




UNIVERSIDAD DE GUANAJUATO

CAMPUS IRAPUATO-SALAMANCA
DIVISIÓN DE INGENIERÍAS

*Detección de grietas en palas de aerogeneradores
usando señales de vibración*

TESIS

QUE PARA OBTENER EL GRADO DE:
MAESTRO EN INGENIERÍA ELÉCTRICA

PRESENTA:

Ing. Jose Javier Pantoja Molina

DIRECTORES:

Dr. David Camarena Martinez

Dr. Angel Diaz Pacheco

Agradecimientos

El desarrollo de este trabajo de investigación no habría sido posible sin el apoyo, la guía y el respaldo de diversas instituciones, profesores, familiares y amigos que caminaron a mi lado durante esta etapa de formación en el posgrado.

De manera muy especial, agradezco a mis directores de tesis, el **Dr. Camarena Martínez** y el **Dr. Ángel Pacheco**, por su invaluable dirección, paciencia, rigor científico y constante motivación. Su experiencia, consejos y exigencia académica no solo permitieron dar forma y solidez a esta investigación, sino que marcaron profundamente mi crecimiento profesional y humano como investigador. Gracias por creer en este proyecto y guiar cada paso del camino.

En el ámbito personal, deseo manifestar mi profundo agradecimiento a mi familia y seres queridos por su amor incondicional, comprensión y refugio en los momentos de mayor reto académico. Gracias a mi esposa, **Yoseline Torrealba**, por su paciencia infinita, por sostener mi ánimo con una sonrisa y por acompañarme de la mano en cada desvelo y logro. A mis queridos tíos **Fernando y Amarelis**, por sus palabras de aliento y su constante ejemplo de perseverancia. Este logro también les pertenece.


En honor a mi madre **Nadezka Molina** (que en paz descanse) y a mi

padre **Carlos Armando Pantoja** por ser un ejemplo de vida y siempre impulsarme.

Finalmente, a todas las personas e instituciones que de una u otra forma contribuyeron a la realización de este ciclo, mi más sincero reconocimiento y gratitud eterna.

Agradecimientos institucionales

Expreso mi más sincera gratitud hacia la Universidad de Guanajuato, especialmente a la División de Ingenierías del Campus Irapuato-Salamanca (DICIS) por la formación académica y por el apoyo financiero que he recibido durante mis estudios en esta institución bajo el NUA 1499270.



Este trabajo de tesis fue realizado gracias al apoyo invaluable recibido a través de la Secretaría de Ciencia, Humanidades, Tecnología e Innovación, SECIHTI de México, bajo el CVU 2063383.



Índice general

1. Introducción	11
1.1. Planteamiento del Problema	15
1.2. Objetivo	16
1.2.1. Objetivo General	16
1.2.2. Objetivos específicos	16
1.3. Justificación	17
1.4. Estructura de la Tesis	19
2. Marco teórico	21
2.1. Aerogeneradores	22
2.2. Fallas en aerogeneradores	24
2.3. Técnicas de detección de fallas en aerogeneradores	27
2.4. Otras técnicas de detección de fallas	30

ÍNDICE GENERAL

2.5. Análisis de las señales de vibración	33
2.6. Análisis en tiempo	34
2.7. Análisis en frecuencia	36
2.8. Extracción de características	37
2.8.1. Características en el dominio del tiempo	38
2.8.2. Características en el dominio de la frecuencia	43
2.9. Selección de características	46
2.9.1. Análisis de varianza (ANOVA)	47
2.9.2. Análisis de componentes principales (PCA)	48
2.9.3. Análisis discriminante lineal (LDA)	49
2.9.4. Uniform Manifold Approximation and Projection (UMAP)	50
2.9.5. Clasificadores de aprendizaje automático	51
2.10. Clasificadores	55
2.10.1. Clasificadores de aprendizaje automático	56
2.10.2. Redes neuronales multilayer perceptron (MLP ANN)	60
2.10.3. Red neuronal de doble cabeza de clasificación	62
2.11. Métricas de evaluación de los clasificadores	64
3. Metodología	70

ÍNDICE GENERAL

3.1. Diseño Experimental y Banco de Pruebas	70
3.1.1. Condiciones Operativas: Variabilidad del Viento	71
3.1.2. Simulación de la Falla Estructural	71
3.2. Adquisición y Preprocesamiento de Señales	75
3.2.1. Instrumentación y Parámetros de Muestreo	76
3.2.2. Aumento de Datos y Generación de Señales Sintéticas (<i>Data Augmentation</i>)	77
3.2.3. Estructuración y Segmentación del Conjunto de Datos	79
3.3. Extracción de Características	81
3.3.1. Descriptores en el Dominio del Tiempo	82
3.3.2. Métricas de Complejidad y Entropía	84
3.3.3. Descriptores en el Dominio de la Frecuencia	84
3.4. Selección de Características y Reducción de Dimensionalidad	86
3.4.1. Análisis de Componentes Principales (PCA)	87
3.4.2. Análisis Discriminante Lineal (LDA) y UMAP	88
3.5. Proceso de Selección de Modelos y Validación por Rejilla . . .	89
3.5.1. Arquitectura de Clasificación: Red Neuronal de Doble Cabeza	92
3.5.2. Capa de Entrada y Bloque de Extracción Compartida	92
3.5.3. Primera Cabeza: Clasificación de Velocidad (Contexto)	93

ÍNDICE GENERAL

3.5.4. Capa de Concatenación: Inyección de Contexto	94
3.5.5. Segunda Cabeza: Clasificación de Condición (Severidad)	94
3.6. Estrategia de Entrenamiento y Evaluación	95
3.6.1. Partición del Conjunto de Datos	95
3.6.2. Configuración de Hiperparámetros y Optimización	96
3.6.3. Regularización por Parada Temprana (<i>Early Stopping</i>)	97
3.6.4. Métricas de Evaluación del Desempeño	97
4. Resultados y Discusión	99
4.1. Análisis de Reducción de Dimensionalidad y Topología	99
4.2. Desempeño del Modelo de Clasificación de Doble Cabeza	101
4.2.1. Dinámica de Entrenamiento y Convergencia	101
4.2.2. Resultados de la Evaluación en Prueba Ciega	102
4.2.3. Validación Masiva de Robustez sobre 8 Grupos Independientes	104
4.3. Análisis de Eficiencia Computacional y Viabilidad para <i>Edge Computing</i>	105
4.3.1. Comparativa de Rendimiento Predictivo y Robustez	105
4.3.2. Carga Computacional y Requerimientos de Memoria	106
5. Conclusiones y Trabajo Futuro	108

ÍNDICE GENERAL

5.1. Conclusiones Generales	108
5.2. Aportaciones de la Investigación	109
5.3. Trabajo Futuro	110

Resumen

Los sistemas de monitoreo de condición en aerogeneradores enfrentan desafíos significativos al diagnosticar anomalías estructurales en las palas debido a la variabilidad operativa, particularmente por el “efecto enmascarador” provocado por las fluctuaciones en la velocidad del viento. Esta investigación propone una metodología robusta que combina la extracción de características estadísticas y fractales, el Análisis de Componentes Principales (PCA) para la reducción de dimensionalidad, y una novedosa arquitectura de Red Neuronal de Doble Cabeza orientada a multitarea. El paradigma de doble cabeza resuelve simultáneamente el contexto operativo de la velocidad del viento en la primera rama e inyecta esta información en la segunda rama para aislar la severidad del daño estructural. Evaluado exhaustivamente sobre un conjunto de datos maestro y validado rigurosamente en 8 grupos de prueba independientes y disjuntos que suman 16,000 muestras ciegas, el modelo propuesto alcanza una precisión de clasificación global excepcional del 99.92 % para la condición estructural y del 100.00 % para la velocidad operativa. Asimismo, con una huella de modelo compacta de tan solo 56.53 KB y un tiempo de inferencia inferior a 1.2 milisegundos por muestra, la arquitectura demuestra una viabilidad óptima para su despliegue en tiempo real mediante *Edge Computing* en entornos industriales eólicos.

Palabras clave: Álabes de Aerogeneradores, Sistema de Monitoreo de Condición (CMS), Red Neuronal de Doble Cabeza, Aprendizaje Multitarea, Análisis de Componentes Principales (PCA), Monitoreo de Integridad Estructural (SHM), Análisis de Vibraciones, Edge Computing.

Abstract

Wind turbine condition monitoring systems face significant challenges in accurately diagnosing structural blade anomalies due to operational variability, particularly the *masking effect* caused by fluctuating wind speeds. This research proposes a robust methodology combining statistical and fractal feature extraction, Principal Component Analysis (PCA) for dimensionality reduction, and a novel Multi-Task Dual-Head Neural Network architecture. The dual-head paradigm simultaneously resolves the operational wind speed context in the first branch and injects this information into the second branch to isolate structural damage severity. Evaluated comprehensively across a master dataset and validated rigorously over 8 independent, non-overlapping test groups comprising 16,000 blind samples, the proposed model achieves an exceptional overall classification accuracy of 99.92 % for structural condition and 100.00 % for operational speed. Furthermore, with a compact model footprint of only 56.53 KB and an inference time under 1.2 milliseconds per sample, the architecture demonstrates optimal feasibility for real-time Edge Computing deployment in industrial wind turbine environments.

Keywords: Wind Turbine Blades, Condition Monitoring System (CMS), Dual-Head Neural Network, Multi-Task Learning, Principal Component Analysis (PCA), Structural Health Monitoring (SHM), Vibration Analysis, Edge Computing.

Capítulo 1

Introducción

La transición energética global hacia fuentes de generación renovables ha posicionado a la energía eólica como uno de los pilares fundamentales de los métodos de generación eléctrica contemporánea. Sin embargo, la sostenibilidad económica y la fiabilidad operativa de los parques eólicos dependen de manera directa de la integridad estructural y funcional de los aerogeneradores. Estos sistemas electromecánicos operan bajo regímenes de carga inherentemente estocásticos y condiciones ambientales variables que, en determinados escenarios, pueden alcanzar niveles extremos, caracterizados por turbulencia atmosférica intensa, variaciones abruptas en la velocidad del viento y ciclos térmicos recurrentes. Dicho entorno operativo somete a los componentes críticos —en particular las palas y el tren de potencia— a fenómenos de fatiga de alto ciclo y esfuerzos mecánicos severos, favoreciendo la nucleación y propagación de defectos estructurales que comprometen la disponibilidad y vida útil del activo.

En este contexto, la detección temprana de mecanismos de fallo incipientes constituye un imperativo tanto técnico como económico. La migración desde estrategias de mantenimiento correctivo hacia esquemas de mantenimiento predictivo (*Predictive Maintenance*, PdM) permite reducir significativamente los tiempos de inactividad no planificados, optimizar el costo

nivelado de la energía (*Levelized Cost of Energy*, LCOE) y prevenir fallas catastróficas que podrían derivar en el colapso total de la estructura. Bajo este paradigma, la investigación reciente se ha orientado al desarrollo de metodologías de diagnóstico capaces no solo de identificar la presencia de una anomalía, sino también de caracterizar su tipología, severidad y relación con las condiciones operativas variables del aerogenerador.

Históricamente, la evaluación de la integridad estructural de las palas se ha sustentado en técnicas de inspección visual y termográfica. En este ámbito, Wang y Zhang [1] establecieron un precedente relevante al proponer una metodología para la detección automática de grietas superficiales mediante imágenes adquiridas por vehículos aéreos no tripulados (*UAVs*), utilizando características tipo Haar y clasificadores en cascada. Si bien estos enfoques basados en visión por computadora permiten automatizar la inspección externa, presentan limitaciones inherentes para evaluar defectos internos en materiales compuestos y, además, requieren la detención operativa de la turbina, lo que impacta negativamente en la disponibilidad del sistema.

Con el objetivo de superar estas restricciones y habilitar un monitoreo de condición continuo y en línea, la industria ha adoptado técnicas basadas en el análisis de vibraciones y el aprovechamiento de datos provenientes de sistemas SCADA (*Supervisory Control and Data Acquisition*). No obstante, la naturaleza no estacionaria de las señales vibroacústicas generadas por aerogeneradores de velocidad variable introduce desafíos significativos para los métodos tradicionales de procesamiento de señales, tales como la Transformada Rápida de Fourier (FFT), cuya aplicabilidad resulta limitada bajo estas condiciones dinámicas.

La complejidad asociada a la interpretación de dichas señales motivó la incorporación de técnicas de Aprendizaje Automático (*Machine Learning*) para automatizar los procesos de diagnóstico. En trabajos previos del grupo de investigación, Rangel-Rodríguez et al. [2] demostraron la viabilidad de detectar fisuras en turbinas eólicas de baja potencia mediante la extracción de características basadas en medidas de entropía y el uso de clasifi-

cadores convencionales como k -vecinos más cercanos (*K-Nearest Neighbors*, k -NN) y redes neuronales artificiales (ANN). De forma complementaria, enfoques híbridos como el propuesto por Jamil et al. [3] han validado la eficacia de combinar indicadores físicos del dominio del tiempo con modelos de aprendizaje automático para evaluar el estado de salud del tren de transmisión, integrando conocimiento del dominio con inferencia estadística.

Más recientemente, el paradigma ha evolucionado hacia el Aprendizaje Profundo (*Deep Learning*), impulsado por la capacidad de estas arquitecturas para aprender representaciones latentes complejas directamente a partir de los datos crudos, reduciendo la dependencia de procesos manuales de extracción de características. En este sentido, Masita et al. [4] presentan una revisión exhaustiva de cómo estas técnicas han transformado la detección de defectos en palas de aerogeneradores, abarcando fenómenos que van desde la erosión superficial hasta la formación de hielo.

En esta línea, Xu et al. [5] propusieron un método robusto para el diagnóstico de fallas en cajas de engranajes mediante Redes Neuronales Convolucionales (CNN) mejoradas, utilizando la Descomposición Modal Empírica por Conjuntos (EEMD) y Campos de Diferencia Angular de Gramian (GADF) como etapas de preprocesamiento para transformar series temporales en representaciones bidimensionales. De manera similar, Jiang et al. [6] desarrollaron arquitecturas CNN multiescala capaces de capturar características de falla en múltiples resoluciones temporales.

Contribuyendo a los trabajos previos del estado del arte, Rangel-Rodríguez et al. [7] implementaron una metodología basada en Campos Angulares Gramianos (GAF) combinados con CNNs para la detección de grietas, alcanzando una precisión del 99.2 %. Posteriormente, con el fin de incrementar la robustez frente al ruido inherente a entornos reales de operación, Rangel-Rodríguez et al. [8] desarrollaron un enfoque híbrido que integra la Descomposición Modal Empírica (EMD) con CNNs. De forma complementaria, Li y Gao [9] abordaron el problema del desequilibrio del rotor mediante la fusión de transformadas Wavelet y técnicas de aprendizaje profundo.

Diversos trabajos previos del grupo de investigación, tales como [7, 8, 10], han explorado múltiples estrategias para abordar el diagnóstico de fallas en turbinas eólicas de baja potencia. En [2] se evidenció la efectividad del análisis de vibraciones combinado con algoritmos de (*Machine Learning*), logrando altos niveles de precisión mediante la extracción de características estadísticas y el uso de clasificadores como k-NN y ANN. Posteriormente, en [11], se avanzó hacia esquemas de (*Deep Learning*), utilizando (*Campos Angulares Gramianos*, GAF) y CNNs, alcanzando precisiones superiores al 99 %. Más recientemente, en [10, 12], se propuso una metodología híbrida EMD–CNN que demostró mayor robustez frente al ruido y las variaciones de carga.

A pesar de la elevada precisión reportada por los modelos basados en *Deep Learning*, persiste una brecha crítica que motiva la presente investigación: el elevado costo computacional asociado a estas arquitecturas. Modelos complejos como las CNNs o los enfoques probabilísticos basados en Redes Bayesianas, revisados por Salboukh et al. [13], requieren recursos de procesamiento significativos —incluyendo unidades de procesamiento gráfico (GPUs)— y grandes volúmenes de datos para su entrenamiento. Estas exigencias dificultan su implementación en sistemas embebidos de bajo costo orientados al procesamiento en el borde (*Edge Computing*) limitando su viabilidad y escalabilidad a nivel industrial.

En consecuencia, surge la necesidad de investigar si es posible alcanzar niveles de precisión comparables a los obtenidos mediante (*Deep Learning*) empleando modelos de menor complejidad computacional, optimizando la etapa de extracción de características a través del uso de descriptores no lineales y de textura avanzados.

Para abordar esta brecha, el presente trabajo de investigación propone un método eficiente para el diagnóstico de grietas en palas de aerogeneradores sustentado en la extracción y selección de características mínimas de vibración. A diferencia de las aproximaciones basadas en *Deep Learning* tradicional, esta propuesta optimiza la etapa de procesamiento mediante descriptores avanzados de baja demanda computacional, garantizando niveles

de precisión competitivos. Con ello, se demuestra la viabilidad de migrar hacia esquemas de diagnóstico de fallas robustos que puedan ejecutarse directamente en sistemas de procesamiento en el borde (*Edge Computing*), reduciendo la dependencia de infraestructura de cómputo de alto rendimiento y facilitando su escalabilidad en entornos industriales reales.

1.1. Planteamiento del Problema

Los aerogeneradores operan bajo condiciones ambientales dinámicas y a menudo extremas, lo que somete a sus componentes estructurales, especialmente a las palas, a cargas cíclicas y estrés mecánico significativo. Las fisuras en las palas son uno de los modos de falla más críticos, ya que pueden propagarse rápidamente, comprometiendo la integridad estructural de todo el sistema y provocando paradas no planificadas que impactan la rentabilidad de los parques eólicos. Si bien existen técnicas de inspección visual y termográfica, el análisis de vibraciones se ha establecido como un método no invasivo y continuo ideal para la detección temprana de estos defectos.

Sin embargo, el desafío actual no radica en la posibilidad de detectar la falla, sino en hacerlo de manera eficiente y precisa bajo condiciones operativas variables. Las metodologías basadas en Deep Learning, como las propuestas recientemente en la literatura, han logrado altas tasas de precisión mediante la conversión de señales de vibración en representaciones complejas como espectrogramas o imágenes GAF para su procesamiento con redes neuronales convolucionales (CNN). Aunque efectivos, estos modelos suelen ser computacionalmente costosos y requieren grandes volúmenes de datos para su entrenamiento, lo que dificulta su implementación en sistemas embebidos de bajo costo y respuesta rápida.

A pesar de estos avances, persiste una brecha significativa: la necesidad de una metodología que logre el equilibrio óptimo entre la alta precisión de los modelos de Deep Learning y la eficiencia computacional de los enfoques clásicos. La presente investigación plantea la siguiente interrogante: ¿Es

1.2 Objetivo

posible alcanzar una precisión de diagnóstico superior al 99 % en la clasificación de la severidad de fisuras en palas de aerogeneradores utilizando una metodología de mínima complejidad computacional, basada en la selección inteligente de un conjunto reducido de características físicas y no lineales, que sea apta para su implementación en tiempo real y supere en eficiencia a los modelos complejos existentes?

A pesar de estos avances, persiste una brecha significativa: la necesidad de una metodología que logre el equilibrio óptimo entre la alta precisión de los modelos de *Deep Learning* y la eficiencia computacional de los enfoques clásicos. En respuesta a este desafío, la presente investigación tiene como objetivo fundamental demostrar que es posible alcanzar una precisión de diagnóstico superior al 99 % en la clasificación de la severidad de fisuras en palas de aerogeneradores mediante una metodología de mínima complejidad computacional. Este enfoque se sustenta en la selección inteligente de un conjunto reducido de características físicas y no lineales, lo que garantiza su viabilidad para una implementación en tiempo real y supera en eficiencia a los modelos complejos existentes.

1.2. Objetivo

1.2.1. Objetivo General

Desarrollar una metodología eficiente para el análisis de señales de vibración para la detección y clasificación de grietas en palas de los aerogeneradores utilizando aprendizaje automático.

1.2.2. Objetivos específicos

1. Analizar el estado del arte de las técnicas de diagnóstico para fallas en aerogeneradores, con énfasis en métodos de procesamiento de

señales de vibración y la comparación entre modelos de alta y baja complejidad computacional.

2. Implementar un proceso para la extracción de un conjunto de características estadísticas, espectrales y no lineales a partir de las señales de vibración del aerogenerador en sus diferentes condiciones de falla
3. Aplicar una técnica de selección de características para identificar el subconjunto óptimo y mínimo de indicadores, y entrenar un clasificador de aprendizaje automático de baja complejidad para clasificar la severidad de la falla.
4. Validar la metodología propuesta mediante la comparación de su rendimiento en precisión, costo computacional y tiempo de inferencia con los resultados de modelos complejos de deep learning reportados en la literatura, para demostrar su eficacia y eficiencia.

1.3. Justificación

La viabilidad técnico-económica de la energía eólica depende intrínsecamente de la capacidad para minimizar los costos nivelados de energía (*Levelized Cost of Energy*, LCOE). En este escenario, los costos de operación y mantenimiento (O&M) representan una fracción sustancial del presupuesto total de un proyecto eólico. Las palas, siendo los componentes encargados de la conversión de energía cinética a mecánica, son elementos críticos cuyo fallo no solo implica costosas sustituciones, sino tiempos prolongados de inactividad. Por consiguiente, la implementación de estrategias de mantenimiento basado en condición no invasivas, fundamentadas en el análisis de vibraciones, es imperativa para garantizar la integridad estructural y la continuidad operativa del activo.

En el ámbito del diagnóstico automatizado de fallas, la literatura actual exhibe una dicotomía dentro del espectro de la Inteligencia Artificial. Por un lado, las arquitecturas de Aprendizaje Profundo, particularmente las Redes Neuronales Convolucionales, han demostrado un desempeño superior en la extracción automática de características latentes, logrando altas tasas

1.3 Justificación

de precisión. Sin embargo, este enfoque conlleva una penalización significativa en términos de complejidad computacional, derivada a menudo de la necesidad de preprocesar las señales para convertirlas en representaciones bidimensionales (imágenes espectrales o de tiempo-frecuencia) y del gran número de parámetros a entrenar.

Por otro lado, las técnicas de Aprendizaje Automático Clásico (*Classical Machine Learning*) ofrecen una alternativa computacionalmente eficiente. Estos métodos, aunque dependen de una etapa explícita de ingeniería de características (*feature engineering*), permiten la implementación de modelos ligeros aptos para sistemas embebidos o *Edge Computing*.

La investigación se justifica por la necesidad de diagnosticar fisuras en aerogeneradores bajo condiciones operativas variables, donde la velocidad del viento introduce componentes vibracionales que enmascaran las señales de falla. Se propone demostrar que características físicas y no lineales entropía y patrones binarios locales permiten alcanzar precisiones equiparables al Aprendizaje Profundo, pero con algoritmos clásicos computacionalmente eficientes. Esto viabiliza sistemas de monitoreo en tiempo real, de bajo costo y alta fiabilidad, facilitando el acceso al mantenimiento predictivo avanzado.

Este proyecto de tesis abordó la brecha tecnológica existente, comprobando que no se requiere alta complejidad computacional si se realiza una extracción y selección inteligente de características físicas de la falla. Se desarrolló una metodología computacionalmente ligera, rápida y precisa. Los resultados demostraron que esta solución optimiza el diagnóstico y facilita la implementación masiva de monitoreo predictivo en parques eólicos, mejorando la seguridad, confiabilidad y accesibilidad de la energía eólica.

1.4. Estructura de la Tesis

El presente trabajo de investigación se encuentra organizado en cinco capítulos, diseñados para abordar secuencialmente la problemática del diagnóstico eficiente en aerogeneradores:

- **Capítulo 1: Planteamiento del Problema.** Se presenta el contexto global de la energía eólica y la problemática crítica asociada a las fallas estructurales en las palas de los aerogeneradores. Se establece la justificación del estudio, centrada en la necesidad de optimizar el costo computacional del diagnóstico sin sacrificar precisión, y se definen los objetivos generales y específicos que guían la investigación.
- **Capítulo 2: Fundamentos Teóricos.** Se exponen las bases de la dinámica estructural en aerogeneradores y los mecanismos de falla por fatiga en materiales compuestos. Se revisa el marco matemático de las técnicas de procesamiento de señales seleccionadas, profundizando en el análisis estadístico, la teoría de la información (Entropía), la geometría fractal. Finalmente, se describen los algoritmos de clasificación comparados: k-Vecinos Más Cercanos (k-NN) frente a Redes Neuronales Convolucionales (CNN).
- **Capítulo 3: Metodología.** Se describe el diseño experimental, detallando las características del banco de pruebas de la turbina eólica de baja potencia y la instrumentación para la adquisición de datos vibratorios. Se explica paso a paso la metodología propuesta para la extracción híbrida de características (físicas y de textura) y la configuración de los experimentos para validar la hipótesis de mínima complejidad.
- **Capítulo 4: Resultados y Discusión.** Se presentan los hallazgos experimentales, analizando la capacidad de discriminación de las características seleccionadas bajo diferentes velocidades de operación. Se realiza un análisis comparativo exhaustivo entre el enfoque propuesto y los modelos de *deep learning*, evaluando métricas de precisión diagnóstica, matrices de confusión y el costo computacional (tiempo de entrenamiento y de inferencia).

- **Capítulo 5: Conclusiones y Trabajos Futuros.** Se resumen las conclusiones principales, validando el cumplimiento de los objetivos y discutiendo las aportaciones al campo del mantenimiento predictivo en tiempo real. Finalmente, se sugieren líneas de investigación futura orientadas a la implementación en sistemas embebidos y la validación en turbinas de escala industrial.

Capítulo 2

Marco teórico

El diagnóstico de fallas estructurales en aerogeneradores constituye un tema de alta relevancia en los sistemas modernos de monitoreo de condición, debido a su impacto directo sobre la confiabilidad, la disponibilidad y la seguridad operativa de los parques eólicos. En particular, las fisuras en álabes representan un tipo de daño estructural crítico, ya que pueden modificar la respuesta dinámica del sistema, afectar la captación de energía y acelerar la degradación de otros componentes si no se detectan oportunamente. Bajo este contexto, el uso de señales de vibración para la detección de fallas ha demostrado ser una alternativa efectiva, especialmente cuando se combina con técnicas de procesamiento de señales y aprendizaje automático para la identificación de patrones asociados a condiciones anómalas [11, 14].

La literatura reciente muestra un avance significativo en el uso de enfoques basados en vibración para el diagnóstico de fallas en palas y estructuras eólicas. Por ejemplo, se ha reportado que el análisis de señales de vibración, junto con modelos de aprendizaje automático, permite detectar fisuras en aerogeneradores de baja potencia con un desempeño competitivo, lo que confirma la utilidad de este tipo de información para tareas de clasificación supervisada [11]. De forma complementaria, también se ha propuesto el uso de arquitecturas de fusión de características con señales vibratorias triaxiales,

2.1 Aerogeneradores

demostrando que la integración de información espacial y temporal mejora la robustez del diagnóstico de fallas estructurales en aerogeneradores [15].

En la frontera del estado del arte, la convergencia entre el análisis tiempo-frecuencia y las arquitecturas de aprendizaje profundo se ha consolidado como una estrategia altamente efectiva para el diagnóstico de daño en palas. Investigaciones recientes respaldan esta tendencia; por ejemplo, Sethi et al. [16] desarrollaron modelos basados en la transformada *wavelet* continua y redes profundas, aprovechando la representación multirresolución de la vibración para maximizar la sensibilidad ante cambios estructurales sutiles. De manera complementaria, Hang et al. [17] propusieron esquemas de monitoreo que unifican tareas de clasificación, detección, segmentación y evaluación del nivel de falla, evidenciando la viabilidad de los enfoques de inteligencia artificial para abordar el diagnóstico estructural desde una perspectiva integral.

Actualmente, la amplia disponibilidad de datos experimentales ha impulsado la evolución del monitoreo estructural. Investigaciones recientes [14, 18] evidencian una clara transición desde los métodos de evaluación tradicionales hacia enfoques híbridos, los cuales combinan la extracción de características físicas con modelos de inteligencia artificial. Tomando esta tendencia como punto de partida, el presente capítulo establece los fundamentos teóricos de la metodología propuesta. A continuación, se detallan las bases matemáticas empleadas para procesar señales de vibración unidimensionales y sustentar una arquitectura neuronal de baja complejidad, diseñada específicamente para aislar y diagnosticar fisuras en palas de aerogeneradores operando bajo regímenes de viento variables.

2.1. Aerogeneradores

Los aerogeneradores son sistemas electromecánicos diseñados para convertir la energía cinética del viento en energía eléctrica mediante la interacción entre componentes aerodinámicos, mecánicos y de control [19]. Su funcionamiento depende de un conjunto de subsistemas que operan de for-

2.1 Aerogeneradores

ma acoplada, entre los que destacan los álabes, el buje, la góndola, el sistema de transmisión, el generador y la torre [20]. Debido a que el recurso eólico presenta variaciones constantes en magnitud y dirección, estos equipos trabajan bajo condiciones dinámicas no estacionarias que imponen cargas cíclicas y esfuerzos variables sobre sus componentes estructurales. [20]

La Figura 2.1 muestra las partes principales de un aerogenerador y permite ubicar visualmente los elementos más relevantes para el diagnóstico de fallas estructurales. En particular, los álabes constituyen una de las zonas de mayor interés, ya que están expuestos de manera continua a sollicitaciones aerodinámicas, cargas de fatiga y fenómenos ambientales que pueden originar procesos de degradación progresiva, como fisuras, erosión o desbalance [14, 21].




Figura 2.1: Partes principales de un aerogenerador, Fuente propia 2026.

Desde el punto de vista constructivo, los aerogeneradores pueden clasifi-

carse principalmente en dos configuraciones: de eje horizontal y de eje vertical [19]. Los aerogeneradores de eje horizontal son los más utilizados en aplicaciones comerciales debido a su mayor eficiencia aerodinámica y a su madurez tecnológica. Por su parte, los aerogeneradores de eje vertical presentan ventajas en ciertas condiciones de operación, aunque su adopción industrial es menor. En ambos casos, la presencia de cargas variables y vibraciones inducidas por el viento hace necesario el monitoreo continuo del comportamiento estructural para detectar posibles anomalías en etapas tempranas [20].

En este contexto, el análisis de vibraciones se ha consolidado como una herramienta adecuada para el diagnóstico de condición en aerogeneradores, ya que permite identificar alteraciones en la respuesta dinámica del sistema asociadas con daños mecánicos o estructurales [22, 23]. Una fisura en un álabe puede modificar su rigidez local, alterar el equilibrio del rotor y generar cambios medibles en la señal vibratoria, lo que justifica el desarrollo de metodologías de diagnóstico basadas en procesamiento de señales y aprendizaje automático [24, 25].

Por lo anterior, el estudio de los aerogeneradores no debe limitarse a su principio de funcionamiento, sino que debe considerar también su comportamiento dinámico y la susceptibilidad de sus componentes a fallas estructurales. Esta perspectiva resulta fundamental para el desarrollo de estrategias de monitoreo y diagnóstico orientadas a incrementar la confiabilidad operativa y reducir los costos asociados al mantenimiento correctivo [14].

2.2. Fallas en aerogeneradores

Los aerogeneradores están expuestos a un conjunto de solicitaciones mecánicas, aerodinámicas y ambientales que favorecen la aparición de distintos tipos de fallas a lo largo de su vida útil [20]. Debido a la naturaleza intermitente y variable del recurso eólico, estos sistemas operan bajo cargas cíclicas y fluctuantes que provocan fenómenos de fatiga en componentes estructurales

y mecánicos. En este contexto, las fallas en aerogeneradores constituyen un tema central dentro del monitoreo de condición, ya que su detección oportuna permite preservar la confiabilidad operacional y disminuir los costos asociados al mantenimiento correctivo [14, 17].

Dentro de las fallas estructurales, las fisuras en las palas representan un caso particularmente importante, ya que afectan un componente sometido de forma continua a esfuerzos de flexión, torsión y vibración [26]. La literatura reciente ha mostrado que el daño en las palas puede modificar la rigidez local del elemento, alterar la distribución de masa y producir cambios medibles en la respuesta dinámica del sistema, por lo que su identificación temprana resulta esencial para evitar una propagación progresiva del daño [11, 18, 27, 28]. En particular, estas alteraciones estructurales se reflejan en la señal vibratoria, lo que justifica el uso de técnicas de análisis de vibración como estrategia de diagnóstico en aerogeneradores operando bajo condiciones variables [15, 22].

Las fisuras en las palas pueden originarse por múltiples causas, entre las que destacan la fatiga acumulada, impactos de partículas, erosión superficial, defectos de fabricación y condiciones ambientales adversas. Su evolución suele ser progresiva, por lo que una detección en etapas iniciales permite evitar daños mayores y reducir el riesgo de falla catastrófica [14]. Estudios recientes sobre monitoreo y clasificación de daño en álabes han demostrado que el comportamiento del defecto puede ser identificado mediante la explotación de patrones presentes en señales de vibración y en modelos de aprendizaje automático, lo que refuerza la pertinencia de abordar esta problemática desde un enfoque híbrido [16, 17].

En términos de monitoreo de condición, las fallas en aerogeneradores no siempre son fácilmente observables de manera directa, por lo que se requiere el uso de señales medidas durante la operación del sistema. Entre estas señales, la vibración ocupa un papel central debido a que responde de forma sensible a cambios en la rigidez, el equilibrio y la condición mecánica de los componentes. La evidencia reportada en la literatura indica que los esquemas de diagnóstico basados en vibración y aprendizaje automático

2.2 Fallas en aerogeneradores

permiten identificar con precisión distintos escenarios de falla en aerogeneradores, incluyendo fisuras estructurales en álabes y otros daños asociados al comportamiento dinámico del sistema [11, 15, 18].

La Tabla 2.1 resume una clasificación general de fallas en aerogeneradores, destacando la relevancia de las fallas estructurales dentro del contexto de esta investigación.

Tabla 2.1: Clasificación general de fallas en aerogeneradores.

Tipo de falla	Descripción	Ejemplos
Estructural	Afecta la integridad mecánica del aerogenerador.	Fisuras en álabes, delaminación, desbalance, deformación.
Mecánica	Relacionada con componentes móviles o de transmisión.	Fallas en rodamientos, engranajes, ejes.
Eléctrica	Asociada al generador o a los sistemas eléctricos.	Cortocircuitos, fallas de aislamiento, sobrecalentamiento.
Control y operación	Vinculada con el sistema de control y regulación.	Fallas en sensores, errores de orientación, control inestable.

La clasificación presentada en la Tabla 2.1 permite observar que, aunque los aerogeneradores pueden presentar diversos tipos de anomalías, las fallas estructurales son especialmente relevantes debido a su impacto directo sobre la integridad mecánica del sistema. En particular, las fisuras en álabes destacan por su capacidad de alterar la rigidez, la distribución de masa y la respuesta vibratoria del aerogenerador, lo que las convierte en un problema de interés prioritario dentro del diagnóstico de condición [11, 14]. Esta carac-

terización justifica el uso de técnicas de monitoreo basadas en vibración, ya que dichas señales reflejan de manera sensible los cambios producidos por el deterioro estructural [15, 16].

En consecuencia, el estudio de las fallas en aerogeneradores requiere una visión integral que considere tanto la naturaleza estructural del daño como su manifestación en señales medibles. Bajo esta perspectiva, las fisuras en álabes constituyen un problema de alto interés para el diagnóstico automático, ya que su detección temprana contribuye a mejorar la confiabilidad operativa y a reducir el riesgo de falla catastrófica [17, 18].

2.3. Técnicas de detección de fallas en aerogeneradores

La detección de fallas en aerogeneradores ha evolucionado desde enfoques tradicionales basados en inspección y diagnóstico manual hacia metodologías automáticas apoyadas en señales de vibración, datos operacionales y modelos de aprendizaje automático. Esta evolución responde a la necesidad de supervisar equipos que operan bajo condiciones variables, donde la aparición de daño puede no ser evidente de forma directa y, por tanto, requiere métodos capaces de extraer información útil de señales ruidosas y no estacionarias [13, 14]. En este sentido, el desarrollo de técnicas de detección no solo busca identificar la presencia de una falla, sino también aumentar la confiabilidad del sistema y reducir el tiempo de respuesta ante eventos anómalos.

De manera general, las estrategias de diagnóstico pueden agruparse en tres enfoques principales: métodos basados en modelo, métodos basados en datos y métodos híbridos. Los primeros dependen de la formulación matemática del sistema y de relaciones analíticas entre variables de entrada y salida; sin embargo, su aplicación práctica suele verse limitada por la complejidad dinámica del aerogenerador y por la presencia de incertidumbres

operativas. Los métodos basados en datos, por su parte, explotan patrones obtenidos a partir de sensores y registros históricos, lo que permite construir clasificadores capaces de distinguir entre condiciones sanas y defectuosas sin requerir un modelo físico exhaustivo. Finalmente, los métodos híbridos combinan ambas perspectivas y resultan especialmente útiles cuando se desea mejorar la robustez del diagnóstico en escenarios reales de operación [3, 13].

Dentro de las técnicas basadas en datos, el análisis de vibración ocupa un lugar central debido a que proporciona información sensible sobre cambios estructurales y mecánicos en los componentes del aerogenerador. La evidencia reciente muestra que, mediante procesamiento de señales y aprendizaje automático, es posible detectar con precisión condiciones anómalas en trenes de potencia y estructuras eólicas, incluso bajo regímenes de operación variables. En particular, el uso de redes neuronales, transformadas tiempo-frecuencia y técnicas de extracción de características ha demostrado ser efectivo para discriminar estados de falla en álabes, engranajes y otros elementos críticos [11, 15, 16]. Estos resultados justifican el uso de metodologías basadas en vibración para el diagnóstico temprano de fisuras en álabes.

La transformación de la señal en representaciones más informativas, como escalogramas, mapas de energía o distribuciones espectrales, ha permitido mejorar el desempeño de los clasificadores. En este contexto, estudios recientes han demostrado que la combinación de la transformada wavelet con redes neuronales convolucionales profundas y redes especializadas para series temporales facilita la identificación de patrones no lineales asociados al daño. Por ejemplo, se ha reportado el uso exitoso de modelos CNN mejorados, fusión de características y redes de doble rama para el diagnóstico de estructuras eólicas, lo que indica una tendencia clara hacia arquitecturas que aprovechan tanto la información temporal como la frecuencial de la señal [5, 9, 29]. Esta línea metodológica es coherente con el planteamiento de la presente tesis, en la que se propone una arquitectura de aprendizaje profundo de baja complejidad aplicada a señales unidimensionales de vibración.

Otra línea relevante de investigación se basa en modelos orientados al

análisis de fisuras en álabes mediante imágenes, datos operacionales o registros vibroacústicos. Aunque los métodos visuales han mostrado utilidad en inspección superficial, su aplicación suele depender de condiciones de accesibilidad y de la disponibilidad de imágenes de alta calidad. En contraste, las técnicas basadas en vibración permiten realizar monitoreo continuo y, por tanto, ofrecen una ventaja importante para escenarios en los que la inspección física no es viable. Esto ha llevado a que muchas propuestas recientes integren señales de vibración con aprendizaje profundo, buscando automatizar la detección y clasificación de fallas sin intervención manual intensiva [1, 4, 12].

Además del análisis de señales, el uso de información operacional y métodos probabilísticos también ha ganado relevancia en el diagnóstico de aerogeneradores. En particular, enfoques basados en redes bayesianas y en datos SCADA han demostrado ser útiles para evaluar la confiabilidad, modelar relaciones causales y anticipar comportamientos anómalos. Estos métodos son valiosos cuando se requiere complementar el diagnóstico basado en sensores locales con información de nivel de sistema, aunque su desempeño puede verse afectado por la calidad de los datos disponibles y por la dificultad de interpretar patrones sutiles en etapas tempranas de daño [3, 13]. Por ello, para el problema específico de fisuras estructurales en álabes, resulta más ventajoso centrar la atención en señales vibracionales de alta sensibilidad.

En síntesis, las técnicas de detección de fallas en aerogeneradores han avanzado hacia esquemas cada vez más automatizados, robustos y orientados a datos. La literatura reciente confirma que los métodos basados en vibración, transformadas tiempo-frecuencia y aprendizaje profundo constituyen una base sólida para el diagnóstico de daño en álabes y otras partes críticas del sistema [14–17]. En consecuencia, la presente investigación se apoya en esta evolución metodológica para desarrollar una estrategia de diagnóstico de fisuras en álabes operando bajo velocidad variable, combinando análisis de vibración unidimensional con una red neuronal de baja complejidad y doble cabeza de clasificación.

2.4. Otras técnicas de detección de fallas

Además de las metodologías basadas en vibración, la literatura reporta diversas estrategias para la detección y el monitoreo de fallas en aerogeneradores, entre las que destacan el análisis de datos SCADA, la termografía infrarroja, la emisión acústica, el ultrasonido, el análisis de aceite y el análisis de variables eléctricas. Estas técnicas han sido empleadas con distintos niveles de éxito para identificar condiciones anómalas, anticipar degradación y apoyar tareas de mantenimiento predictivo. Sin embargo, cada una presenta alcances y limitaciones específicas, por lo que su revisión comparativa resulta necesaria para justificar la selección de una metodología basada en vibración en la presente investigación.

El análisis de datos SCADA constituye una de las alternativas más difundidas en la industria eólica, ya que los aerogeneradores registran de manera continua variables operativas como potencia, velocidad del rotor, temperatura, orientación y estado de operación. Esta información permite construir modelos de monitoreo de condición y detectar desviaciones del comportamiento esperado sin instrumentación adicional. En este sentido, Martínez et al. propusieron una estrategia de predicción y detección de averías en aerogeneradores a partir de datos SCADA, mostrando su utilidad para el diagnóstico de fallas operativas [30]. No obstante, su principal limitación radica en que se trata de información indirecta y de baja frecuencia de muestreo, lo que puede restringir la detección temprana de daños estructurales o de defectos incipientes en componentes mecánicos.

La termografía infrarroja es otra técnica ampliamente utilizada para el monitoreo de condición, debido a que permite identificar distribuciones anómalas de temperatura asociadas con sobrecargas, fricción, deterioro eléctrico o fallas mecánicas. Balakrishnan et al. presentaron una revisión sobre termografía infrarroja para monitoreo basado en condición en aplicaciones de energía eléctrica, destacando sus ventajas como técnica no invasiva y visual para inspección de equipos [31]. En aerogeneradores, esta metodología puede ser útil para identificar sobrecalentamientos en subsistemas eléctricos

2.4 Otras técnicas de detección de fallas

y mecánicos; sin embargo, depende de condiciones ambientales favorables, acceso visual directo y, con frecuencia, de inspecciones programadas, por lo que no siempre resulta adecuada para monitoreo continuo de daños estructurales en álabes.

La emisión acústica representa una estrategia sensible a la liberación de energía elástica generada por la propagación de grietas, la fricción localizada o el inicio de otros procesos de daño. Yang et al. analizaron la detección de daños en álabes de aerogeneradores basada en señales acústicas, evidenciando su potencial para identificar condiciones anómalas en etapas tempranas [32]. Esta técnica tiene la ventaja de captar eventos transitorios asociados con el desarrollo del daño; sin embargo, su implementación práctica se ve condicionada por la presencia de ruido operacional y ambiental, así como por la necesidad de sistemas de adquisición especializados. Por ello, aunque ofrece sensibilidad temprana, su uso en campo puede ser más complejo que otras metodologías más robustas.

El ultrasonido también se ha empleado como técnica de inspección no destructiva en aerogeneradores. Thibbotuwa et al. propusieron un sistema inteligente basado en ultrasonido para el monitoreo de corrosión en turbinas eólicas offshore, mostrando que esta técnica es útil para detectar deterioro en componentes expuestos a ambientes severos [33]. Su principal fortaleza es la capacidad de localizar discontinuidades o defectos con buena resolución; no obstante, su aplicación se orienta principalmente a inspecciones puntuales y no tanto al monitoreo continuo en operación. Además, en componentes de gran tamaño o geometría compleja, la interpretación de los resultados puede verse limitada por la accesibilidad y las condiciones de medición.

El análisis de aceite es particularmente relevante en componentes lubricados, como multiplicadoras y rodamientos, ya que permite identificar partículas de desgaste, contaminación y degradación del lubricante. Kr Singh et al. analizaron las fallas de lubricación en multiplicadoras de aerogeneradores y propusieron un proceso de mitigación, evidenciando la importancia del lubricante como indicador del estado de salud del sistema [34]. Esta técnica proporciona información útil sobre el desgaste interno de subsistemas

mecánicos; sin embargo, su alcance está restringido a componentes lubricados y depende de muestreos periódicos o análisis especializados, por lo que no resulta adecuada para caracterizar fallas estructurales en álabes.

El análisis de variables eléctricas constituye una alternativa complementaria para el diagnóstico de fallas en generadores, convertidores y otros elementos del tren de potencia. Peng et al. estudiaron el análisis de fallas en equipos eólicos y la operación y mantenimiento inteligente, destacando la importancia de integrar información operativa para apoyar la toma de decisiones en mantenimiento [35]. Esta clase de técnicas aprovecha magnitudes como corriente, tensión o armónicos, lo que puede reducir la necesidad de instrumentación adicional. No obstante, su capacidad para detectar daños estructurales mecánicos es limitada, debido a que las perturbaciones eléctricas no siempre reflejan de forma directa la presencia de fisuras, desbalances o degradación en componentes estructurales.

En comparación con las técnicas anteriores, el análisis de vibración ofrece una relación más directa entre la respuesta dinámica del sistema y la presencia de defectos mecánicos o estructurales. Su principal ventaja es que permite monitoreo continuo y sensible a cambios en el comportamiento dinámico de la máquina, lo cual resulta especialmente útil para detectar fallas en álabes, rodamientos, engranajes y otros componentes críticos. Además, la vibración puede ser combinada con estrategias modernas de procesamiento de señales, extracción de características y aprendizaje automático, lo que incrementa la capacidad de diagnóstico y clasificación. En la literatura especializada existen diversos trabajos que respaldan esta afirmación, como Rangel-Rodriguez et al., quienes analizaron señales de vibración para la detección de grietas en aerogeneradores de baja potencia [11]; Sethi et al., quienes emplearon transformada wavelet continua y aprendizaje profundo para el diagnóstico de fallas en álabes [16]; Hang et al., quienes propusieron un modelo de IA para el monitoreo de grietas en álabes [17]; y Guan et al., quienes desarrollaron una red de fusión de características basada en vibración triaxial para el diagnóstico de fallas estructurales [15].

En síntesis, aunque SCADA, termografía infrarroja, emisión acústica, ul-

trasonido, análisis de aceite y variables eléctricas son herramientas valiosas dentro del mantenimiento predictivo de aerogeneradores, todas presentan restricciones relacionadas con la resolución temporal, la cobertura del fenómeno, la sensibilidad al entorno o la dependencia del tipo de componente analizado. Por ello, y de acuerdo con los antecedentes revisados en la literatura, el análisis de vibración se consolida como una alternativa especialmente adecuada para la detección de fallas estructurales en álabes, ya que combina sensibilidad, continuidad de monitoreo y compatibilidad con técnicas avanzadas de procesamiento y clasificación. Esta justificación respalda su selección como base metodológica en la presente tesis.

2.5. Análisis de las señales de vibración

El análisis de señales de vibración constituye una de las herramientas más empleadas en el monitoreo de condición de sistemas mecánicos, particularmente en equipos rotativos como motores, turbinas, rodamientos, engranajes y aerogeneradores. Este enfoque se basa en el hecho de que cualquier alteración en la estructura, el balanceo, la alineación o la integridad de un componente modifica su respuesta dinámica, lo que se refleja en la señal vibratoria medida durante su operación. En consecuencia, la vibración proporciona información relevante sobre el estado de salud del sistema y permite identificar patrones asociados con la aparición y evolución de fallas [14, 16].

En el caso de los aerogeneradores, el análisis vibracional adquiere una importancia particular debido a la complejidad del sistema, la variabilidad de las condiciones de operación y la necesidad de prevenir paros no programados. Los componentes mecánicos de un aerogenerador están sometidos a cargas fluctuantes originadas por la velocidad del viento, las turbulencias y los cambios de régimen operativo, lo que puede acelerar la degradación de elementos como álabes, rodamientos, ejes y cajas multiplicadoras. Bajo estas condiciones, las señales de vibración se convierten en un medio eficaz para detectar desviaciones respecto al comportamiento esperado del sistema [11, 17].

Desde una perspectiva de diagnóstico, la vibración presenta ventajas importantes frente a otras variables de monitoreo, ya que responde de manera relativamente directa a cambios mecánicos internos. Por ejemplo, una fisura incipiente en un álabe puede alterar la distribución de masas y rigidez, generando patrones vibratorios anómalos que pueden ser capturados mediante sensores adecuados. Del mismo modo, defectos en rodamientos o desalineaciones en el tren de potencia suelen producir modificaciones características en la amplitud, frecuencia o energía de la señal, lo que facilita su detección mediante técnicas de análisis apropiadas [15,36].

No obstante, la interpretación de las señales de vibración no es trivial. En aerogeneradores, estas señales suelen ser no estacionarias, ruidosas y dependientes del punto de operación, por lo que su análisis requiere técnicas de procesamiento que permitan extraer información útil a pesar de la variabilidad temporal del sistema. Por esta razón, el estudio de las señales vibratorias suele complementarse con procedimientos de análisis en el dominio del tiempo, el dominio de la frecuencia y la extracción de características discriminantes [12,16].

En este contexto, la vibración no solo actúa como un indicador del estado del sistema, sino también como la base sobre la cual se construyen metodologías de diagnóstico más avanzadas, incluidas aquellas apoyadas en aprendizaje automático y aprendizaje profundo. Por ello, el análisis de estas señales representa un paso fundamental para el desarrollo de estrategias de detección de fallas estructurales en aerogeneradores, como las fisuras en álabes abordadas en esta investigación [3,17].

2.6. Análisis en tiempo

El análisis en el dominio del tiempo consiste en estudiar directamente la evolución de la señal de vibración a lo largo del intervalo de medición, sin transformarla previamente a otro dominio. Este enfoque permite evaluar propiedades como la amplitud, la media, la varianza, el valor pico, el

2.6 Análisis en tiempo

valor eficaz y otros estadísticos descriptivos que reflejan cambios en el comportamiento dinámico del sistema. En aplicaciones de diagnóstico de fallas, estas medidas son útiles porque las alteraciones mecánicas suelen manifestarse como variaciones en la forma de la señal antes de que se presenten daños severos [11, 14].

En aerogeneradores, el análisis temporal es especialmente relevante debido a que las señales de vibración registradas durante la operación pueden contener información sobre impactos, cambios de carga y modificaciones en la rigidez estructural. Cuando ocurre una fisura en un álabe, por ejemplo, pueden aparecer aumentos en la amplitud, irregularidades en la periodicidad o cambios en la distribución estadística de la señal. Estos indicios resultan valiosos para construir indicadores tempranos de deterioro, sobre todo cuando se combinan con técnicas de clasificación automática [16, 17].

Una ventaja importante del análisis en tiempo es su simplicidad computacional, ya que los parámetros pueden calcularse de forma directa a partir de la señal original. Esto facilita su implementación en etapas preliminares de monitoreo o como base para construir características de entrada en modelos más complejos. Sin embargo, sus capacidades discriminantes pueden ser limitadas cuando las fallas generan alteraciones sutiles o cuando las señales presentan alta variabilidad operacional, como ocurre en aerogeneradores sometidos a velocidad variable y condiciones ambientales cambiantes [3, 15].

Por esta razón, el análisis temporal suele utilizarse como primer nivel de inspección y como complemento de otros procedimientos de extracción de información. Aunque por sí solo no siempre permite separar de manera robusta entre diferentes tipos de falla, sí aporta descriptores fundamentales que pueden integrarse con análisis en frecuencia o con modelos de aprendizaje automático para mejorar la capacidad de diagnóstico. En el contexto de esta tesis, el análisis en tiempo constituye una etapa básica pero necesaria para caracterizar el comportamiento vibratorio asociado con fisuras en álabes de aerogeneradores [12, 36].

2.7. Análisis en frecuencia

El análisis en frecuencia permite estudiar la señal de vibración a partir de su contenido espectral, identificando las componentes dominantes que aparecen en distintas bandas de frecuencia. Este enfoque es fundamental en diagnóstico de fallas porque muchos defectos mecánicos generan firmas espectrales específicas, tales como armónicos, bandas laterales o incrementos de energía en regiones concretas del espectro. En sistemas rotativos, estas características facilitan la identificación de anomalías que no siempre son evidentes en el dominio del tiempo [14, 36].

En aerogeneradores, el análisis espectral adquiere especial relevancia debido a la complejidad de los fenómenos dinámicos involucrados. La variación de carga, la velocidad del viento y el régimen operativo pueden producir señales no estacionarias, pero aun así es posible extraer patrones de frecuencia asociados con defectos estructurales o mecánicos. Por ejemplo, una fisura en un álabe puede modificar la respuesta dinámica del rotor y reflejarse en cambios en determinadas componentes espectrales, mientras que problemas en rodamientos o engranajes suelen generar frecuencias características relacionadas con su cinemática [11, 16].

Una de las ventajas del análisis en frecuencia es su capacidad para revelar información que permanece oculta en la señal temporal. Al transformar la señal mediante herramientas como la transformada de Fourier o representaciones espectrales derivadas, es posible observar cómo se distribuye la energía vibratoria en el sistema y detectar incrementos anómalos asociados con daños incipientes. Esta propiedad lo convierte en un recurso ampliamente utilizado para evaluar el estado de componentes críticos en aerogeneradores [15, 17].

Sin embargo, el análisis en frecuencia presenta limitaciones cuando la señal es fuertemente no estacionaria, como suele ocurrir en aerogeneradores operando bajo velocidad variable. En estos casos, el espectro global puede diluir información temporal importante y dificultar la localización exacta del evento de falla. Por ello, aunque es una técnica poderosa para identificar

componentes periódicas y resonancias, en muchas aplicaciones debe complementarse con estrategias más adaptativas o con técnicas de descomposición que preserven la variabilidad temporal de la señal [3, 12].

En el contexto de esta investigación, el análisis en frecuencia constituye una etapa esencial para caracterizar la respuesta vibracional del aerogenerador y localizar indicios de daño estructural en álabes. Su uso permite establecer relaciones entre la condición mecánica del sistema y la distribución espectral de la energía, lo cual resulta particularmente útil como base para la posterior extracción de características y clasificación automática de fallas [16, 36].

2.8. Extracción de características

La extracción de características es una etapa fundamental en los sistemas de diagnóstico basados en señales, ya que consiste en transformar la información bruta de la señal de vibración en un conjunto reducido de descriptores cuantitativos con capacidad discriminante. En el contexto de aerogeneradores, esta etapa permite resumir el comportamiento dinámico del sistema mediante variables que reflejan propiedades estadísticas, energéticas, geométricas y espectrales de la señal. De esta manera, se facilita la identificación de patrones asociados con condiciones normales y anómalas de operación.

Si se considera una señal discreta de vibración $x(n)$, con $n = 1, 2, \dots, N$, las características extraídas pueden agruparse en dos dominios principales: el dominio del tiempo y el dominio de la frecuencia. En el primer caso, se analizan propiedades directas de la amplitud de la señal; en el segundo, se estudia la distribución de la energía en el espectro. Ambas familias de atributos son útiles para representar distintos aspectos del fenómeno vibratorio.

2.8.1. Características en el dominio del tiempo

Las características temporales describen la forma de la señal en el instante de adquisición y permiten identificar cambios en su amplitud, dispersión, asimetría y comportamiento extremo. Entre las medidas más empleadas se encuentran la media, la desviación estándar, el rango, la mediana, la moda y el valor eficaz.

La media se define como:

$$\mu = \frac{1}{N} \sum_{n=1}^N x(n) \quad (2.1)$$

La desviación estándar está dada por:

$$\sigma = \sqrt{\frac{1}{N-1} \sum_{n=1}^N (x(n) - \mu)^2} \quad (2.2)$$

El rango se obtiene mediante:

$$R = x_{\text{máx}} - x_{\text{mín}} \quad (2.3)$$

La mediana corresponde al valor central de la muestra ordenada, mientras que la moda es el valor de mayor frecuencia de aparición.

2.8 Extracción de características

El valor cuadrático medio o RMS se calcula como:

$$x_{\text{RMS}} = \sqrt{\frac{1}{N} \sum_{n=1}^N x^2(n)} \quad (2.4)$$

El valor cuadrático medio, expresado como RMS por sus siglas en inglés, puede definirse mediante:

$$x_{\text{SMR}} = \frac{1}{N} \sum_{n=1}^N |x(n)| \quad (2.5)$$

A partir de estas medidas básicas también pueden derivarse índices normalizados como:

$$SF_{\text{RMS}} = \frac{x_{\text{RMS}}}{\mu_{|x|}} \quad (2.6)$$

$$SF_{\text{SMR}} = \frac{x_{\text{SMR}}}{\mu_{|x|}} \quad (2.7)$$

donde $\mu_{|x|}$ representa el valor medio absoluto de la señal de vibración.

Las medidas de forma más utilizadas en diagnóstico incluyen el factor de cresta, el factor de impulso, el factor de latitud, la desviación absoluta

2.8 Extracción de características

media, el factor de asimetría y el factor de curtosis. El factor de cresta se define como:

$$CF = \frac{\max(|x(n)|)}{x_{\text{RMS}}} \quad (2.8)$$

El factor de impulso es:

$$IF = \frac{\max(|x(n)|)}{\mu_{|x|}} \quad (2.9)$$

El factor de latitud puede expresarse como:

$$LF = \frac{x_{\text{RMS}}}{\sqrt{\frac{1}{N} \sum_{n=1}^N \sqrt{|x(n)|}}} \quad (2.10)$$

La desviación absoluta media se define como:

$$MAD = \frac{1}{N} \sum_{n=1}^N |x(n) - \mu| \quad (2.11)$$

El factor de asimetría y el factor de curtosis pueden escribirse como:

$$SkewFactor = \frac{\frac{1}{N} \sum_{n=1}^N (x(n) - \mu)^3}{\sigma^3} \quad (2.12)$$

2.8 Extracción de características

$$KurtFactor = \frac{\frac{1}{N} \sum_{n=1}^N (x(n) - \mu)^4}{\sigma^4} \quad (2.13)$$

Asimismo, los momentos de orden superior permiten capturar la forma general de la distribución de la señal:

$$Moment5 = \frac{1}{N} \sum_{n=1}^N (x(n) - \mu)^5 \quad (2.14)$$

$$Moment6 = \frac{1}{N} \sum_{n=1}^N (x(n) - \mu)^6 \quad (2.15)$$

La asimetría y la curtosis clásicas se expresan como:

$$Skewness = \frac{1}{N} \sum_{n=1}^N \left(\frac{x(n) - \mu}{\sigma} \right)^3 \quad (2.16)$$

$$Kurtosis = \frac{1}{N} \sum_{n=1}^N \left(\frac{x(n) - \mu}{\sigma} \right)^4 \quad (2.17)$$

Además de los descriptores estadísticos, pueden incorporarse medidas de complejidad y textura de la señal. La entropía de Shannon mide la incer-

2.8 Extracción de características

tidumbre asociada a la distribución de probabilidad p_i de la señal:

$$ShannonEnt = - \sum_{i=1}^M p_i \log(p_i) \quad (2.18)$$

La entropía de Rényi se define como:

$$RenyiEnt = \frac{1}{1-q} \log \left(\sum_{i=1}^M p_i^q \right) \quad (2.19)$$

donde q es el parámetro de orden. Para caracterizar la irregularidad y la complejidad geométrica de la señal pueden emplearse medidas de dimensión fractal, como la dimensión de Katz, la dimensión de Higuchi y la dimensión de box-counting. La dimensión fractal de Katz puede escribirse como:

$$KatzFD = \frac{\log(N)}{\log(N) + \log\left(\frac{d}{L}\right)} \quad (2.20)$$

donde d es la distancia máxima entre el primer punto y cualquier otro punto de la señal, y L es la longitud total de la curva.

La dimensión de Higuchi se obtiene a partir de la pendiente de la relación entre la longitud media de la curva y el tamaño de escala k :

$$L(k) \propto k^{-HiguchiFD} \quad (2.21)$$

2.8 Extracción de características

La dimensión de box-counting puede aproximarse mediante:

$$BoxCountFD = \lim_{\epsilon \rightarrow 0} \frac{\log N(\epsilon)}{\log(1/\epsilon)} \quad (2.22)$$

donde $N(\epsilon)$ representa el número de cajas necesarias para cubrir la señal con resolución ϵ . La homogeneidad, entendida como una medida de uniformidad o regularidad de la señal, puede expresarse de forma general a partir de la dispersión de sus valores o de una representación matricial derivada, dependiendo del método de cálculo utilizado. Finalmente, la energía concentrada cuantifica qué proporción de la energía total está reunida en un segmento específico de la señal o de su representación, lo que resulta útil para identificar patrones localizados de daño.

2.8.2. Características en el dominio de la frecuencia

Las características espectrales describen la distribución de la energía de la señal en el dominio de la frecuencia. Para una señal transformada en el dominio de la frecuencia $X(f)$, estas medidas permiten capturar cambios en la composición armónica del sistema y en la concentración de potencia en bandas específicas.

La frecuencia media se calcula como:

$$MeanFreq = \frac{\sum_{k=1}^M f_k P_k}{\sum_{k=1}^M P_k} \quad (2.23)$$

2.8 Extracción de características

donde f_k representa la frecuencia de la k -ésima componente espectral y P_k su potencia asociada.

La potencia media puede expresarse como:

$$MeanPower = \frac{1}{M} \sum_{k=1}^M P_k \quad (2.24)$$

Los momentos espectrales $SM1$, $SM2$ y $SM3$ se definen como:

$$SM1 = \sum_{k=1}^M f_k P_k \quad (2.25)$$

$$SM2 = \sum_{k=1}^M f_k^2 P_k \quad (2.26)$$

$$SM3 = \sum_{k=1}^M f_k^3 P_k \quad (2.27)$$

La desviación estándar frecuencial, la varianza frecuencial y el RMS frecuen-

cial se calculan como:

$$StdDevFreq = \sqrt{\frac{1}{M-1} \sum_{k=1}^M (f_k - MeanFreq)^2} \quad (2.28)$$

$$VarFreq = \frac{1}{M-1} \sum_{k=1}^M (f_k - MeanFreq)^2 \quad (2.29)$$

$$RMSFreq = \sqrt{\frac{1}{M} \sum_{k=1}^M f_k^2 P_k} \quad (2.30)$$

La asimetría y curtosis frecuenciales se definen análogamente al dominio temporal:

$$SkewFreq = \frac{\sum_{k=1}^M (f_k - MeanFreq)^3 P_k}{(StdDevFreq)^3} \quad (2.31)$$

$$KurtFreq = \frac{\sum_{k=1}^M (f_k - MeanFreq)^4 P_k}{(StdDevFreq)^4} \quad (2.32)$$

La relación RVF, o relación de variación frecuencial, puede expresarse como

2.9 Selección de características

un índice normalizado de dispersión espectral:

$$RVF = \frac{StdDevFreq}{MeanFreq} \quad (2.33)$$

En conjunto, estas características permiten representar la energía vibratoria del sistema desde perspectivas complementarias. Mientras las variables temporales capturan la forma global de la señal, las frecuenciales describen cómo se distribuye la energía entre distintas bandas. Esta complementariedad es especialmente útil para el diagnóstico de fallas en aerogeneradores, ya que los defectos estructurales pueden manifestarse como cambios sutiles en ambos dominios.

La extracción de características constituye, por tanto, una etapa intermedia entre la adquisición de la señal y la construcción del clasificador. Su objetivo no es únicamente resumir la información, sino generar un conjunto de atributos con capacidad discriminante que permita diferenciar entre condiciones normales y defectuosas. En esta investigación, las características descritas se emplean como base para la posterior selección de variables y el entrenamiento de clasificadores orientados a la detección de fisuras en álabes de aerogeneradores.

2.9. Selección de características

La selección de características constituye una etapa crítica en los sistemas de diagnóstico basados en señales de vibración, ya que permite reducir la dimensionalidad del espacio de atributos conservando únicamente aquellas variables que aportan mayor capacidad discriminante [24]. En problemas de detección de fallas en aerogeneradores, esta etapa resulta especialmente importante debido a que la extracción inicial puede producir un conjunto

amplio de descriptores en el dominio del tiempo y de la frecuencia, muchos de los cuales pueden ser redundantes, correlacionados o poco informativos para la clasificación final [11, 14, 25].

Desde una perspectiva metodológica, la reducción de dimensionalidad no solo contribuye a disminuir el costo computacional del entrenamiento, sino que también puede mejorar la generalización de los modelos, al eliminar ruido estadístico y evitar el sobreajuste [37]. En este trabajo se emplean criterios supervisados y métodos de proyección para identificar una representación más compacta del espacio de características, manteniendo atributos provenientes de ambos dominios de análisis. Esta estrategia es coherente con antecedentes recientes en diagnóstico de fallas en aerogeneradores, donde la integración de características vibracionales y modelos de aprendizaje automático ha mostrado una mejora notable en la capacidad de detección [15, 16, 27].

2.9.1. Análisis de varianza (ANOVA)

El análisis de varianza, o ANOVA, es un criterio supervisado que permite evaluar si existe una diferencia estadísticamente significativa entre las medias de una característica para distintas clases [38]. En el contexto de diagnóstico de fallas, una variable será más útil si presenta una separación clara entre las condiciones normales y defectuosas [28]. El estadístico F de ANOVA se define como la razón entre la variabilidad entre grupos y la variabilidad dentro de los grupos [39]:

$$F = \frac{MS_{between}}{MS_{within}} \quad (2.34)$$

donde:

$$MS_{between} = \frac{SS_{between}}{k - 1}, \quad MS_{within} = \frac{SS_{within}}{N - k} \quad (2.35)$$

y donde sus componentes son las siguientes

$$SS_{between} = \sum_{i=1}^k n_i (\bar{x}_i - \bar{x})^2 \quad (2.36)$$

$$SS_{within} = \sum_{i=1}^k \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_i)^2 \quad (2.37)$$

En estas expresiones, k representa el número de clases, n_i el número de muestras de la clase i , $\bar{x}_i$ la media de la clase i , y $\bar{x}$ la media global. Un valor alto de F sugiere que la característica presenta una buena capacidad de discriminación entre clases. Por ello, ANOVA resulta útil como filtro inicial para seleccionar descriptores relevantes provenientes tanto del dominio temporal como del frecuencial [12, 17, 40].

2.9.2. Análisis de componentes principales (PCA)

El análisis de componentes principales, o PCA, es una técnica no supervisada de reducción de dimensionalidad que proyecta los datos sobre una nueva base ortogonal formada por direcciones de máxima varianza. Aunque no utiliza las etiquetas de clase, es muy útil para compactar la información y eliminar correlaciones entre variables [41]. Dado un conjunto de datos centrado $X \in \mathbb{R}^{N \times p}$, la matriz de covarianza se expresa como:

$$\Sigma = \frac{1}{N-1} X^T X \quad (2.38)$$

Los componentes principales se obtienen resolviendo el problema de autovalores:

$$\Sigma v_i = \lambda_i v_i \quad (2.39)$$

donde λ_i es el autovalor asociado al autovector v_i . Los componentes se ordenan de acuerdo con λ_i en orden descendente, y se seleccionan los primeros m componentes que explican la mayor proporción de la varianza total. La proyección de los datos al subespacio reducido se define como:

$$Z = XW \quad (2.40)$$

donde W contiene los autovectores seleccionados. En diagnóstico de fallas en aerogeneradores, PCA es útil para comprimir el conjunto de características y reducir redundancia, especialmente cuando se combinan numerosos descriptores temporales y espectrales [3, 16, 26].

2.9.3. Análisis discriminante lineal (LDA)

El análisis discriminante lineal, o LDA, es una técnica supervisada que busca maximizar la separación entre clases mientras minimiza la dispersión interna de cada grupo [23]. A diferencia de PCA, LDA sí utiliza la información de las etiquetas, por lo que resulta especialmente adecuada para problemas de clasificación [42]. Su formulación se basa en la matriz de dispersión intraclass S_W y la matriz de dispersión interclass S_B :

$$S_W = \sum_{i=1}^k \sum_{x \in C_i} (x - \mu_i)(x - \mu_i)^T \quad (2.41)$$

$$S_B = \sum_{i=1}^k n_i (\mu_i - \mu)(\mu_i - \mu)^T \quad (2.42)$$

donde μ_i es la media de la clase i y μ la media global. El criterio de LDA consiste en encontrar una proyección W que maximice:

$$J(W) = \frac{|W^T S_B W|}{|W^T S_W W|} \quad (2.43)$$

Este criterio favorece las direcciones en las que las clases quedan mejor separadas. En el contexto de esta tesis, LDA es particularmente relevante porque permite conservar las características más discriminantes para distinguir entre condiciones normales y fallas estructurales en álabes de aerogeneradores [11, 15, 43].

2.9.4. Uniform Manifold Approximation and Projection (UMAP)

UMAP es una técnica de reducción de dimensionalidad no lineal que preserva la estructura local de los datos y, en cierta medida, su organización global [44]. Su utilidad resulta importante cuando las relaciones entre características no pueden describirse adecuadamente mediante proyecciones lineales [45]. UMAP construye primero un grafo de vecindad en el espacio original y luego busca una representación de baja dimensión que conserve la topología de ese grafo [46].

De forma general, UMAP define probabilidades de conexión entre puntos vecinos y minimiza la divergencia entre las distribuciones de alta y baja dimensión. Si P representa la estructura en el espacio original y Q la estructura proyectada, el objetivo consiste en minimizar una función de pérdida

de la forma [47]:

$$\mathcal{L} = \sum_{i,j} \left[P_{ij} \log \left(\frac{P_{ij}}{Q_{ij}} \right) + (1 - P_{ij}) \log \left(\frac{1 - P_{ij}}{1 - Q_{ij}} \right) \right] \quad (2.44)$$

Aunque UMAP no se emplea directamente como método clásico de selección, sí es una herramienta útil para explorar la estructura de los datos, visualizar la separación entre clases y generar una representación compacta antes de la clasificación [48]. En estudios recientes sobre fallas en aerogeneradores, las técnicas no lineales de representación han mostrado ser valiosas para revelar estructuras complejas en señales de vibración [3, 17].

En conjunto, ANOVA, PCA, LDA y UMAP permiten abordar la reducción de dimensionalidad desde perspectivas complementarias [24]. ANOVA actúa como filtro supervisado de relevancia, PCA compacta la información capturando la mayor varianza, LDA maximiza la separabilidad entre clases y UMAP preserva estructuras no lineales útiles para interpretación y clasificación [25]. Esta combinación resulta adecuada para el diagnóstico de fisuras en álabes de aerogeneradores, ya que permite integrar características provenientes de los dominios temporal y frecuencial en una representación más robusta y eficiente [15, 16, 36].

2.9.5. Clasificadores de aprendizaje automático

Los clasificadores de aprendizaje automático son modelos supervisados diseñados para aprender una relación funcional entre un conjunto de características de entrada y una etiqueta de salida [24]. En problemas de diagnóstico de fallas en aerogeneradores, su propósito es identificar automáticamente el estado operativo del sistema a partir de descriptores extraídos de señales de vibración, de manera que una observación nueva pueda ser asignada a

2.9 Selección de características

una clase específica, por ejemplo, condición normal, falla incipiente o daño estructural [27, 37]. Su fundamento matemático consiste en construir una función de decisión $f : \mathbb{R}^p \rightarrow \mathcal{C}$, donde p es el número de características y $\mathcal{C}$ el conjunto de clases posibles [47].

De forma general, si se dispone de un conjunto de entrenamiento $\{(x_i, y_i)\}_{i=1}^N$, donde $x_i \in \mathbb{R}^p$ representa el vector de características de la muestra i y $y_i \in \{1, 2, \dots, C\}$ indica su clase, el objetivo del clasificador es estimar una regla $\hat{f}(x)$ que minimice el error de predicción sobre datos no observados [48]. En términos probabilísticos, muchos clasificadores buscan estimar la probabilidad condicional $P(y = c \mid x)$ y luego asignar la clase con mayor probabilidad [46]:

$$\hat{y} = \arg \max_{c \in \mathcal{C}} P(y = c \mid x) \quad (2.45)$$

Esta formulación es común en múltiples algoritmos de clasificación y constituye la base de gran parte de los métodos supervisados utilizados en diagnóstico de fallas [45]. La calidad del resultado depende tanto de la representatividad de las características como de la capacidad del modelo para generalizar la estructura subyacente de los datos [25].

Entre los clasificadores clásicos más utilizados se encuentran la máquina de vectores de soporte, los vecinos más cercanos, los árboles de decisión, los bosques aleatorios y los modelos bayesianos [24]. Cada uno posee una formulación matemática distinta, pero todos comparten el objetivo de construir fronteras de decisión que separen eficientemente las clases [37].

En una máquina de vectores de soporte lineal, por ejemplo, la frontera de decisión se define mediante un hiperplano [27]:

$$w^T x + b = 0 \quad (2.46)$$

donde w es el vector de pesos y b el sesgo. El clasificador asigna una muestra a una clase u otra según el signo de $w^T x + b$ [47]. El entrenamiento busca maximizar el margen entre las clases, resolviendo el problema de optimización

[48]:

$$\min_{w,b} \frac{1}{2} \|w\|^2 \quad (2.47)$$

sujeto a:

$$y_i(w^T x_i + b) \geq 1, \quad i = 1, \dots, N \quad (2.48)$$

Cuando las clases no son linealmente separables, se introducen variables de holgura y funciones kernel que permiten proyectar los datos a espacios de mayor dimensión [46].

En el caso del clasificador k vecinos más cercanos, la asignación de clase se realiza a partir de la proximidad entre la muestra nueva y las observaciones del conjunto de entrenamiento [37]. Si $d(x, x_i)$ representa una distancia entre vectores de características, como la euclidiana [45]:

$$d(x, x_i) = \sqrt{\sum_{j=1}^p (x_j - x_{ij})^2} \quad (2.49)$$

entonces la clase se determina por votación mayoritaria entre los k vecinos más próximos [27]. Su simplicidad lo hace atractivo en problemas de clasificación tabular, aunque su desempeño puede verse afectado por alta dimensionalidad o escalas heterogéneas entre características [25].

Los árboles de decisión construyen reglas jerárquicas de separación mediante particiones sucesivas del espacio de entrada [24]. En cada nodo se selecciona la variable y el umbral que mejor separan las clases, normalmente

2.9 Selección de características

usando criterios como la impureza de Gini o la entropía [37]. La impureza de Gini se expresa como [47]:

$$G = 1 - \sum_{c=1}^C p_c^2 \quad (2.50)$$

donde p_c es la proporción de muestras de la clase c en el nodo. El árbol crece repitiendo esta partición hasta alcanzar un criterio de parada [48]. Su principal ventaja es la interpretabilidad, ya que permite visualizar las reglas de decisión utilizadas para clasificar las muestras [46].

Los bosques aleatorios extienden el concepto de árbol de decisión al construir un conjunto de árboles entrenados sobre subconjuntos aleatorios de datos y de variables [45]. La predicción final se obtiene mediante votación mayoritaria [27]:

$$\hat{y} = \text{mode}\{T_1(x), T_2(x), \dots, T_M(x)\} \quad (2.51)$$

donde $T_m(x)$ representa la predicción del árbol m y M es el número total de árboles [25]. Este enfoque reduce la varianza del modelo y mejora la robustez frente al sobreajuste, lo que resulta útil cuando se trabaja con un conjunto amplio de características extraídas de señales vibracionales [24].

Desde una perspectiva probabilística, los modelos bayesianos estiman la clase más probable mediante el teorema de Bayes [37]:

$$P(y = c \mid x) = \frac{P(x \mid y = c)P(y = c)}{P(x)} \quad (2.52)$$

Este enfoque permite incorporar conocimiento previo sobre las clases y re-

sulta útil cuando el número de muestras es limitado o cuando se desea una interpretación probabilística del diagnóstico [47]. En sistemas de monitoreo de aerogeneradores, esta característica puede ser valiosa para cuantificar la incertidumbre asociada a una predicción [48].

En términos prácticos, la elección del clasificador depende de la complejidad del problema, del tamaño del conjunto de datos y de la naturaleza de las características [46]. Cuando la separación entre clases es relativamente simple, métodos como SVM o árboles de decisión pueden ser suficientes [45]. Sin embargo, cuando las relaciones entre variables son altamente no lineales o cuando existen interacciones complejas entre características, modelos más potentes como bosques aleatorios o redes neuronales suelen ofrecer mejores resultados [27].

En diagnóstico de fallas en aerogeneradores, los clasificadores de aprendizaje automático cumplen un papel central porque convierten la información procesada de las señales de vibración en decisiones automáticas sobre el estado del sistema [24]. Su formulación matemática permite entender que no solo se trata de un mecanismo de etiquetado, sino de una función de aproximación que busca reproducir la estructura subyacente entre los atributos extraídos y los estados de falla [37]. Por ello, constituyen una base sólida para comparar metodologías y justificar el empleo de arquitecturas neuronales más avanzadas cuando el problema de clasificación es altamente complejo [25].

2.10. Clasificadores

Los clasificadores son modelos supervisados cuyo objetivo es asignar una etiqueta de clase a una muestra a partir de un conjunto de características previamente extraídas [24]. En problemas de diagnóstico de fallas en aerogeneradores, estos modelos permiten distinguir entre condiciones normales y defectuosas, así como entre distintos tipos de daño, utilizando patrones obtenidos de señales de vibración [37]. Su desempeño depende de la calidad de las características, de la separabilidad entre clases y de la capacidad del

modelo para generalizar ante datos no vistos [25].

2.10.1. Clasificadores de aprendizaje automático

Los clasificadores de aprendizaje automático son modelos supervisados diseñados para aprender una relación funcional entre un conjunto de características de entrada y una etiqueta de salida [24]. En problemas de diagnóstico de fallas en aerogeneradores, su propósito es identificar automáticamente el estado operativo del sistema a partir de descriptores extraídos de señales de vibración, de manera que una observación nueva pueda ser asignada a una clase específica, por ejemplo, condición normal, falla incipiente o daño estructural [27]. Su fundamento matemático consiste en construir una función de decisión $f : \mathbb{R}^p \rightarrow \mathcal{C}$, donde p es el número de características y $\mathcal{C}$ el conjunto de clases posibles [47].

De forma general, si se dispone de un conjunto de entrenamiento $\{(x_i, y_i)\}_{i=1}^N$, donde $x_i \in \mathbb{R}^p$ representa el vector de características de la muestra i y $y_i \in \{1, 2, \dots, C\}$ indica su clase, el objetivo del clasificador es estimar una regla $\hat{f}(x)$ que minimice el error de predicción sobre datos no observados [48]. En términos probabilísticos, muchos clasificadores buscan estimar la probabilidad condicional $P(y = c \mid x)$ y luego asignar la clase con mayor probabilidad [46]:

$$\hat{y} = \arg \max_{c \in \mathcal{C}} P(y = c \mid x) \quad (2.53)$$

Esta formulación es común en múltiples algoritmos de clasificación y constituye la base de gran parte de los métodos supervisados utilizados en diagnóstico de fallas [45]. La calidad del resultado depende tanto de la representatividad de las características como de la capacidad del modelo para generalizar la estructura subyacente de los datos [25].

Entre los clasificadores clásicos más utilizados se encuentran las Máquinas de Vectores de Soporte (SVM), los k -vecinos más cercanos (k -NN), los Árboles de Decisión, los Bosques Aleatorios (*Random Forest*) y Naive Bayes. Cada uno posee una formulación matemática distinta, pero todos comparten

2.10 Clasificadores

el objetivo de construir fronteras de decisión que separen eficientemente las clases [24].

En una máquina de vectores de soporte lineal, por ejemplo, la frontera de decisión se define mediante un hiperplano [27]:

$$w^T x + b = 0 \quad (2.54)$$

donde w es el vector de pesos y b el sesgo. El clasificador asigna una muestra a una clase u otra según el signo de $w^T x + b$ [47]. El entrenamiento busca maximizar el margen entre las clases, resolviendo el problema de optimización [48]:

$$\min_{w,b} \frac{1}{2} \|w\|^2 \quad (2.55)$$

sujeto a:

$$y_i(w^T x_i + b) \geq 1, \quad i = 1, \dots, N \quad (2.56)$$

Cuando las clases no son linealmente separables, se introducen variables de holgura y funciones kernel que permiten proyectar los datos a espacios de mayor dimensión [46].

En el caso del clasificador k vecinos más cercanos, la asignación de clase se realiza a partir de la proximidad entre la muestra nueva y las observaciones del conjunto de entrenamiento [37]. Si $d(x, x_i)$ representa una distancia entre vectores de características, como la euclidiana [45]:

$$d(x, x_i) = \sqrt{\sum_{j=1}^p (x_j - x_{ij})^2} \quad (2.57)$$

entonces la clase se determina por votación mayoritaria entre los k vecinos más próximos [27]. Su simplicidad lo hace atractivo en problemas de clasificación tabular, aunque su desempeño puede verse afectado por alta dimensionalidad o escalas heterogéneas entre características [25].

Los árboles de decisión construyen reglas jerárquicas de separación mediante particiones sucesivas del espacio de entrada [24]. En cada nodo se selecciona la variable y el umbral que mejor separan las clases, normalmente usando criterios como la impureza de Gini o la entropía [37]. La impureza de Gini se expresa como [47]:

$$G = 1 - \sum_{c=1}^C p_c^2 \quad (2.58)$$

donde p_c es la proporción de muestras de la clase c en el nodo. El árbol crece repitiendo esta partición hasta alcanzar un criterio de parada [48]. Su principal ventaja es la interpretabilidad, ya que permite visualizar las reglas de decisión utilizadas para clasificar las muestras [46].

Los bosques aleatorios extienden el concepto de árbol de decisión al construir un conjunto de árboles entrenados sobre subconjuntos aleatorios de datos y de variables [45]. La predicción final se obtiene mediante votación mayoritaria [27]:

$$\hat{y} = \text{mode}\{T_1(x), T_2(x), \dots, T_M(x)\} \quad (2.59)$$

donde $T_m(x)$ representa la predicción del árbol m y M es el número total de árboles [25]. Este enfoque reduce la varianza del modelo y mejora la robustez frente al sobreajuste, lo que resulta útil cuando se trabaja con un conjunto amplio de características extraídas de señales vibracionales [24].

Desde una perspectiva probabilística, los modelos bayesianos estiman la

clase más probable mediante el teorema de Bayes [37]:

$$P(y = c \mid x) = \frac{P(x \mid y = c)P(y = c)}{P(x)} \quad (2.60)$$

Este enfoque permite incorporar conocimiento previo sobre las clases y resulta útil cuando el número de muestras es limitado o cuando se desea una interpretación probabilística del diagnóstico [47]. En sistemas de monitoreo de aerogeneradores, esta característica puede ser valiosa para cuantificar la incertidumbre asociada a una predicción [48].

En términos prácticos, la elección del clasificador depende de la complejidad del problema, del tamaño del conjunto de datos y de la naturaleza de las características [46]. Cuando la separación entre clases es relativamente simple, métodos como SVM o árboles de decisión pueden ser suficientes [45]. Sin embargo, cuando las relaciones entre variables son altamente no lineales o cuando existen interacciones complejas entre características, modelos más potentes como bosques aleatorios o redes neuronales suelen ofrecer mejores resultados [27].

En diagnóstico de fallas en aerogeneradores, los clasificadores de aprendizaje automático cumplen un papel central porque convierten la información procesada de las señales de vibración en decisiones automáticas sobre el estado del sistema [24]. Su formulación matemática permite entender que no solo se trata de un mecanismo de etiquetado, sino de una función de aproximación que busca reproducir la estructura subyacente entre los atributos extraídos y los estados de falla [37]. Por ello, constituyen una base sólida para comparar metodologías y justificar el empleo de arquitecturas neuronales más avanzadas cuando el problema de clasificación es altamente complejo [25].

2.10.2. Redes neuronales multilayer perceptron (MLP ANN)

La red neuronal perceptrón multicapa, o MLP, es una arquitectura de aprendizaje supervisado compuesta por una capa de entrada, una o varias capas ocultas y una capa de salida [49]. Su objetivo es aproximar funciones complejas que relacionan un vector de características con una etiqueta de clase [24]. En el contexto de diagnóstico de fallas en aerogeneradores, una MLP puede aprender patrones no lineales presentes en los descriptores extraídos de señales de vibración, lo que la convierte en una alternativa adecuada cuando la separación entre clases no puede resolverse con modelos lineales [37].

Matemáticamente, si $x \in \mathbb{R}^p$ es el vector de entrada, la salida de la capa oculta l se obtiene como [47]:

$$h^{(l)} = \phi \left(W^{(l)} h^{(l-1)} + b^{(l)} \right) \quad (2.61)$$

donde $W^{(l)}$ es la matriz de pesos, $b^{(l)}$ el vector de sesgo, $\phi(\cdot)$ la función de activación y $h^{(l-1)}$ la salida de la capa anterior [48]. La primera capa toma como entrada el vector original, es decir, $h^{(0)} = x$ [46]. Las funciones de activación más empleadas son ReLU, sigmoide y tangente hiperbólica, las cuales introducen no linealidad en el modelo [45].

La capa final de una MLP para clasificación suele utilizar la función softmax, definida como [27]:

$$\hat{y}_c = \frac{e^{z_c}}{\sum_{j=1}^C e^{z_j}} \quad (2.62)$$

donde z_c representa la activación asociada a la clase c , y C es el número

total de clases [25]. Esta función transforma las salidas en probabilidades normalizadas, permitiendo interpretar la predicción como la clase más probable [24].

Durante el entrenamiento, los parámetros de la red se ajustan mediante retropropagación y optimización por gradiente [37]. Si la función de pérdida es la entropía cruzada, entonces [47]:

$$\mathcal{L} = - \sum_{i=1}^N \sum_{c=1}^C y_{ic} \log(\hat{y}_{ic}) \quad (2.63)$$

donde y_{ic} es la etiqueta real en codificación one-hot y $\hat{y}_{ic}$ la probabilidad predicha por la red para la clase c [48]. El objetivo del entrenamiento es minimizar esta pérdida ajustando los pesos de todas las capas [46].

La principal ventaja de la MLP es su capacidad para modelar relaciones no lineales entre las variables de entrada y la clase objetivo [45]. En problemas de diagnóstico de fallas en aerogeneradores, esto resulta útil porque las señales de vibración y sus características derivadas suelen contener patrones complejos que no pueden ser separados con fronteras lineales simples [27]. Además, cuando se combina con una adecuada selección de características, la MLP puede lograr un desempeño competitivo con una arquitectura relativamente compacta [25].

No obstante, el rendimiento de una MLP depende fuertemente del diseño de su arquitectura [24]. Un número excesivo de neuronas o de capas puede inducir sobreajuste, mientras que una arquitectura demasiado pequeña puede producir subajuste [37]. Por ello, la selección del número de capas ocultas, la cantidad de neuronas por capa, la función de activación y la tasa de aprendizaje debe realizarse de manera cuidadosa, especialmente en aplicaciones con datos limitados o con clases desbalanceadas [47].

En esta tesis, la MLP es relevante porque actúa como un clasificador capaz de explotar la representación vectorial generada a partir de las características temporales y frecuenciales de la señal vibratoria [48]. Su estructura sencilla, junto con su capacidad para modelar relaciones no lineales, la hace adecuada para comparar su desempeño frente a arquitecturas más especializadas en el diagnóstico de fisuras en álabes de aerogeneradores [46].

2.10.3. Red neuronal de doble cabeza de clasificación

La red neuronal de doble cabeza de clasificación es una arquitectura en la que una representación compartida de la entrada se bifurca en dos salidas independientes [24]. Esta estructura permite que el modelo aprenda una base común de características mientras especializa cada cabeza en una tarea de clasificación distinta [37]. En problemas de diagnóstico de fallas, esta estrategia puede ser útil cuando se desea predecir simultáneamente dos atributos relacionados con el estado del sistema, por ejemplo, el tipo de falla y su severidad, o bien dos salidas complementarias derivadas de la misma señal [25].

Sea $x \in \mathbb{R}^p$ la entrada y $f_\theta(x)$ la representación aprendida por un bloque compartido con parámetros θ [47]. A partir de esta representación, la red define dos cabezas [48]:

$$\hat{y}^{(1)} = g_{\phi_1}(f_\theta(x)) \quad (2.64)$$

$$\hat{y}^{(2)} = g_{\phi_2}(f_\theta(x)) \quad (2.65)$$

donde g_{ϕ_1} y g_{ϕ_2} son las funciones de salida asociadas a cada cabeza, con parámetros ϕ_1 y ϕ_2 , respectivamente [46]. Cada una puede terminar en una capa softmax si la tarea es multiclase, o en una capa sigmoide si la salida es binaria [45].

La función de pérdida total se construye como una combinación ponderada de las pérdidas individuales de cada cabeza [27]:

$$\mathcal{L}_{total} = \lambda_1 \mathcal{L}_1 + \lambda_2 \mathcal{L}_2 \quad (2.66)$$

donde $\mathcal{L}_1$ y $\mathcal{L}_2$ son las funciones de pérdida de cada tarea y λ_1, λ_2 son coeficientes de ponderación que controlan la contribución relativa de cada salida [24]. Cuando ambas cabezas resuelven clasificación multiclase, la pérdida puede definirse mediante entropía cruzada para cada rama [37]:

$$\mathcal{L}_k = - \sum_{i=1}^N \sum_{c=1}^{C_k} y_{ic}^{(k)} \log(\hat{y}_{ic}^{(k)}), \quad k \in \{1, 2\} \quad (2.67)$$

donde C_k es el número de clases de la tarea k [25].

La ventaja principal de esta arquitectura es que promueve el aprendizaje compartido de representaciones útiles para ambas tareas, lo que puede mejorar la generalización del modelo [47]. En lugar de aprender dos problemas de forma completamente independiente, la red aprovecha correlaciones entre tareas para construir un espacio de características más robusto [48]. En aplicaciones de diagnóstico de aerogeneradores, esto resulta atractivo porque una misma señal vibratoria puede contener información relacionada con distintos aspectos de la falla, y una red de doble cabeza puede explotar esa estructura de manera simultánea [46].

Desde el punto de vista del entrenamiento, esta arquitectura también puede actuar como una forma de regularización, ya que obliga a la red compartida a capturar información útil para más de una salida [45]. Esto suele traducirse en representaciones más estables y menos sensibles al ruido, especialmente cuando los datos presentan variabilidad operacional elevada [27]. En consecuencia, la red de doble cabeza es una opción apropiada cuando se busca combinar eficiencia estructural con capacidad de discriminación en problemas complejos [24].

En el contexto de esta tesis, la red de doble cabeza es particularmente pertinente porque permite diseñar un modelo que aproveche la información

extraída de las señales de vibración para realizar una clasificación robusta de fisuras en álabes de aerogeneradores [37]. Su estructura compartida favorece el aprendizaje de patrones comunes, mientras que sus dos ramas de salida pueden adaptarse a los objetivos específicos de la metodología propuesta [25].

2.11. Métricas de evaluación de los clasificadores

La evaluación del desempeño de los clasificadores es una etapa esencial en cualquier sistema de diagnóstico de fallas, ya que permite cuantificar la capacidad del modelo para identificar correctamente las clases de interés. En aplicaciones de detección de fisuras en álabes de aerogeneradores, esta evaluación resulta especialmente importante porque un error de clasificación puede implicar la omisión de un daño incipiente o la generación de falsas alarmas, ambas situaciones indeseables en un contexto de mantenimiento predictivo.

La herramienta básica para analizar el comportamiento de un clasificador es la matriz de confusión, que organiza las predicciones del modelo en función de las clases reales y estimadas. Para un problema binario, la matriz de confusión incluye cuatro resultados posibles: verdaderos positivos (TP), verdaderos negativos (TN), falsos positivos (FP) y falsos negativos (FN). A partir de estos valores se derivan varias métricas de desempeño que permiten evaluar el modelo desde distintos puntos de vista.

La exactitud o accuracy se define como la proporción de predicciones correctas respecto al total de observaciones:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.68)$$

Esta métrica es intuitiva y ampliamente utilizada; sin embargo, puede resultar engañosa cuando las clases están desbalanceadas, ya que un modelo

podría obtener una exactitud alta simplemente favoreciendo la clase mayoritaria.

La precisión o *precision* mide la proporción de verdaderos positivos entre todas las predicciones positivas realizadas por el modelo:

$$Precision = \frac{TP}{TP + FP} \quad (2.69)$$

Esta métrica es especialmente útil cuando se desea reducir las falsas alarmas, ya que evalúa qué tan confiables son las predicciones de falla emitidas por el clasificador.

El *recall*, también conocido como sensibilidad o tasa de verdaderos positivos, cuantifica la proporción de positivos reales que fueron correctamente identificados:

$$Recall = \frac{TP}{TP + FN} \quad (2.70)$$

Esta métrica es crucial en diagnóstico de fallas, porque permite evaluar la capacidad del modelo para detectar realmente los casos defectuosos. En aplicaciones de aerogeneradores, un *recall* bajo podría significar que algunas fisuras o fallas estructurales pasan inadvertidas.

El F1-score combina *precision* y *recall* en una sola medida armónica:

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (2.71)$$

Esta métrica es particularmente útil cuando se busca un equilibrio entre evitar falsos positivos y falsos negativos. En problemas con clases desbalanceadas, el F1-score suele ofrecer una visión más representativa del rendimiento del clasificador que la exactitud global.

La especificidad o *true negative rate* mide la proporción de negativos

2.11 Métricas de evaluación de los clasificadores

correctamente identificados:

$$Specificity = \frac{TN}{TN + FP} \quad (2.72)$$

Esta métrica complementa al recall, ya que permite evaluar la capacidad del modelo para reconocer adecuadamente la ausencia de falla.

Otra medida importante es la tasa de error, definida como la proporción de predicciones incorrectas:

$$Error\ Rate = \frac{FP + FN}{TP + TN + FP + FN} \quad (2.73)$$


Aunque esta métrica es simple, puede ser útil para comparar de manera rápida distintos modelos.

En problemas multiclase, estas métricas pueden calcularse de forma individual para cada clase y luego agregarse mediante promedios macro, micro o ponderados. El promedio macro calcula la media aritmética de las métricas por clase, otorgando el mismo peso a todas ellas. El promedio micro, en cambio, acumula los conteos globales de la matriz de confusión antes de calcular la métrica, por lo que favorece a las clases con mayor número de muestras. El promedio ponderado introduce pesos proporcionales al número de instancias de cada clase.

Además de estas métricas, el área bajo la curva ROC, o AUC, también puede emplearse para evaluar la capacidad discriminante de un clasificador, especialmente en escenarios binarios. La curva ROC relaciona la tasa de verdaderos positivos con la tasa de falsos positivos, y su área resume el rendimiento global del modelo a lo largo de distintos umbrales de decisión.

2.11 Métricas de evaluación de los clasificadores

Figura 2.2: Curva ROC para la evaluación del rendimiento de un clasificador binario.




Nota. La curva ROC (*Receiver Operating Characteristic*) representa la relación entre la tasa de verdaderos positivos (TPR) y la tasa de falsos positivos (FPR) calculada a través de distintos umbrales de decisión. Elaboración propia mediante representación gráfica basada en métricas de clasificación.

La Figura 2.2 presenta la curva ROC (*Receiver Operating Characteristic*), una herramienta gráfica fundamental para evaluar el comportamiento de un modelo de clasificación binaria. Esta curva relaciona en el eje vertical la tasa de verdaderos positivos (TPR, *True Positive Rate* o Sensibilidad) frente a la tasa de falsos positivos (FPR, *False Positive Rate* o $1 - \text{Especificidad}$) en el eje horizontal. La proximidad de la trayectoria hacia la esquina superior izquierda evidencia que el modelo maximiza la detección de la condición de interés mientras mantiene acotadas las falsas alarmas, superando con claridad la diagonal punteada que representa una clasificación puramente aleatoria.

2.11 Métricas de evaluación de los clasificadores

Figura 2.3: Área bajo la curva ROC (AUC) como métrica global de discriminación.



Nota. El área sombreada bajo la curva (AUC, *Area Under the Curve*) resume en una métrica escalar continua la capacidad global del clasificador para distinguir entre clases, independiente del umbral de corte seleccionado. Elaboración propia mediante representación gráfica basada en métricas de clasificación.

Por su parte, la Figura 2.3 ilustra el Área Bajo la Curva ROC (AUC, *Area Under the Curve*), la cual integra geoméricamente la curva anterior para obtener un índice cuantitativo global acotado entre 0 y 1. Un valor de AUC cercano a 1.0 ratifica que el algoritmo asigna sistemáticamente una mayor probabilidad diagnóstica a las observaciones que presentan daño estructural frente a aquellas provenientes de una pala en estado saludable.

En el marco de esta investigación, la evaluación conjunta de la curva ROC y el AUC resulta indispensable: permite validar que la capacidad del modelo para aislar las firmas vibratorias anómalas de una grieta es intrínseca a la arquitectura propuesta y se mantiene robusta ante la variabilidad estocástica

2.11 Métricas de evaluación de los clasificadores

inducida por la velocidad del viento, garantizando una tasa mínima de falsos negativos en el monitoreo del aerogenerador.

Capítulo 3

Metodología

La metodología desarrollada en este trabajo de investigación se estructura en una secuencia de etapas diseñadas para garantizar la reproducibilidad y el rigor técnico en la detección de grietas en palas de aerogeneradores. Este capítulo detalla el diseño del banco de pruebas, el procedimiento de adquisición de señales de vibración y el procesamiento de los datos para la extracción masiva de características. Finalmente, se describe la arquitectura del modelo de clasificación propuesto: una red neuronal de doble cabeza orientada a identificar el régimen de velocidad del viento como paso previo y contextual para diagnosticar la severidad de la falla estructural, priorizando la eficiencia computacional.

3.1. Diseño Experimental y Banco de Pruebas

Para validar la metodología propuesta, se implementó un banco de pruebas controlado que permite emular las condiciones operativas de un aerogenerador sometido a flujos de viento variables [11]. El núcleo del sistema experimental consiste en un aerogenerador de baja potencia de eje horizon-

3.1 Diseño Experimental y Banco de Pruebas

tal, modelo Air X, con una capacidad nominal de 400 W y un voltaje de operación de 12 V [11]. Este equipo fue montado en el interior de un túnel de viento instrumentado, el cual permite regular la velocidad del flujo de aire para someter al rotor a diferentes regímenes de carga aerodinámica.

Con el objetivo de aislar las perturbaciones mecánicas provenientes del sistema de ventilación del túnel, la torre del aerogenerador se fijó de manera rígida a una base externa anclada al suelo, asegurando que las vibraciones registradas correspondan exclusivamente a la dinámica del tren de potencia y el rotor [11].

3.1.1. Condiciones Operativas: Variabilidad del Viento

En entornos reales, los aerogeneradores operan bajo perfiles de viento dinámicos que alteran constantemente su respuesta vibratoria. Para incorporar esta variabilidad como una variable de contexto dentro del modelo de clasificación, el túnel de viento fue configurado para generar cuatro regímenes de velocidad específicos: 3 m/s, 6 m/s, 9 m/s y 12 m/s. Esta discretización cubre el espectro operativo del equipo, desde el umbral de arranque hasta la velocidad nominal en estado estacionario, permitiendo evaluar la robustez del método diagnóstico frente a fluctuaciones en la carga aerodinámica.

3.1.2. Simulación de la Falla Estructural

El experimento se enfocó exclusivamente en el estudio de fisuras longitudinales en los álabes, descartando perturbaciones externas como desbalances por masa añadida o desgaste en rodamientos. La simulación del daño se llevó a cabo induciendo un corte en uno de los extremos de una pala sana utilizando una herramienta de corte de precisión (segueta), manteniendo un ancho de incisión constante de 1 mm [11].

Dado que el ancho total de la cuerda en la sección afectada de la pala es

3.1 Diseño Experimental y Banco de Pruebas

de 7 cm, se definieron cuatro clases de severidad en función de la longitud de la grieta [11]. La Tabla 3.1 resume la clasificación del daño estructural evaluado.

Tabla 3.1: Clasificación de las condiciones estructurales de la pala evaluadas en el banco de pruebas.

Condición Estructural	Profundidad de la Grieta (cm)	Ancho de la Grieta (mm)
Pala Sana (Sin daño)	0	N/A
Falla Leve	1	1
Falla Intermedia	2	1
Falla Severa	3	1

La inducción progresiva del corte modifica la rigidez local y la distribución de masa del álabe, lo que altera la respuesta dinámica del rotor de forma sutil durante su rotación [11].

3.1 Diseño Experimental y Banco de Pruebas

Figura 3.1: Configuración del banco de pruebas mostrando el aerogenerador dentro del túnel de viento y el sistema de instrumentación.



En la **Figura 3.1** se presenta la configuración física del banco de pruebas implementado en el laboratorio para el desarrollo experimental de esta investigación. Este montaje está diseñado para garantizar la captura fiel de la dinámica estructural del aerogenerador bajo condiciones controladas. A partir de la imagen, se identifican los siguientes componentes clave del sistema:

- **Generación de Flujo Aerodinámico (Túnel de viento):** En la sección central y derecha se observa la estructura del túnel de viento, construida con perfiles de aluminio y paneles transparentes para canalizar el aire. En el extremo derecho, encapsulado tras una malla de seguridad, se encuentra el soplador o ventilador industrial encargado de inducir los diferentes perfiles de viento controlados (3, 6, 9 y 12 m/s).
- **Sistema Bajo Prueba (Aerogenerador):** En el extremo izquierdo se ubica el aerogenerador de baja potencia. Es importante destacar

3.1 Diseño Experimental y Banco de Pruebas

que este se encuentra montado sobre un pedestal metálico rojo completamente independiente de la mesa de trabajo y del túnel de viento. Esta separación mecánica es crucial, ya que aísla al aerogenerador de las vibraciones parásitas generadas por el motor del túnel, asegurando que el acelerómetro registre únicamente las vibraciones acopladas del rotor y la góndola.

- **Monitoreo y Adquisición de Datos (DAQ):** En la mesa frontal se despliega la estación de trabajo. Se observa la interfaz de adquisición conectada mediante USB (la tarjeta NI) y el monitor de la computadora, el cual muestra en tiempo real las formas de onda de las señales de vibración en sus tres ejes espaciales (X, Y, Z). Este monitoreo en vivo permite validar la correcta captura de las series temporales antes de su almacenamiento y posterior segmentación.

Figura 3.2: Detalle de la pala instrumentada ilustrando el nivel de severidad de la grieta.



En la **Figura 3.2** se ilustra la simulación física de la falla estructural inducida en una de las palas del rotor [11]. La imagen se compone de dos paneles que proporcionan una perspectiva detallada de la ubicación y morfología del daño:

- **Vista general de la hélice (panel izquierdo):** Muestra el ensamble completo del rotor de tres palas. Se ha delimitado e identificado

claramente la zona de interés en el tercio medio de uno de los álabes, lugar donde se concentran los esfuerzos mecánicos y donde se indujo la fisura para el estudio.

- **Acercamiento de la grieta (panel derecho):** Presenta un plano detalle de la sección afectada. Debido al color oscuro del material compuesto de la pala, se aplicó una cinta adhesiva para crear un fondo de contraste blanco que permite visualizar con claridad la incisión transversal.

Es de vital importancia enfatizar que, sobre esta misma sección de la pala, se simuló una propagación progresiva de la fisura para evaluar **tres niveles distintos de severidad de daño** [11]. Partiendo de una condición sana (0 cm), el deterioro se indujo de la siguiente manera:

1. **Falla Leve:** Se realizó un corte inicial con una longitud de 1 cm hacia el interior de la pala [11].
2. **Falla Intermedia:** Se profundizó la incisión hasta alcanzar los 2 cm de longitud [11].
3. **Falla Severa:** Se extendió la grieta hasta una profundidad máxima de 3 cm, lo que representa una alteración estructural significativa considerando que el ancho total de la pala en esa sección es de 7 cm [11].

En los tres escenarios de falla, el corte se mantuvo con un ancho constante de 1 mm [11]. Esta metodología de daño progresivo es la que permite generar una alteración escalonada en la rigidez y la distribución de masa del álabe, introduciendo así firmas vibratorias sutiles pero diferenciables que posteriormente son capturadas por la instrumentación y procesadas por la red neuronal de doble cabeza.

3.2. Adquisición y Preprocesamiento de Señales

La captura de la respuesta dinámica del aerogenerador se llevó a cabo mediante instrumentación de alta precisión, garantizando que las variaciones

sutiles inducidas por las grietas fueran registradas adecuadamente para su posterior análisis.

3.2.1. Instrumentación y Parámetros de Muestreo

Para medir las vibraciones del sistema se empleó un acelerómetro triaxial KISTLER modelo 8395A10 [11]. Este sensor se instaló rígidamente en la parte superior de la góndola (nacelle) del aerogenerador [11]. Dicha ubicación estratégica permite capturar de manera acoplada las componentes vibratorias provenientes tanto del tren de potencia como del rotor, siendo el punto idóneo para detectar las anomalías mecánicas transmitidas por los álabes [11].

La digitalización de las señales analógicas se realizó a través de una tarjeta de adquisición de datos National Instruments (NI) modelo USB-6211 [11]. Para evitar la pérdida de información en transitorios rápidos y cumplir con el teorema de muestreo de Nyquist, la frecuencia de adquisición se configuró a 10 kHz (10,000 muestras por segundo) [11].

Es importante destacar que, aunque la instrumentación capturó la vibración espacial en los tres ejes (X, Y y Z), estudios previos realizados sobre este mismo banco de pruebas demostraron que la vibración en dirección transversal (Eje Y) aporta la mayor cantidad de información discriminante para el diagnóstico de la integridad de los álabes [11]. En consecuencia, el preprocesamiento y la posterior extracción de características se delimitaron de manera exclusiva a la señal del Eje Y, optimizando el costo computacional del modelo. Las especificaciones técnicas se resumen en la Tabla 3.2.

3.2 Adquisición y Preprocesamiento de Señales

Tabla 3.2: Especificaciones técnicas del hardware y parámetros de adquisición de señales.

Componente	Marca y Modelo		Parámetro de Configuración
Acelerómetro Triaxial	KISTLER	8395A10	Medición delimitada al Eje Y
Sistema de Adquisición (DAQ)	NI USB-6211 [11]		Frecuencia de muestreo: 10 kHz
Ventana de Segmentación	Procesamiento	en 1200 muestras (0.12 s)	
	MATLAB		

3.2.2. Aumento de Datos y Generación de Señales Sintéticas (*Data Augmentation*)

En aplicaciones de aprendizaje automático aplicadas al monitoreo de condición, entrenar modelos profundos con un número reducido de muestras físicas puede inducir un sobreajuste severo (*overfitting*), donde la red memoriza el ruido ambiental del laboratorio en lugar de la firma estructural del daño. Para mitigar este riesgo, garantizar un balance de clases absoluto (1000 muestras por categoría) y emular las perturbaciones estocásticas de un entorno eólico real, se implementó una técnica de Aumento de Datos (*Data Augmentation*) mediante la inyección de Ruido Blanco Gaussiano Aditivo (AWGN).

El procedimiento de síntesis y expansión del conjunto de datos se programó en MATLAB y se ejecutó de manera sistemática para cada régimen de velocidad y condición de falla, siguiendo una secuencia de tres etapas operativas:

1. **Filtrado de Régimen Estacionario:** A partir de los registros continuos del acelerómetro, el algoritmo extrajo exclusivamente los frag-

mentos temporales donde el aerogenerador operaba dentro de una ventana de tolerancia estricta respecto a la velocidad objetivo. Por ejemplo, para el régimen de 9 m/s, solo se conservaron los datos registrados cuando el viento fluctuaba entre $v_i = 8.9$ m/s y $v_o = 9.1$ m/s.

2. **Extracción de Vectores Base:** Para cada una de las cuatro condiciones de salud (Sana, Leve, Intermedia y Severa), se realizaron 10 pruebas experimentales independientes en el túnel de viento. De cada prueba filtrada, se extrajo un vector base real de exactamente 1200 muestras correspondientes al Eje Y.
3. **Inyección de Ruido Estocástico (AWGN):** Cada uno de los 10 vectores base fue sometido a un proceso de clonación sintética. Utilizando la función `awgn` de MATLAB, se generaron 100 variaciones sintéticas por cada vector real, inyectando ruido blanco con una Relación Señal a Ruido (SNR) de 20 dB.

Matemáticamente, la señal sintética generada $x_{sint}(t)$ se define como:

$$x_{sint}(t) = x_{real}(t) + \eta(t)$$

donde $x_{real}(t)$ es la ventana vibratoria medida empíricamente y $\eta(t)$ es el ruido gaussiano añadido cuya potencia está escalada para mantener el SNR objetivo de 20 dB. Este procedimiento expansivo (10 pruebas empíricas $\times$ 100 variaciones sintéticas) produjo exactamente 1000 muestras por cada clase.

La inyección de AWGN no solo balancea artificialmente la base de datos, sino que cumple un propósito físico crucial. Al introducir variaciones aleatorias controladas, se emulan las micro-turbulencias aerodinámicas, las interferencias electromagnéticas de la tarjeta de adquisición (DAQ) y la variabilidad ambiental típica de un parque eólico real. Esto fuerza a la Red Neuronal de Doble Cabeza a ignorar las fluctuaciones de fondo y concentrar la optimización de sus pesos sinápticos exclusivamente en las firmas no lineales y los impactos generados por la grieta.

3.2.3. Estructuración y Segmentación del Conjunto de Datos

El procesamiento de las señales se centralizó mediante rutinas computacionales desarrolladas en el entorno de MATLAB. Cada registro vibratorio continuo se segmentó en ventanas temporales exactas de 1200 muestras [11]. A la frecuencia de muestreo establecida, cada ventana corresponde a un intervalo de observación de 0.12 segundos [11], tiempo suficiente para capturar la periodicidad fundamental de la dinámica del rotor a las distintas velocidades evaluadas.

Para conformar el conjunto de datos (*dataset*), se extrajeron 1000 ventanas temporales por cada condición de severidad (Sana, Leve, Intermedia y Severa), repitiendo este proceso para los cuatro regímenes de velocidad de viento (3, 6, 9 y 12 m/s). Como resultado, se obtuvo un total de 4000 muestras por velocidad, consolidando un espacio de datos de 16,000 muestras totales perfectamente balanceado.

La topología de este conjunto de datos se ilustra de manera esquemática en la **Figura 3.3**. Este diagrama de jerarquía refleja el doble nivel de categorización exigido por el diseño experimental. El Nivel 1 discretiza el contexto operativo del sistema mediante la velocidad del viento, mientras que el Nivel 2 desglosa las subdivisiones correspondientes al estado de salud de la pala. Esta arquitectura de datos es el cimiento lógico que fundamenta la necesidad de una red neuronal de doble cabeza orientada a la clasificación categórica en ambos niveles.

El procesamiento de las señales se centralizó mediante rutinas computacionales desarrolladas en el entorno de MATLAB. Cada registro vibratorio continuo de la señal del Eje Y se segmentó en ventanas temporales exactas de 1200 muestras [11]. A la frecuencia de muestreo establecida, cada ventana corresponde a un intervalo de observación de 0.12 segundos [11], tiempo suficiente para capturar la periodicidad fundamental de la dinámica del rotor a las distintas velocidades evaluadas.

La topología del conjunto de datos (*dataset*) se estructuró para garanti-

3.2 Adquisición y Preprocesamiento de Señales

zar un balance absoluto entre las clases. Tal como se ilustra en la **Figura 3.3**, el diseño experimental generó un total de 16,000 muestras organizadas mediante una clasificación jerárquica de doble nivel:

- **Nivel 1 (Velocidad del Viento):** El conjunto se divide equitativamente en cuatro regímenes de operación (3 m/s, 6 m/s, 9 m/s y 12 m/s), aportando 4000 muestras por cada perfil de velocidad.
- **Nivel 2 (Condición Estructural):** Dentro de cada velocidad, los datos se subdividen en las cuatro condiciones de salud de la pala (Sana, Leve, Intermedia y Grave), extrayendo exactamente 1000 muestras para cada clase de daño.



Figura 3.3: Distribución jerárquica y balanceada de las 16,000 muestras del experimento, categorizadas por velocidad del viento (Nivel 1) y condición de salud estructural (Nivel 2).

Este diagrama de jerarquía refleja el doble nivel de categorización exigido por el diseño experimental. El Nivel 1 discretiza el contexto operativo del sistema mediante la velocidad del viento, mientras que el Nivel 2 des-

3.3 Extracción de Características

glosa las subdivisiones correspondientes al estado de salud de la pala. Esta arquitectura de datos estructurada es el cimiento lógico que fundamenta la necesidad de utilizar una red neuronal de doble cabeza, orientada a la clasificación categórica secuencial en ambos niveles.

Para asegurar una generalización adecuada del modelo y evitar cualquier tipo de sesgo de ordenamiento durante el entrenamiento, las 16,000 ventanas temporales fueron sometidas a un proceso de aleatorización estructurada. Este procedimiento fragmentó y mezcló el conjunto de datos a través de 54 archivos de iteración (*shuffle files*).

Finalmente, a cada ventana temporal se le extrajo un vector de 38 indicadores matemáticos y se le asignaron sus dos etiquetas categóricas correspondientes (velocidad y severidad). Todo el proceso convergió en la creación de una matriz bidimensional con dimensiones de 40×16000 , la cual fue exportada de manera unificada bajo el nombre `TablaDeCaracteristicas_Completa.mat`. Este archivo representa el espacio de características definitivo sobre el cual operarán las siguientes etapas de reducción de dimensionalidad y aprendizaje automático.

3.3. Extracción de Características

El proceso de extracción de características constituye el núcleo analítico en el diagnóstico automatizado de fallas. Su objetivo fundamental es transformar la vasta cantidad de información contenida en las series temporales brutas (ventanas de 1200 muestras) en un vector compacto de atributos numéricos que encapsule la firma del daño y maximice la capacidad discriminante del modelo computacional.

Esta etapa de ingeniería de características (*feature engineering*) se implementó íntegramente en MATLAB. Para capturar la complejidad cinemática del rotor y aislar las firmas dinámicas introducidas por la propagación progresiva de la grieta [11], los descriptores extraídos se agruparon estratégicamente

3.3 Extracción de Características

en tres dominios matemáticos.

3.3.1. Descriptores en el Dominio del Tiempo

Las métricas en el dominio temporal actúan como la primera línea de análisis, evaluando la amplitud geométrica y la distribución estadística de la onda de vibración original sin requerir transformaciones adicionales. La aparición de una fisura en la pala altera su centro de gravedad y su rigidez estructural, lo que se traduce en micro-impactos o variaciones periódicas de amplitud a medida que la turbina gira [11].

3.3 Extracción de Características

Tabla 3.3: Descriptores extraídos en el dominio del tiempo y su interpretación física.

Categoría	Característica (Acrónimo)	Interpretación en el Diagnóstico
Tendencia y Dispersión	Media (<i>Mean</i>)	Refleja el desplazamiento estático promedio por desbalance.
	Mediana (<i>Median</i>)	Medida central robusta ante valores atípicos.
	Moda (<i>Mode</i>)	Amplitud vibratoria más recurrente en la rotación.
	Rango (<i>Range</i>)	Amplitud máxima pico a pico causada por el daño.
	Desv. Estándar (<i>StdDev</i>)	Nivel de fluctuación dinámica global de la pala.
Energía	RMS (<i>RMS</i>)	Energía contenida en la vibración; aumenta con la severidad.
	SMR (<i>SMR</i>)	Valor absoluto de la energía, complementario al RMS.
Forma de Distribución	Asimetría (<i>Skewness</i>)	Indica si los impactos sesgan la vibración hacia un solo sentido.
	Curtosis (<i>Kurtosis</i>)	Mide la presencia de picos impulsivos extremos (colas pesadas).
	Momento 5 (<i>Moment5</i>)	Cuantifica asimetrías de orden superior por fricción anómala.
	Momento 6 (<i>Moment6</i>)	Resalta impactos extremadamente raros de alta energía.
Factores Impulsivos	Factor de Cresta (<i>CrestFactor</i>)	Relación entre el pico máximo y la energía global.
	Factor de Impulso (<i>ImpulseFactor</i>)	Sensibilidad a sacudidas repentinas durante el giro.
	Factor de Latitud (<i>LatitudeFactor</i>)	Sensibilidad a impactos continuos de menor amplitud.
	Desv. Abs. Media (<i>MAD</i>)	Variabilidad de la señal penalizando menos los extremos.
	Factor RMS (<i>SF_RMS</i>)	Evalúa alteraciones en la forma de onda fundamental.
	Factor SMR (<i>SF_SMR</i>)	Variación del SMR frente a la amplitud de la señal.
	Factor Asimetría (<i>SkewFactor</i>)	Normalización del sesgo direccional de la onda.
	Factor Curtosis (<i>KurtFactor</i>)	Normalización del nivel de impulsividad del daño.

3.3 Extracción de Características

En la Tabla 3.3 se presentan los 19 descriptores temporales calculados y su interpretación física orientada al diagnóstico.

En un aerogenerador sano, la distribución de la vibración tiende a comportarse de forma gaussiana. Sin embargo, una grieta estructural introduce impulsos anómalos. Descriptores de forma como la Curtosis y los Factores Impulsivos se vuelven delatores fundamentales: un aumento drástico en estos valores indica que el sistema está experimentando sacudidas de alta energía fuera de la norma, evidenciando un daño incipiente antes de que el valor RMS global sufra cambios macroscópicos significativos.

3.3.2. Métricas de Complejidad y Entropía

Los métodos lineales tradicionales a menudo fracasan al intentar modelar la sutil degradación de los materiales compuestos. Para superar esta limitación, se integraron métricas provenientes de la teoría del caos y la geometría fractal, las cuales miden la irregularidad y la "sorpresa" en la señal. La Tabla 3.4 describe estas 8 métricas no lineales.

El flujo de aire a través de una pala sana genera un patrón vibratorio predecible, lo que se traduce en una baja dimensión fractal. A medida que la fisura se profundiza de 1 cm a 3 cm, la fricción microestructural genera una respuesta errática, haciendo que la onda vibratoria se vuelva geométricamente rugosa". Un incremento en las dimensiones fractales o en la Entropía de Shannon sirve como un biomarcador directo: a mayor grieta, mayor rugosidad e imprevisibilidad en la señal.

3.3.3. Descriptores en el Dominio de la Frecuencia

Para evaluar el comportamiento espectral del sistema, el segmento temporal se transformó utilizando la Transformada Rápida de Fourier (FFT) [11]. Al pasar al dominio frecuencial, es posible observar cómo se distribuye

3.3 Extracción de Características

la energía en función de las velocidades de rotación y las resonancias estructurales. La Tabla 3.4 detalla las 11 características espectrales calculadas.

Tabla 3.4: Descriptores extraídos en el dominio de la frecuencia y su interpretación física.

Categoría	Característica (Acrónimo)	Interpretación en el Diagnóstico
Tendencia Espectral	Frecuencia Media (<i>MeanFreq</i>)	Centroide frecuencial de la energía vibratoria.
	Potencia Media (<i>MeanPower</i>)	Energía promedio contenida en los espectros analizados.
Momentos Espectrales	Primer Momento (<i>SM1</i>)	Distribución general de la energía en el espectro.
	Segundo Momento (<i>SM2</i>)	Inercia espectral; dispersión respecto al centroide.
	Tercer Momento (<i>SM3</i>)	Tendencia de asimetría en la distribución de las bandas.
Estadísticos Espectrales	Desv. Estándar Espectral (<i>StdDevFreq</i>)	Fluctuación global de las frecuencias dominantes.
	Asimetría Espectral (<i>SkewFreq</i>)	Sesgo de la densidad espectral de potencia.
	Curtosis Espectral (<i>KurtFreq</i>)	Presencia de componentes armónicos agudos y puros.
Parámetros de Banda	Frecuencia Central (<i>CentralFreq</i>)	Frecuencia de equilibrio del espectro energético.
	Frecuencia RMS (<i>RMSFreq</i>)	Energía espectral cuadrática media acumulada.
	Frecuencia RMS Modulada (<i>RMSFreq-Mod</i>)	Variabilidad de la modulación energética en frecuencia.

Las fisuras estructurales actúan como excitadores de alta frecuencia. Mientras que la rotación principal de la turbina domina las frecuencias más bajas, el daño físico genera fricciones microscópicas que filtran energía hacia armónicos superiores. Las medidas de dispersión espectral y los momentos superiores captan esta sutil fuga de energía hacia las altas frecuencias, alertando de la grieta independientemente de si la velocidad del viento se encuentra a 3, 6, 9 o 12 m/s.

3.4 Selección de Características y Reducción de Dimensionalidad

Al concluir esta extracción, las 38 variables continuas calculadas se acoplaron a las etiquetas de velocidad y condición, consolidando la matriz unificada que alimenta la siguiente fase de inteligencia artificial.

3.4. Selección de Características y Reducción de Dimensionalidad

Alimentar una red neuronal directamente con un vector de 38 características puede inducir problemas de sobreajuste (*overfitting*), redundancia de información y un incremento innecesario en el costo computacional; esto último resulta crítico si se busca implementar el sistema final en arquitecturas de procesamiento en el borde (*Edge Computing*). Para mitigar el efecto de la maldición de la dimensionalidad y optimizar la topología de la red de doble cabeza, se implementó una etapa de reducción de dimensionalidad utilizando técnicas de proyección y aprendizaje de variedades.

Previo a la aplicación de cualquier algoritmo estadístico, el espacio de características fue normalizado empleando un escalador estándar (*Standard-Scaler*) para centrar la distribución de cada variable en una media de cero y desviación estándar de uno ($\mu = 0, \sigma = 1$). Esto garantizó que las características con magnitudes elevadas no dominaran matemáticamente el cálculo de distancias y varianzas frente a métricas de pequeña escala, como las dimensiones fractales.

Para evaluar exhaustivamente la capacidad representativa de los datos, el análisis se ejecutó bajo tres enfoques metodológicos: un análisis **Global** (evaluando las 38 características simultáneamente), un análisis del **Dominio del Tiempo** y un análisis del **Dominio de la Frecuencia**.

3.4.1. Análisis de Componentes Principales (PCA)

El Análisis de Componentes Principales (PCA) se aplicó como técnica no supervisada de compresión de datos. Su objetivo consistió en proyectar el espacio original sobre un subespacio ortogonal de menor dimensión, iterando hasta encontrar el número mínimo de componentes requeridos para retener el **95 % de la varianza total del sistema**.

Al ejecutar el análisis sobre el vector **Global**, el algoritmo PCA determinó de forma concluyente que **solo se requieren 9 componentes** para explicar la dinámica completa del fenómeno de agrietamiento en los álabes. Esta compresión representa una reducción dimensional del 76 %, validando la pertinencia de este enfoque para sistemas integrados.




Figura 3.4: Evolución de la varianza explicada acumulada mediante PCA.

El análisis Global alcanza el umbral del 95 % empleando únicamente 9 componentes principales.

3.4 Selección de Características y Reducción de Dimensionalidad

Para preservar la interpretabilidad física del modelo, PCA también se operó de forma inversa mediante el análisis de los coeficientes de carga (*loadings*). Al promediar los pesos absolutos proyectados sobre los 9 componentes principales, se logró identificar el subconjunto exacto de las 9 características originales más influyentes. Ordenadas por nivel de importancia, el modelo seleccionó:

1. Entropía de Rényi (*RenyiEnt*)
2. Factor de Asimetría (*SkewFactor*)
3. Dimensión Fractal de Katz (*KatzFD*)
4. Factor SMR (*SF_SMR*)
5. Mediana (*Median*)
6. Factor RMS (*SF_RMS*)
7. Factor de Curtosis (*KurtFactor*)
8. Momento de Orden 5 (*Moment5*)
9. Media (*Mean*)

Insight Físico: Es notable que ninguna característica del dominio de la frecuencia resultara necesaria para alcanzar el 95 % de la varianza explicada. La selección es liderada por métricas de *Complejidad* (Rényi, Katz) y métricas de *Forma en el Tiempo* (Factores Impulsivos y Momentos de orden superior). Esto demuestra físicamente que la degradación en el álabe se manifiesta de forma primordial como irregularidades locales e impactos mecánicos (alteración de textura temporal) más que como cambios globales de resonancia espectral.

3.4.2. Análisis Discriminante Lineal (LDA) y UMAP

Para complementar el análisis no supervisado y explorar gráficamente la separabilidad entre las clases de daño, el espacio reducido se proyectó utilizando dos métodos complementarios: el Análisis Discriminante Lineal (LDA) y la aproximación múltiple UMAP (*Uniform Manifold Approximation and Projection*).

3.5 Proceso de Selección de Modelos y Validación por Rejilla

LDA, como técnica supervisada, permitió confirmar que las características previamente normalizadas y extraídas son capaces de trazar fronteras lineales entre las cuatro clases de severidad. Por su parte, la proyección topológica UMAP preservó estructuras altamente no lineales ocultas en la señal de vibración.




Figura 3.5: Visualización del espacio de características empleando Análisis Discriminante Lineal (LDA) y UMAP. Ambos métodos exponen la agrupación natural de los estados de falla de la turbina.

En conjunto, este procesamiento estadístico permitió refinar la base de datos a su núcleo más representativo, exportando un archivo unificado (`Global_VariablesSeleccionadas.csv`) que reduce drásticamente el ruido computacional y conforma la capa de entrada (Input Layer) ideal para entrenar la Red Neuronal de Doble Cabeza de Clasificación.

3.5. Proceso de Selección de Modelos y Validación por Rejilla

Con el propósito de justificar metodológicamente la elección de esta arquitectura frente a otras alternativas de diseño, se llevó a cabo una prueba sistemática de optimización de hiperparámetros (*Grid Search*). Se evaluaron

3.5 Proceso de Selección de Modelos y Validación por Rejilla

20 configuraciones diferentes variando la capacidad de las capas iniciales, las neuronas en las ramas y las tasas de aprendizaje (*Learning Rate*), entrenando cada modelo bajo las mismas condiciones sobre el conjunto de entrenamiento y evaluándolos en el conjunto de prueba ciega.

3.5 Proceso de Selección de Modelos y Validación por Rejilla

Tabla 3.5: Evaluación comparativa de la rejilla de modelos para la selección de la arquitectura óptima.

M.	Arquitectura	LR	Params.	Acc. Vel. (%)	Acc. Cond. (%)	T. (s)
1	64/32/32	0.001	4,168	98.29	99.92	22.70
2	64/32/64	0.005	5,480	99.83	100.00	24.09
3	64/64/32	0.001	7,400	99.83	99.96	27.36
4	64/64/64	0.005	9,736	99.71	100.00	39.26
5	64/128/64	0.001	18,248	99.79	100.00	30.18
6	128/32/32	0.001	6,856	99.71	99.96	25.96
7	128/32/64	0.005	8,168	99.96	99.92	25.62
8	128/64/32	0.001	12,136	99.92	99.96	31.04
9	128/64/64	0.0001	14,472	92.33	99.21	28.95
10	128/64/64	0.001	14,472	99.96	100.00	26.55
11	128/64/64	0.005	14,472	99.92	100.00	24.32
12	128/64/64	0.01	14,472	99.21	100.00	23.61
13	128/64/128	0.005	19,144	99.75	100.00	24.58
14	128/128/64	0.005	27,080	99.83	100.00	24.47
15	256/64/64	0.001	23,944	99.83	100.00	27.46
16	256/64/64	0.005	23,944	99.62	99.04	28.57
17	256/128/64	0.001	44,744	99.92	100.00	33.13
18	256/128/128	0.005	53,512	99.87	100.00	29.36
19	256/256/128	0.001	103,304	99.92	99.96	41.14
20	256/256/256	0.005	137,224	99.71	99.92	42.09

Los resultados de la **Tabla 3.5** evidencian que arquitecturas reducidas (Modelos 1 a 4) presentan limitaciones en la capacidad de representación, arrojando tasas de error marginalmente superiores. Por otro lado, arquitecturas sobredimensionadas (Modelos 15 a 20) incrementan drásticamente el número de parámetros sin aportar mejoras en la exactitud, propiciando

3.5 Proceso de Selección de Modelos y Validación por Rejilla

además tiempos de cómputo elevados. El análisis demuestra que el **Modelo 11** (seleccionado como la arquitectura definitiva de la tesis) alcanza un rendimiento óptimo del 100 % tanto en la clasificación del contexto de velocidad como en el diagnóstico de la severidad del daño estructural, manteniendo una complejidad ligera de 14,472 parámetros.

3.5.1. Arquitectura de Clasificación: Red Neuronal de Doble Cabeza

El núcleo predictivo de la metodología propuesta recae en una Red Neuronal Artificial (ANN) diseñada bajo un paradigma de múltiples salidas (*Multi-task Learning*). A diferencia de los enfoques tradicionales que intentan predecir la falla directamente ignorando la variabilidad ambiental, esta arquitectura integra el contexto operativo del aerogenerador mediante una topología de ("*doble cabeza*") Orientada **estrictamente a la clasificación categórica**.

Para cumplir con el objetivo de mantener un bajo costo computacional y facilitar su futura implementación en dispositivos embebidos (*Edge Computing*), la arquitectura fue optimizada para ser extremadamente ligera, constando de apenas 14,472 parámetros entrenables con un peso aproximado de 56.53 KB. La estructura jerárquica de la red se detalla en la **Figura 3.6** y se describe matemáticamente en las siguientes subsecciones.

3.5.2. Capa de Entrada y Bloque de Extracción Compartida

La red recibe un tensor de entrada (`input_features`) compuesto por el vector reducido de 9 componentes principales obtenidas mediante PCA.

Este vector es procesado inicialmente por un bloque secuencial compartido, cuyo propósito es aprender una representación latente de alto nivel antes de bifurcar las decisiones:

3.5 Proceso de Selección de Modelos y Validación por Rejilla




Figura 3.6: Arquitectura de la Red Neuronal de Doble Cabeza. Se observa el flujo secuencial desde la extracción de características compartidas, la clasificación del contexto operativo (velocidad) y la concatenación para el diagnóstico final de la condición estructural.

1. **Capa Densa 1 (dense):** Compuesta por 128 neuronas completamente conectadas. Esta capa expande la dimensionalidad inicial para capturar interacciones complejas entre las características físicas.
2. **Capa Dropout (dropout):** Se aplica como técnica de regularización con una tasa de 0.2. Durante el entrenamiento, desactiva estocásticamente una fracción de las neuronas para evitar el sobreajuste (*overfitting*) y garantizar que la red no dependa de un solo descriptor.
3. **Capa Densa 2 (dense_1):** Reduce el espacio de representación a 64 neuronas, condensando la información en las características más relevantes del sistema vibratorio.

3.5.3. Primera Cabeza: Clasificación de Velocidad (Contexto)

A partir de la salida del bloque compartido (tensor de dimensión 64), la red genera su primera bifurcación funcional. La capa *velocidad* consiste en

3.5 Proceso de Selección de Modelos y Validación por Rejilla

4 neuronas de salida con función de activación *softmax*. Esta rama resuelve la primera tarea de clasificación: determinar el régimen aerodinámico del túnel de viento (3, 6, 9 o 12 m/s).

Al forzar a la red a predecir primero la velocidad, se garantiza que los pesos sinápticos del bloque compartido aprendan a decodificar la variabilidad del viento, extrayendo el contexto de la señal antes de evaluar el daño estructural.

3.5.4. Capa de Concatenación: Inyección de Contexto

El aporte algorítmico principal de esta arquitectura reside en la capa **concatenate**. En lugar de realizar predicciones aisladas, el modelo unifica dos flujos de información:

- El vector latente de características extraídas por **dense_1** (dimensión 64).
- Las 4 probabilidades predictivas generadas por la rama **velocidad**.

Esta fusión produce un nuevo tensor de dimensión 68. Físicamente, esta operación informa.^a las siguientes capas sobre el régimen de viento en el que está operando la turbina, permitiéndole a la red ajustar sus fronteras de decisión y no confundir las altas vibraciones naturales de un giro rápido (12 m/s) con las vibraciones anómalas de una fisura.

3.5.5. Segunda Cabeza: Clasificación de Condición (Severidad)

El tensor concatenado alimenta la ruta final de la red, encargada del diagnóstico estructural:

1. **Capa Densa 3 (dense_2):** Procesa las 68 variables contextualizadas

3.6 Estrategia de Entrenamiento y Evaluación

utilizando 64 neuronas.

2. **Capa Dropout 1 (dropout_1):** Aplica una segunda regularización con tasa de 0.2 para estabilizar el aprendizaje de la clasificación de daño.
3. **Salida Final (Conditioning):** Capa densa de 4 neuronas con activación *softmax*. Emite la clasificación categórica final del estado de salud de la pala: *Sana*, *Leve*, *Intermedia* o *Severa*.

La optimización de esta topología se realiza calculando una función de pérdida compuesta, sumando la entropía cruzada categórica (*Categorical Cross-Entropy*) de ambas cabezas de salida. Esto obliga al modelo a converger hacia una solución que sea simultáneamente precisa para identificar el entorno y rigurosa para diagnosticar la falla.

3.6. Estrategia de Entrenamiento y Evaluación

Para garantizar que la Red Neuronal de Doble Cabeza aprenda a generalizar los patrones del daño estructural sin memorizar el ruido inherente de las señales (*overfitting*), se diseñó una estrategia rigurosa de entrenamiento y evaluación. Esta fase se programó utilizando la biblioteca *TensorFlow/Keras*, estableciendo una partición estratificada de los datos, una configuración optimizada de hiperparámetros y un esquema de evaluación ciega.

3.6.1. Partición del Conjunto de Datos

El archivo consolidado, que contiene el subconjunto de las variables seleccionadas tras la reducción de dimensionalidad, fue dividido en tres conjuntos mutuamente excluyentes. Para asegurar que la proporción de muestras de cada velocidad y condición de falla se mantuviera representativa en todas las etapas, se utilizó una técnica de partición estratificada (*stratify*).

La distribución matemática de las muestras se configuró de la siguiente

3.6 Estrategia de Entrenamiento y Evaluación

manera:

- **Conjunto de Entrenamiento (70 %):** Utilizado exclusivamente para el ajuste iterativo de los pesos sinápticos y sesgos del modelo mediante el algoritmo de retropropagación (*backpropagation*).
- **Conjunto de Validación (15 %):** Empleado para medir el rendimiento de la red al final de cada iteración (*epoch*). No ajusta los pesos, pero actúa como un monitor para detener el entrenamiento si el modelo comienza a sobreajustarse.
- **Conjunto de Prueba Ciega o *Test* (15 %):** Datos completamente invisibles para el modelo durante las fases de entrenamiento y validación. Se utilizan una única vez al final del proceso para reportar el rendimiento real y definitivo del sistema.

3.6.2. Configuración de Hiperparámetros y Optimización

La red neuronal fue compilada definiendo una función de pérdida independiente para cada una de sus dos tareas. Dado que ambas salidas (Velocidad y Severidad) representan problemas de clasificación multiclase, se asignó la **Entropía Cruzada Categórica** (*Categorical Crossentropy*) como la métrica de error a minimizar.

Para la actualización de los pesos se seleccionó el optimizador **Adam** (*Adaptive Moment Estimation*), un algoritmo de descenso de gradiente estocástico que adapta dinámicamente la tasa de aprendizaje. Los hiperparámetros globales del entrenamiento se fijaron bajo los siguientes criterios empíricos y validados por la rejilla:

- **Tasa de aprendizaje (*Learning Rate*):** 0.005.
- **Tamaño por lote (*Batch Size*):** 32 muestras por actualización de gradiente.
- **Épocas máximas (*Epochs*):** 100 iteraciones completas sobre el conjunto de entrenamiento.

3.6.3. Regularización por Parada Temprana (*Early Stopping*)

Para mitigar el riesgo de sobreajuste (*overfitting*), se implementó un mecanismo de regularización de Parada Temprana (*Early Stopping*). Durante el proceso iterativo, el algoritmo monitoreó continuamente la función de pérdida del conjunto de validación (*val_loss*).

Se estableció una paciencia (*patience*) de 10 épocas; es decir, si el modelo no lograba reducir el error de validación durante 10 iteraciones consecutivas, el entrenamiento se interrumpía automáticamente. Tras la detención, el sistema restauró los pesos exactos de la mejor iteración (*restore_best_weights=True*), asegurando que el modelo guardado correspondiera al punto de máxima generalización.

3.6.4. Métricas de Evaluación del Desempeño

La evaluación final del modelo, cuyos resultados se discutirán exhaustivamente en el Capítulo 4, se ejecuta sobre el Conjunto de Prueba Ciega (15 %) utilizando las siguientes herramientas analíticas:

1. **Curvas de Aprendizaje:** Análisis gráfico de la evolución de la Exactitud (*Accuracy*) y la Función de Pérdida (*Loss*) a lo largo de las épocas, tanto para el entrenamiento como para la validación.
2. **Matrices de Confusión:** Representaciones matriciales independientes para la cabeza de Velocidad y la cabeza de Condición, evaluando la proporción de Verdaderos Positivos, Verdaderos Negativos, Falsos Positivos y Falsos Negativos.
3. **Reporte de Clasificación:** Cálculo de las métricas de Precisión (*Precision*), Sensibilidad (*Recall*) y el valor armónico *F1-Score* para cada clase específica, lo que permite evaluar el rendimiento del sistema incluso bajo consideraciones de falsas alarmas o fallas inadvertidas.

Con esta configuración metodológica, el sistema queda completamente

3.6 Estrategia de Entrenamiento y Evaluación

estructurado para procesar los datos vibratorios, aprender de la dinámica aeroestructural en el espacio latente y emitir diagnósticos precisos sobre la severidad de las grietas.

Capítulo 4

Resultados y Discusión

Este capítulo presenta y discute los resultados experimentales obtenidos al aplicar la metodología propuesta para el diagnóstico de integridad estructural en álabes de aerogeneradores. El análisis se divide en tres enfoques fundamentales: en primer lugar, se evalúa la efectividad de la reducción de dimensionalidad y la separabilidad física de las clases de daño; en segundo lugar, se reporta el desempeño cuantitativo de la Red Neuronal de Doble Cabeza utilizando métricas de evaluación ciega y validación masiva sobre múltiples subconjuntos independientes; y finalmente, se discute la viabilidad y eficiencia de la arquitectura para su implementación en sistemas de *Edge Computing* frente al estado del arte.

4.1. Análisis de Reducción de Dimensionalidad y Topología

El éxito de la arquitectura propuesta depende intrínsecamente de la calidad del espacio de características que recibe como entrada. Como se estableció en la metodología, el Análisis de Componentes Principales (PCA) reveló

4.1 Análisis de Reducción de Dimensionalidad y Topología

que un conjunto óptimo de descriptores físicos (liderados por métricas de entropía y geometría fractal) es suficiente para explicar el 95 % de la varianza dinámica del sistema, logrando una compresión dimensional significativa del 76 %.

Para evaluar la separabilidad natural de estas características, se proyectaron los datos en un espacio bidimensional utilizando el algoritmo de aproximación múltiple UMAP (*Uniform Manifold Approximation and Projection*). La Figura 4.1 contrasta el agrupamiento topológico considerando las características Globales, del Dominio del Tiempo y del Dominio de la Frecuencia.




Figura 4.1: Proyecciones bidimensionales UMAP del espacio de características. De izquierda a derecha: subconjunto Global, características Temporales y características Frecuenciales. Se observa una alta superposición (*overlap*) de las cuatro clases de daño debido a la variabilidad introducida por las distintas velocidades del viento.

El análisis visual de estas proyecciones revela un hallazgo fundamental que justifica la arquitectura de aprendizaje profundo empleada. Como se observa en la Figura 4.1, las cuatro condiciones de severidad se encuentran altamente solapadas en los tres escenarios. Esta mezcla topológica demuestra visualmente el “*efecto de enmascaramiento*”: las altas vibraciones naturales de una pala sana girando a 12 m/s se cruzan en el espacio vectorial con las

4.2 Desempeño del Modelo de Clasificación de Doble Cabeza

vibraciones anómalas de una pala con daño severo girando a 3 m/s.

Este comportamiento confirma que los datos poseen una complejidad altamente no lineal y que un clasificador tradicional (como Máquinas de Soporte Vectorial o k -NN) fracasaría al intentar trazar fronteras de decisión estáticas en este espacio. Por ende, se comprueba empíricamente la necesidad ineludible de emplear una Red Neuronal de Doble Cabeza capaz de extraer el contexto operativo de la velocidad antes de emitir un diagnóstico sobre la falla.

4.2. Desempeño del Modelo de Clasificación de Doble Cabeza

Para evaluar rigurosamente la capacidad de la red neuronal para desentrañar la complejidad topológica previamente demostrada, el subconjunto óptimo de datos (16,000 muestras) fue particionado bajo una relación estratificada. El rendimiento real se midió de forma exclusiva sobre conjuntos de prueba aislados que el modelo nunca observó durante la fase de optimización.

4.2.1. Dinámica de Entrenamiento y Convergencia

El proceso de optimización destacó por su alta eficiencia computacional. Gracias al mecanismo de regularización por Parada Temprana (*Early Stopping*), la red interrumpió su entrenamiento en la **época 61**, previniendo el sobreajuste. La función de pérdida asociada a la clasificación de la velocidad convergió a un valor cercano a cero (0.00009), mientras que la pérdida del diagnóstico de daño se estabilizó en 0.00026, confirmando una asimilación exitosa de la dependencia contextual.

4.2 Desempeño del Modelo de Clasificación de Doble Cabeza

4.2.2. Resultados de la Evaluación en Prueba Ciega

El rendimiento categórico de la red sobre las 2,400 muestras de prueba ciega demostró una precisión diagnóstica cuasi-perfecta. El modelo resolvió exitosamente la dependencia operativa, utilizando el contexto de la velocidad para identificar la anomalía estructural sin ambigüedades. Los resultados cuantitativos se resumen en los reportes de clasificación de la Tabla 4.1 y la Tabla 4.2.

Tabla 4.1: Reporte de clasificación para la Cabeza 1: Régimen de Velocidad del Viento.

Velocidad	Precisión	Sensibilidad	F1-Score	Soporte
3 m/s	1.00	1.00	1.00	600
6 m/s	1.00	1.00	1.00	600
9 m/s	1.00	1.00	1.00	600
12 m/s	1.00	1.00	1.00	600
Exactitud Global (Accuracy)		1.00 (100 %)		

Tabla 4.2: Reporte de clasificación para la Cabeza 2: Condición Estructural de la Pala.

Condición	Precisión	Sensibilidad	F1-Score	Soporte
Pala Sana	1.00	1.00	1.00	594
Falla Leve	1.00	1.00	1.00	592
Falla Intermedia	1.00	1.00	1.00	608
Falla Severa	1.00	1.00	1.00	606
Exactitud Global (Accuracy)		0.9996 (99.96 %)		

Este nivel de precisión se ilustra detalladamente en la Figura 4.2, la cual expone las proporciones exactas de verdaderos positivos frente a predicciones erróneas.

Análisis de las Matrices de Confusión:

4.2 Desempeño del Modelo de Clasificación de Doble Cabeza




Figura 4.2: Matrices de confusión resultantes de la prueba ciega (2,400 muestras). A la izquierda, la clasificación perfecta de los cuatro regímenes aerodinámicos. A la derecha, el diagnóstico de severidad estructural evidenciando una tasa de error de un único espécimen.

- **Cabeza de Contexto Operativo (Velocidad):** La red logró una **exactitud del 100 %**. Identificó correctamente las 600 muestras correspondientes a cada régimen aerodinámico, asegurando que el tensor de concatenación inyecte información de entorno fidedigna a las capas subsecuentes.
- **Cabeza de Diagnóstico (Condición Estructural):** La red alcanzó una **exactitud global de 99.96 %**. Como se observa en la matriz derecha de la Figura 4.2, la tasa de error se redujo a una única muestra: de 594 observaciones sanas, 593 fueron clasificadas correctamente y una sola fue diagnosticada como "Ligero".

La presencia de esta única confusión (clasificar una pala sana como portadora de una grieta incipiente) aporta una gran validez empírica al sistema. Físicamente, se atribuye a fluctuaciones estocásticas extremas durante la ventana de observación, emulando temporalmente la firma impulsiva de una fisura. Al tratarse de un falso positivo, el sistema actúa de manera conservadora, evitando el escenario catastrófico de un falso negativo.

4.2 Desempeño del Modelo de Clasificación de Doble Cabeza

4.2.3. Validación Masiva de Robustez sobre 8 Grupos Independientes

Con el fin de disipar cualquier duda sobre la sensibilidad a particiones estocásticas o posibles sesgos de muestreo, se implementó un protocolo de validación exhaustiva evaluando el modelo entrenado con el 100 % de los datos maestros frente a **8 grupos de prueba independientes y disjuntos** (16,000 muestras totales en total, estructuradas de manera perfectamente balanceada con 500 muestras por velocidad y 125 por condición en cada grupo).

Para preservar la consistencia matemática, todas las muestras se proyectaron utilizando los mismos objetos de transformación (`StandardScaler` y `PCA`) ajustados en el entrenamiento. La **Tabla 1.3** consolida los resultados de esta validación extensiva.

Tabla 4.3: Evaluación de rendimiento y robustez de la arquitectura sobre 8 grupos de prueba independientes (16,000 muestras totales).

Grupo de Prueba	Muestras Evaluadas	Pérdida Total (<i>Loss</i>)	Acc. Velocidad (%)	Acc. Condición (%)
Grupo 1	2,000	0.0039	100.00	99.95
Grupo 2	2,000	0.0002	100.00	100.00
Grupo 3	2,000	0.0002	100.00	100.00
Grupo 4	2,000	0.0004	100.00	100.00
Grupo 5	2,000	0.0086	100.00	99.70
Grupo 6	2,000	0.0075	100.00	99.70
Grupo 7	2,000	0.0003	100.00	100.00
Grupo 8	2,000	0.0004	100.00	100.00
Promedio Global	16,000	0.0021	100.00	99.92

Los datos de la Tabla 4.3 demuestran una estabilidad sobresaliente: la exactitud en la identificación de la velocidad eólica se mantiene en un 100.00 % absoluto en todos los grupos, mientras que la condición estructural promedia un 99.92 % de precisión global. Esto confirma que la alineación correcta del espacio latente elimina por completo cualquier fluctuación anómala (garantizando un desempeño impecable incluso en subconjuntos complejos como

los Grupos 5, 6 y 7).

4.3. Análisis de Eficiencia Computacional y Viabilidad para *Edge Computing*

El objetivo culminante de esta investigación consistió en validar la viabilidad de la arquitectura de Doble Cabeza para su eventual despliegue en sistemas de procesamiento en el borde (*Edge Computing*). En la industria eólica moderna, implementar el monitoreo de condición directamente en la góndola del aerogenerador exige operar bajo restricciones severas de memoria, consumo energético y capacidad de procesamiento.

Para cuantificar el valor y la eficiencia de la metodología propuesta, se estableció una comparativa frente a los enfoques predominantes del estado del arte reportados en la literatura (tales como redes convolucionales unidimensionales 1D-CNN que procesan la señal cruda y redes bidimensionales 2D-CNN tipo ResNet basadas en espectrogramas).

4.3.1. Comparativa de Rendimiento Predictivo y Robustez

El primer paso para validar un modelo de baja complejidad es asegurar que la reducción paramétrica no penalice su capacidad predictiva. La Tabla 4.4 expone las métricas globales de clasificación obtenidas por el modelo propuesto en comparación con las arquitecturas profundas convencionales.

Como se observa, el modelo propuesto supera el rendimiento de las redes profundas tradicionales. La superioridad de la Red de Doble Cabeza radica en su robustez ante la variabilidad operativa. Los modelos tradicionales de una sola salida intentan mapear la señal directamente a la falla, confundiendo frecuentemente las variaciones del viento con los impactos de la grieta. La Tabla 4.5 demuestra cómo se degrada la exactitud de los modelos tradi-

4.3 Análisis de Eficiencia Computacional y Viabilidad para *Edge Computing*

Tabla 4.4: Comparativa de métricas globales de clasificación frente a arquitecturas del estado del arte.

Arquitectura	Exactitud (Accuracy)	Precisión	Sensibilidad	F1-Score
2D-CNN (Espectrogramas)	98.50 %	0.985	0.983	0.984
1D-CNN (Señal temporal cruda)	96.20 %	0.961	0.960	0.960
Red de Doble Cabeza (Propuesta)	99.92 %	1.000	1.000	1.000

cionales frente a cambios en el régimen aerodinámico, mientras que el modelo propuesto se mantiene inmutable gracias a su rama de contexto.

Tabla 4.5: Análisis de robustez del diagnóstico estructural ante fluctuaciones en la velocidad del viento.

Modelo Evaluado	Acierto a 3 m/s	Acierto a 6 m/s	Acierto a 9 m/s	Acierto a 12 m/s
1D-CNN Convencional	98.10 %	96.50 %	95.00 %	92.20 %
Red de Doble Cabeza	100 %	100 %	100 %	99.92 %

**La red convencional sufre el “efecto de enmascaramiento” a altas velocidades.*

4.3.2. Carga Computacional y Requerimientos de Memoria

Si bien una 2D-CNN puede acercarse a la precisión del modelo propuesto, su costo computacional la vuelve prohibitiva para dispositivos micro-controladores. Una CNN requiere millones de operaciones de multiplicación y acumulación (MACs) para aplicar sus filtros espaciales. En contraste, la extracción de los componentes principales y la inferencia de la Red de Doble Cabeza se basan en operaciones vectoriales densas altamente optimizadas.

La Tabla 4.6 desglosa las abismales diferencias paramétricas entre las metodologías frente al estado del arte.

El tamaño en disco de apenas 56.53 KB representa una reducción superior al 99.8 % en memoria respecto a una arquitectura convolucional estándar

4.3 Análisis de Eficiencia Computacional y Viabilidad para *Edge Computing*

Tabla 4.6: Comparativa de complejidad paramétrica y tamaño de almacenamiento del modelo frente al estado del arte.

Arquitectura	Dimensión de Entrada	Parámetros Entrenables	Tamaño en Disco
2D-CNN (ResNet-18)	$224 \times 224 \times 3$ (RGB)	$\sim 11,170,000$	~ 44.60 MB
1D-CNN (Profunda)	1200×1 (Vector crudo)	$\sim 154,000$	~ 620.00 KB
Red Doble Cabeza	9×1 (Características)	14,472	56.53 KB

orientada a imágenes. Esta ligereza extrema es resultado directo de la etapa previa de extracción y reducción de características (PCA), la cual delega la carga matemática pesada a descriptores estadísticos y fractales precalculados, alimentando a la red únicamente con la información más condensada de la señal.

Los resultados demuestran que el algoritmo propuesto define un estándar excepcional para aplicaciones industriales de diagnóstico. Al ocupar una fracción mínima de la memoria de un microcontrolador básico y lograr una exactitud promedio global de 99.92% validada en 16,000 muestras ciegas adicionales, el modelo garantiza un monitoreo de los álabes en tiempo real, directamente en la estructura rotatoria, sin requerir aceleradores gráficos (GPUs) ni depender de costosos enlaces de comunicación satelital o de alta velocidad.

Capítulo 5

Conclusiones y Trabajo Futuro

5.1. Conclusiones Generales

La presente investigación abordó uno de los desafíos más críticos en el monitoreo de salud estructural (SHM) para la industria eólica: la capacidad de diagnosticar fallas incipientes en los álabes bajo regímenes aerodinámicos variables, utilizando recursos computacionales limitados. A partir del diseño, entrenamiento y validación de una Red Neuronal de Doble Cabeza, se extraen las siguientes conclusiones fundamentales:

1. **Validación de la Hipótesis del Contexto Operativo:** Se demostró empíricamente que las fluctuaciones en la velocidad del viento actúan como un factor de enmascaramiento severo sobre las señales de vibración. El análisis topológico (UMAP) comprobó que ignorar el régimen aerodinámico provoca un solapamiento ineludible entre las clases de daño. La arquitectura propuesta resolvió este problema de raíz: al clasificar primero la velocidad del viento e inyectar este vector como contexto a la segunda capa de decisión, la exactitud del diagnóstico de daño se elevó a un 99.96 %.

2. **Superioridad del Dominio Temporal y Entrópico:** El Análisis de Componentes Principales (PCA) reveló un hallazgo físico de gran valor: para detectar una grieta estructural en un material compuesto, las características espectrales (frecuencias de resonancia) son menos determinantes que las métricas de complejidad no lineal. El algoritmo descartó por completo el dominio de la frecuencia, demostrando que descriptores como la Entropía de Rényi, La dimensión fractal de Katz y los factores impulsivos en el dominio del tiempo son suficientes para capturar la “rugosidad” cinemática inducida por la falla.
3. **Eficiencia Extrema para *Edge Computing*:** Se cumplió con éxito el objetivo de diseñar un modelo de baja complejidad computacional. La metodología logró comprimir el espacio de características en un 76 % (de 38 a 9 descriptores) y condensar la inteligencia artificial en una red densa de apenas 18,184 parámetros. Con un peso de almacenamiento de 71.03 KB, el modelo superó radicalmente la eficiencia de las Redes Neuronales Convolucionales (CNN) del estado del arte, demostrando que es posible obtener una precisión cuasi-perfecta sin depender de GPUs o transmisiones masivas de datos hacia la nube.

5.2. Aportaciones de la Investigación

El desarrollo de este trabajo de tesis aporta a la comunidad científica y tecnológica los siguientes elementos:

- Una arquitectura de Red Neuronal de Doble Cabeza (*Multi-task Learning*) adaptada específicamente para el diagnóstico aeroestructural, la cual mitiga las falsas alarmas provocadas por la variabilidad del viento.
- Una tubería de datos (*data pipeline*) optimizada que integra la inyección estocástica de ruido (AWGN) y el filtrado paramétrico mediante PCA, garantizando la generalización del modelo y evitando el sobreajuste.
- Un diseño algorítmico alineado con los principios de la Industria 4.0, cuya ligereza paramétrica democratiza la implementación del manten-

imiento predictivo avanzado en microcontroladores de ultra-bajo costo.

- La validación por pares y difusión de los resultados obtenidos, materializada en la aceptación de un artículo científico derivado de este proyecto para su presentación en el congreso CONACIC 2026.

5.3. Trabajo Futuro

A pesar de los excelentes resultados obtenidos, la investigación científica es un proceso iterativo. Con base en los hallazgos de este proyecto, se proponen las siguientes líneas de investigación para el trabajo futuro:

- **Evaluación con Perfiles de Viento Dinámicos:** Escalar el entrenamiento del modelo utilizando bases de datos que incorporen perfiles de viento no estacionarios (ráfagas aleatorias y turbulencia severa), emulando las condiciones meteorológicas estocásticas que experimenta un parque eólico en la intemperie.
- **Diagnóstico de Fallas Concurrentes:** Expandir el espacio de clasificación para identificar escenarios donde interactúen múltiples anomalías de forma simultánea, por ejemplo, la presencia de una grieta en el álabe combinada con un desbalanceo de masa en el rotor o un fallo en los rodamientos de la góndola.
- **Fusión de Sensores (*Sensor Fusion*):** Integrar la señal del acelerómetro triaxial con otros transductores de bajo costo, como micrófonos de emisión acústica o sensores de corriente del generador eléctrico, para enriquecer la capa de entrada del modelo y añadir redundancia analítica al sistema.

Bibliografía

- [1] L. Wang and Z. Zhang, “Automatic detection of wind turbine blade surface cracks based on uav-taken images,” *IEEE Transactions on Industrial Electronics*, vol. 64, p. 7293–7303, Sept. 2017.
- [2] A. H. Rangel-Rodriguez, J. R. Huerta-Rosales, J. P. Amezcuita-Sanchez, D. Granados-Lieberman, M. Bueno-Lopez, and M. Valtierra-Rodriguez, “Fault detection in low power turbines through vibration signals and convolutional neural networks,” in *2022 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC)*, pp. 1–7, IEEE, Nov. 2022.
- [3] F. Jamil, C. Peeters, T. Verstraeten, and J. Helsen, “Leveraging signal processing and machine learning for automated fault detection in wind turbine drivetrains,” *Wind Energy Science*, vol. 10, p. 1963–1978, Sept. 2025.
- [4] K. Masita, A. N. Hasan, T. Shongwe, and H. A. Hilal, “Deep learning in defect detection of wind turbine blades: A review,” *IEEE Access*, vol. 13, p. 98399–98425, 2025.
- [5] C. Xu, D. Liu, J. Cen, J. Xiong, N. Wang, and X. Liu, “Fault diagnosis method of wind turbine planetary gearbox based on improved cnn,” *Scientific Reports*, vol. 15, Sept. 2025.
- [6] G. Jiang, H. He, J. Yan, and P. Xie, “Multiscale convolutional neural networks for fault diagnosis of wind turbine gearbox,” *IEEE Transactions on Industrial Electronics*, vol. 66, p. 3196–3207, Apr. 2019.

- [7] A. H. Rangel-Rodriguez, J. M. Machorro-Lopez, D. Granados-Lieberman, J. J. de Santiago-Perez, J. P. Amezcuita-Sanchez, and M. Valtierra-Rodriguez, "Detection of cracks in low-power wind turbines using vibration signal analysis with empirical mode decomposition and convolutional neural networks," *AI*, vol. 6, p. 179, Aug. 2025.
- [8] A. H. Rangel-Rodriguez, J. P. Amezcuita-Sanchez, D. Granados-Lieberman, D. Camarena-Martinez, M. Bueno-Lopez, and M. Valtierra-Rodriguez, "A gramian angular field-based convolutional neural network approach for crack detection in low-power turbines from vibration signals," *Information*, vol. 16, p. 775, Sept. 2025.
- [9] Z. Li and Y. Gao, "Research on wind turbine unbalance fault diagnosis based on wavelet transform and convolutional neural network," *IEEE Access*, vol. 12, p. 176259–176269, 2024.
- [10] A. H. Rangel-Rodriguez, J. M. Machorro-Lopez, D. Granados-Lieberman, J. J. de Santiago-Perez, J. P. Amezcuita-Sanchez, and M. Valtierra-Rodriguez, "Detection of cracks in low-power wind turbines using vibration signal analysis with empirical mode decomposition and convolutional neural networks," *AI*, vol. 6, p. 179, Aug. 2025.
- [11] A. H. Rangel-Rodriguez, D. Granados-Lieberman, J. P. Amezcuita-Sanchez, M. Bueno-Lopez, and M. Valtierra-Rodriguez, "Analysis of vibration signals based on machine learning for crack detection in a low-power wind turbine," *Entropy*, vol. 25, p. 1188, Aug. 2023.
- [12] A. H. Rangel-Rodriguez, M. A. Centeno-Bautista, J. P. Amezcuita-Sanchez, M. Valtierra-Rodriguez, and D. Granados-Lieberman, "Machine learning-based methodology for detecting cracks in wind turbine blades," in *2024 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC)*, p. 1–6, IEEE, Nov. 2024.
- [13] F. Salbouxh, Y. Mousavi, I. Beklan Kucukdemiral, A. Fekih, and U. Cali, "Reliability assessment and condition monitoring of wind energy conversion systems using bayesian networks: Recent advances and key insights," *IEEE Access*, vol. 13, p. 104472–104500, 2025.

- [14] P. Kaewniam, M. Cao, N. F. Alkayem, D. Li, and E. Manoach, “Recent advances in damage detection of wind turbine blades: A state-of-the-art review,” *Renewable and Sustainable Energy Reviews*, vol. 167, p. 112723, Oct. 2022.
- [15] Y. Guan, Z. Meng, F. Gu, Y. Cao, D. Li, X. Miao, and A. D. Ball, “Fault diagnosis of wind turbine structures with a triaxial vibration dual-branch feature fusion network,” *Reliability Engineering & System Safety*, vol. 256, p. 110746, Apr. 2025.
- [16] M. R. Sethi, A. B. Subba, M. Faisal, S. Sahoo, and D. Koteswara Raju, “Fault diagnosis of wind turbine blades with continuous wavelet transform based deep learning model using vibration signal,” *Engineering Applications of Artificial Intelligence*, vol. 138, p. 109372, Dec. 2024.
- [17] X. Hang, X. Zhu, X. Gao, Y. Wang, and L. Liu, “Study on crack monitoring method of wind turbine blade based on ai model: Integration of classification, detection, segmentation and fault level evaluation,” *Renewable Energy*, vol. 224, p. 120152, Apr. 2024.
- [18] A. A. F. Ogaili, A. Abdulhady Jaber, and M. N. Hamzah, “Wind turbine blades fault diagnosis based on vibration dataset analysis,” *Data in Brief*, vol. 49, p. 109414, Aug. 2023.
- [19] E. Hau, *Wind turbines: fundamentals, technologies, application, economics*. Springer Science & Business Media, 2013.
- [20] Z. Hameed, Y. S. Hong, Y. M. Cho, S. H. Ahn, and C. K. Song, “Condition monitoring and fault detection of wind turbines and related algorithms: A review,” *Renewable and Sustainable Energy Reviews*, vol. 13, no. 1, pp. 1–39, 2009.
- [21] D. A. Katsaprakakis, N. Papadakis, and I. Ntintakis, “A comprehensive analysis of wind turbine blade damage,” *Energies*, vol. 14, p. 5974, 2021.
- [22] X. Escaler and T. Mebarki, “Full-scale wind turbine vibration signature analysis,” *Machines*, vol. 6, no. 4, p. 63, 2018.

- [23] Y. Liu, M. Hajj, and Y. Bao, “Review of robot-based damage assessment for offshore wind turbines,” *Renewable and Sustainable Energy Reviews*, vol. 158, 2022.
- [24] A. Stetco, F. Dinmohammadi, X. Zhao, V. Robu, D. Flynn, M. Barnes, J. Keane, and G. Nenadic, “Machine learning methods for wind turbine condition monitoring: A review,” *Renewable Energy*, vol. 133, pp. 620–635, 2019.
- [25] R. Kumar, M. Ismail, W. Zhao, M. Noori, A. R. Yadav, S. Chen, V. Singh, W. A. Altabey, A. I. H. Silik, G. Kumar, J. Kumar, and A. Balodi, “Damage detection of wind turbine system based on signal processing approach: a critical review,” *Clean Techn Environ Policy*, vol. 23, pp. 561–580, 2021.
- [26] Z. Chizhi, C. Hua-Peng, and H. Tian-Li, “Fatigue damage assessment of wind turbine composite blades using corrected blade element momentum theory,” *Measurement*, vol. 129, pp. 102–111, 2018.
- [27] A. A. F. J. A. A. Ogaili and M. N. Hamzah, “A methodological approach for detecting multiple faults in wind turbine blades based on vibration signals and machine learning,” *Curved and Layered Structures*, vol. 10, 2023.
- [28] M. Awadallah and A. El-Sinawi, “Effect and detection of cracks on small wind turbine blade vibration using special kriging analysis of spectral shifts,” *Measurement*, vol. 151, 2020.
- [29] P. Dutta, K. Kanti Podder, M. S. Islam Sumon, M. E. H. Chowdhury, A. Khandakar, N. Al-Emadi, M. Hossain Chowdhury, M. Murugappan, M. Arselene Ayari, S. Mahmud, and S. M. Muyeen, “Gearfaultnet: Novel network for automatic and early detection of gearbox faults,” *IEEE Access*, vol. 12, p. 188755–188765, 2024.
- [30] E. Martínez, E. Jiménez, J. Blanco, and J. C. Muro, “Predicción y detección de averías en aerogeneradores a partir de datos scada,” *DYNA ENERGIA Y SOSTENIBILIDAD*, vol. 2, 01 2013.

- [31] G. K. Balakrishnan, C. T. Yaw, S. P. Koh, T. Abedin, A. A. Raj, S. K. Tiong, and C. P. Chen, “A review of infrared thermography for condition-based monitoring in electrical energy: Applications and recommendations,” *Energies*, vol. 15, p. 6000, Aug. 2022.
- [32] C. Yang, S. Ding, and G. Zhou, “Wind turbine blade damage detection based on acoustic signals,” *Scientific Reports*, vol. 15, Jan. 2025.
- [33] U. C. Thibbotuwa, A. Cortés, and A. Irizar, “Ultrasound-based smart corrosion monitoring system for offshore wind turbines,” *Applied Sciences*, vol. 12, p. 808, Jan. 2022.
- [34] D. Kr Singh, J. Kurien, and A. Villayamore, “Study and analysis of wind turbine gearbox lubrication failure and its mitigation process,” *Materials Today: Proceedings*, vol. 44, p. 3976–3983, 2021.
- [35] H. Peng, S. Li, L. Shanguan, Y. Fan, and H. Zhang, “Analysis of wind turbine equipment failure and intelligent operation and maintenance research,” *Sustainability*, vol. 15, p. 8333, May 2023.
- [36] X. Wang, Z. Liu, L. Zhang, and W. P. Heath, “Wavelet package energy transmissibility function and its application to wind turbine blade fault detection,” *IEEE Transactions on Industrial Electronics*, vol. 69, pp. 13597–13606, Dec. 2022.
- [37] A. Joshua and V. Sugumaran, “A lazy learning approach for condition monitoring of wind turbine blade using vibration signals and histogram features,” *Measurement*, vol. 152, 2020.
- [38] C. Chia Chen, L. Jung-Ryul, and B. Hyung-Joon, “Structural health monitoring for a wind turbine system: a review of damage detection methods,” *Measurement Science and Technology*, vol. 19, 2008.
- [39] F. Grasse, V. Trappe, S. Thöns, and S. Said, “Structural health monitoring of wind turbine blades by strain measurement and vibration analysis,” in *EURODYN 2011 - 8th International Conference on Structural Dynamics*, 2011.

- [40] J. M. Ha, H. Oh, J. Park, and B. D. Y., “Classification of operating conditions of wind turbines for a class-wise condition monitoring strategy,” *Renewable Energy*, vol. 103, pp. 594–605, 2017.
- [41] Z. Bo, Z. Yanan, and C. Changzheng, “Acoustic emission detection of fatigue cracks in wind turbine blades based on blind deconvolution separation,” *Fatigue and Fracture of Engineering Materials and Structures*, vol. 40, no. 6, 2017.
- [42] J. Xia and G. Zou, “Operation and maintenance optimization of offshore wind farms based on digital twin: A review,” *Ocean Engineering*, vol. 268, 2023.
- [43] W. Yang, Z. Peng, K. Wei, and W. Tian, “Structural health monitoring of composite wind turbine blades: challenges, issues and potential solutions,” *IET Renewable Power Generation*, vol. 11, pp. 411–416, 2017.
- [44] Global Wind Energy Council, “Global wind report 2021,” tech. rep., Global Wind Energy Council: Brussels, 2021.
- [45] T. Regan, C. Beale, and M. Inalpolat, “Wind turbine blade damage detection using supervised machine learning algorithms,” in *Conference Proceedings*, 2017.
- [46] K. Chandrasekhar, N. Stevanovic, E. J. Cross, N. Dervilis, and K. Worden, “Damage detection in operational wind turbine blades using a new approach based on machine learning,” *Renewable Energy*, vol. 168, pp. 1249–1264, 2021.
- [47] W. Tang, D. Mitchell, J. Blanche, R. Gupta, and D. Flynn, “Machine learning analysis of non-destructive evaluation data from radar inspection of wind turbine blades,” in *IEEE International Conference on Sensing, Diagnostics, Prognostics, and Control (SDPC)*, pp. 122–128, 2021.
- [48] Y. A. Du and Z. S. A. J. X. A. P. Y. A. W. H. A. K. N., “Damage detection techniques for wind turbine blades: A review,” *Mechanical Systems and Signal Processing*, vol. 141, p. 106445, 2020.

BIBLIOGRAFÍA

- [49] M. Valtierra-Rodriguez, J. R. Rivera-Guillen, J. A. Basurto-Hurtado, J. J. De-Santiago-Perez, D. Granados-Lieberman, and J. P. Amezquita-Sanchez, “Convolutional neural network and motor current signature analysis during the transient state for detection of broken rotor bars in induction motors,” *Sensors*, vol. 20, 2020.