señales de vibración representadas en la Figura 4.5 corresponden a datos asociados con los niveles de daño previamente mencionados. El comportamiento en frecuencia de estas señales, obtenido mediante FFT, se presenta en la Figura 4.6. Aunque la inspección temporal no revela de manera directa la presencia de fallas, se observa un cambio sutil en frecuencia, con el incremento de aproximadamente 2Hz entre las condiciones “Sano” y “daño severo”. Sin embargo, esta variación no ocurre de manera lineal, dado que en el caso de “daño leve” la frecuencia decae por debajo del estado “Sano”. Es importante resaltar que estos cambios no obedecen un patrón consistente para todos los datos de su tipo, por lo que se requiere del uso de otras herramientas que brinden un análisis más detallado de las señales.

Un aspecto importante en la construcción de la base de datos es la extracción y organización de los datos. En este caso, las señales capturadas por el osciloscopio se encuentran en archivos

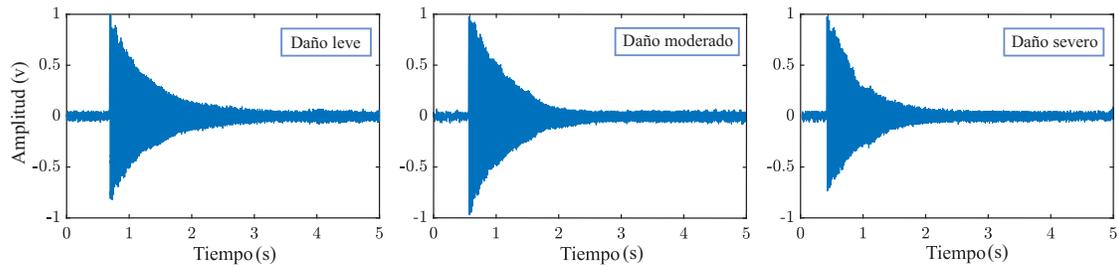


Figura 4.5: Señales obtenidas según los niveles de daños (leve, moderado y severo).

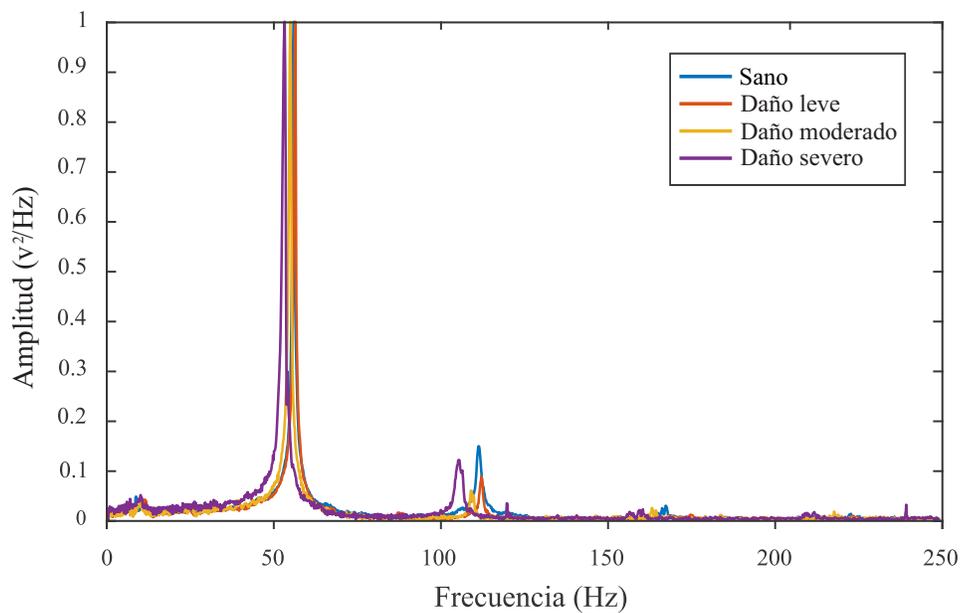


Figura 4.6: Transformada rápida de Fourier para las distintas condiciones de la viga.

individuales con formato CSV. El esquema de la Figura 4.2 muestra a grandes rasgos cómo están almacenados los datos, en una primera etapa la base de datos se componía de carpetas organizadas por viga (1, 2, 3) y por condición (sana, daños leve, severo y moderado) que a su vez contienen siete carpetas con los archivos de variación por longitud.

Para condensar toda la información en estructuras de datos, que contengan los datos de interés en un mismo lugar, se hace uso del Algoritmo 1. Producto del algoritmo se obtiene una matriz por cada una de las 4 condiciones de estado de la viga en cuestión, lo que suma 1400 datos por viga, para un total de 4200 datos que constituyen la base de datos.

Algorithm 1 Extracción de datos de los archivos CSV

Input: Archivos *.csv* capturados con el osciloscopio**Output:** V_k Condicion(D_{datos}): Estructura de datos para una condición de la viga k

▷ Recorrido por carpetas de vigas

for $k = 1$ hasta 3 **do** Inicializar $Datos \rightarrow (350 \times 50000)$, matriz de datos Inicializar $j \rightarrow$ conteo de datos almacenados en la estructura Nombrar la carpeta: Viga(k)Condicion

Entrar a la carpeta de la viga

▷ Recorrido por carpetas de longitudes

for $m = 16$ hasta 22 **do** Nombrar la carpeta: (m)cm

Entrar a la carpeta de la longitud

▷ Recorrido por archivos

for $n = 1$ hasta 50 **do** Nombrar la archivo: med(n) Leer archivo y extraer la señal \rightarrow $signal$ (1×50000) $Datos_{(j,:)} = signal$ **end** **end** **return:** V_k Condicion(D_{datos})**end**

4.1.1. Subconjuntos de la base de datos

Gracias a los múltiples escenarios sobre los que se construye la base de datos, es posible crear diferentes combinaciones entre los grupos de datos. La intención de crear estos subconjuntos de datos es agregar desafíos adicionales a la metodología de clasificación para demostrar su robustez y eficacia en la detección de varios tipos de fallas en los sistemas de viga cantiléver. A continuación se detallan los conjuntos de datos a evaluar:

- **BD1:** En este primer grupo se le da prioridad a las clases de ubicación de daño (V1, V2, V3) y condición de afectación (Dl, Ds, Dm), sobre las características propias del sistema, al

mezclar los datos tomados a diferentes longitudes. La base de datos BD1 está constituida por 10 clases con un número de datos desbalanceados. Los datos que componen la clase sana son los tomados para las tres vigas previo a los daños (VSana), esto constituye un 25 % del total de la BD1, la disposición y las etiquetas de los datos se presentan en la siguiente tabla:

Tabla 4.1: Distribución de la base de datos de prueba BD1.

Etiquetas	VSana	V1Dl	V1Dm	V1Ds	V2Dl	V2Dm	V2Dl	V3Dl	V3Dm	V3Ds
Nº datos	1050	350	350	350	350	350	350	350	350	350

- **BD2:** A diferencia del primer conjunto de datos, en este subconjunto se toman en consideración las diferentes longitudes de la viga (16 – 22), pero sólo para los datos que tienen presencia de daño. En otras palabras, la base de datos BD2 la constituyen todos los posibles casos de daños (Vx), multiplicados por los distintos sistemas cantiléver que se generan al variar el área transversal de la viga. En concreto, la BD2 cuenta con 63 clases y un total de 3150 datos, cuya distribución es balanceada y se ejemplifica a continuación:

Tabla 4.2: Distribución de la base de datos de prueba BD2.

Etiquetas	VxDl16...VxDl22	VxDm16...VxDm22	VxDs16...VxDs22
Nº datos	50 ... 50	50 ... 50	50 ... 50

- **BD3:** Este conjunto de datos adiciona a las clases de daños descritos en BD2, los datos de la clase sana para un conglomerado de 64 clases, el máximo valor de posibles combinaciones de clases según los datos recolectados. Al adicionar la clase de datos sin falla se crea un desbalance de datos considerable, entre las 63 clases de daños con 50 datos cada una, contra los 1050 datos que pertenecen a la clase sana, tal y como se muestra en la tabla de etiquetas:

Tabla 4.3: Distribución de la base de datos de prueba BD3.

Etiquetas	VSana	V1Dl16...V1Ds22	V2Dl16...V2Ds22	V3Dl16...V3Ds22
Nº datos	1050	50 ... 50	50 ... 50	50 ... 50

4.2. Extracción de características

La extracción de características es un paso esencial en la implementación de modelos ML, este proceso implica la selección de un conjunto de atributos que representen de manera óptima la estructura de los datos originales. En relación con esta investigación, es importante destacar que las señales de vibración constituyen datos complejos que contienen mucha información sobre el comportamiento de los sistemas. Por consiguiente, resulta fundamental disponer de herramientas capaces de representar de forma precisa y coherente los aspectos esenciales de estas señales; en este contexto sobresalen las métricas estadísticas [88, 89]. La eficacia de estas métricas en el análisis de sistemas de vibración se atribuye en parte a su capacidad de mitigar los efectos del ruido, efectos inherentes en este tipo de sistemas; en consecuencia, se garantizan resultados más confiables y precisos.

Otro grupo de atributos empleados en el estudio de señales, que también se distingue por su robustez al ruido, son las relacionadas con la dimensión fractal (*fractal dimension*, FD). En términos generales, la FD ofrece una medida cuantitativa de la irregularidad y complejidad de un conjunto de datos [90]. Basándose en conceptos de geometría fractal como la autosimilitud, se consigue capturar los patrones representativos de los fenómenos. En nuestro caso de estudio en particular, se han reportado diversos trabajos en los que la identificación de grietas en sistemas de viga cantiléver se cimienta en el análisis de FD [91, 92]. Si bien su uso propiamente como características de entrenamiento en algoritmos de ML es relativamente reciente [93, 94], han demostrado su capacidad para expresar información compleja, mejorando significativamente el rendimiento de las clasificaciones de diversos tipos de señales.

El conjunto de características a extraer consta de 23 elementos, seleccionados mediante una revisión detallada del estado del arte para la representación de señales de vibración, y a partir de una serie de ensayos experimentales. Por su parte, el Algoritmo 2, describe el proceso relacionado con la extracción de características de las estructuras de datos previamente generadas en el Algoritmo 1. Con este propósito se hace uso de funciones paralelas, que determinan el

grupo de atributos estadísticos (Sf_Calc_Est), calculados según las ecuaciones de las Tablas 4.5 y 4.6. Por su parte, las características de dimensión fractal (Sf_Calc_Fra) son generadas a partir de sus algoritmos propios mencionados en la Tabla 4.5.

Algorithm 2 Extracción de características

Input: $VxCond$: Estructuras de datos ($VxSana, VxD1, VxD2, VxD3$)

Ts : tiempo de Muestreo de las señales

Output: $featuresVx_{(S,D1,D2,D3)}$: Estructuras de datos con las características

Leer las estructuras de condición por viga ($VxCond$)

Determinar $Ns \rightarrow$ número de señales por estructura

Determinar $Fs \rightarrow$ frecuencia de muestreo de las señales

▷ Recorrido para cada condición de la viga Vx

for $k = 1$ hasta 4 **do**

▷ Recorrido para la extracción de características

for $j = 1$ hasta Ns **do**

$Sf_Calc_Est(VxCond(:, j), Fs)$ ▷ Características Estadísticas

$Sf_Calc_Fra(VxCond(:, j), Fs)$ ▷ Características Fractales

 Unir las características en una fila de la matriz $\rightarrow Sf_VxCond(j, :)$ (1×23)

end

Sf_VxCond (350×23)

 Unir las características por condición en la estructura $\rightarrow featuresVx_{(S,D1,D2,D3)}$

end

return: $featuresVx_{(S,D1,D2,D3)}$

De este modo se obtiene el conjunto de las 23 características seleccionadas en un tiempo de 107.37 segundos por cada una de las estructuras de datos de las vigas (V_x). Los primeros 17 atributos describen el comportamiento estadístico de las señales de vibración en el tiempo (Tabla 4.4), utilizando métricas comunes como la media (x_μ) que determina el valor promedio de las señales, o la desviación estándar (x_σ) que cuantifica la dispersión con relación a la media.

Tabla 4.4: Características estadísticas en el dominio del tiempo

Característica	Ecuación	Característica	Ecuación
Moda	$x_{mo} = \arg \max_x \sum_{i=1}^N I(x_i - x)$	Curtosis	$x_{Curt} = \frac{1}{N-1} \frac{\sum_{i=1}^N (x_i - x_\mu)^4}{x_\sigma^4}$
Mediana	$x_{me} = \frac{1}{n} \sum_{i=1}^n f_i x_i$	5to momento estadístico	$x_{5to} = \frac{1}{N-1} \frac{\sum_{i=1}^N (x_i - x_\mu)^5}{x_\sigma^5}$
Media	$x_\mu = \frac{1}{N} \sum_{i=1}^N x_i$	6to momento estadístico	$x_{6to} = \frac{1}{N-1} \frac{\sum_{i=1}^N (x_i - x_\mu)^6}{x_\sigma^6}$
Varianza	$x_{\sigma^2} = \frac{1}{N} \sum_{i=1}^N x_i - \mu ^2$	Factor de forma con RMS	$x_{SRMS} = \frac{x_{RMS}}{\frac{1}{N} \sum_{i=1}^N x_i }$
Desviación estándar	$x_\sigma = \sqrt{\sigma^2}$	Factor de forma con SMR	$x_{SSMR} = \frac{x_{SMR}}{\frac{1}{N} \sum_{i=1}^N x_i }$
Rango	$x_{Rg} = \max(x) - \min(x)$	Factor de cresta	$x_{FC} = \frac{\max(\mathbf{x})}{x_{RMS}}$
Asimetría \ Sesgo	$x_{sk} = \frac{1}{N-1} \frac{\sum_{i=1}^N (x_i - x_\mu)^3}{x_\sigma^3}$	Factor de latitud	$x_{FL} = \frac{\max(\mathbf{x})}{x_{SMR}}$
RMS	$x_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i)^2}$	Factor de impulso	$x_{FI} = \frac{\max(\mathbf{x})}{\frac{1}{N} \sum_{i=1}^N x_i }$
SMR	$x_{SMR} = [\frac{1}{N} \sum_{i=1}^N x_i ^{\frac{1}{2}}]^2$		

En este conjunto de características también se incluyen métricas más orientadas al estudio de las señales, tal es el caso de la raíz cuadrática media (*Root Mean Square*, RMS) y raíz media cuadrática (*Square-Mean-Root*, SMR) que indican la amplitud efectiva de una señal; la relación con su valor promedio se expresa por los factores de forma x_{SRMS} y x_{SSMR} .

Para finalizar el conjunto de características estadísticas, se agregan 3 atributos del dominio de la frecuencia (Tabla 4.4). En función de los resultados obtenidos por las FFTs de las señales, se generan características como: la frecuencia media cuadrática (x_{FRMS}) que aporta información valiosa sobre la intensidad de la frecuencia fundamental, o la frecuencia central (x_{FC}) que es análoga a la frecuencia de resonancia del sistema, ambas variables importantes en el contexto de la vibración de maquinarias o estructuras, ya que pueden indicar una condición

anómala. En la caracterización de señales, especialmente en las de vibración, es crucial incluir atributos que reflejen su dispersión. En el dominio de frecuencia se puede cuantificar mediante la raíz de la varianza frecuencial (x_{FRVF}).

Tabla 4.5: Características estadísticas en el dominio de la frecuencia

Característica	Ecuación
Frecuencia media cuadrática	$x_{FRMS} = \frac{\sum_{i=1}^N f_i^2 p_i}{\sum_{i=1}^N p_i}$
Frecuencia central	$x_{FC} = \frac{\sum_{i=1}^N f_i p_i}{\sum_{i=1}^N p_i}$
Raíz de la varianza frecuencial	$x_{FRVF} = \sqrt{\left(\frac{\sum_{i=1}^N (f_i - F_\mu)^2 p_i}{\sum_{i=1}^N p_i} \right)}$

El tercer conjunto de características, está compuesto por 3 atributos de carácter fractal de la Tabla 4.6, los cuales tienen como objetivo capturar patrones relacionados con la naturaleza irregular de las señales de vibración. El primer atributo de este grupo (x_{HFD}) es determinado por el algoritmo *Higuchi*, método especialmente útil para manipular las formas de onda como objetos. El HFD se desarrolla dividiendo la señales en segmentos de diferentes longitudes. El segundo método usado es el algoritmo de *Fractal Box Dimension* que destaca en la literatura por su simplicidad; genera una curva que representa las autosimilitudes de la señal (x_{BCFD}), mediante el mallado con hipercubos sobre la señal de entrada. Finalmente, se emplea el algoritmo de *Sevcik* que mide la relación entre la longitud de un objeto y su área o volumen en diferentes escalas (x_{SFD}). Para descripciones más detalladas de los algoritmos [93, 94].

Tabla 4.6: Características de dimensión fractal

Característica	Algoritmo
Dimensión fractal de Higuchi	$x_{HFD} = \frac{\log(L(k))}{\log\left(\frac{1}{k}\right) + \bar{b}}$
Dimensión fractal de la caja	$x_{BCFD} = \lim_{n \rightarrow \infty} \frac{\log(Nn(\Delta))}{\log(2^n)}$
Dimensión fractal de Sevcik	$x_{SFD} = 1 + \frac{\ln(L)}{\ln(2N_l)}$

4.2.1. Comportamiento de las características

Con el propósito de examinar detalladamente el comportamiento de las características obtenidas anteriormente, se generan los tres diagramas de cajas mostrados en la Figura 4.7. Estos diagramas fueron construidos a partir de los 50 datos que corresponden al estado sano de las vigas (V1, V2, V3) para una longitud fija e intermedia de 190mm.

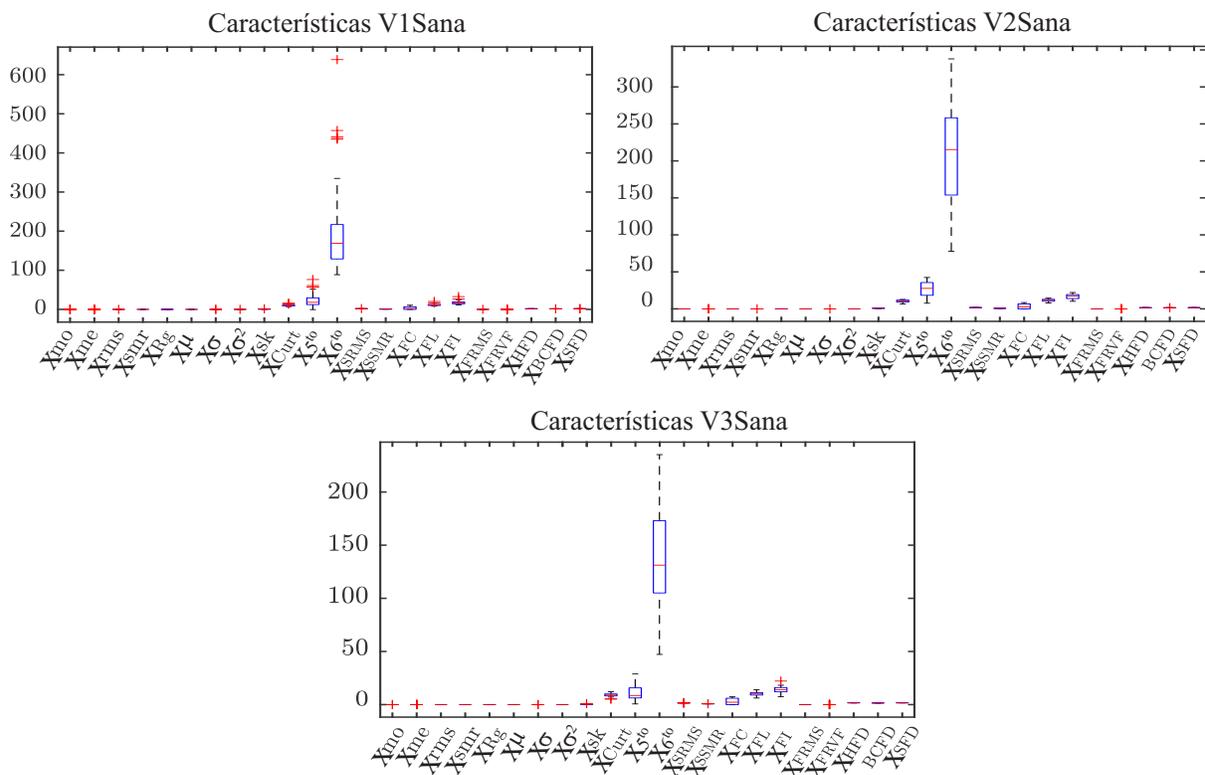


Figura 4.7: Diagramas de caja del comportamiento del conjunto de características original.

Los diagramas de la Figura 4.7 ofrecen una visualización clara de la distribución de las características de la clase en cuestión, permitiendo identificar patrones o discrepancias entre ellas, así como la presencia de valores atípicos (representados en la Figura 4.7 como cruces rojas) tal el caso del sexto momento estadístico (X_{6to}). Este atributo muestra un fenómeno interesante, ya que no presenta un comportamiento que tienda hacia un punto en ninguna

de las tres vigas; por el contrario, presenta un amplio rango de valores que no siguen un patrón discernible. Al ser esta una medida que proporciona información sobre la simetría de un conjunto de datos, su comportamiento en señales asimétricas, como las de vibración, puede ser variado y dependerá en gran medida de la naturaleza específica de dichas señales.

Este tipo de comportamiento puede perjudicar la efectividad de los algoritmos de clasificación, por lo que se opta por eliminar la contribución del atributo $X_{6^{to}}$ del conjunto de características a utilizar. Posterior a la exclusión se generan nuevamente los diagramas (Figura 4.8), donde se aprecia una reducción significativa en la variabilidad de los valores de las características, lo que justifica la necesidad de una etapa de preprocesamiento para el conjunto de características. Este preprocesamiento permitirá gestionar de manera eficiente la información y eliminar posibles datos anómalos para mejorar la precisión y el rendimiento del modelo.

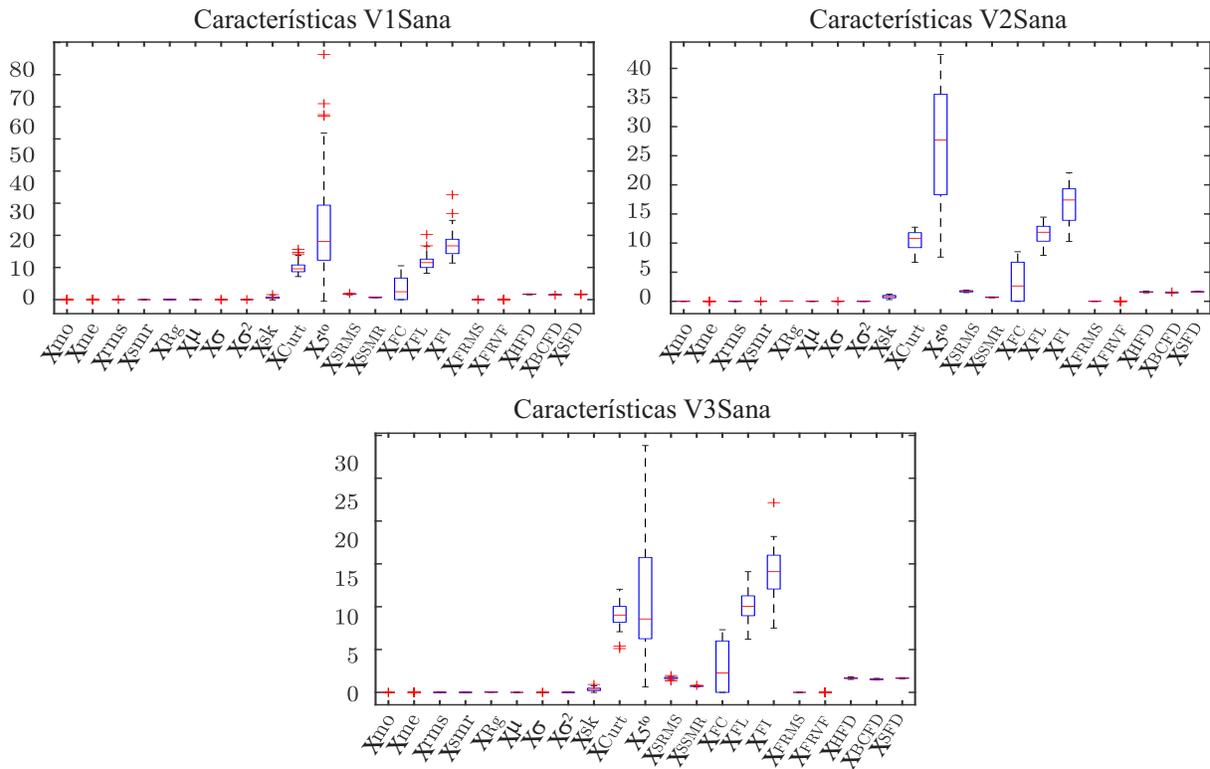


Figura 4.8: Diagramas de caja que ilustran el comportamiento de las características finales.

4.3. Adimensionalización

Para asegurar una comparación efectiva entre las características obtenidas, es crucial que estén dentro de un rango similar. Esto evita que atributos con valores extremadamente grandes o pequeños dominen sobre los demás durante el proceso de clasificación, lo que puede perjudicar la precisión del modelo. La adimensionalización o cambio de escala, es un proceso comúnmente empleado en el preprocesamiento de datos, ya que es efectivo en este propósito; además de que evita discrepancias entre diferentes unidades [95]. En este estudio, se evaluaron varios métodos de adimensionalización durante la etapa de visualización de los datos previo al entrenamiento de los clasificadores, entre ellos Z-score, normalización max-min, y la normalización máxima. Se encontró que los métodos basados en cambios de escala producían resultados visualmente más compactos, destacando la normalización máxima.

$$x'_{i,n} = \frac{x_{i,n}}{\max(|x_i|)} \quad (4.1)$$

Este tipo de métodos de adimensionalización son útiles para preservar las relaciones entre los datos de entrada originales $X_{i,n}$, la normalización máxima en particular es una variante de la normalización max-min [95, 96], en la que se cambia la escala de los datos al dividir cada característica por su valor máximo tal y como lo define la ecuación 4.1, lo que posiciona a las características en la escala de $(-1, 1)$.

4.4. Reducción de dimensionalidad

Antes de proceder con la clasificación, se realiza una etapa de preprocesamiento en los conjuntos de datos para eliminar las redundancias de las características extraídas previamente. Este proceso se centra en preservar únicamente la información relevante para el sistema, lo que simplifica la interpretación de los modelos de ML y mejora la calidad de los resultados obte-

nidos. En este contexto, se recurre a las técnicas de reducción de dimensionalidad detalladas en el Capítulo 2. Estos algoritmos realizan una transformación de las características, reemplazando los datos originales por un conjunto más reducido de variables subyacentes. Mediante este enfoque facilita la visualización y el análisis de los datos, contribuyendo así a una mejor comprensión y rendimiento del modelo de clasificación.

En este apartado se evalúan dos enfoques de transformación de características (PCA/LDA), los cuales posibilitan una visualización del comportamiento de los subconjuntos de datos (BD1/BD2/BD3). Este proceso se lleva a cabo de la siguiente manera, una vez que los datos han sido adimensionalizados, se aplica una de las técnicas de reducción de dimensionalidad propuestas. A partir de los componentes más significativos, se grafica el comportamiento de los datos. En el caso de PCA, se emplea la función integrada de Matlab para identificar los componentes principales. Por su parte, para LDA se utiliza una función propia, desarrollada para determinar las medidas de dispersión descritas en el marco teórico, para calcular las direcciones más discriminantes. Posteriormente, en el Capítulo de resultados se comparan los efectos de su aplicación en el acondicionamiento de los datos para la clasificación de fallos. A continuación se presenta la representación de los datos de los conjuntos según las técnicas:

4.4.1. Análisis de componentes principales (PCA)

Con el propósito de identificar las direcciones de máxima variabilidad en los datos, se generan las representaciones mostradas en la Figura 4.9, conforme a los componentes principales obtenidos. En las gráficas en dos dimensiones (2D), la distinción entre las clases no resulta fácil de apreciar. Sin embargo, en las representaciones tridimensionales (3D) de la derecha, se visualiza un poco mejor las direcciones o ejes que toman los grupos de datos. Esto se hace especialmente notable en la Figura 4.9d, que corresponde al conjunto de datos balanceado BD2, en donde se tienen todos los efectos de daños posibles. En esta Figura se puede apreciar de manera más clara la maximización de los ejes de componentes para la separación de clases.

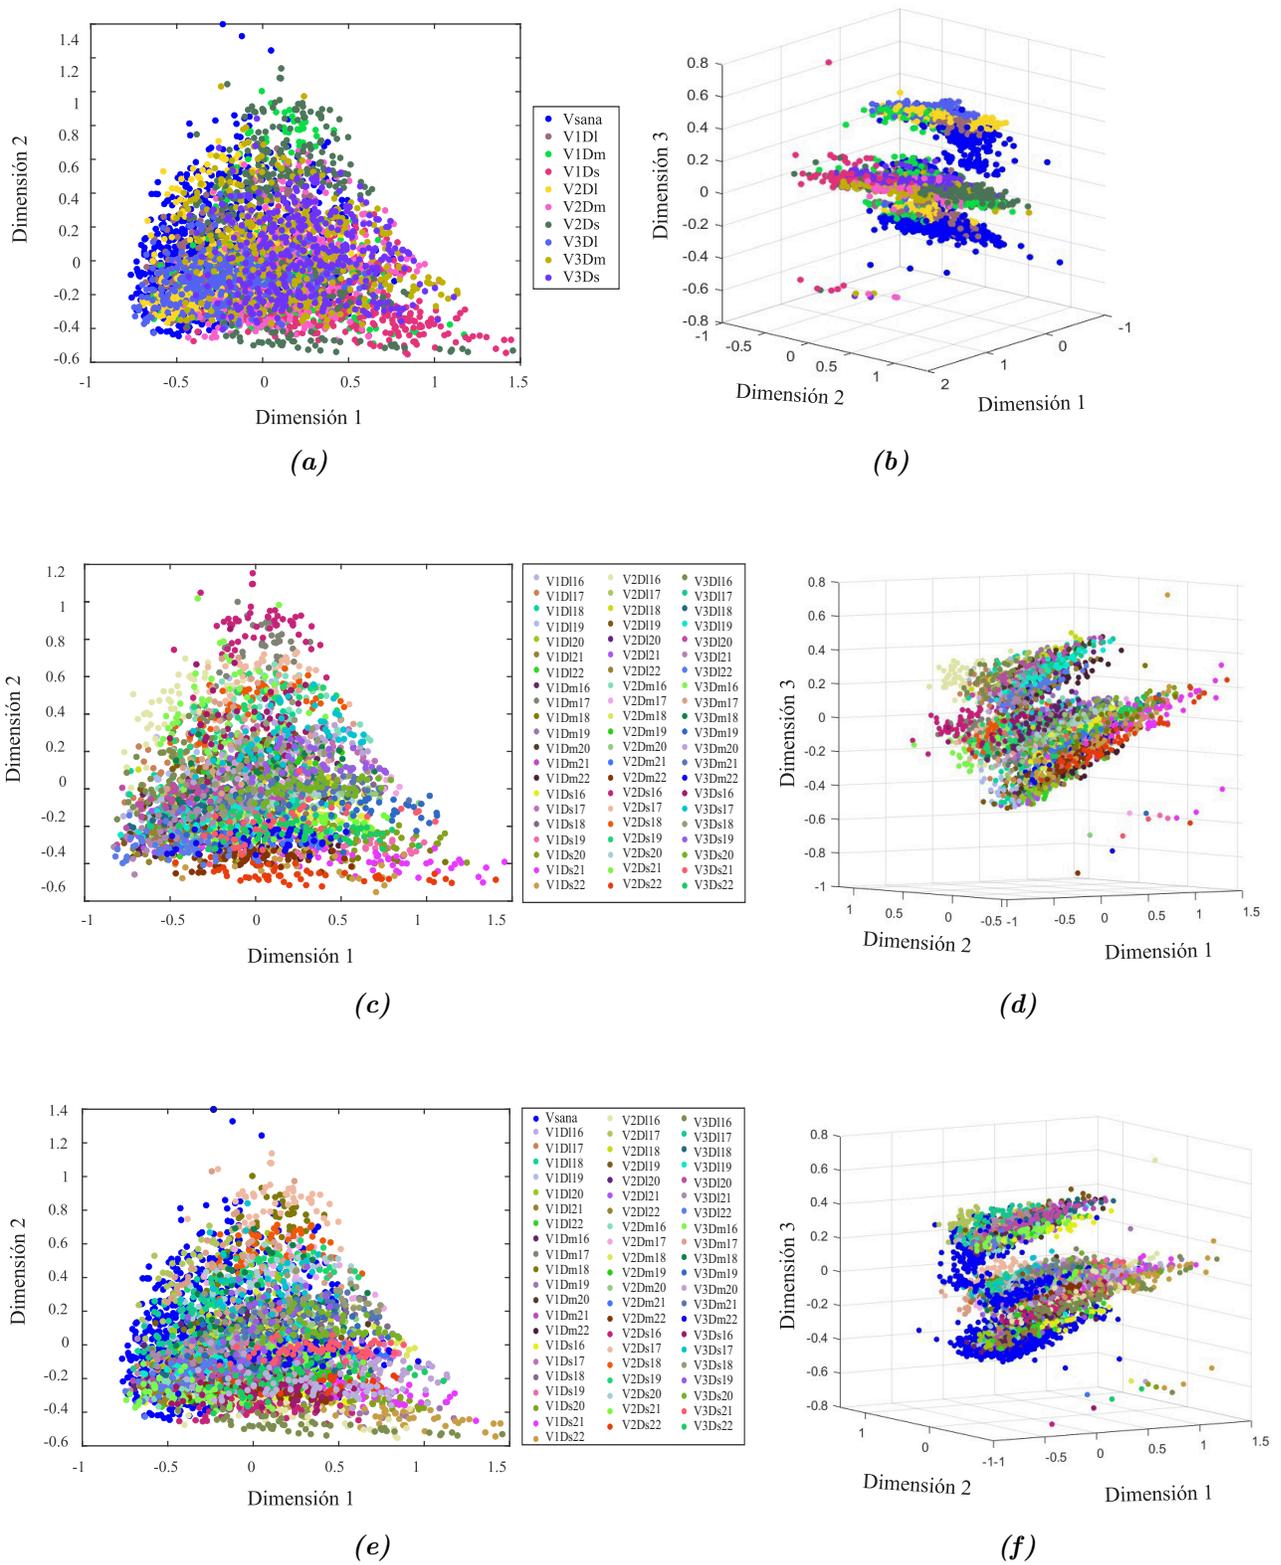
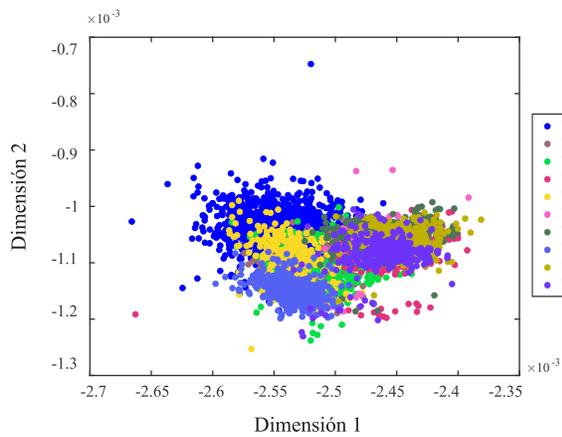


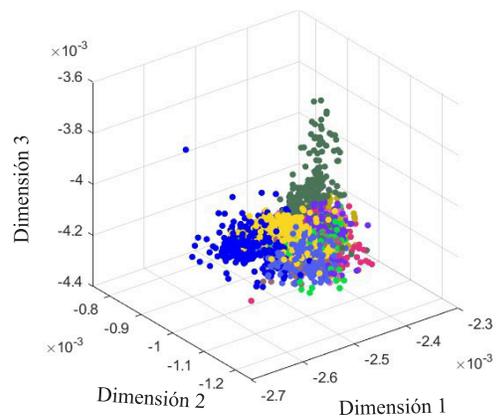
Figura 4.9: Representaciones de los datos en 2D y 3D mediante PCA, para cada una de las bases de datos (BD1, BD2 y BD3).

4.4.2. Análisis discriminaste lineal (LDA)

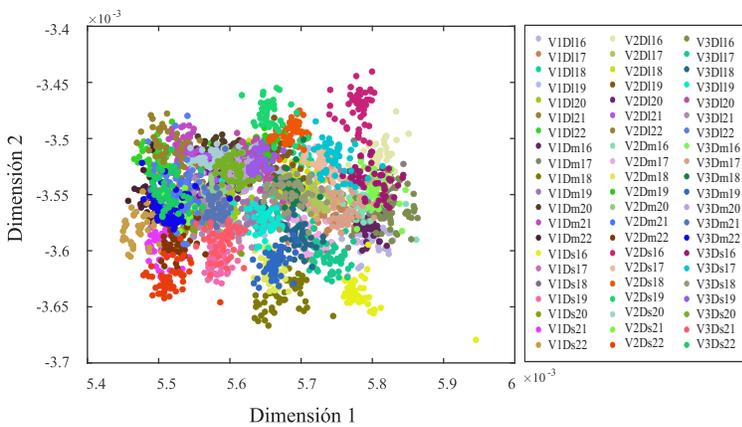
El objetivo de LDA consiste en maximizar la separación entre las clases en un conjunto de datos, al mismo tiempo que se reduce la varianza dentro de cada clase. Esto último se aprecia claramente en las representaciones de los subconjuntos de datos de la Figura 4.9, donde se generan agrupaciones relativamente compactas, aunque no se alcanza una separabilidad notable entre estas clases. En el caso particular del subconjunto BD2 (Figura 4.10c y 4.10d), pese a la homogeneidad de los datos y el gran número de clases, se consigue agrupaciones visiblemente distinguibles, esto podría representar un mayor rendimiento en la etapa de clasificación.



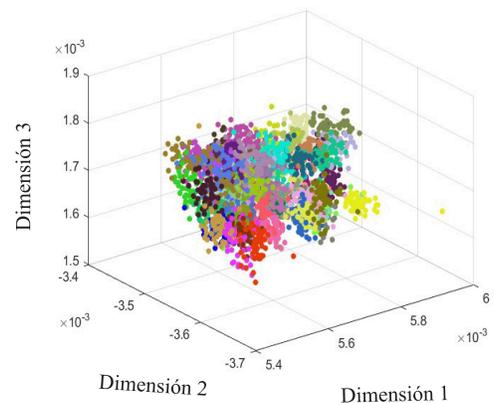
(a)



(b)



(c)



(d)

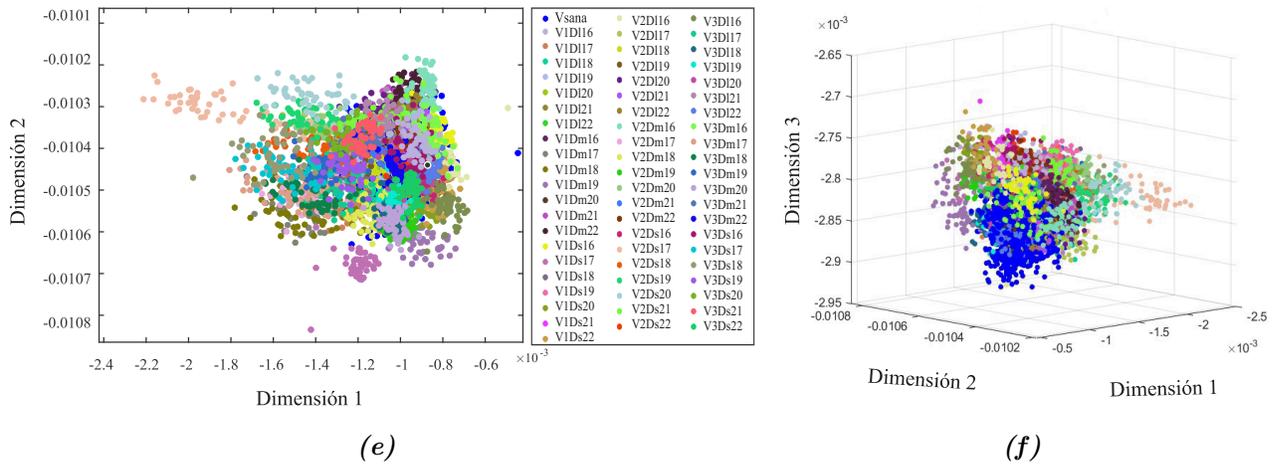


Figura 4.9: Visualización de los datos en 2D y 3D a través de LDA, para cada una de las bases de datos (BD1, BD2 y BD3).

Estas imágenes ofrecen una perspectiva visual y representativa del grado de dificultad con el que cuentan los subconjuntos de datos. Así como de los beneficios que podía suponer el uso de PCA o LDA en la metodología de clasificación de fallas, presentada en la siguiente sección.

4.5. Clasificación e identificación de fallas

En la etapa final de la metodología propuesta para la clasificación de daños (Figura 4.1), se lleva a cabo el entrenamiento de tres modelos de aprendizaje diferentes (KNN/SVM/DT) en este proceso a su vez se comprueban los efectos de las técnicas PCA y LDA en el preprocesamiento de las características para cada una de las bases de datos (BD1/BD2/BD3). El diagrama de flujo de la Figura 4.10, describe de manera general el procedimiento que se realiza para la clasificación de fallas o daños del sistema viga cantiléver. Posterior a la adimensionalización y reducción de dimensionalidad, se comienza un ciclo de ejecuciones (nr) que permita evaluar el comportamiento estadístico de los diferentes modelos creados a partir de conjuntos de datos que se conforman según la etapa de división de datos, explicada a continuación:

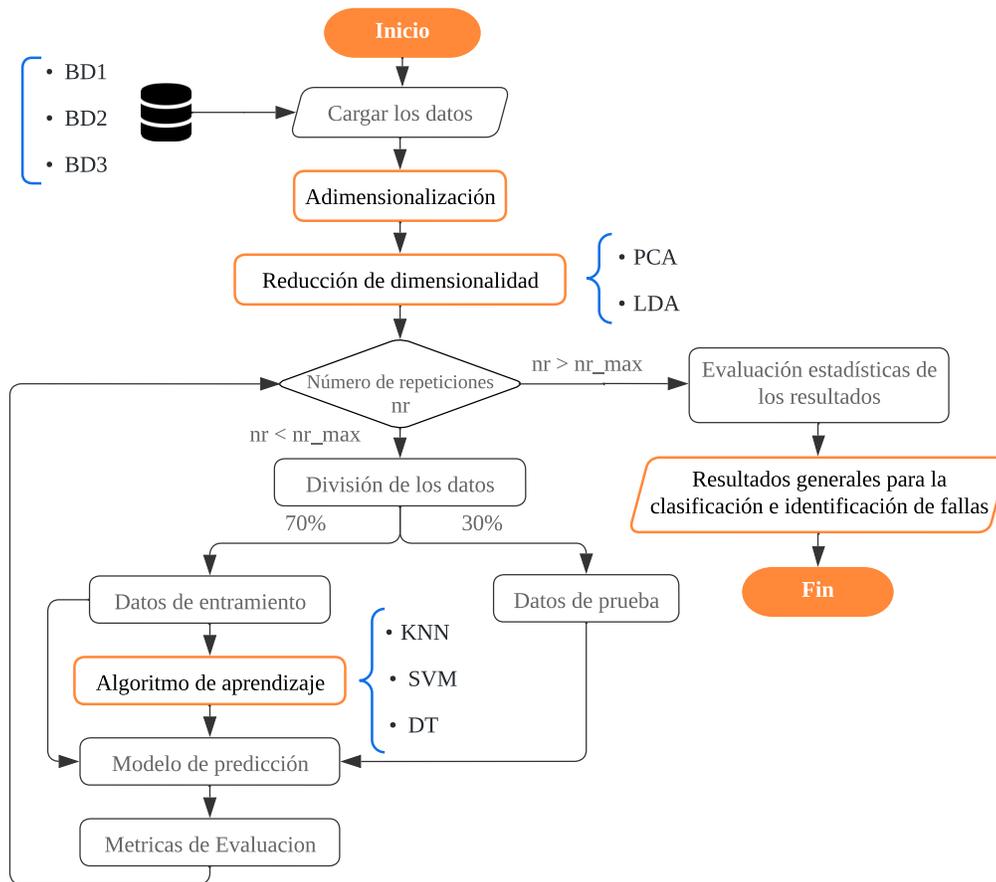


Figura 4.10: Diagrama de flujo general para la clasificación de fallas.

4.5.1. División de los Datos

La división de los datos es una práctica habitual previa a la aplicación de los modelos de ML, este proceso implica separar la base de datos en dos grupos. Un conjunto de entrenamiento, que generalmente contiene mayor parte de los datos, en nuestro caso se destina un 70 % de la base de datos, para construir los modelos de aprendizaje que estarán basados en los patrones presentes en estos datos. El 30 % de los datos restantes corresponden al conjunto de prueba, datos que son reservados para evaluar el modelo creado y su capacidad generalización ante datos no vistos. Esto proporciona una estimación objetiva del rendimiento del modelo.

Algorithm 3 División de los datos

Input: BD : Matriz de datos, $DTrain$: Porcentaje de entrenamiento Nc : Número de clases, Num : Número de datos por clase**Output:** $Train$: Matriz de datos de entrenamiento, $Test$: Matriz de datos de prueba

▷ Función para la división de datos por clases

for $i = 1$ hasta Nc **do** $NumTrain = Num * DTrain$ → número de datos para entrenamiento $NumTest = Num - NumTrain$ → número de datos para prueba $idx = randperm(Num)$ → vector con índices de datos mezclados aleatoriamente

▷ Asignación de datos a los conjuntos

 $Train(i * NumTrain) = BD(1 : NumTrain, :)$ $Test(i * NumTest) = BD(NumTrain + 1 : end, :)$ **end****return:** $Train, Test$

Por otro parte, existen diferentes estrategias para la división de los datos, la utilizada en el proyecto es el muestreo estratificado. Esta técnica preserva la proporción de las clases o categorías en los conjuntos de entrenamiento y prueba; el algoritmo 3 describe el procedimiento de la función creada con este propósito. Al dividir de manera equitativa los datos de cada clase, se evitan sesgos y se promueve la generalización del modelo durante el entrenamiento; lo que a su vez mejora la fiabilidad y representatividad de la evaluación del rendimiento durante las pruebas. Este método es especialmente útil en conjuntos de datos desbalanceados, como las bases de datos BD1 y BD3, donde la clase *Vsana* cuenta con mayor número de instancias.

4.5.2. Algoritmos de aprendizaje

En este punto se procede a iniciar con la identificación de los patrones característicos presentes en los datos, mediante el uso de los algoritmos de aprendizaje supervisado descritos en el Capítulo 2. Los tres algoritmos empleados para clasificar los diferentes conjuntos de

fallas o daños poseen parámetros propios que determinan su funcionamiento. A través de experimentación previa, se determinó que modificar ciertos parámetros de los algoritmos podría aportar mayores beneficios que otros. Por lo tanto, se establecieron algunos criterios fijos y otros variables, los cuales se analizan con mayor detalle en el Capítulo 5. Seguidamente, se describen los criterios establecidos para cada algoritmo:

- **KNN:** Para este algoritmo se emplea de manera fija la distancia entre instancias de similitud de coseno (ecuación en la Tabla 2.2 referida al ángulo entre dos vectores). En cuanto al valor óptimo de número de vecinos (k) se hace un estudio en paralelo con la metodología implementada, para determinar qué valor es más conveniente según el caso.
- **SVM:** En este caso se ponen a prueba las funciones de kernel gaussiano y polinomial de tercer orden. En ambos caso se estableció que el algoritmo de ascenso por subgradiente incremental (*Incremental Subgradient Descent Algorithm, ISDA*), para resolver el problema de optimización de SVM.
- **DT:** En este clasificador se toman en consideración, como parámetros variables, las pruebas estadísticas para determinar la mejor manera de dividir los nodos en el árbol de decisión. Los predictores estudiados son: prueba de curvatura, y prueba de interacción.

Los resultados de aplicar estos parámetros en las diferentes combinaciones de técnicas, derivadas de la metodología de clasificación de fallas propuesta empleada en los subconjuntos de datos antes mencionados (BD1/BD2/BD3), se presentan y analizan en el próximo capítulo.

Capítulo 5

Resultados

Este capítulo presenta los resultados obtenidos al aplicar la metodología de clasificación e identificación de fallas, descrita en el capítulo anterior. El capítulo se divide en tres pruebas que examinan los subconjuntos de datos BD1, BD2 y BD3, los cuales se derivan de la base de datos original. Cada caso de estudio se ha estructurado con la intención de explorar diferentes aspectos del sistema viga cantiléver, y la naturaleza de los daños infligidos, tales como la presencia, ubicación y profundidad de la grieta. Esto permite comprobar la robustez y eficacia de la metodología de aprendizaje automático implementada, a la vez se evalúa la solidez de los datos de vibración capturados con el arreglo reflectivo de fibra óptica.

Concretamente, los resultados aquí mostrados proporcionan una evaluación de cómo las técnicas de reducción de dimensionalidad impactan en las etapas de preprocesamiento de los datos y en su posterior clasificación. Además, se lleva a cabo un análisis comparativo de la respuesta de los algoritmos de aprendizaje automático ante los conjuntos de datos mencionados, centrándose principalmente en la exactitud y la capacidad de generalización de los modelos.

Pruebas preliminares

En esta sección introductoria se describen las primeras pruebas, que se realizaron de forma simultánea con el proceso de adquisición de datos. El propósito principal de estas pruebas fue verificar la calidad de los datos recopilados, para la construcción de modelos de clasificación utilizando los algoritmos KNN y SVM. Así como también evaluar la consistencia de la metodología propuesta para el procesamiento de los datos. En estas primeras aproximaciones, se utilizaron 200 datos correspondientes a un sistema de viga cantiléver con una longitud fija de 19 cm. Los datos incluyeron las cuatro clases equilibradas que reflejan la progresión de la grieta inducida a la viga. Las clases abarcan desde el estado “Sana” hasta un estado denominado “Daño severo”, atravesando las etapas de “Daño leve” y “Daño moderado”.

Siguiendo el procedimiento de clasificación propuesto, posterior a la adimensionalización, se procede aplicar los algoritmos de reducción de dimensionalidad PCA y LDA, a partir de los cuales se generan las Figuras 5.1a y 5.1b. En estas Figuras se aprecia las agrupaciones de puntos que corresponden a cada una de las clases a estudiar, dando un buen indicio de la capacidad de los datos y las características escogidas en la representación de los fallos.

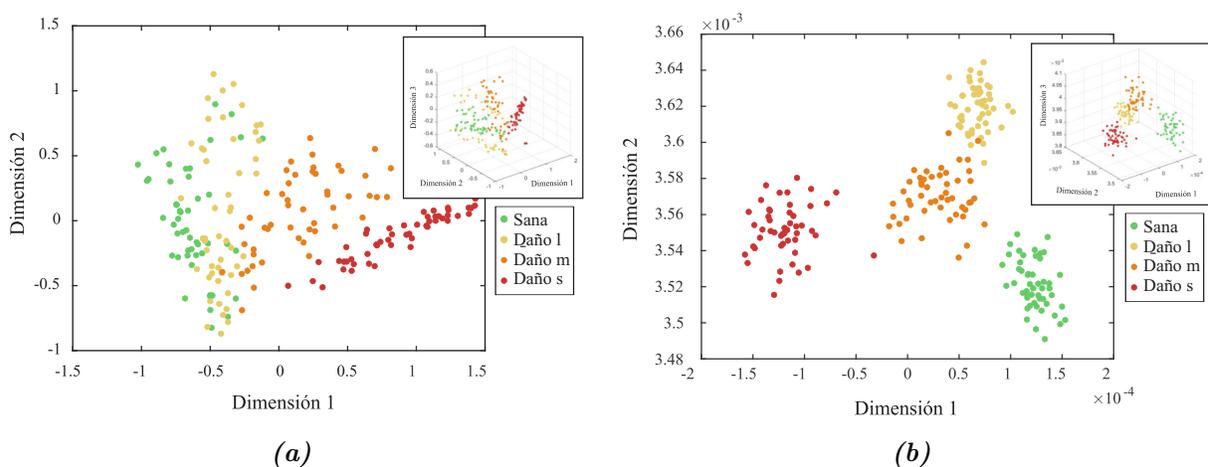


Figura 5.1: Comportamiento de los datos reagrupados mediante los algoritmos de reducción de dimensionalidad. (a) Representación a partir de PCA. (b) Representación según LDA

La representación de los datos lograda mediante LDA (Figura 5.1b) destaca por la manera concisa y separable en que se posicionan los datos reagrupados de cada clase, lo que lleva a una mayor exactitud al momento de la clasificación. Los resultados obtenidos con ambas metodologías de reducción de dimensionalidad y la combinación posterior con los algoritmos de clasificación para 50 réplicas se presentan en la Tabla 5.1.

Tabla 5.1: Resultados de pruebas preliminares.

Metodología	Acc $\pm \sigma$ [%]	C_v [%]	iqr [%]	Max [%]	Min [%]	Tiempo [seg]
PCA+KNN	96.20 \pm 2.52	2.620	3.333	100.00	90.00	1.194
PCA+SVM	84.30 \pm 4.91	5.830	8.333	93.33	71.66	4.8954
LDA+KNN	98.46 \pm 1.34	1.361	1.666	100.00	95.00	1.083
LDA+SVM	97.73 \pm 1.64	1.679	1.666	100.00	93.33	1.8891

En términos de rendimiento, la exactitud promedio (Acc) de las cuatro metodologías propuestas oscila el 90 % en la clasificación de prueba para datos desconocidos. Específicamente, los resultados derivados de la fusión de LDA superan a sus contrapartes obtenidas mediante la combinación con PCA. De forma individual, la combinación de las técnicas **LDA+KNN** exhibe el más alto desempeño con un 98.46 % de exactitud promedio, luego de 50 iteraciones en un tiempo de 1.083 segundos. Al evaluar la dispersión de estos modelos, se observa una desviación estándar (σ) de 1.34 % y un coeficiente de variación (C_v) de 1.361, indicando que LDA+KNN exhibe la menor variabilidad a lo largo de las ejecuciones realizadas. Este hallazgo se ve respaldado por el reducido valor del rango intercuartílico (*iqr*) de 1.66. La solidez de los resultados producto la combinación de LDA no sólo se limita al algoritmo KNN, sino que se extiende también al empleo de SVM, donde se producen resultados igualmente satisfactorios, llegando a obtener hasta el 100 % de clasificación correcta en ambos casos.

La matriz de confusión de prueba para SVM se muestra en la Figura 5.2a, en donde el eje x corresponde a la predicción de clases, mientras que el eje y representa la clasificación real. Por su parte, los elementos correctamente clasificados se sitúan en la diagonal principal, para este

modelo en particular corresponden al 95 % de aciertos en proporción de los datos de prueba. Las muestras que se sitúan fuera de la diagonal, o más allá de las regiones de clasificación definidas por el kernel gaussiano utilizado en la creación del modelo SVM mostrado en la Figura 5.2b, equivalen a datos clasificados incorrectamente. Para este caso en específico, representan una falta de distinción entre las clases que se encuentran inmediatamente superiores o inferiores en la escala de evolución del daño. Este tipo de errores puede deberse a ciertos datos ruidosos; aunque el proceso de toma de datos se lleve de manera rigurosa, sigue siendo un proceso manual que puede verse influenciado por el error humano.

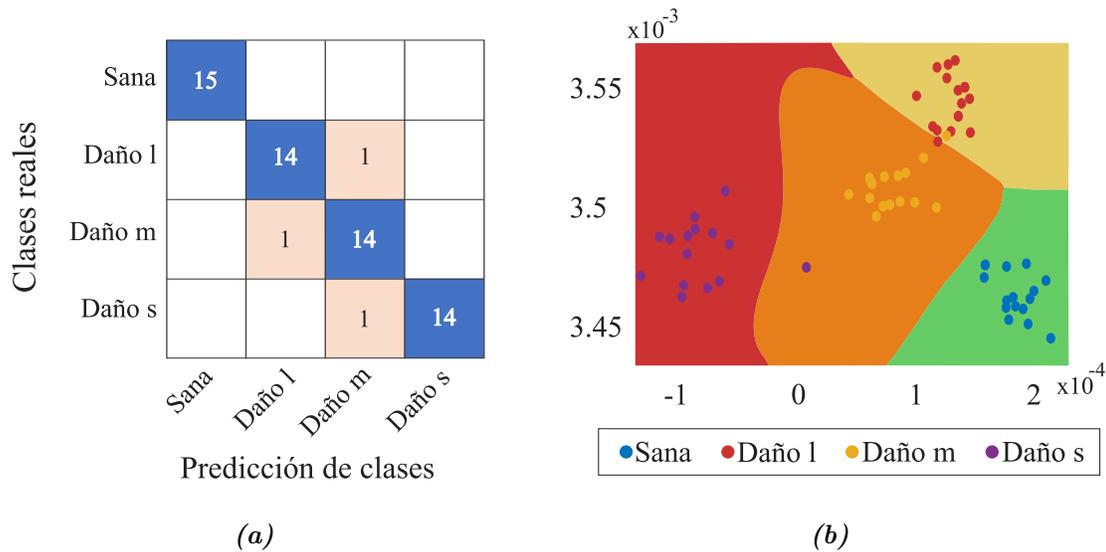


Figura 5.2: Pruebas preliminares con el modelo SVM: (a) Matriz de confusión del modelo. (b) Regiones de clasificación con kernel gaussiano

Estas primeras pruebas evidencian la capacidad de representación de daños a través de los datos de vibración capturados, así como la eficacia de las metodologías propuestas para su clasificación. Aprovechando los buenos resultados en exactitud y tiempo obtenidos con la metodología planteada, se procede a realizar pruebas con conjuntos de datos más complejos. El objetivo es añadir desafíos adicionales a esta metodología de clasificación, con el fin de demostrar su robustez y eficacia en la detección de diversos tipos de fallas en sistemas cantiléver.

5.1. Prueba BD1

En esta primera prueba, nos centramos en la presencia o gravedad del daño, ignorando las condiciones en las que se tomaron las muestras. Cada viga y su nivel de daño se consideran como clases separadas, generando 9 clases de datos distintos, además del estado inicial de las vigas, conocido como *VSana*. La complejidad de este conjunto de datos deriva tanto del mayor número de clases en comparación con las pruebas preliminares, como en la falta de consideración de las características intrínsecas del sistema. Situación que se refleja en la mezcla de muestras tomadas a diferentes longitudes, lo que añade una capa adicional de dificultad a la clasificación.

Los datos previamente mencionados pertenecen al subconjunto BD1, el cual abarca la totalidad de las muestras capturadas por el arreglo óptico, sumando un total de 4200 muestras. Estos datos se distribuyen en 10 clases, con un desbalance significativo entre la clase sana, que comprende 1050 muestras, y las clases que representan los distintos tipos de daños en las vigas, con 350 muestras para cada tipo de daño. Siguiendo el proceso general de clasificación expuesto en el Capítulo 4, se selecciona una de las metodologías de reducción de dimensionalidad (PCA/LDA) y se realiza una prueba inicial para determinar el número de componentes adecuado para cada algoritmo de aprendizaje.

Apoyándose en la regla del “codo” (*Elbow method*), se establece el número óptimo de componentes que se pueden descartar sin afectar los resultados. Este método implica trazar un gráfico que muestra la relación entre el número de componentes y la varianza explicada, medida que indica cuánta información se conserva al retener un cierto número de componentes. Al identificar el punto en el gráfico donde la disminución en la variabilidad se vuelve más gradual, formando un “codo”, se estima que es el punto donde se tiene la máxima información sin redundancia. Añadir más componentes después de este punto no proporciona beneficios significativos. Aplicando esta técnica en los datos transformados con PCA, se genera la gráfica que se muestra en la Figura 5.3a. Partiendo de esta aproximación se realiza una evaluación independiente de cada algoritmo (KNN, SV, DT), para determinar el número óptimo de com-

ponentes principales que ofrece las mejores soluciones. Los círculos en la gráfica indican en qué número de componentes se registraron los mejores resultados.

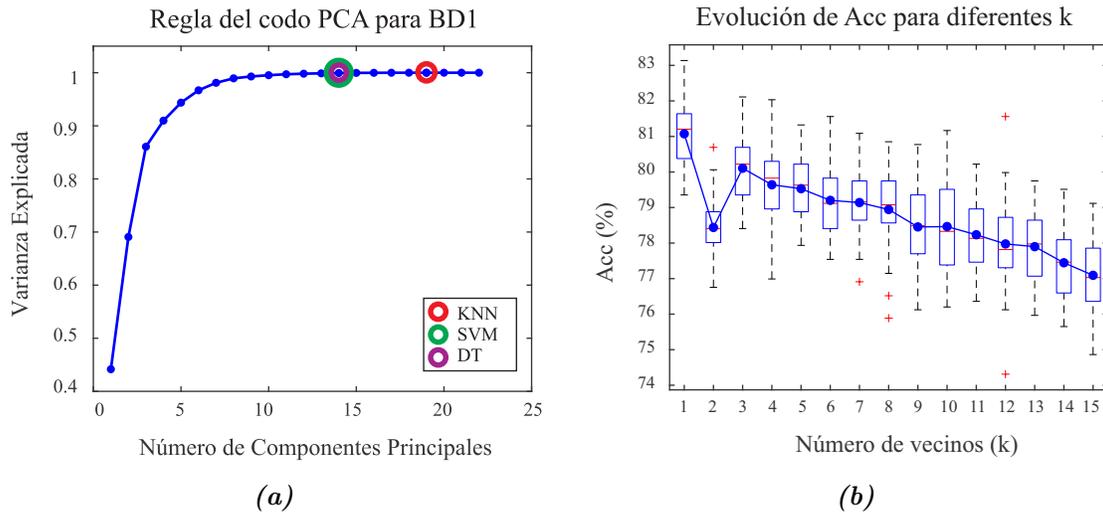


Figura 5.3: Pruebas para BD1 con PCA. (a) Estudio de número de componentes en función de la varianza de los datos. (b) Evolución de la exactitud para diferentes números de vecinos.

Al aplicar el análisis de la regla del codo y considerar los resultados de las evaluaciones independientes, se logra reducir el número de características de 22 a 14 para los algoritmos SVM y DT, mientras que KNN requiere 19 componentes principales para alcanzar el mejor rendimiento. Cualquiera que sea la reducción en la dimensionalidad de los datos, conlleva un menor costo computacional y una utilización más eficiente de la información al evitar redundancias, lo que se traduce en mejores resultados.

Después del preprocesamiento de los datos, se procede a evaluar el número de vecinos más eficaz para el algoritmo de KNN, siguiendo los criterios previamente establecidos. La Figura 5.3b muestra cómo la exactitud (Acc) varía en función del número de vecinos (k) empleados. Los resultados más sobresalientes se alcanzan con k igual a 3 y 5, luego de este valor el rendimiento comienza a disminuir al aumentar el número de vecinos. Es fundamental recalcar que el uso de más de un vecino es necesario para evitar clasificaciones excesivamente sesgadas por posibles valores atípicos en el conjunto de datos de entrenamiento.

El proceso de aprendizaje y pruebas para los algoritmos de clasificación, comienza con la división de los datos utilizando el procedimiento estratificado del algoritmo 3. Los datos de entrenamiento (*datosE*) se emplean para construir los modelos, los cuales luego se evalúan con los datos reservados para pruebas (*datosP*). Este proceso se repite para generar un total de 50 modelos distintos para cada uno de los casos de los algoritmos de aprendizaje. El rendimiento promedio de estos modelos y los tiempos totales de ejecución se presenta en la Tabla 5.2.

Tabla 5.2: Resultados de PCA con algoritmos de aprendizaje para BD1.

Metodología	Acc $\pm \sigma$ [%]	C_v [%]	iqr [%]	Max [%]	Min [%]	Tiempo [seg]
KNN (k=3)	80.24 \pm 0.78	0.979	0.788	82.11	78.72	3.333
KNN (k=5)	79.76 \pm 0.933	1.169	1.497	81.87	77.93	3.130
SVM (Gaussiano)	78.02 \pm 1.12	1.441	1.418	80.06	75.49	638.215
SVM (Polinomial (d=3))	78.34 \pm 1.14	1.467	2.048	80.77	75.65	788.261
DT (Prueba: Curvatura)	66.80 \pm 1.42	2.136	1.970	69.66	63.27	3.988
DT (Prueba: Interacción)	66.83 \pm 1.45	2.179	2.206	69.50	63.27	3.940

La técnica de clasificación más destacada en esta evaluación es KNN, seguida de cerca por SVM, con una diferencia de exactitud de alrededor del 2% entre ambos algoritmos. En contraste, el rendimiento del algoritmo DT está aproximadamente un 13% por debajo de sus contrapartes, lo que demuestra un desempeño menos competitivo en este problema específico. El algoritmo KNN con una configuración de 3 vecinos sobresalió respecto a los demás algoritmos, al exhibir una exactitud promedio del 80.24%, y una desviación estándar excepcionalmente baja 0.78, lo que refleja un nivel significativo de solidez en los resultados encontrados en un tiempo de ejecución de 3.33 segundos. Además, las medidas de coeficiente de variación (C_v) y rango intercuartílico (*iqr*) de los resultados de exactitud para este tipo de modelo son las más bajas del estudio, inferior al 1% lo que sugiere una mayor capacidad de generalización y robustez en los resultados de esta prueba.

De manera análoga al proceso llevado a cabo para la selección de componentes principales (PCA) adecuados para cada algoritmo, se procede en esta ocasión con LDA. La Figura 5.4a

presenta la varianza explicada de los componentes de LDA, donde, siguiendo la regla del codo, se establece de manera subjetiva que el componente número 12 marca el punto de estabilización en la gráfica. A partir de este punto, se lleva a cabo un análisis variando el número de componentes para cada algoritmo, con el propósito de determinar el valor inmejorable para cada uno. Se ha encontrado que para alcanzar el mayor rendimiento de KNN y SVM utilizando LDA, se requieren 15 componentes, en tanto que DT necesita 18 componentes en este caso.

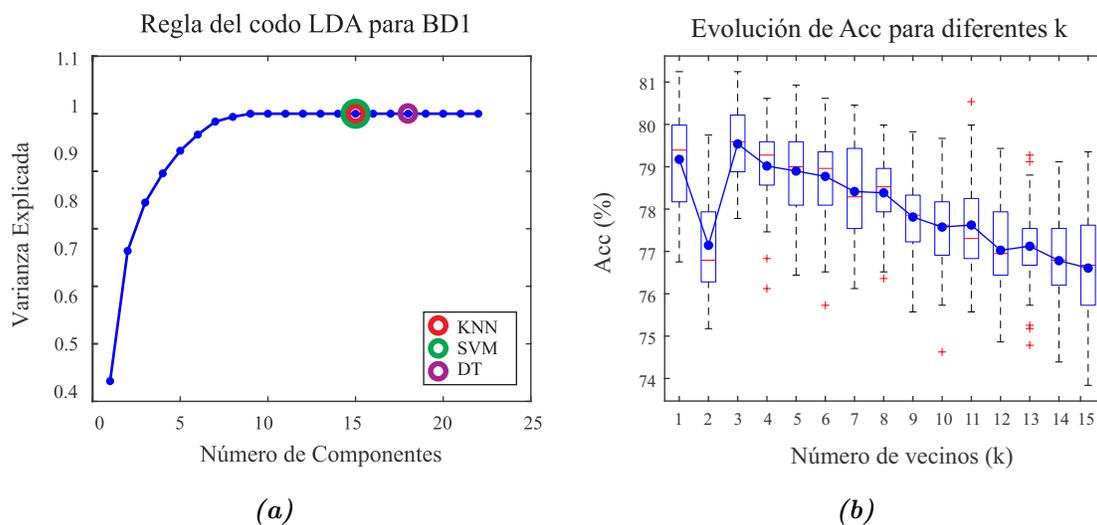


Figura 5.4: Pruebas para BD1 con LDA. (a) Estudio del número de componentes en función de la varianza de los datos. (b) Evolución de la exactitud para diferentes números de vecinos

Para este nuevo conjunto de características transformadas y reducidas mediante LDA, también se procede a evaluar el número óptimo de vecinos para el algoritmo KNN. La Figura 5.4b muestra un análisis mediante gráficos de caja y tendencia de la media, detalla cómo varía la exactitud (Acc) en función del número de vecinos (k). En estos gráficos se puede observar que la mayor eficacia en términos de precisión se alcanza al calcular la distancia entre el punto de interés y sus 3 vecinos más cercanos. Un desempeño igualmente satisfactorio, sin presencia de valores atípicos, se obtienen para un valor de k igual a 5. Los resultados promedio logrados para las 50 repeticiones de KNN bajo estos parámetros, junto con las pruebas de los demás algoritmos de aprendizaje, se detallan en la Tabla 5.3, mostrada a continuación.

Tabla 5.3: Resultados de LDA con algoritmos de aprendizaje para BD1.

Metodología	Acc $\pm \sigma$ [%]	C_v [%]	iqr [%]	Max [%]	Min [%]	Tiempo [seg]
KNN (k=3)	79.62 \pm 0.74	0.934	1.103	81.00	77.77	2.775
KNN (k=5)	78.90 \pm 0.78	0.999	1.103	80.85	77.22	2.794
SVM (Gaussiano)	76.55 \pm 1.14	1.489	1.576	79.27	74.31	605.806
SVM (Polinomial (d=3))	76.61 \pm 2.04	2.668	3.546	81.56	72.81	517.790
DT (Prueba: Curvatura)	63.59 \pm 1.27	2.001	1.576	67.45	60.83	3.967
DT (Prueba: Interacción)	63.51 \pm 1.26	1.996	1.733	67.21	60.83	4.0715

Los hallazgos encontrados revelan que, al igual que en PCA, en el caso de LDA, el algoritmo KNN con 3 vecinos muestra el mejor desempeño. Este modelo logró una exactitud promedio del 79.62 %, con una desviación estándar del 0.74 %, en un tiempo de ejecución de 2.775 segundos. Además, se observó un C_v de 0.934 que indica una relativa estabilidad en los resultados obtenidos. Lo que se valida con el valor del rango intercuartílico *iqr* de 1.103. Por otra parte, se evidencia un rendimiento alrededor de 3 % menor al de KNN para las dos pruebas realizadas con SVM; sin embargo, las medidas de dispersión y el tiempo para estos modelos aumentan considerablemente en comparación con KNN y DT. En última posición se encuentra en algoritmo DT, el cual resulta el menos competitivo en términos de exactitud.

En términos generales, para la base de datos BD1 los resultados más destacados surgieron de la combinación de **PCA+KNN** con 19 componentes principales. Este enfoque cuenta con una exactitud promedio de 80.24 %, superando ligeramente a su contraparte con LDA, que exhibió un rendimiento un 0.62 % inferior, logrando una exactitud máxima de hasta 82.11 %. La Figura 5.5a presenta un gráfico Anova que proporciona una representación visual del rendimiento de ambas metodologías. En este gráfico se evidencia que la combinación de PCA+KNN exhibe la menor variabilidad, lo que demuestra, junto con las medidas de dispersión, la solidez de los resultados obtenidos en la clasificación de fallos y severidad de las vigas en estudio.

Para realizar un análisis más exhaustivo del método que registro el mayor rendimiento, se recurre la matriz de confusión de Figura 5.5b. Este resultado en particular exhibe una exactitud

de 81.56 %, y se ubica entre los valores más altos de clasificación registrados. Al observar la matriz de confusión, se puede notar que la mayoría de los datos clasificados incorrectamente se encuentran a la derecha de la diagonal principal, representando un 11.82 % de los errores totales. En contraste, sólo un 6.62 % de los errores se localizan a la izquierda de la diagonal principal. Esta tendencia de errores sugiere una mayor probabilidad de clasificación incorrecta para muestras con un menor grado de daño, que con un daño mayor al estado actual.

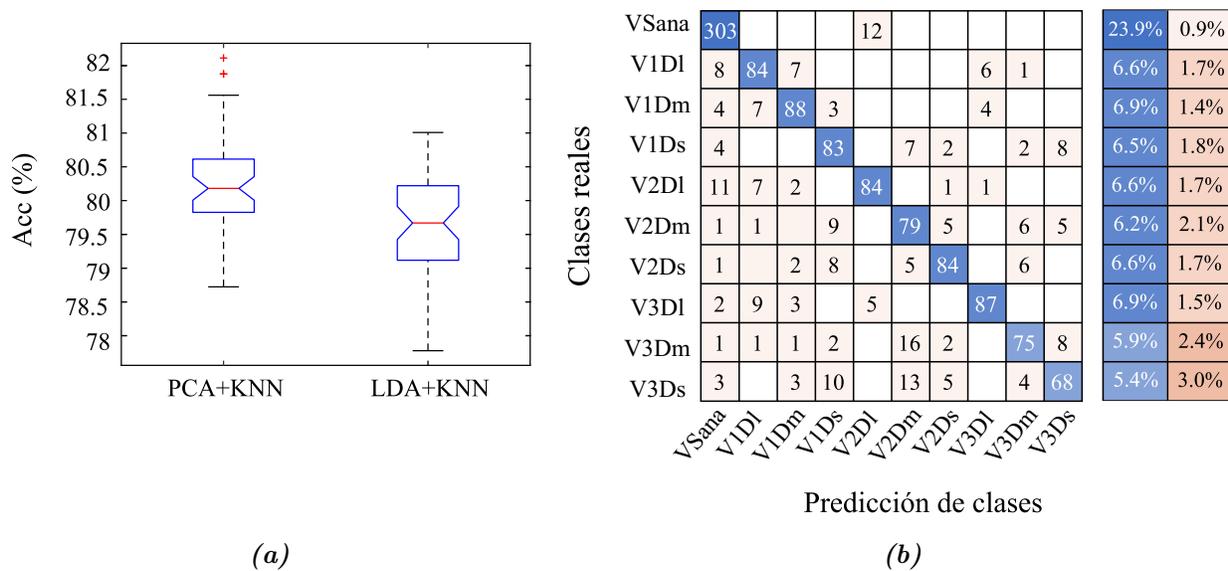


Figura 5.5: (a) Gráfica Anova de los mejores resultados para BD1. (b) Matriz de confusión generada con el modelo PCA+KNN.

En detalle, la clase de datos que representan estructuras saludables (VSana) se clasifica correctamente casi en su totalidad, con solo 12 de 315 muestras que fueron erróneamente asignadas a la categoría de daño leve en la viga 2 (V2Dl). Por otro lado, las clases de daño moderado y severo en la viga 3 (V3Dm, V3Ds) fueron las que presentan porcentajes de error más altos, lo cual podría deberse a que las grietas se ubican en el punto más alejado de la base fija de la estructura, desde donde se registran las mediciones.

5.2. Prueba BD2

En este segundo banco de pruebas, se toman en consideración las condiciones del sistema bajo las cuales se recolectaron las muestras. Cada nivel de daño cuenta con mediciones a diferentes longitudes de área transversal, para la base de datos BD2 cada uno de estos conjuntos corresponden a una clase específica. En total se tienen 63 clases balanceadas de 50 datos, lo que suman 3150 muestras. Es importante señalar que la base de datos BD2, abarcan todos los casos posibles de fallos, excluyendo las muestras que representan el estado sano del sistema. La complejidad de este conjunto de datos deriva de dos factores principales, el gran número de clases y la similitud entre las observaciones tomadas a longitudes consecutivas, lo que da lugar a clases bastante homogéneas y a datos potencialmente confusos. Este comportamiento se puede apreciar en la sección de reducción de dimensionalidad del Capítulo 4, donde se visualizan los subconjuntos de datos. Este escenario representa un reto tanto para la capacidad de representación de datos, como para el poder de clasificación de la metodología propuesta.

En cuanto al procedimiento experimental, se sigue el mismo enfoque y emplea las mismas herramientas de comparación y análisis que se detallaron previamente para las pruebas BD1. El número de componentes principales inmejorable para los algoritmos de clasificación se ilustran en la Figura 5.6a. Esta gráfica de codo muestra que para obtener el máximo rendimiento, se requieren 14 componentes para los algoritmos SVM y DT, mientras que KNN necesita 15 componentes. Estos resultados están en concordancia con el punto donde el incremento en la varianza explicada empieza a estabilizarse, lo que sugiere que a partir de allí, la adición de más componentes tiene un efecto mínimo en el rendimiento del modelo.

Con respecto al estudio de los parámetros ideales de KNN para este problema de clasificación, la Figura 5.6a lleva el registro de los valores de exactitud (Acc) en función al número de vecinos (k). Los modelos que lograron los niveles más altos de exactitud, evitando problemas de generalización asociados con el uso de un solo vecino, fueron aquellos configurados con un valor de k igual a 4 y 5, con el uso de estos parámetros se tienen un rendimiento similar. Este

rango de valores parece proporcionar el equilibrio adecuado entre precisión y estabilidad del modelo. Los resultados de aplicar los algoritmos de aprendizaje con los datos transformados con PCA, luego de 50 ejecuciones, se plasman en la Tabla 5.4.

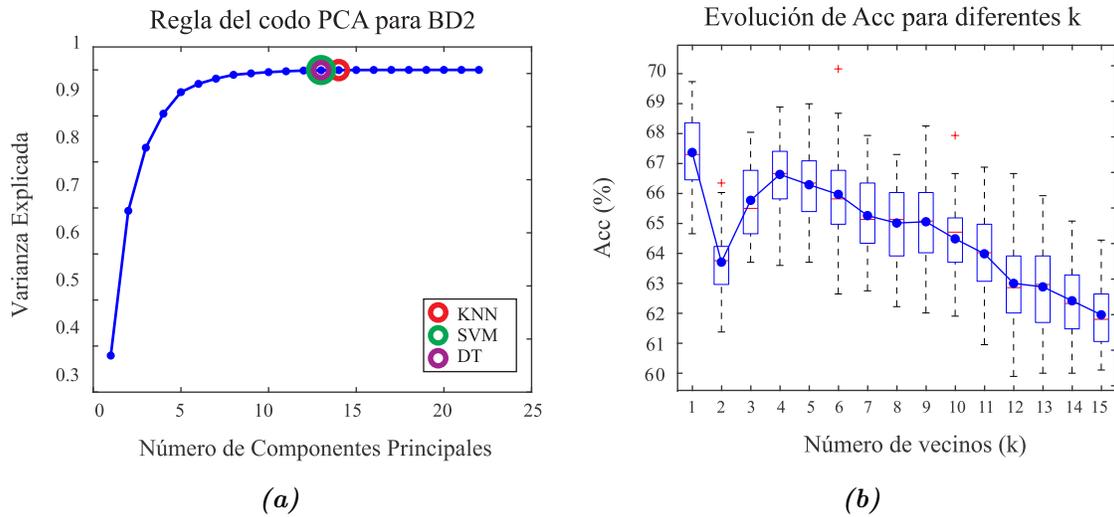


Figura 5.6: Pruebas para BD2 con PCA. (a) Estudio de número de componentes en función de la varianza de los datos. (b) Evolución de la exactitud para diferentes números de vecinos.

Tabla 5.4: Resultados de PCA con algoritmos de aprendizaje para BD2.

Metodología	Acc $\pm \sigma$ [%]	C_v [%]	iqr [%]	Max [%]	Min [%]	Tiempo [seg]
KNN (k=4)	66.00 \pm 1.29	1.958	1.693	68.57	62.85	2.998
KNN (k=5)	66.16 \pm 1.27	1.927	1.904	69.52	63.70	2.0351
SVM (Gaussiano)	63.53 \pm 1.28	2.015	1.693	66.34	60.21	7208.16
SVM (Polinomial (d=3))	70.38 \pm 0.98	1.399	1.058	73.43	68.14	6530.4
DT (Prueba: Curvatura)	50.86 \pm 1.72	3.387	2.433	55.44	46.45	5.332
DT (Prueba: Interacción)	50.73 \pm 1.71	3.373	2.433	55.44	46.45	4.609

Los algoritmos SVM y KNN demostraron un rendimiento superior en comparación con los dos conjuntos de pruebas realizadas para los árboles de decisión (DT). De manera puntual, el modelo que mostró el rendimiento más alto, en términos de exactitud promedio, fue el SVM con kernel polinomial de grado tres, alcanzando un valor del 70.38% con una desviación estándar

de 0.98. La capacidad de este tipo de kernel para crear una superficie de decisión compleja, se ajusta bien a los datos transformados con PCA cuya estructura compleja no es estrictamente lineal, permitiendo una mejor separación entre clases. Cabe destacar que este algoritmo también presentó un coeficiente de variación más bajo (1.399 %), lo que indica mayor consistencia en el rendimiento, aunque su tiempo de ejecución fue considerablemente más prolongado.

La gráfica de codo de la Figura 5.7a, expone los puntos donde se encontró el mejor rendimiento de los algoritmos. A diferencia de la evaluación de componentes anterior con PCA, para este caso LDA se beneficia de las condiciones homogéneas con las que fueron capturados los datos de las clases en BD2. Estas condiciones de la toma de datos repercuten de cierto modo en una varianza intra clase inherentemente baja. Las ventajas implícitas de los datos permite reducir más de la mitad de sus componentes sin comprometer la precisión del modelo, alcanzando los mejores resultados para SVM y DT en 9 componentes, mientras que KNN sólo necesitó de 8, implicando una reducción mayor al 60 % de las características iniciales.

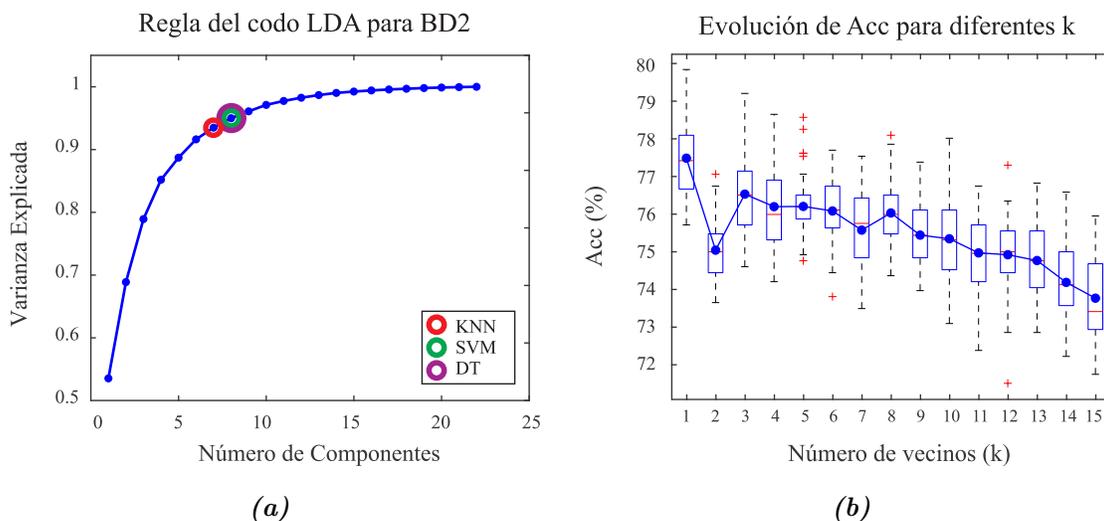


Figura 5.7: Pruebas para BD2 con LDA. (a) Estudio del número de componentes en función de la varianza de los datos. (b) Evolución de la exactitud para diferentes números de vecinos.

En relación con la investigación de los parámetros óptimos de KNN para la configuración con LDA, la gráfica de cajas en la Figura 5.6a muestra el rendimiento según el número de vecinos

(k). Luego de descartar el primer vecino, los niveles de exactitud promedio indican que para k igual a 3 se alcanzan los resultados más satisfactorios. No obstante, es relevante señalar que k igual a 5 también ofrece un rendimiento similar y bastante consistente, aunque se observa la presencia de algunos valores atípicos. La Tabla 5.5 contiene los resultados promedios producto de 50 repeticiones, para estas configuraciones de KKN y los demás algoritmos de aprendizaje.

Tabla 5.5: Resultados de LDA con algoritmos de aprendizaje para BD2.

Metodología	Acc $\pm \sigma$ [%]	C_v [%]	iqr [%]	Max [%]	Min [%]	Tiempo [seg]
KNN ($k=3$)	76.67 \pm 1.18	1.541	1.904	79.25	73.43	2.315
KNN ($k=5$)	76.61 \pm 1.31	1.714	2.010	79.36	74.17	2.233
SVM (Gaussiano)	80.25 \pm 1.07	1.333	1.587	82.75	78.20	6263.34
SVM (Polinomial ($d=3$))	78.08 \pm 1.23	1.583	1.693	81.16	75.87	5349.36
DT (Prueba: Curvatura)	68.02 \pm 1.14	1.682	1.693	70.26	64.97	4.492
DT (Prueba: Interacción)	68.23 \pm 1.08	1.591	1.269	70.79	66.03	4.770

De acuerdo con la Tabla 5.5, el rendimiento de los modelos producto de la combinación con LDA se consigue un 80.25 % de exactitud promedio con el algoritmo de SVM con kernel gaussiano, llegando a alcanzar como máximo de hasta un 82.75 % y un mínimo del 78.20 %, superando en aproximadamente un 2 % a KNN y en un 10 % a DT. Las métricas de dispersión para este enfoque de SVM indican una alta repetitividad y menores índices de variabilidad, con una desviación estándar de 1.07 y un C_v de 1.333, para los 50 modelos generados y evaluados. Pese a la alta precisión de esta metodología, se obtuvo un tiempo significativamente más largo alrededor de 1 hora y 44 minutos, entre la creación y evaluación de los modelos.

En resumen, las pruebas realizadas con el subconjunto de datos BD2 indican que las combinaciones más destacadas para cada metodología de reducción de dimensionalidad incluyen SVM, como se puede observar en el gráfico Anova de la Figura 5.8. Sin embargo, también es relevante señalar que estas metodologías requieren de un tiempo de ejecución prolongado. El rendimiento óptimo en términos de exactitud se logró con la combinación de **LDA+SVM** utilizando un kernel gaussiano y 9 componentes. En este caso, LDA permitió una significativa

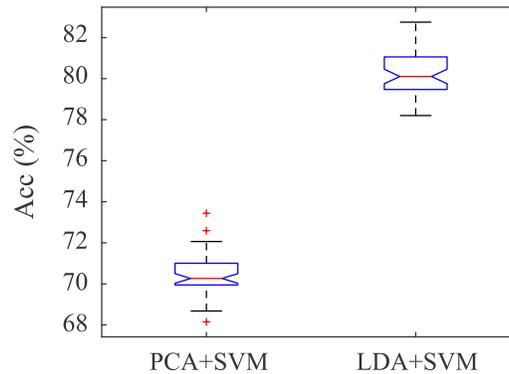


Figura 5.8: (a) Gráfica Anova de los resultados más destacados para BD2.

reducción de dimensiones basándose en la consistencia de los datos de BD2, lo que mejoró la interpretabilidad y contribuyó a un modelo más eficaz. En general, este enfoque mostró una mejora de hasta el 10% en el rendimiento de los algoritmos de aprendizaje SVM y KNN, y hasta un 18% para DT, en comparación con las configuraciones derivadas de PCA. Los resultados sugieren que la combinación de LDA y SVM puede ser especialmente eficaz para problemas de clasificación donde la interpretabilidad y la exactitud son clave.

5.3. Prueba BD3

La última prueba establecida abarca todas las posibles clases capturadas con el arreglo óptico. Para el conjunto de datos BD3, además de las clases de daños definidas en BD2, se incluye una nueva clase que representa condiciones sin fallas, lo que resulta en un total de 64 clases distintas. No obstante, al incorporar el estado "Sano", se genera un considerable desequilibrio en los datos. Puesto que las 63 clases que representan diferentes niveles de daños en diversas condiciones del sistema, cuentan con 50 muestras cada una. En cambio, la nueva clase contiene 1050 instancias, también recopiladas en diferentes condiciones del sistema. El desbalance en la base de datos BD3 puede complicar el entrenamiento de los algoritmos de ML, ya que los modelos tienden a sesgarse hacia la clase con más datos [97]. Además, persiste

el desafío, señalado anteriormente en BD2, relacionado con el gran número de clases y su alto grado de similitud. Esta situación plantea retos importantes para la metodología propuesta, incrementando el riesgo de errores de clasificación y poniendo entre dicho la eficacia del enfoque.

Siguiendo la misma metodología para clasificar fallos y evaluar los componentes involucrados, se llevarán a cabo los análisis de esta prueba. En la gráfica del codo de PCA para el subconjunto BD3 (Figura 5.9a), se identifica el número de componentes principales requeridos para obtener el máximo rendimiento interno en cada algoritmo de aprendizaje. Este valor fluctúa entre las técnicas de clasificación empleadas, el algoritmo DT y SVM precisan de 11 y 12 componentes, para un mejor desempeño. En tanto que KNN sólo admite la reducción de 3 componentes, requiriendo un total de 19 para lograr modelos más adaptados.

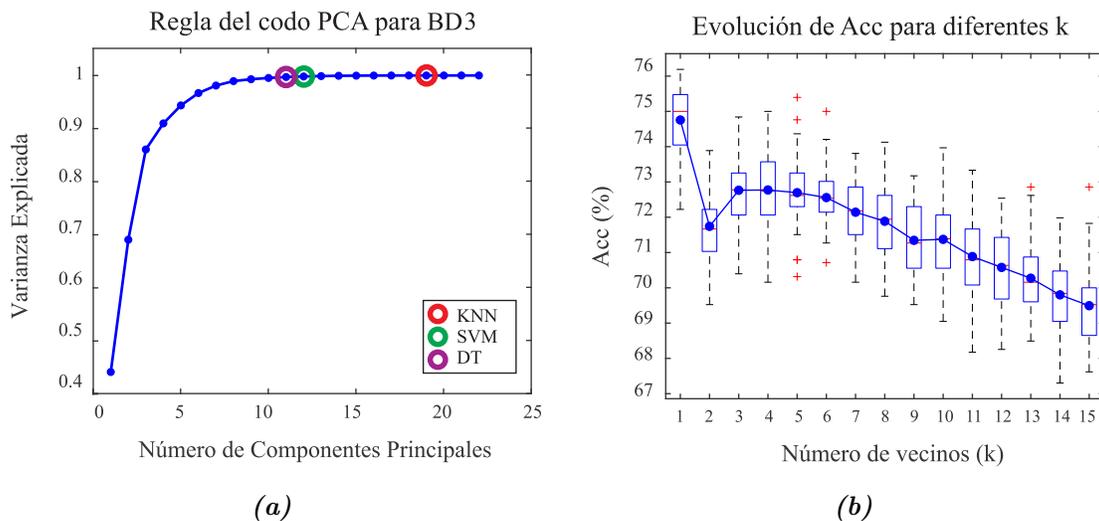


Figura 5.9: Pruebas para BD3 con PCA. (a) Estudio de número de componentes en función de la varianza de los datos. (b) Evolución de la exactitud para diferentes números de vecinos.

En cuanto a los valores óptimos para KNN, la Figura 5.9b presenta gráficos de caja con el rendimiento en términos de exactitud (Acc) con el uso de 1 a 15 vecinos (k). Sin embargo, se descarta el uso de un solo vecino porque, como se mencionó anteriormente, una decisión basada en un único punto puede hacer que el modelo sea excesivamente sensible. Por lo tanto, se recomienda el uso de varios vecinos para mejorar la estabilidad y la confiabilidad de las

predicciones. En este contexto, se considera el uso de 3 y 4 vecinos, los resultados promedio de estos parámetros, junto con los otros algoritmos de aprendizaje, se plasman en la Tabla 5.6.

Tabla 5.6: Resultados de PCA con algoritmos de aprendizaje para BD3.

Metodología	Acc $\pm \sigma$ [%]	C_v [%]	iqr [%]	Max [%]	Min [%]	Tiempo [seg]
KNN (k=3)	72.95 \pm 1.11	1.533	1.349	76.19	69.52	4.178
KNN (k=4)	72.70 \pm 1.11	1.533	1.269	74.92	69.68	4.425
SVM (Gaussiano)	69.18 \pm 1.06	1.542	1.349	71.03	66.03	8229.152
SVM (Polinomial (d=3))	65.23 \pm 3.26	5.011	2.698	68.80	55.79	7446.468
DT (Prueba: Interacción)	59.07 \pm 1.27	2.162	1.671	61.90	55.79	7.884
DT (Prueba: Curvatura)	59.08 \pm 1.14	2.146	1.592	61.98	55.79	7.158

Para el subconjunto de datos BD3, con el uso del algoritmo de reducción de dimensionalidad PCA, los resultados más destacados luego de 50 repeticiones, tanto en términos de exactitud como de tiempo, se obtuvieron con KNN. Puntualmente, al emplear 3 vecinos se logra una exactitud promedio apenas superior de 72.95% con desviación estándar de 1.11, llegando a obtener hasta un 76.19% de datos correctamente clasificados. Con respecto a las métricas estadísticas, aunque este modelo demuestra una mayor estabilidad dentro de la prueba, su C_v es ligeramente más alto que el de la misma metodología en pruebas anteriores. Esto podría atribuirse a la naturaleza específica de este conjunto de datos.

Como siguiente paso, y en consecuencia con el procedimiento de pruebas realizado anteriormente, se evalúa la reducción ideal de componentes transformados con LDA para cada algoritmo de aprendizaje. La Figura 5.10a expone el número de componentes que aportaron mejor rendimiento individual y que, por lo tanto, se utilizaron en el entrenamiento de los modelos. Aunque la regla del codo podría sugerir un resultado diferente, el algoritmo SVM solo necesitó 7 componentes para alcanzar su máximo rendimiento, mientras que KNN y DT requirieron 10 y 11 componentes, respectivamente, para desempeñarse de manera superior.

A continuación, se procede a establecer el número de vecinos que resultan efectivos para

el problema de clasificación para BD3. La Figura 5.10b muestra la exactitud (Acc) promedio en función del número de vecinos (k). Los valores que ofrecen soluciones más adecuadas, tras descartar el primer vecino por razones previamente discutidas, son k igual a 3 y 5. Por su parte, con el cálculo de distancia para 3 vecinos se tiene una mayor dispersión en los resultados. No obstante, el uso de 5 vecinos presenta un mayor riesgo de valores atípicos.

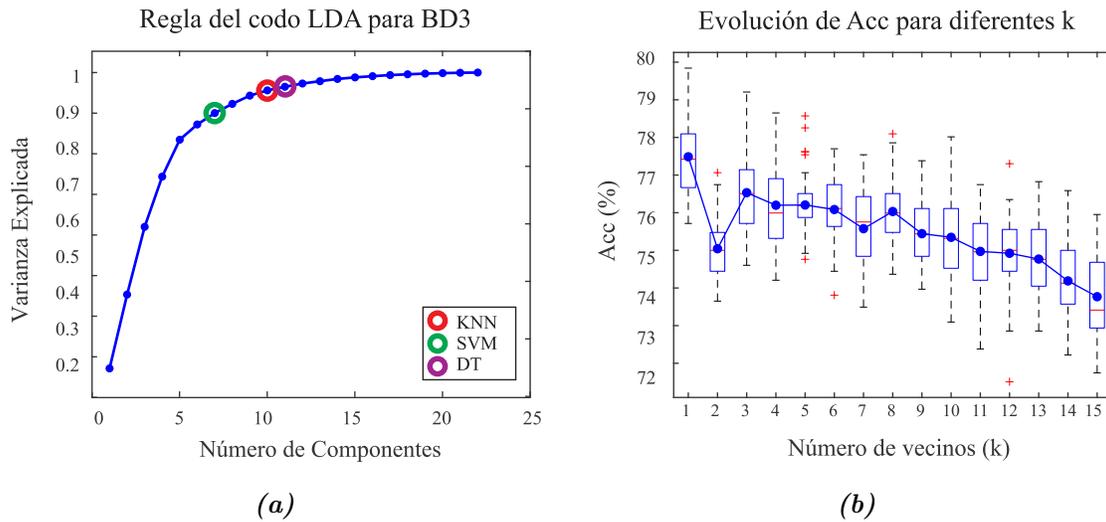


Figura 5.10: Pruebas para BD3 con LDA. (a) Estudio del número de componentes en función de la varianza de los datos. (b) Evolución de la exactitud para diferentes números de vecinos.

Tabla 5.7: Resultados de LDA con algoritmos de aprendizaje para BD3.

Metodología	Acc $\pm \sigma$ [%]	C_v [%]	iqr [%]	Max [%]	Min [%]	Tiempo [seg]
KNN (k=3)	76.38 \pm 1.03	1.357	1.349	78.09	72.69	3.1344
KNN (k=5)	76.05 \pm 0.95	1.258	1.428	78.33	74.12	7.1493
SVM (Gaussiano)	78.41 \pm 1.02	1.300	1.349	80.47	75.71	7281.714
SVM (Polinomial (d=3))	73.42 \pm 1.47	2.008	2.142	76.58	70.23	7700.304
DT (Prueba: Interacción)	62.94 \pm 1.41	2.238	1.981	67.06	60.31	6.726
DT (Prueba: Curvatura)	62.93 \pm 1.143	2.985	2.592	60.57	52.73	6.858

Producto las características transformadas con LDA y previamente reducidas, y de la evaluación de ciertos parámetros de los algoritmos de aprendizaje en cuestión, se obtuvieron los

resultados de prueba de la Tabla 5.7. En lo que respecta a la exactitud de las metodologías, basándose en el promedio 50 modelos, destaca SVM con kernel gaussiano. Con una clasificación promedio del 78.41 % y una desviación estándar del 1.02 %, esta técnica demuestra su capacidad de generalización gracias a sus bajos niveles de dispersión. En lo referente al tiempo de creación y evaluación de 50 modelos, refleja el más prolongado con aproximadamente 2 horas de ejecución. A diferencia de los modelos de KNN que ofrecen resultados igualmente estables en términos de variabilidad, logrando una exactitud de alrededor del 76 % en cuestión de segundos, lo que los hace más eficientes para aplicaciones con restricciones de tiempo.

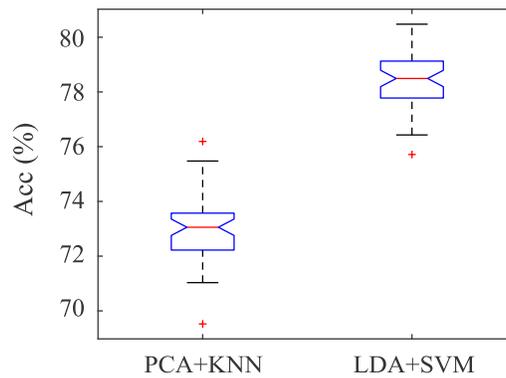


Figura 5.11: (a) Gráfico Anova de los resultados más sobresalientes para BD3.

Las pruebas realizadas con la base de datos BD3, sugieren que PCA produce modelos menos competitivos, posiblemente debido a la naturaleza específica de estos datos, que requiere enfoques más flexibles para lograr un mejor rendimiento. Por el contrario, la metodología integrada con LDA encuentra modelos apropiados para la clasificación de las 64 clases presentes, demostrando ser más eficaz en este contexto. Los resultados más destacados para las dos técnicas de reducción de dimensionalidad evaluadas se presentan en el gráfico de la Figura 5.11. Individualmente, la combinación de **LDA+SVM** con 7 componentes y un kernel gaussiano ofrece el rendimiento más alto, con condiciones ligeramente más estables que sus contrapartes. Sin embargo, es importante tener en cuenta que aunque esta metodología requiere de un amplio tiempo de ejecución para las condiciones establecidas en estas pruebas, no implica un factor limitante en su implementación en tiempo real, donde se hace uso del modelo ya construido.

Capítulo 6

Conclusiones

Este estudio presenta una metodología que combina un arreglo reflectivo de fibra óptica con técnicas de aprendizaje automático para analizar y clasificar diferentes conjuntos de señales de vibración en sistemas de vigas cantiléver.

El arreglo de fibra óptica empleado opera mediante modulación de amplitud por reflexión, donde una fibra óptica multimodo (FG105UCA) detecta las vibraciones inducidas en la viga cantiléver. Esta fibra recoge parte de la luz emitida y reflejada tras interactuar con la viga, utilizando un acoplador multimodo de tres puertos (TM105R5F1A). La intensidad de la luz captada es altamente sensible a los cambios de distancia entre la fibra y la superficie de la viga, reflejando el comportamiento vibratorio del sistema. La validación de las señales obtenidas, basada en su frecuencia fundamental, mostró un error relativo inferior al 5% para distintos valores del área transversal de la viga cantiléver. Estos resultados confirman la capacidad del arreglo óptico para captar señales de vibración con buena precisión.

La calidad de las aproximaciones obtenidas con el arreglo óptico permitió avanzar a la siguiente fase del proyecto, donde se creó una robusta base de datos con 4200 muestras. La recopilación de señales de vibración en múltiples escenarios del sistema viga cantiléver, facilitó la creación de tres subconjuntos de datos que posibilitan la evaluación de diferentes aspectos,

tanto de los datos como de la metodología de aprendizaje automático propuesta. Para el análisis y clasificación de las señales de vibración, se extrajeron tres grupos de características, de las cuales se identificaron 22 atributos con un comportamiento consistente, capaz de generar patrones que reflejan el funcionamiento del sistema. La metodología general para la clasificación de fallas, cuenta con una etapa de preprocesamiento para eliminar el ruido y la redundancia en las características. Para este fin, se evaluaron las técnicas de PCA y LDA, aplicándolas individualmente a los tres algoritmos de aprendizaje utilizados en la etapa de clasificación.

Previo a evaluar los subconjuntos, se realizó una prueba preliminar con las clases que muestran la progresión del crack, inducido en una viga con área transversal fija. Esta prueba demostró la capacidad de los datos para representar los daños y la eficacia de las metodologías de clasificación propuesta, alcanzando una exactitud superior al 96 % para tres de las cuatro técnicas utilizadas, llegando incluso al 100 % en algunos casos. La solidez de estos resultados abrieron paso a la prueba BD1, donde las técnicas de PCA o LDA con el algoritmo KNN mostraron un rendimiento superior. En particular, la combinación PCA+KNN, con 19 componentes, alcanzó una exactitud promedio del 80.24 % al priorizar la presencia o gravedad del daño sin considerar las condiciones intrínsecas del sistema. Por su parte, la matriz de confusión reveló cierta falta de distinción entre clases adyacentes en la escala de evolución del daño.

El segundo y tercer banco de pruebas incluyen todas las condiciones presentes durante la recolección de muestras. La prueba BD2 se enfoca en los casos de fallos, excluyendo las muestras del estado sano, mientras que la prueba BD3 sí las incluye. En ambas pruebas, el uso de PCA produce modelos menos competitivos en comparación con el desempeño que ofrece LDA, permitiendo reducir más de la mitad de los atributos originales. Para la clasificación de BD2, la estrategia más efectiva en este contexto fue LDA+SVM, pese a la cantidad y similitud de las clases, consigue un 80.25 % con el uso de 9 componentes. En cuanto al subconjunto BD3 donde se planteaba un escenario con mayor dificultad, la combinación LDA+SVM con 7 componentes alcanzó una exactitud promedio del 78.41 % al discernir entre las 64 condiciones específicas del sistema viga cantiléver.

En general, estas pruebas demostraron que incluso en entornos diferentes, complejos y desafiantes, la combinación adecuada de las técnicas propuestas en la metodología, según el conjunto de datos y las necesidades del modelo, puede ofrecer un rendimiento sólido. Esto se ve respaldado por la baja dispersión registrada en los resultados, lo que indica una alta repetitividad y, por ende, una buena capacidad de generalización. En cuanto al objetivo principal del proyecto, la integración del arreglo óptico con técnicas de aprendizaje automático, permitió el análisis y clasificación de las señales de vibración de manera eficiente y precisa en diversos contextos. Es importante destacar que producto de este trabajo se obtuvo una base de datos de procedencia óptica, con un nivel de exploración inicial bastante sólido. Esta base de datos queda a disposición de la comunidad científica para futuros estudios y análisis adicionales.

Finalmente, podemos decir que el enfoque multidisciplinario prestado en esta investigación representa una alternativa con gran potencial de aplicación en campos como la ingeniería estructural, la monitorización del estado de infraestructuras y la detección de fallas mecánicas. No obstante, este enfoque cuenta con ciertas limitaciones; por parte del arreglo óptico, se podría mejorar las propiedades de la punta expuesta de la fibra para incrementar su capacidad de colectar la irradiancia de luz, a la vez que se agrega mayor robustez y posibilidad de maniobra del arreglo. En cuanto al nivel de abstracción que concierne a los algoritmos empleados y al ajuste de sus hiperparámetros se podrían obtener mejores rendimientos empleando técnicas algorítmicas un poco más avanzadas. En primer lugar, se puede emplear metodologías basadas en el Diseño Automático de Algoritmos. Entre las múltiples opciones existentes se puede emplear una hiper-heurística de selección para la combinación de algoritmos. En cuanto a los hiperparámetros podemos emplear enfoques como el IRACE (*Iterated Racing for Automatic Algorithm Configuration*) para determinar el mejor ajuste para el modelo propuesto.

Referencias

- [1] S. Das, P. Saha, and S. K. Patro, “Vibration-based damage detection techniques used for health monitoring of structures: a review,” *Journal of Civil Structural Health Monitoring*, vol. 6, pp. 477–507, July 2016.
- [2] K. Loupos and A. Amditis, “Structural Health Monitoring Fiber Optic Sensors,” in *Fiber Optic Sensors: Current Status and Future Possibilities* (I. R. Matias, S. Ikezawa, and J. Corres, eds.), Smart Sensors, Measurement and Instrumentation, pp. 185–206, Cham: Springer International Publishing, 2017.
- [3] G. Boscato, L. Z. Fragonara, A. Cecchi, E. Reccia, and D. Baraldi, “Structural Health Monitoring through Vibration-Based Approaches,” *Shock and Vibration*, vol. 2019, p. 2380616, Feb. 2019.
- [4] Y. Yang, Y. Zhang, and X. Tan, “Review on Vibration-Based Structural Health Monitoring Techniques and Technical Codes,” *Symmetry*, vol. 13, p. 1998, Nov. 2021.
- [5] G. White, *Introducción al análisis de vibraciones*. Woburn, MA, Estados Unidos: Ázima DLI, 1 ed., 2010.
- [6] A. Moreno-Gomez, C. A. Perez-Ramirez, A. Dominguez-Gonzalez, M. Valtierra-Rodriguez, O. Chavez-Alegria, and J. P. Amezcua-Sanchez, “Sensors Used in Structural Health Monitoring,” *Arch Computat Methods Eng*, vol. 25, pp. 901–918, Nov. 2018.
- [7] A. Arnau *et al.*, *Piezoelectric transducers and applications*, vol. 2004. Springer, 2004.

- [8] N. Sabri, S. A. Aljunid, M. S. Salim, and S. Fouad, “Fiber Optic Sensors: Short Review and Applications,” in *Recent Trends in Physics of Material Science and Technology* (F. L. Gaol, K. Shrivastava, and J. Akhtar, eds.), Springer Series in Materials Science, pp. 299–311, Singapore: Springer, 2015.
- [9] K. Fidanboylyu and H. Efendioglu, “Fiber optic sensors and their applications,” *5th International Advanced Technologies Symposium (IATS’09)*, vol. 6, pp. 2–3, 2009.
- [10] D. Jauregui-Vazquez, J. Estudillo-Ayala, A. Castillo-Guzman, R. Rojas-Laguna, R. Selvas-Aguilar, E. Vargas-Rodriguez, J. Sierra-Hernandez, V. Guzman-Ramos, and A. Flores-Balderas, “Highly sensitive curvature and displacement sensing setup based on an all fiber micro fabry–perot interferometer,” *Optics Communications*, vol. 308, pp. 289–292, 2013.
- [11] D. Jauregui-Vazquez, J. Korterik, H. Offerhaus, R. Rojas-Laguna, and J. Alvarez-Chavez, “Strain optical fiber sensor with modified sensitivity based on the vernier effect,” *Instrumentation Science & Technology*, vol. 51, no. 4, pp. 421–434, 2023.
- [12] S. D. Guevara-Hernandez, J. C. Hernandez-Garcia, J. D. Filoteo-Razo, J. M. Estudillo-Ayala, S. G. H. García, M. R. Tapia-Garcia, O. Pottiez, D. Jauregui-Vazquez, D. A. Razo-Medina, and R. Rojas-Laguna, “Design and study of fiber optic interferometric devices applied to vibration detection systems,” in *Physics and Simulation of Optoelectronic Devices XXXII*, vol. 12880, pp. 27–36, SPIE, 2024.
- [13] D. Jauregui-Vazquez, J. Korterik, C. Osornio-Martinez, J. M. Estudillo-Ayala, H. Offerhaus, and J. A. Alvarez-Chavez, “A strain reflection-based fiber optic sensor using thin core and standard single-mode fibers,” *Optics Communications*, vol. 522, p. 128659, 2022.
- [14] D. Toral-Acosta, J. S. Hernández, D. Jauregui-Vazquez, A. Castillo-Guzmán, R. Rojas-Laguna, J. Estudillo-Ayala, and R. Selvas-Aguilar, “Torsion sensor using a mach-zehnder interferometer,” in *Photonic Fiber and Crystal Devices: Advances in Materials and Innovations in Device Applications VII*, vol. 8847, pp. 164–169, SPIE, 2013.

- [15] T. Wu, G. Liu, S. Fu, and F. Xing, “Recent Progress of Fiber-Optic Sensors for the Structural Health Monitoring of Civil Infrastructure,” *Sensors*, vol. 20, p. 4517, Jan. 2020.
- [16] Y. García, J. Corres, and J. Goicoechea, “Vibration Detection Using Optical Fiber Sensors,” *Journal of Sensors*, vol. 2010, Jan. 2010.
- [17] B. Gholamzadeh and H. Nabovati, “Fiber optic sensors,” *International Journal of Electronics and Communication Engineering*, vol. 2, no. 6, pp. 1107–1117, 2008.
- [18] B. H. Lee, Y. H. Kim, K. S. Park, J. B. Eom, M. J. Kim, B. S. Rho, and H. Y. Choi, “Interferometric fiber optic sensors,” *sensors*, vol. 12, no. 3, pp. 2467–2486, 2012.
- [19] J. Chen, B. Liu, and H. Zhang, “Review of fiber bragg grating sensor technology,” *Frontiers of Optoelectronics in China*, vol. 4, pp. 204–212, 2011.
- [20] E. Reyes-Vera, A. Valencia-Arias, V. García-Pineda, E. F. Aurora-Vigo, H. Alvarez Vásquez, and G. Sánchez, “Machine learning applications in optical fiber sensing: A research agenda,” *Sensors*, vol. 24, no. 7, p. 2200, 2024.
- [21] P. Xu, “Review on Studies of Machine Learning Algorithms,” *Journal of Physics*, vol. 1187, p. 052103, Apr. 2019.
- [22] M. O. Riedl, “Human-centered artificial intelligence and machine learning,” *Human Behavior and Emerging Technologies*, vol. 1, no. 1, pp. 33–36, 2019.
- [23] A. Venketeswaran, N. Lalam, J. Wuenschell, P. R. Ohodnicki Jr., M. Badar, K. P. Chen, P. Lu, Y. Duan, B. Chorpening, and M. Buric, “Recent Advances in Machine Learning for Fiber Optic Sensor Applications,” *Advanced Intelligent Systems*, vol. 4, no. 1, p. 2100067, 2022.
- [24] F. Khoshnoudian and A. Esfandiari, “Structural damage diagnosis using modal data,” *Scientia Iranica*, vol. 18, pp. 853–860, Aug. 2011.
- [25] F.-K. Chang, J. F. C. Markmiller, J. Yang, and Y. Kim, “Structural Health Monitoring,” in *System Health Management*, pp. 419–428, John Wiley & Sons, Ltd, 2011.

- [26] E. Udd and W. B. S. Jr, *Fiber Optic Sensors: An Introduction for Engineers and Scientists*. John Wiley & Sons, Oct. 2011.
- [27] C. I. Merzbacher, A. D. Kersey, and E. J. Friebele, “Fiber optic sensors in concrete structures: a review,” *Smart Materials and Structures*, vol. 5, p. 196, Apr. 1996.
- [28] C. Du, S. Dutta, P. Kurup, T. Yu, and X. Wang, “A review of railway infrastructure monitoring using fiber optic sensors,” *Sensors and Actuators A: Physical*, vol. 303, p. 111728, Mar. 2020.
- [29] F. I. H. Sakiyama, F. Lehmann, and H. Garrecht, “Structural health monitoring of concrete structures using fibre-optic-based sensors: a review,” *Magazine of Concrete Research*, vol. 73, pp. 174–194, Feb. 2021.
- [30] U. M. N. Jayawickrema, H. M. C. M. Herath, N. K. Hettiarachchi, H. P. Sooriyaarachchi, and J. A. Epaarachchi, “Fibre-optic sensor and deep learning-based structural health monitoring systems for civil structures: A review,” *Measurement*, vol. 199, p. 111543, 2022.
- [31] W. A. Altabey, Z. Wu, M. Noori, and H. Fathnejat, “Structural health monitoring of composite pipelines utilizing fiber optic sensors and an ai-based algorithm—a comprehensive numerical study,” *Sensors*, vol. 23, no. 8, p. 3887, 2023.
- [32] D. Goyal and B. S. Pabla, “The Vibration Monitoring Methods and Signal Processing Techniques for Structural Health Monitoring: A Review,” *Arch Computat Methods Eng*, vol. 23, pp. 585–594, Dec. 2016.
- [33] P. Puangmali, K. Althoefer, and L. D. Seneviratne, “Mathematical Modeling of Intensity-Modulated Bent-Tip Optical Fiber Displacement Sensors,” *IEEE Transactions on Instrumentation and Measurement*, vol. 59, pp. 283–291, Feb. 2010.
- [34] R. J. Black and B. Moslehi, “Advanced end-to-end fiber optic sensing systems for demanding environments,” in *Nanophotonics and Macrophotonics for Space Environments IV*, vol. 7817, pp. 167–175, SPIE, Sept. 2010.

- [35] X. Liu, B. Jin, Q. Bai, Y. Wang, D. Wang, and Y. Wang, “Distributed Fiber-Optic Sensors for Vibration Detection,” *Sensors*, vol. 16, p. 1164, Aug. 2016.
- [36] Q. Qiu and D. Lau, “Measurement of structural vibration by using optic-electronic sensor,” *Measurement*, vol. 117, pp. 435–443, Mar. 2018.
- [37] D. Goyal, Vanraj, B. S. Pabla, and S. S. Dhimi, “Non-contact sensor placement strategy for condition monitoring of rotating machine-elements,” *Engineering Science and Technology, an International Journal*, vol. 22, pp. 489–501, Apr. 2019.
- [38] A. Güemes, A. Fernández-López, P. F. Díaz-Maroto, A. Lozano, and J. Sierra-Perez, “Structural Health Monitoring in Composite Structures by Fiber-Optic Sensors,” *Sensors*, vol. 18, p. 1094, Apr. 2018.
- [39] F. Zhang, M. Jiang, L. Zhang, S. Ji, Q. Sui, C. Su, and S. Lv, “Internal Combustion Engine Fault Identification Based on FBG Vibration Sensor and Support Vector Machines Algorithm,” *Mathematical Problems in Engineering*, vol. 2019, p. e8469868, May 2019.
- [40] D. Goyal, S. S. Dhimi, and B. S. Pabla, “Non-Contact Fault Diagnosis of Bearings in Machine Learning Environment,” *IEEE Sensors Journal*, vol. 20, pp. 4816–4823, May 2020.
- [41] D. Malacara, *Óptica básica*. Ediciones Científicas Universitarias, FCE - Fondo de Cultura Económica, 2015.
- [42] D. Meschede, *Optics, Light and Lasers: The Practical Approach to Modern Aspects of Photonics and Laser Physics*. Physics textbook, Wiley, 2008.
- [43] E. Hecht, *Optics, Global Edition*. Pearson Education, 2016.
- [44] G. R. Fowles, *Introduction to modern optics*. Courier Corporation, 1989.
- [45] R. Paschotta, “Lasers.” RP Photonics Encyclopedia, Aug 2014.
- [46] R. Paschotta, “Refractive index.” RP Photonics Encyclopedia, Nov 2007.

- [47] R. Paschotta, “Total internal reflection.” RP Photonics Encyclopedia, Apr 2013.
- [48] R. Paschotta, “Specular reflection.” RP Photonics Encyclopedia, Dec 2019.
- [49] R. Paschotta, “Fibers.” RP Photonics Encyclopedia, Dec 2005.
- [50] G. Keiser, *Optical fiber communications*, vol. 2. McGraw-Hill New York, 2000.
- [51] F. Mitschke, *Fiber Optics: Physics and Technology*. Springer Berlin Heidelberg, 2010.
- [52] C. M. Davis, “Fiber Optic Sensors: An Overview,” *Optical Engineering*, vol. 24, no. 2, p. 242347, 1985.
- [53] S. V. Tawade, D. R. J. Patil, and A. S. Kale, “Comparative analysis of natural frequency of transverse vibration of a cantilever beam by analytical and experimental methods,” *International Research Journal of Engineering and Technology*, vol. 09, no. 4, 2022.
- [54] C. Rainieri and G. Fabbrocino, “Operational modal analysis of civil engineering structures,” *Springer, New York*, vol. 142, p. 143, 2014.
- [55] C. Gawali, AL y Sanjay, “Vibration analysis of beams,” *World Research Journal of Civil Engineering*, vol. 1, no. 1, pp. 15–29, 2011.
- [56] W. Thomson and H. Castell, *Teoría de vibraciones: aplicaciones*. Prentice-Hall Hispanoamericana, 1982.
- [57] D. J. Villalobos, J. C. J. Correa, A. M. Pérez, and J. E. Zarate, “Modelado matemático de una viga en voladizo por la ecuación de Euler-Bernoulli,” *Memorias del XV congreso internacional anual de la SOMIM*, 2009.
- [58] J. A. Ruiz, “Vibraciones de elementos simples con condiciones de contorno dependientes del tiempo,” Master’s thesis, Universidad Carlos III de Madrid, 2010.
- [59] C. Janiesch, P. Zschech, and K. Heinrich, “Machine learning and deep learning,” *Electronic Markets*, vol. 31, no. 3, pp. 685–695, 2021.

- [60] Z. Zhou and S. Liu, *Machine Learning*. Springer Nature Singapore, 2021.
- [61] G. Bonaccorso, *Machine learning algorithms*. Packt Publishing Ltd, 2017.
- [62] T. Mitchell, *Machine Learning*. McGraw-Hill series in computer science, McGraw-Hill, 1997.
- [63] A. P. T. Lau and F. N. Khan, *Machine Learning for Future Fiber-Optic Communication Systems*. Academic Press, 2022.
- [64] C. Cortes and V. Vapnik, “Support-vector networks,” *Machine learning*, vol. 20, pp. 273–297, 1995.
- [65] R. Duda, P. Hart, and D. Stork, *Pattern Classification*. Wiley, 2012.
- [66] L. Breiman, J. Friedman, C. Stone, and R. Olshen, *Classification and Regression Trees*. Taylor & Francis, 1984.
- [67] I. H. Sarker, “Machine Learning: Algorithms, Real-World Applications and Research Directions,” *SN Computer Science*, vol. 2, p. 160, Mar. 2021.
- [68] V. Sumithra and S. Surendran, “A review of various linear and non linear dimensionality reduction techniques,” *Int J Comput Sci Inf Technol*, vol. 6, no. 3, pp. 2354–60, 2015.
- [69] M. A. Salam, A. T. Azar, M. S. Elgendy, and K. M. Fouad, “The effect of different dimensionality reduction techniques on machine learning overfitting problem,” *Int. J. Adv. Comput. Sci. Appl*, vol. 12, no. 4, pp. 641–655, 2021.
- [70] F. S. Tsai and K. L. Chan, “Dimensionality reduction techniques for data exploration,” in *2007 6th International conference on information, communications & signal processing*, pp. 1–5, IEEE, 2007.
- [71] W. Jia, M. Sun, J. Lian, and S. Hou, “Feature dimensionality reduction: a review,” *Complex & Intelligent Systems*, vol. 8, no. 3, pp. 2663–2693, 2022.

- [72] S. Ayesha, M. K. Hanif, and R. Talib, “Overview and comparative study of dimensionality reduction techniques for high dimensional data,” *Information Fusion*, vol. 59, pp. 44–58, 2020.
- [73] G. T. Reddy, M. P. K. Reddy, K. Lakshmana, R. Kaluri, D. S. Rajput, G. Srivastava, and T. Baker, “Analysis of dimensionality reduction techniques on big data,” *Ieee Access*, vol. 8, pp. 54776–54788, 2020.
- [74] Y. Wang, P. Wang, K. Ding, H. Li, J. Zhang, X. Liu, Q. Bai, D. Wang, and B. Jin, “Pattern recognition using relevant vector machine in optical fiber vibration sensing system,” *IEEE Access*, vol. 7, pp. 5886–5895, 2019.
- [75] M. Grandini, E. Bagli, and G. Visani, “Metrics for Multi-Class Classification: an Overview,” Aug. 2020.
- [76] J. Devore, *Probabilidad Y Estadística Para Ingenierías Y Ciencias*. CENGAGE Learning, 2008.
- [77] R. Walpole, K. Ye, R. Myers, and S. Myers, *Essentials of Probability and Statistics for Engineers and Scientists, a la Carte*. Pearson Education, 2011.
- [78] M. Triola, L. Ayala, and R. Ramírez, *Estadística*. Pearson Education, 2012.
- [79] Thorlabs, *Optical Fiber-FG105UCA*, 2013.
- [80] Thorlabs, *Multimode Fiber Optic Coupler-TM105R5F1A*, 2017.
- [81] Crusier, *Visual Fault Locator, VFL*, 2020.
- [82] Thorlabs, *Photodetector-DET025AFC/M*, 2013.
- [83] P. Polygerinos, L. D. Seneviratne, and K. Althoefer, “Modeling of light intensity-modulated fiber-optic displacement sensors,” *IEEE transactions on instrumentation and measurement*, vol. 60, no. 4, pp. 1408–1415, 2010.

- [84] P. Puangmali, K. Althoefer, and L. D. Seneviratne, “Mathematical modeling of intensity-modulated bent-tip optical fiber displacement sensors,” *IEEE transactions on Instrumentation and Measurement*, vol. 59, no. 2, pp. 283–291, 2009.
- [85] E. O. Brigham, *The fast Fourier transform and its applications*. Prentice-Hall, Inc., 1988.
- [86] Z. Jassim, N. Ali, F. Mustapha, and N. A. Jalil, “A review on the vibration analysis for a damage occurrence of a cantilever beam,” *Engineering Failure Analysis*, vol. 31, pp. 442–461, 2013.
- [87] V. Khalkar and S. Ramachandran, “The effect of crack geometry on stiffness of spring steel cantilever beam,” *Journal of low frequency noise, vibration and active control*, vol. 37, no. 4, pp. 762–773, 2018.
- [88] J. J. Yanez-Borjas, M. Valtierra-Rodriguez, D. Camarena-Martinez, and J. P. Amezcuita-Sanchez, “Statistical time features for global corrosion assessment in a truss bridge from vibration signals,” *Measurement*, vol. 160, p. 107858, 2020.
- [89] J. J. Yanez-Borjas, D. Camarena-Martinez, M. Valtierra-Rodriguez, and J. P. Amezcuita-Sanchez, “Statistical time features-based methodology for fatigue cracks detection in a four-story building,” in *2020 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC)*, vol. 4, pp. 1–6, IEEE, 2020.
- [90] A. Banerjee and G. Pohit, “Crack investigation of rotating cantilever beam by fractal dimension analysis,” *Procedia Technology*, vol. 14, pp. 188–195, 2014.
- [91] A. Katunin, “Fractal dimension-based crack identification technique of composite beams for on-line shm systems,” *Machine Dynamics Research*, vol. 34, no. 2, pp. 60–69, 2010.
- [92] Y. Liu, K. Dai, D. Li, M. Luo, Y. Liu, Y. Shi, J. Xu, and Z. Huang, “Structural performance assessment of concrete components based on fractal information of cracks,” *Journal of Building Engineering*, vol. 43, p. 103177, 2021.

- [93] C.-T. Shi, “Signal pattern recognition based on fractal features and machine learning,” *Applied Sciences*, vol. 8, no. 8, 2018.
- [94] A. L. Coelho and C. A. Lima, “Assessing fractal dimension methods as feature extractors for emg signal classification,” *Engineering Applications of Artificial Intelligence*, vol. 36, pp. 81–98, 2014.
- [95] D. Singh and B. Singh, “Investigating the impact of data normalization on classification performance,” *Applied Soft Computing*, vol. 97, p. 105524, 2020.
- [96] B. Uragun and R. Rajan, “Developing an appropriate data normalization method,” in *2011 10th International Conference on machine Learning and Applications and Workshops*, vol. 2, pp. 195–199, IEEE, 2011.
- [97] J. Gu and D. Oelke, “Understanding bias in machine learning,” *arXiv preprint arXiv:1909.01866*, 2019.