



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Especialidad en Mecatrónica

Análisis tiempo-frecuencia de vibraciones y redes neuronales convolucionales
para detectar daño en aerogeneradores de baja potencia

Opción de titulación

Tesis

Que como parte de los requisitos para obtener el Grado de
Maestría en Ciencias (Mecatrónica)

Presenta:

Ing. Ángel Humberto Rangel Rodríguez

Dirigido por:

Dr. Martín Valtierra Rodríguez

Mayo 2022



Universidad Autónoma de Querétaro
Facultad de Ingeniería
Especialidad en Mecatrónica

Análisis tiempo-frecuencia de vibraciones y redes neuronales convolucionales
para detectar daño en aerogeneradores de baja potencia

Opción de titulación
Tesis

Que como parte de los requisitos para obtener el Grado de
Maestría en Ciencias (Mecatrónica)

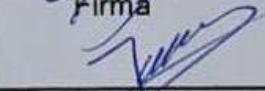
Presenta:
Ing. Ángel Humberto Rangel Rodríguez

Dirigido por:
Dr. Martín Valtierra Rodríguez

Dr. Martín Valtierra Rodríguez
Presidente


Firma

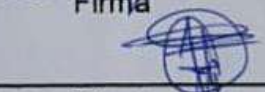
Dr. Juan Primo Benítez Rangel
Secretario


Firma

Dr. Gerardo Israel Pérez Soto
Vocal


Firma

Dr. J. Jesús de Santiago Pérez
Suplente


Firma

Dr. Luis Morales Velázquez
Suplente


Firma

Campus San Juan del Río
San Juan del Río, Querétaro
Mayo 2022

RESUMEN

El monitoreo y detección de los daños en aerogeneradores reduce el costo de mantenimiento y alarga su tiempo de vida útil. Si el daño es detectado en una etapa temprana, el daño ligero o incipiente puede ser reparado antes de que este empeore. Por esta razón, el presente documento muestra una metodología basada en redes neuronales convolucionales y señales de vibraciones para la detección de daños en aspas (3 niveles de severidad) y rodamientos. En general, la metodología empleada consiste en la adquisición de las señales de vibraciones de cada condición de daño y la condición sana. Entonces se calcula su espectrograma para obtener una imagen del plano tiempo-frecuencia de las vibraciones. Esta imagen es segmentada y analizada mediante redes neuronales convolucionales para la detección automática de los daños. Los resultados obtenidos muestran una efectividad del 100% en la detección.

Palabras clave: aerogeneradores, daño de desbalance, daño de rodamientos, plano tiempo-frecuencia, redes neuronales convolucionales, señales de vibraciones.

SUMMARY

Monitoring and detection of damages in wind turbines (WT) minimize the cost of repairment and maintenance, as well as increase their life time. The early fault detection permits the repairment before the damage becomes more severe. In this work, a methodology that consists of convolutional neural networks (CNN) and the representation time-frequency of the vibration signals for the detection of 3 levels of imbalance damage (i.e., low, medium, and high) and bearings of WT is shown. In general terms, the proposal consists of the acquisition of vibration signals from both the damage conditions and the healthy condition. After that, the spectrogram function is applied to obtain the time-frequency representation of the vibration signals, which is treated as image. Thus, the image is processed by the CNN to diagnose the wind turbine condition automatically. Results show the suitable effectiveness of the proposed methodology since 100 % of accuracy is achieved.

Key words: Bearing damage, convolutional Neural Network, imbalance damage, time-frequency plane, vibration signals, wind turbines.

DEDICATORIA

Con mucho agradecimiento dedico este trabajo a mis padres Humberto Rangel Zamora y Leticia Rodríguez Cortés quienes me brindaron su apoyo en el transcurso del tiempo que duró, a su vez a mis hermanos Daniel Uriel Rangel Rodríguez, Dulce Midori Rangel Rodríguez y Erick Isaac Rangel Rodríguez.

AGRADECIMIENTOS

A mi papá Humberto Rangel Zamora y mi mamá Leticia Rodríguez, así como a mis hermanos Daniel Uriel Rangel Rodríguez, Dulce Midori Rangel Rodríguez y Erick Isaac Rangel Rodríguez por estar siempre conmigo apoyándome, respaldándome y brindándome todo su cariño en las buenas y en las malas.

Al Dr. Martín Valtierra Rodríguez, director de este trabajo de tesis, por sus enseñanzas y conocimientos brindados durante la realización de este proyecto, no importando el día o la hora.

A todos los profesores de la Maestría en Ciencias (Mecatrónica) por transmitirme todos los conocimientos necesarios para obtener este grado.

A todos los compañeros y amigos dentro y fuera de la Maestría por su solidaridad, compañerismo y los excelentes momentos que compartimos en esta parte de nuestra formación académica.

A la Facultad de Ingeniería de la Universidad Autónoma de Querétaro por brindarme todas las facilidades para poder realizar con éxito la Maestría.

Al Consejo Nacional de Ciencia y Tecnología (CONACYT) por brindarme la beca número 763465 con la cual pude dedicarme de tiempo completo a la realización del posgrado.

ÍNDICE

1. INTRODUCCIÓN	10
1.1 ANTECEDENTES	10
1.2 JUSTIFICACIÓN	15
1.3 DESCRIPCIÓN DEL PROBLEMA	16
1.4 HIPÓTESIS Y OBJETIVOS	18
1.4.1 Hipótesis	18
1.4.2 Objetivo General:	18
1.4.3 Objetivos particulares:	18
1.4.4 Diagrama General:	19
2. MARCO TEÓRICO	22
2.1 EL AEROGENERADOR	22
2.2 AEROGENERADOR DE BAJA POTENCIA	25
2.3 TÚNELES DE VIENTO	26
2.4 VIBRACIÓN	27
2.5 ACCELERÓMETRO	29
2.6 TRANSFORMADA CORTA DE FOURIER	30
2.7 REDES NEURONALES CONVOLUCIONALES	31
2.8 DAÑOS EN RODAMIENTOS	34
2.9 DESBALANCE EN ASPAS	35
3. METODOLOGÍA	37
3.1 METODOLOGÍA DE ANÁLISIS	39
3.2 PUESTA EN EXPERIMENTACIÓN	41
4. RESULTADOS	47
4.1 DESBALANCE	47
4.2 DAÑOS POR DESBALANCE	49
4.3 DAÑOS EN RODAMIENTOS	55
4.4 DETECCIÓN DEL DAÑO	59
5. CONCLUSIONES	62

6. REFERENCIAS	64
-----------------------------	-----------

ÍNDICE DE TABLAS

TABLA 1 MATRIZ DE PRUEBAS (DESBALANCE).....	48
TABLA 2 ESTRUCTURA DE LA CNN.....	50
TABLA 3 SELECCIÓN DEL LEARNING RATE.....	51
TABLA 4 RESULTADOS CON DISTINTO MAX EPOCHS.....	52
TABLA 5 MATRIZ DE PRUEBAS CON RODAMIENTOS.....	56
TABLA 6 MATRIZ DE CONFUSIÓN.....	60
TABLA 7 COMPARATIVA DE TRABAJOS.....	61

ÍNDICE DE FIGURAS

FIGURA 1 DIAGRAMA GENERAL.....	21
FIGURA 2. 1 PARTES DEL AEROGENERADOR (ADAPTACIÓN DE AULAFACIL, 2020).....	23
FIGURA 2. 2 AEROGENERADOR DE 5 ASPAS (RANGEL, 2020).....	24
FIGURA 2. 3 AEROGENERADOR DE BAJA POTENCIA (MINAS, 2004).....	25
FIGURA 2. 4 TÚNEL DE VIENTO (AUTORÍA PROPIA).....	27
FIGURA 2. 5 PLANO TIEMPO FRECUENCIA (VALTIERRA ET AL., 2020).....	30
FIGURA 2. 6 ARQUITECTURA DE UNA CNN (ADAPTADO DE VALTIERRA, 2020).....	32
FIGURA 3. 1 DIAGRAMA GENERAL DE LA METODOLOGÍA.....	37
FIGURA 3. 2 DIAGRAMA GENERAL DE LA METODOLOGÍA.....	40
FIGURA 3. 3 COMPONENTES UTILIZADOS.....	41
FIGURA 3. 4 BASE DEL AEROGENERADOR.....	42
FIGURA 3. 5 UBICACIÓN DEL ACELERÓMETRO.....	43
FIGURA 3. 6 PRIMERA PESTAÑA DE LA APLICACIÓN.....	44
FIGURA 3. 7 PESTAÑA DE DISEÑO.....	45
FIGURA 3. 8 PESTAÑA DE IDENTIFICACIÓN.....	46

FIGURA 4. 1 MASAS POR NIVEL DE SEVERIDAD A) GRAVE B) MEDIO C) LIGERO.....	48
FIGURA 4.2. 1 ESPECTROGRAMA Y TIEMPO-FRECUENCIA DE LAS CONDICIONES LIGERO (IZQUIERDA) Y SEVERO (DERECHA).....	49
FIGURA 4.2. 2 RED NEURONAL CONVOLUCIONAL PROPUESTA.....	53
FIGURA 4.2. 3 COMPARATIVA ENTRE VELOCIDADES.....	54
FIGURA 4.2. 4 ENTRENAMIENTO DE CNN SEGUNDA VELOCIDAD.....	55
FIGURA 4.3. 2 DAÑO EN RODAMIENTO.....	56
FIGURA 4.3. 3 COMPARATIVA FFT SANO VS DAÑO.....	57
FIGURA 4.3. 4 COMPARATIVA ESPECTROGRAMA DAÑO VS SANO.....	58
FIGURA 4.3. 5 RESULTADOS CON DAÑO EN RODAMIENTOS.....	58

Abreviaturas y Siglas

APP	Abreviatura de la palabra inglesa Application
CNN	Red Neuronal Convolutiva (del inglés Convolutional Neural Network)
DSC	Del inglés discrete spectrum correction
FFT	Del inglés Fast Fourier Transform
g	Gramos
IEPE	Del inglés Integrated Electronics Piezo-Electric
MSI	Del inglés multivariable spectrum imaging
NI	National Instruments
PC	Del inglés Personal Computer
RMS	Valor cuadrático medio, del inglés Root Mean Squared
SCADA	Del inglés Supervisory Control And Data Acquisition, es decir: control supervisado y adquisición de datos
SFTF	Del inglés Short Time Fourier Transform
SVM	Del inglés support vector machine
SWT	Del inglés Synchrosqueezed Wavelet Transform
TF	Transformada de Fourier
TWD	Transformada Wavelet Discreta
WT	Aerogenerador (del inglés Wind Turbine)

1. INTRODUCCIÓN

1.1 Antecedentes

La energía eólica es una fuente de energía renovable y sostenible que gana gran popularidad en el contexto de la limitada cantidad de fuentes de energía tradicionales y la contaminación masiva generada por la combustión de energía fósil (Cao et al., 2019). Esta fuente de energía es no contaminante, es permanente y minimiza el uso de combustibles fósiles, los cuales son generan la problemática de efecto invernadero y por lo tanto el calentamiento global. La energía eólica se es transformada a través de un generador, el cual recibirá la energía del viento, a energía eléctrica para ser aprovechada en distintos usos (Byll, 2019).

Como es presentado por Baggeröhr et al. (2020), las turbinas eólicas (WT por sus siglas en inglés *Wind Turbine*) son sistemas electromecánicos complejos y de gran escala que se utilizan ampliamente en las aplicaciones de energía renovable. Un aerogenerador comprende cientos de piezas clave, tales como: torre, cubo de rotor, sistema de cadena de transmisión (eje principal, sistema de engranajes motor y rodamientos), conjunto de cuchillas, marco generador, gabinetes de refrigeración, electrónica de potencia, etc. A pesar de ser diseñados

con alta eficiencia y ser máquinas robustas, todas sus piezas son susceptibles a fallar.

El diagnóstico de fallas por daños incipientes en máquinas mecánico-eléctricas, como turbinas eólicas, puede reducir los costos de reparación y mantenimiento, así como los costos asociados con el tiempo de inactividad no programado del proceso de generación de energía. Además, este diagnóstico es fundamental para mantener y mejorar la eficiencia de los aerogeneradores y el proceso de generación de energía (Chávez et al., 2019). La estrategia de mantenimiento, reactivo, preventivo y predictivo, en aerogeneradores tiene como objetivo la mejora continua del sistema de producción, así como prolongar la vida de los equipos, requiriendo, entre otros factores, la medición constante de vibraciones mecánicas. Es bien sabido que la mayoría de los problemas en los aerogeneradores están relacionados directa e indirectamente a las vibraciones mecánicas; es decir, por un lado, las vibraciones mecánicas pueden generar daños en el aerogenerador, pero, por otro lado, las vibraciones pueden ayudar a diagnosticar el daño ya que estas contienen información de la dinámica del aerogenerador en sus distintas condiciones de operación. En este sentido, muchos trabajos de investigación han sido publicados en la literatura actual con el objetivo de contribuir a la solución de problemas de monitoreo y diagnóstico de daños en aerogeneradores.

De manera internacional, Guo et al. (2018) presentan un análisis de las fallas en maquinaria rotativa mediante señales de vibraciones, redes neuronales y la transformada wavelet para descomposición temporal en anchos frecuenciales específicos. En el trabajo de Puruncajas et al. (2020) se presenta un método de análisis estructural para detección de fallas en estructuras costa afuera mediante señales de vibraciones y la utilización de redes neuronales convolucionales. Por otro lado, Ulmer et al. (2020) realizan la detección de fallas en aerogeneradores mediante señales de vibraciones obtenidas por un sistema SCADA (por sus siglas en inglés *Supervisory Control And Data Acquisition*, es decir: control supervisado y

adquisición de datos) y el procesamiento de extracción de características y clasificación basado en redes neuronales convolucionales. En estos trabajos se observa y demuestra el aprovechamiento de las señales de vibraciones para realizar la detección de daños, así como de la aplicación de redes neuronales para el diagnóstico automático.

Uno de los países que más aborda el tema de los análisis en daños de aerogeneradores es China. Los trabajos que se encontraron se enfocan, en su mayoría, en el diagnóstico de un solo daño de los aerogeneradores como lo son el caso de las palas o aspas del aerogenerador, rodamientos o caja de engranes. Con respecto al daño en las aspas, se encuentra el trabajo de Cao et al. (2019) en el cual se propone un método de detección de desbalance basado en la técnica de imagen espectral multivariable (MSI por sus siglas en inglés *multivariable spectrum imaging*) y redes neuronales convolucionales de las señales en vibraciones, la velocidad del generador y el torque del generador; también, Yang & Zhang (2020) presentan la detección de ruptura de una de las palas del aerogenerador, utilizando un método de procesamiento y clasificación basado en redes neuronales.

En la parte de los rodamientos se encuentra el trabajo de Yang et al. (2018), en el cual proponen un diagnóstico basado en redes neuronales convolucionales para fallas en rodamientos, teniendo como dato de entrada un modelo del espectro de la transformada corta de Fourier de las señales de vibraciones del rodamiento.

Finalmente, en la caja de engranes, se encuentra el trabajo de He et al. (2016). Ellos proponen un análisis de las vibraciones de una caja de engranes mediante la utilización de la corrección espectral discreta (DSC por sus siglas en inglés *discrete spectrum correction*) para así demostrar su efectividad y robustez para el diagnóstico de fallas. Por su parte, Jiang et al. (2018) proponen un análisis de señales de vibraciones mediante la utilización de redes neuronales convolucionales. Mientras que Qiu et al. (2019) obtienen las señales de vibraciones horizontales y verticales de una caja de engranes para determinar el grado de degradación de los engranes en 5 diferentes condiciones de operación para

posteriormente comparar el procesamiento mediante máquinas de soporte vectorial (SVM por sus siglas en inglés *support vector machine*) y redes neuronales convolucionales profundas. Por otro lado, Zhao et al. (2019) proponen la utilización de la transformada Wavelet de sincronía y resignación de energía en el plano tiempo frecuencia (SWT por sus siglas en inglés *Synchrosqueezed Wavelet Transform*) y redes neuronales convolucionales para el análisis de señales de vibraciones y la detección de fallas en cajas de engranes. Y, por último, Chen et al. (2019) realizan la detección de fallas en la caja de engranes mediante la fusión de dos señales de vibraciones de diferentes direcciones y un procesamiento de señales en redes neuronales convolucionales profundas. Como se observa anteriormente, muchos trabajos orientados al diagnóstico de daños en aerogeneradores se han presentado en la literatura; no obstante, ellos se han enfocado en un solo daño, dejando la oportunidad de estudiar y proponer metodologías que consideren más de un solo tipo de daño.

También, con el objetivo de considerar aerogeneradores de gran escala, varios trabajos se han enfocado en el análisis de datos obtenidos en simulaciones, lo cual puede divergir de los datos reales dependiendo de las consideraciones hechas en el modelo de simulación; en este sentido, la experimentación real y controlada en aerogeneradores de menor potencia resulta atractiva ya que el aerogenerador se encuentra en condiciones más reales de operación. Además, es importante mencionar que los aerogeneradores de baja potencia son cada vez más usados en ambientes urbanos ya que requieren una menor cantidad de viento y espacio a comparación de los aerogeneradores de mayor potencia, razón que incentiva aún más su estudio.

Dentro de México también hay diferentes trabajos que se han presentado para la detección y diagnóstico de aerogeneradores. Por ejemplo, en el trabajo de Salinas et al. (2017) se propone un análisis de ajuste basado en una red neuronal para la predicción de fallas en aerogeneradores de baja potencia, para esto se utiliza como señal de estudio la aceleración angular del eje de baja velocidad. También,

Ortiz et al. (2018) proponen la detección de fallas en el estator de un aerogenerador mediante la utilización de la transformada rápida de Fourier (FFT por sus siglas en inglés *Fast Fourier Transform*) y la transformada wavelet discreta (TWD) mediante las señales de corriente. Por otro lado, Sánchez et al. (2019) proponen un sistema de monitoreo de vibraciones para la detección de daños en aerogeneradores, principalmente de daños en las palas, mediante la utilización de un análisis estadístico de frecuencia basado en Matlab y LabVIEW. Al igual que la mayoría de los trabajos internacionales, los trabajos nacionales se han enfocado en el estudio de un solo daño, lo cual puede limitar la aplicabilidad de los métodos/metodologías o sistemas desarrollados.

Finalmente, en la Universidad Autónoma de Querétaro se encuentra el trabajo de Hernández (2018) en el cual se realiza la detección de daños en aerogeneradores de baja potencia mediante un sistema de análisis de vibraciones con un procesamiento basado en la transformada wavelet. También se encuentra el trabajo de Rangel (2020), en el cual se realiza la detección de daño en las aspas del aerogenerador en diferentes grados de severidad y con dos condiciones de viento basado en la transformada rápida de Fourier y un árbol de decisiones. Ambos trabajos se desarrollan en aerogeneradores de baja potencia.

Como se observa, aunque ya se han desarrollado trabajos orientados a la detección de daños en aerogeneradores, aún es necesario investigar casos de estudio donde se consideren distintos niveles de severidad de daño, así como diferentes tipos de daño y bajo diferentes condiciones de viento con el objetivo de proponer metodologías más robustas y genéricas. También, es necesario investigar la aplicación de redes neuronales convolucionales como técnicas automáticas para extracción y clasificación automática de características, lo cual puede permitir una mayor eficiencia en la clasificación ya que no depende de la experiencia del diseñador. Por lo tanto, en el presente trabajo se investigará y desarrollará una metodología basada en el análisis tiempo-frecuencia mediante la transformada corta de Fourier y redes neuronales convolucionales en señales de vibraciones de

un aerogenerador de baja potencia, esto con el propósito de obtener una técnica automática para la extracción y clasificación de daños por desbalance en las aspas y daño en los rodamientos.

1.2 Justificación

A medida que las tecnologías van avanzando, nuevas formas de energía también se van desarrollando, tal es el caso de las fuentes de energía renovable. De estas, la energía eólica está llegando a ser una de las fuentes de energía más utilizadas (SEGOB, 2015). Si los generadores de turbinas eólicas, que son los dispositivos principales de la tecnología de generación de energía eólica, pueden funcionar de forma segura durante un largo período de tiempo, se tendrán diversos beneficios para las empresas de generación de energía y el desarrollo económico local (auto consumidores). Por lo tanto, la detección de daños tempranos en los aerogeneradores otorga la posibilidad de mantenimientos preventivos y, por lo tanto, una ventaja económica; si estos daños crecen, pueden derivar en problemas más severos en los cuales se tenga que parar el suministro eléctrico o poner en riesgo la integridad del aerogenerador completo así con aquellos que los rodean.

Al ver el panorama descrito en los antecedentes es evidente la necesidad de estudiar y desarrollar métodos que puedan diagnosticar más de un tipo de daño. En particular, el estudio en este trabajo se centrará en aerogeneradores de baja potencia, considerando que cada vez son más comunes en los lugares urbanos (casas habitación, edificios o establecimientos, así como distintas instituciones y empresas), esto debido a la menor cantidad de viento que ocupan para su funcionamiento y menor espacio requerido para su montaje.

Los aerogeneradores de baja potencia no siempre contienen una caja multiplicadora, la cual es una de las zonas más estudiadas para la detección de daños. En este sentido, es importante realizar la detección temprana de daños en las palas y rodamientos (otros daños comúnmente reportados en la literatura), los cuales pueden dañar por completo el aerogenerador si el daño es severo.

También es importante mencionar que el uso de redes neuronales convolucionales (CNN por sus siglas en inglés: *Convolutional Neural Network*) se justifica debido a los excelentes resultados que se observan en el diagnóstico de diferentes sistemas. En este trabajo, se emplearán las CNN para extraer y reconocer patrones de forma automática para dos diferentes tipos de daño. Como la CNN normalmente trabaja sobre imágenes, la transformada corta de Fourier será usada con el objeto de obtener el plano tiempo-frecuencia de las señales de vibración el cual será tratado como una imagen. Además, se espera que las señales de vibraciones tengan propiedades no estacionarias, lo cual justifica el uso de la STFT.

Finalmente, otro factor que motiva la realización del presente estudio es el potencial de la energía eólica en México. Por ejemplo, se sabe que México está entre los primeros países con más potencial de generación eólica en el mundo (SEGOB, 2015), lo cual permite tener una visualización del país como un importante productor de infraestructura eólica. De hecho, México cuenta con 31 parques eólicos funcionando y otros en desarrollo en varios estados; tal es el caso del parque eólico AERUS quien tiene una producción de 250MW, el cual es uno de los 22 parque eólicos ubicados en el estado de Oaxaca (SEMAEDES, 2020). A partir de esta información es evidente la necesidad de desarrollar e implementar tecnologías que contribuyan a las soluciones de detección y diagnóstico de daños.

1.3 Descripción del problema

El problema por resolver en este trabajo de tesis es desarrollar una metodología que sea capaz de detectar dos tipos de daños mecánicos en aerogeneradores de baja potencia, es decir: daño por desbalance en aspas y daño en rodamientos. Si los daños no son detectados a tiempo, el daño puede aumentar hasta hacer que el aerogenerador falle completamente, lo cual implicaría un gasto mayor. Es evidente que mientras exista el daño, el aerogenerador no podrá operar

con la eficiencia esperada, por eso la importancia de una detección y diagnóstico oportunos.

El desbalance es un problema común dentro de los aerogeneradores debido tanto a problemas del medio ambiente como lo es hielo o tierra en la punta de las aspas (desbalance positivo), como por accidentes relacionados con animales como lo son las aves que chocan con ellas causando pérdida de masa en las aspas (desbalance negativo). En general, el desbalance afecta la flecha o rotor, generando desgaste y vibraciones excesivas, lo cual reduce la vida útil del aerogenerador. Por otro lado, los problemas en rodamientos están relacionados con el desgaste de estos debido a aspectos tales como: desalineamientos, vibraciones de otras partes del aerogenerador, una mala calidad de los materiales, un mal diseño o proceso de construcción y/o la contaminación o mala calidad de los lubricantes. Todos estos factores afectan negativamente la integridad del aerogenerador y pueden conducir a daños mucho más severos si no son corregidos a tiempo.

Respecto a lo expuesto en los antecedentes del presente documento, se tienen diferentes problemáticas esenciales que se deben resolver para poder proveer una contribución a la solución de la detección de daños en aerogeneradores. La primera consiste en habilitar la puesta de experimento tanto del túnel de viento que excitará al aerogenerador como el aerogenerador bajo diferentes condiciones de operación (sano, desbalance en el aspa y daño en el rodamiento), todo esto de forma controlada y sin inducir un daño permanente en el aerogenerador. Otro punto para resolver es poder determinar patrones característicos según el tipo de daño en el plano tiempo-frecuencia, esto con la intención de no solo detectar la presencia de daño, sino conocer qué tipo de daño tiene el aerogenerador. Para esto se deberán analizar las vibraciones en los tres ejes con la intención de determinar que eje provee más información asociada al daño. Durante el análisis también se deberá buscar una estructura eficiente para la arquitectura de la red neuronal convolucional ya que no existe una regla específica para su construcción; por lo tanto, se deberán buscar los parámetros que generen

una alta eficiencia en el diagnóstico, pero sin dejar de buscar una eficiencia en el tiempo de cómputo.

1.4 Hipótesis y Objetivos

1.4.1 Hipótesis

Mediante el uso de redes neuronales convolucionales y el análisis tiempo-frecuencia de señales de vibraciones es posible la detección automática de daños por desbalance en aspas y daños en rodamientos de aerogeneradores de baja potencia considerando diferentes niveles de severidad.

1.4.2 Objetivo General:

Desarrollar una metodología basada en redes neuronales convolucionales y el análisis tiempo-frecuencia de señales de vibraciones para la detección automática de daños por desbalance en las aspas y rodamientos de aerogeneradores de baja potencia considerando diferentes niveles de severidad.

1.4.3 Objetivos particulares:

- Implementar un sistema de adquisición de datos de vibraciones en un aerogenerador de baja potencia mediante el empleo de Matlab y un acelerómetro triaxial para la obtención de un banco de datos.
- Ajustar y calibrar el sistema de regulación del túnel de viento con el propósito de obtener las condiciones de viento requeridas para la realización de las pruebas, incluyendo estado transitorio y estado estable en los perfiles de viento.
- Elaborar una matriz de condiciones de operación controladas en el aerogenerador, conteniendo las condiciones de sano, daño por desbalance y daño en rodamientos para la realización de las pruebas.

- Desarrollar un sistema de procesamiento basado en la integración de la transformada corta de Fourier y redes neurales convolucionales para la identificación automática y monitoreo de cada condición de prueba.
- Comparar la efectividad en términos de la clasificación correcta de los resultados obtenidos respecto a los reportados en el estado de arte para validar la metodología empleada.

1.4.4 Diagrama General:

En la Figura 1 se muestra el diagrama general que se va a seguir para el desarrollo del trabajo, el cual está formado por los siguientes bloques:

Documentación y estado del arte: Se realiza una investigación de los antecedentes para realizar la contribución al estado del arte. También se revisa la fundamentación teórica de los conceptos necesarios para abordar este trabajo de investigación.

Desarrollo de Sistema de adquisición de datos en Matlab: Con el uso de un acelerómetro y una tarjeta de adquisición de datos se obtendrá una base de datos de las señales de vibraciones obtenidas de las pruebas a realizar.

Ajuste de túnel de viento para velocidades controladas: El túnel de viento se configura para encender, mantener la velocidad deseada, hacer la captura de datos en la velocidad que se ocupa y apagar el túnel de viento, para ello se utilizarán 2 velocidades de viento.

Adaptación de daño de desbalance y rodamientos en aerogeneradores: Para el caso de desbalance se utilizará una masa en una de las aspas, esta masa será de distinto peso dependiendo la severidad. Para el caso de rodamientos, se hace un orificio en el contorno exterior del rodamiento.

Experimentación: Se realizará la matriz de pruebas que consiste en las diferentes condiciones de daño en el aerogenerador siendo diferentes severidades en el caso del desbalance o un solo daño en el caso de rodamientos, considerando dos velocidades diferentes.

Diseño, entrenamiento y validación de red neuronal convolucional: Con la base de datos se procesarán las señales para obtener imágenes las cuales se ajustarán para poder entrenar la red neuronal convolucional, para ello se utilizará solo una parte de las imágenes dejando el resto para la validación.

Análisis de resultados y redacción de tesis: Se registrarán los resultados en una matriz de confusión para obtener la exactitud del método empleado y se continuará con la redacción del trabajo en el documento.

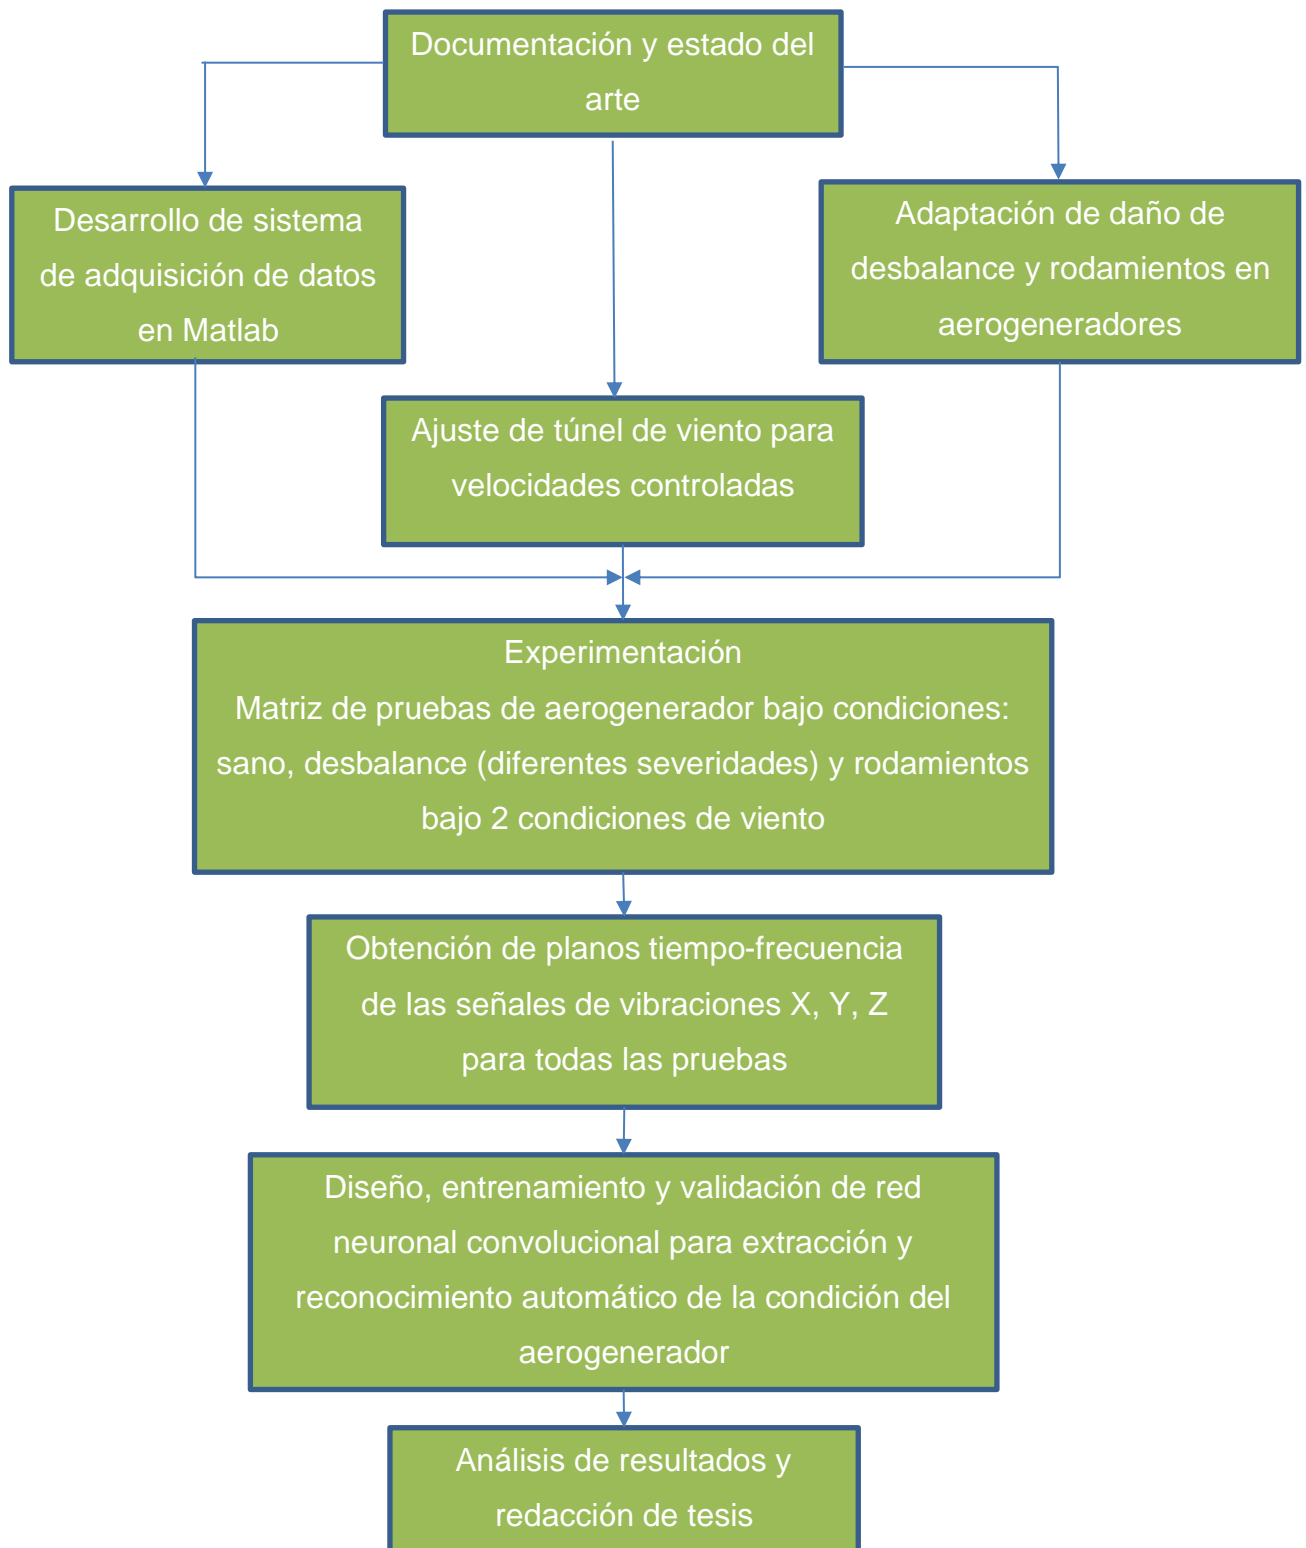


Figura 1 Diagrama general.

2. Marco Teórico

Esta sección introduce los temas necesarios para abordar el presente trabajo, incluyendo el tema de aerogeneradores el cual es el objeto de estudio ya que en él se realizarán las pruebas, los túneles de viento ya que se utilizará uno para la realización de las pruebas y así conseguir las diferentes condiciones de operación de viento sobre el aerogenerador, las vibraciones que son las variables físicas de medición, los acelerómetros que conforman parte del sistema de adquisición de datos, la transformada corta de Fourier que es la técnica de procesamiento para obtener el plano tiempo-frecuencia y las redes neuronales convolucionales las cuales son el método de reconocimiento de patrones automático.

2.1 El Aerogenerador

Los aerogeneradores o turbinas eólicas son máquinas eléctricas que transforman la energía cinética del viento en energía eléctrica. Existen 2 tipos de aerogeneradores de acuerdo al eje de rotación, es decir: vertical y horizontal. El aerogenerador más comúnmente usado hoy en día es el aerogenerador de eje

horizontal debido a su eficiencia y mejor rendimiento. Para este tipo de aerogenerador, su eje de rotación está paralelo al suelo o punto de anclaje (S.L., 2020). En general, estos aerogeneradores presentan su eje de rotación en la parte alta de la torre que lo soporta y requieren de un sistema de control de orientación para poder adaptarse a los cambios de dirección que presenta el viento en el mundo.

Las principales partes de un aerogenerador con eje horizontal son (ver **Figura 2. 1**) (Aulafacil, 2020):

- **Palas o aspas:** Captan el viento y pasan su potencia al rotor.
- **Rotor:** Su función principal es convertir la energía cinética que tiene el viento en un par mecánico que mueva la flecha o rotor a través de las aspas.
- **Generador eléctrico:** Su principal función del generador es convertir la energía cinética en energía eléctrica.
- **Caja de engranajes:** puede ser parte o no de los aerogeneradores, esto depende principalmente de la potencia. Su función es modificar la velocidad del rotor de baja a alta velocidad de rotación usando engranajes.
- **Góndola:** es la cubierta/almacén de las diferentes partes del aerogenerador.




Figura 2. 1 Partes del aerogenerador (adaptación de Aulafacil, 2020).

Existen distintos tipos de aerogeneradores, los cuales pueden ser clasificados de distintas maneras, ejemplo: por su potencia, la cantidad de aspas y la orientación del eje (horizontal o vertical). El aerogenerador que se utilizará en el presente trabajo contiene un juego de 5 aspas (ver Figura 2. 2).



Figura 2. 2 Aerogenerador de 5 aspas (Rangel, 2020).

Generalmente, los aerogeneradores constan de una turbina eólica de eje horizontal, los cuales pueden funcionar con cambios en velocidad, un variador de velocidad (variador de frecuencia), la caja de engranes, una máquina eléctrica rotativa en modo generador y un sistema de acoplamiento a la red eléctrica ya sea mediante un transformador o un inversor. En general, el aerogenerador opera capturando la energía cinética del viento mediante las aspas o álabes y la convierte en energía mecánica mediante el torque y rotación inducido en el generador. La potencia del aerogenerador normalmente está asociada al tamaño de este. Los aerogeneradores de gran potencia requieren grandes cantidades de viento y, normalmente, se encuentran en zonas no urbanas; por otro lado, los de baja potencia suelen requerir

velocidades de viento típicas de las zonas urbanas y no a mucha altura, haciéndolos atractivos para el sector privado-urbano.

2.2 Aerogenerador de baja potencia

Se pueden considerar aerogeneradores de baja potencia cuando esta no sobrepasa los 100 kW. Su uso está orientado a casas-habitación y establecimientos pequeños. Al no requerir condiciones geográficas y climáticas muy específicas, estos pueden encontrarse en diferentes partes del país (Dodero,2012).

Una principal diferencia en estos aerogeneradores es que no contienen caja de engranes (ver Figura 2. 3), los componentes que tiene son:

- Aspas
- Rotor
- Góndola
- Torre




Figura 2. 3 Aerogenerador de baja potencia (Minas, 2004).

Aunque en algunos trabajos se marque como parte de los componentes la caja de engranes, esta no es siempre contemplada en la construcción de este (Lima, 2017). En el caso del aerogenerador que se utiliza en el presente trabajo, al ser de baja potencia, no contiene caja multiplicadora o caja de engranes, conteniendo exclusivamente el generador eléctrico.

2.3 Túneles de viento

Los túneles de viento son una herramienta usada en la investigación de los efectos del aire (laminar o turbulento) impactando diferentes objetos y materiales. En el caso de aerogeneradores, se utiliza para estudios de su comportamiento bajo diferentes condiciones de viento controlado. El principio de operación consiste en aspirar o soplar aire a través de un ducto/túnel equipado con una zona comúnmente tubular para la realización de pruebas. Los túneles de viento se pueden clasificar en 2 clases (Rangel, 2020):

- **Circuito abierto:** aquí el aire es aspirado o soplado hacia el túnel para después ser liberado hacia el exterior.
- **Circuito cerrado:** aquí el aire es obligado a recircular dentro del túnel durante las pruebas requeridas.

Un túnel de viento consiste comúnmente de:

- **Ventilador:** Genera la presión y velocidad del aire.
- **Difusor:** Reduce la velocidad del flujo e incrementa la presión para reducir las pérdidas debidas a la fricción.
- **Contracción:** Incrementa la velocidad del aire y lo concentra en la zona de entrada hacia la zona de pruebas.

- **Sección de Pruebas o ensayos:** Zona para colocar los objetos e instrumentos requeridos para realizar las pruebas y mediciones.
Las partes arriba mencionadas se pueden apreciar en la Figura 2. 4.

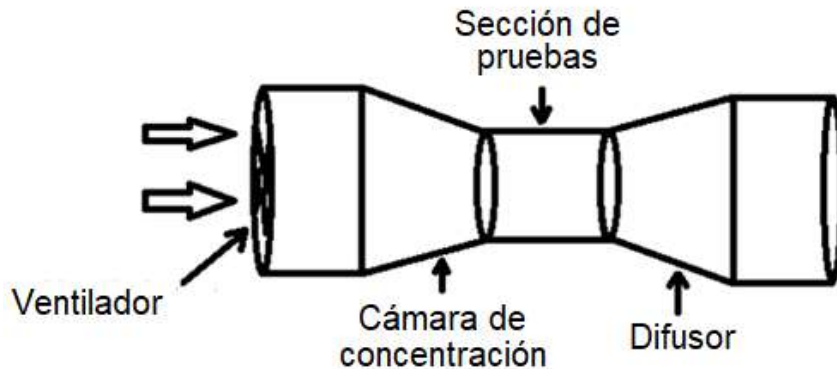


Figura 2. 4 Túnel de Viento (autoría propia).

2.4 Vibración

Los aerogeneradores como cualquier otra máquina rotativa se deterioran con su uso. Este deterioro se puede identificar/caracterizar a través de las vibraciones producidas. Por lo que, para la detección de las fallas, el análisis de vibraciones mecánicas es un método de monitoreo comúnmente utilizado.

La vibración mecánica es generada cuando un sistema cambia de una posición en equilibrio estable. Esto se traduce como la cantidad de movimiento / desplazamiento de un cuerpo (o partícula) que se mueve de forma oscilatoria alrededor de una posición de equilibrio. Esto sucede mientras el cuerpo tiende a regresar a su posición de equilibrio mediante la acción de fuerzas restauradoras (ya sea fuerzas elásticas o fuerzas gravitacionales).

La ventana de tiempo necesaria para que el sistema concrete un ciclo de movimiento completo se llama periodo de la vibración. El número de estos periodos por unidad de tiempo (segundo) hace referencia a la frecuencia y el desplazamiento máximo medida con respecto a su posición de equilibrio recibe el nombre de amplitud de la vibración (Beer et al., 2010).

El periodo de la vibración libre τ_n medido en segundos, se muestra en la ecuación siguiente:

$$\tau_n = \frac{2\pi}{\omega_n} \quad (1)$$

donde la frecuencia circular natural de la vibración se denota por ω_n .

La frecuencia natural de la vibración se conoce como el número de ciclos por unidad de tiempo, f_n . Se tiene:

$$f_n = \frac{1}{\tau_n} = \frac{\omega_n}{2\pi} \quad (2)$$

La frecuencia unitaria es una frecuencia de 1 ciclo por segundo, implicando que su periodo es de 1 s. Así, su unidad fundamental es: $\frac{1}{s}$ o s^{-1} , la cual recibe el nombre de Hertz (Hz) en el Sistema Internacional de Unidades (Beer et al., 2010).

El control de vibraciones y el diagnóstico de vibraciones son problemas prácticos diferentes. En el diagnóstico de vibraciones, la fuerza de oscilación que se aplica a la zona defectuosa define la falla y esta fuerza se relaciona con la aceleración de la oscilación. Para el diagnóstico, a menudo tanto la aceleración de vibración como la velocidad de vibración se miden en rangos de frecuencia baja restringidos, dependiendo el sistema dinámico bajo estudio.

La mayoría de las mediciones de vibración usan sensores de vibración-aceleración que se basan en el efecto piezoeléctrico. Para este tipo de sensores, la carga eléctrica de salida es proporcional a la fuerza aplicada al sensor, es decir que la señal de vibración se convierte en señales eléctricas.

2.5 Acelerómetro

El acelerómetro es un instrumento que sensa la aceleración de un objeto, la cual está relacionada con su vibración. La fuerza inducida por la vibración o el cambio de su aceleración permite que la masa comprima el material piezoeléctrico, produciendo una carga eléctrica proporcional a la fuerza ejercida sobre el material piezoeléctrico.

En general, hay 2 tipos de acelerómetros piezoeléctricos (Rangel, 2020):

- **Alta impedancia:** en este tipo, el cristal piezoeléctrico produce una carga eléctrica acoplada directamente a los equipos de medida.
- **Baja Impedancia:** en este tipo, se agrega un acelerómetro de carga en su extremo frontal, un circuito integrado y un transistor FET (por sus siglas en inglés *Field-Effect Transistor*, es decir: transistor de efecto de campo) para transformar la carga eléctrica en una tensión de baja impedancia para poder acoplarse a los instrumentos de medición.

Un acelerómetro puede proveer la medida analógica correspondiente a la señal de vibración del cuerpo al que está conectado. Estos pueden ser

mono-axiales o triaxiales, midiendo las vibraciones de uno o tres ejes (X, Y Z), respectivamente.

2.6 Transformada corta de Fourier

La transformada corta de Fourier (SFTF por sus siglas en inglés *Short Time Fourier Transform*) es un método utilizado para la obtención del plano tiempo frecuencia de señales, así la detección de patrones asociados con las condiciones de daño puede ser llevada a cabo. Un ejemplo de patrón de falla en motores de inducción con falla de barra rota es el patrón V (ver Figura 2. 5). La transformada de Fourier (TF) es un método conveniente para la identificación de componentes frecuenciales de señales estacionarias; sin embargo, esta se degrada mediante el análisis de señales con ruido o señales no estacionarias. Para reducir esta limitante, la SFTF, una variación de la transformada de Fourier es recomendada para análisis de señales con propiedades no estacionarias (Valtierra et al., 2020).

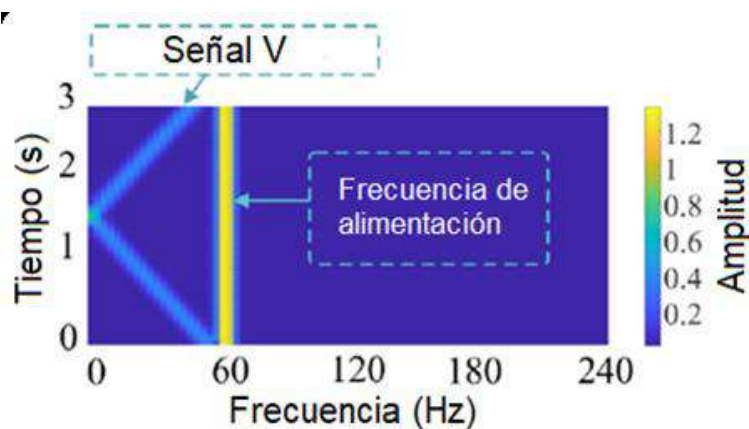


Figura 2. 5 Plano tiempo frecuencia (Valtierra et al., 2020).

En general este método divide la señal original en pequeñas ventanas de tiempo, donde cada segmento es analizado mediante el método de la transformada de Fourier, permitiendo así observar el comportamiento de las componentes frecuenciales respecto al tiempo. Es importante mencionar que la selección de la ventana de tiempo define la resolución de tiempo y frecuencia, por ejemplo, ventanas de tiempo largas incrementan la resolución de frecuencia, pero reducen la resolución del tiempo y viceversa. Para reducir de alguna manera este hecho negativo, las ventanas de tiempo pueden ser sobrepuestas, por ejemplo, el siguiente segmento de datos solo se desplaza un porcentaje del anterior. En adición, una función de ventana puede ser utilizada para reducir el problema de *leakage* (chorreo frecuencial). Por lo tanto, la ventana SFTF de una señal $x(n)$ es calculada mediante:

$$X(m, \omega) = \sum_{n=1}^N x[n] \omega[n - m] e^{-j\omega n} \quad (3)$$

donde ω es la función de ventana centrada en la muestra m , n es un indicador escalar para las muestras de señales de tiempo, y $e^{-j\omega n}$ representa la transformada del Kernel.

2.7 Redes Neuronales Convolucionales

Las redes neuronales convolucionales son un tipo de redes neuronales profundas inspiradas en la percepción visual. Desde los inicios de los 2000, las CNN han sido aplicadas para la detección, segmentación y reconocimiento de objetos y regiones de imágenes con buenos resultados. Fueron diseñadas para el procesamiento de información en forma de arreglos (Cao, 2019):

- 1D: Señales, lenguaje u otro tipo de secuencia
- 2D: Imágenes, espectrogramas de audio.
- 3D: Imágenes volumétricas, video.

Comparado con otros algoritmos tradicionales de aprendizaje de máquina (ML por sus siglas en inglés *Machine Learning*), las CNN tienen las siguientes ventajas extracción automática de características, expresión fuerte capacidad mejorada con su estructura profunda y no linealidad, varias técnicas para superar el sobreajuste, incluyendo agrupaciones de capa, capa de deserción, decaimiento de peso y, además, menos parámetros para optimizar debido a los pesos compartidos. La Figura 2. 6 muestra la arquitectura típica de una CNN. Las CNN consisten en una serie de etapas; por lo general, comienzan con capas convolucionales y de agrupamiento. En las etapas finales, ellas son similares a un perceptrón multicapa de una red neuronal, consistiendo en capas totalmente conectadas y un clasificador.




Figura 2. 6 Arquitectura de una CNN (adaptado de Valtierra, 2020).

Una capa convolucional contiene un conjunto de filtros w , también conocidos como Kernels, quienes conducen convoluciones sobre la capa de entrada x . Cada filtro contiene el peso compartido mediante todas las neuronas de entrada y reproduce un mapa característico a través de un cierto tipo de funciones de activación f . La totalidad de los mapas característicos extraídos forman los datos de entrada para la siguiente capa y , que se puede expresar como:

$$y = f(\sum w * x + b) \quad (4)$$

donde b denota el bias. El proceso de convolución en cierta medida emula la respuesta de las neuronas a estímulos visuales externos. La función de las capas convolucionales es extraer entidades automáticamente de los datos de entrada.

Una capa de agrupación suele seguir de la capa convolucional, utilizando sub-muestreado para obtener una resolución más baja de la entidad mapas. El más común es la agrupación máxima, que mantiene el valor máximo de cada grupo de neuronas en los mapas característicos. La agrupación de capas puede reducir significativamente el esfuerzo computacional y evitar el sobreajuste (Cao, 2019).

Después de una serie de capas convolucionales y capas de agrupación, las neuronas de salida en forma de matriz de múltiples dimensiones se aplanan como una matriz 1-D y se alimentan a capas totalmente conectadas (también conocidas como capas densas), donde todas las neuronas de dos capas adyacentes están completamente interconectadas. Las salidas de capas totalmente conectadas se pueden representar como las salidas de percepción de multicapas:

$$y = f(\sum x * w + b) \quad (5)$$

donde x son las entradas de la capa anterior, w y b denotan pesos y bias, respectivamente. f denota la función de activación, por ejemplo, *ReLU*, o *SoftMax*, y es la salida final. Cabe resaltar que la ecuación 4 y 5 son distintas con los valores de w y el orden de multiplicación/convolución. La función *SoftMax* es actualmente uno de los clasificadores más utilizados en CNN. Matemáticamente, la función *SoftMax* convierte un vector no normalizado en una distribución de probabilidad normalizada. La probabilidad prevista de la j clase se representa como:

$$P(y = j|x; w_j, b_j) = \frac{e^{x*w_j+b_j}}{\sum_{k=1}^K e^{x*w_k+b_k}} \quad (6)$$

donde k es la dimensión de salida.

Una vez que se establecen la estructura y todos los hiper-parámetros, la red está lista para ser entrenada. El rendimiento de CNN se evalúa contra la verdad fundamental mediante una función de pérdida predefinida, por ejemplo, el error RMS (valor cuadrático medio, por sus siglas en inglés *Root Mean Squared*) y la entropía cruzada categórica. El objetivo de la formación es optimizar la función de pérdida en todos los parámetros que se puedan aprender, es decir, w y b . CNN está normalmente entrenado con el método de retro propagación, que calcula la función de pérdida, así como el gradiente que se requiere para la optimización de la salida y distribuye hacia atrás capas. Para ahorrar esfuerzo computacional, normalmente en cada etapa, la función de pérdida se calcula en un subconjunto de las muestras de formación (conocidas como lote) en lugar de todas ellas (Cao, 2019).

2.8 Daños en rodamientos

Si un rodamiento es montado y lubricado correctamente, así como libre de abrasivos, suciedad y agentes corrosivos, el rodamiento solo tendría un fallo posible asociado a la fatiga mecánica del material de las pistas y elementos rodantes. Esta, aunque no deseada, se considera una falla normal; no obstante, hay otras fallas anormales, tales como:

- Desgastes de pistas y elementos rodantes por contaminación del lubricante por polvo
- Falta o exceso de lubricación
- Desgaste o daño del canastillo
- Rodamientos sueltos en el eje
- Rodamientos sueltos en su alojamiento

- Paso de corriente a través del rodamiento
- Selección incorrecta
- Defectos de fabricación del rodamiento

Dentro de este trabajo se abordará un solo tipo de falla o daño en los rodamientos del aerogenerador, siendo este la picadora en las pistas de los elementos rodantes, la cual produce una excitación cada vez que la zona dañada hace contacto con la otra superficie que gira. De esta manera, las variaciones abruptas en los esfuerzos de las superficies de contacto, es decir: entre los elementos rodantes y las pistas, cuando un elemento rodante pasa sobre el daño se genera una fuerza impulsiva en la zona. Esta fuerza impulsiva genera vibraciones y ondas de esfuerzos, las cuales pueden ser continuamente monitoreadas para detectar la existencia del daño.

2.9 Desbalance en aspas

El desbalance en las aspas es un tipo de daño que se genera debido al cambio de la masa en una de las aspas, este cambio puede ser ocurrido de forma positiva (aumento de la masa) o negativo (decremento de la masa). El desbalance en aspas positivo es uno de los daños más comunes ya que suele ocurrir principalmente por:

- Mal Armado
- Congelamiento
- Fallo de manufactura
- Animales

El nivel de severidad en el daño por desbalance es medido de forma porcentual respecto a la masa del aspa y si el daño se mantiene puede afectar otros componentes, por ejemplo:

- Si el desbalance es ligero ($<10\%$) este puede dañar más las aspas.
- Si el desbalance es medio (entre 10% y 20%) se ve más afectada en la flecha y los rodamientos.
- Si el desbalance es grave ($>20\%$) puede llegar a dañar el estator de aerogenerador.

3. METODOLOGÍA

La metodología que se propone y se desea llevar a cabo en el desarrollo de este trabajo se compone las siguientes secciones: Túnel de viento, condiciones de pruebas (daños por desbalance o rodamientos), adquisición de datos, PC, procesamiento de la información y diagnóstico (ver Figura 3. 1).

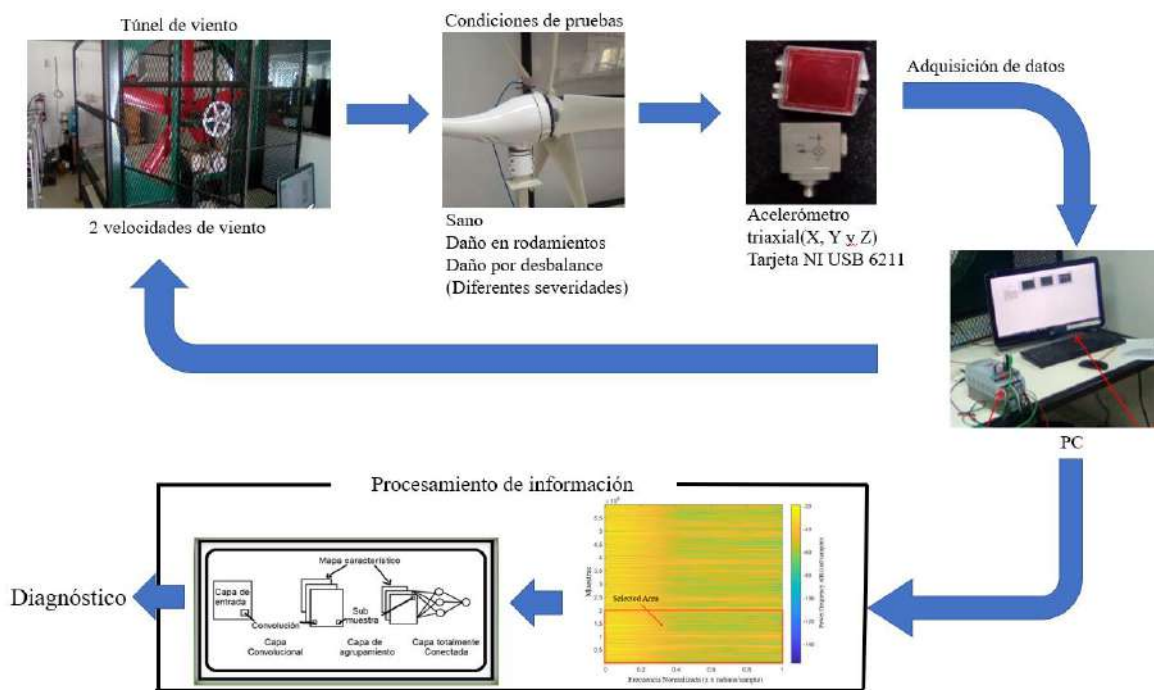


Figura 3. 1 Diagrama general de la metodología.

A continuación, se describen con mayor detalle las secciones antes mencionadas:

Túnel de viento: en esta sección es la regulación de la velocidad de viento utilizada para las condiciones de prueba que se estuvieran desarrollando, esto es controlado desde un variador de velocidad que a su vez es controlado por la tarjeta NI USB-6211 con el fin de encender el túnel de viento a la velocidad deseada de la prueba y una vez los datos fueran obtenidos apagar el túnel de viento para dar por finalizada la prueba y ajustarse para la siguiente prueba.

Condiciones de prueba: Se acondicionará el aerogenerador a cada condición de daño requerida mediante el uso de matrices de pruebas, una matriz para la condición por desbalance en el cual se encuentran diferentes niveles de severidad y otra matriz para la condición de daño en rodamientos.

Adquisición de datos: Diseño y desarrollo de un sistema de adquisición de datos de vibraciones, mediante la utilización de un sensor triaxial marca KISTLER y una tarjeta de adquisición *National Instruments* NI-USB 6211 para el desarrollo de un banco de datos (señales de vibraciones del aerogenerador bajo distintas condiciones de operación) mediante la utilización de un programa desarrollado en Matlab.

PC: Desde la computadora (PC) se ajustan los tiempos de encendido/apagado del túnel de viento, inicio de captura de datos cuando las condiciones para la prueba estén listas, tiempo de captura y almacenamiento de la base de datos obtenida.

Procesamiento de información: Se desarrollará el procesamiento de los datos adquiridos mediante la utilización de espectrograma para transformar las señales de vibraciones a imágenes, posteriormente las imágenes serán ajustadas para para su análisis en la CNN.

Diagnóstico: Una vez obtenidas las imágenes del procesamiento, se entrenará la CNN para obtener la configuración más eficiente para el diagnóstico de las diferentes condiciones de daño mediante el uso de Matlab. Para realizar el diagnóstico de forma automática se empleará una aplicación que desarrollará cada sección del procesamiento de las señales para dar un diagnóstico del daño analizado.

3.1 METODOLOGÍA DE ANÁLISIS

Como se muestra en la Figura 3. 2 se realizan las pruebas controlando la velocidad de viento a la cual se va a trabajar. Se utilizaron 2 velocidades de viento, las cuales se aplican sobre el aerogenerador el cual se encuentra configurado al tipo de daño del cual se va a tomar la prueba. Como condiciones de operación del aerogenerador, se usarán dos tipos de daño y el estado sano, el primero es el daño por desbalance en las aspas el cual se llevará a cabo capturando 3 niveles de severidad, el segundo es el daño en rodamientos el cual debido a que es un caso destructivo solo se aplicó para una velocidad de viento.

Para el análisis, únicamente se selecciona la parte de la señal o señales de vibraciones que se encuentran en estado estable; por lo tanto, antes de adquirir los datos se debe aguardar para que tanto la velocidad como la señal de vibración generada por aerogenerador se encuentren en estado estable. Esta consideración se hace debido a que la representación tiempo-frecuencia se obtiene con la técnica de Fourier la cual provee mejores resultados con señales estacionarias, Además, al ser una de las primeras investigaciones, se decide usar técnicas no tan sofisticadas. Las pruebas muestran que después de 10 segundos, el aerogenerador ya se encuentra en estado estable; de esta manera, las señales son adquiridas después de este tiempo (10 s).

Una vez capturados los datos de los distintos casos, se dividen pruebas en dos secciones, la primera sección es la del entrenamiento de la red neuronal convolucional y la segunda sección es para la comprobación de un buen funcionamiento del reconocimiento automático realizado a través de una app diseñada en matlab.

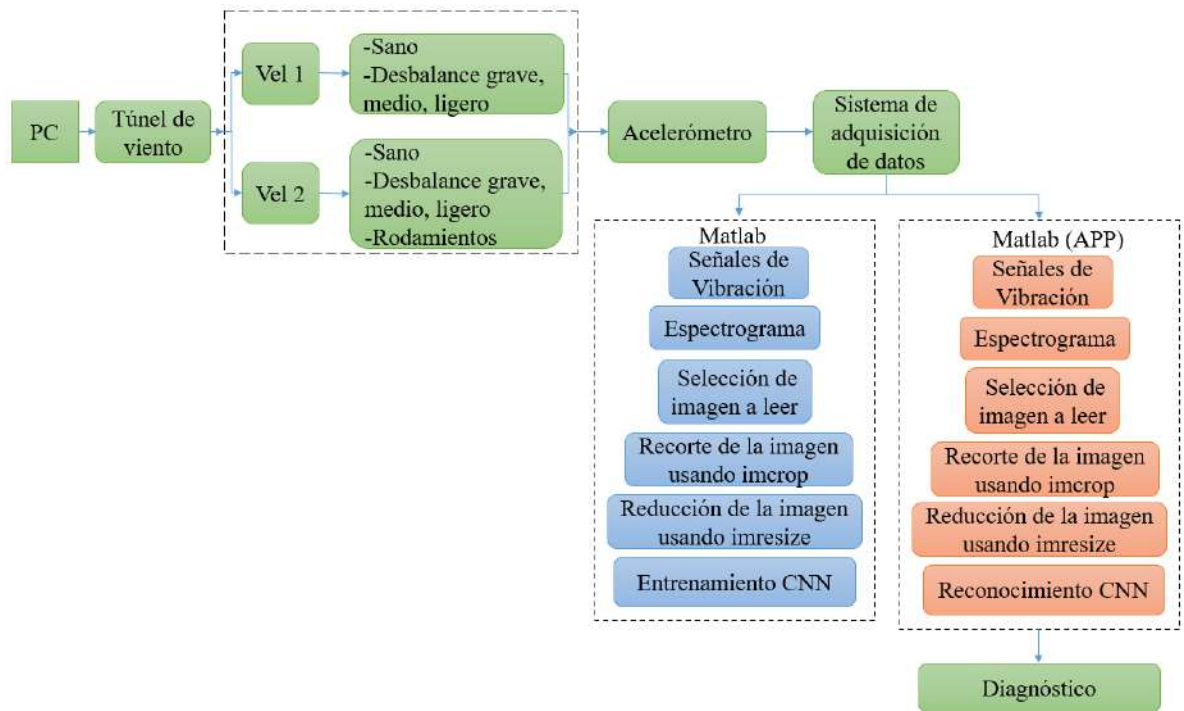


Figura 3. 2 Diagrama general de la metodología.

Entrenamiento (azul): Para el entrenamiento se llevó a cabo un procesamiento de las señales convirtiéndolas de su forma tiempo-frecuencia a imágenes, las imágenes fueron procesadas y la CNN fue entrenada con una parte de esas imágenes y posteriormente se realiza una comprobación con las imágenes sobrantes.

App: La aplicación se separó en 3 pestañas en las que se realiza el procesamiento de las señales hasta el diagnóstico de estas, separando en la primera sección se realiza la obtención de las señales tiempo-frecuencia, la segunda sección se realiza el procesamiento de las señales para la obtención de las imágenes ya ajustadas para la CNN, y la tercera sección es el diagnóstico del daño.

3.2 Puesta en experimentación

Como se menciona en la parte trasera del túnel de viento se encuentra el aerogenerador como se muestra en la Figura 3. 3. La tarjeta NI-USB 6211 está conectada y se utiliza para el encendido del túnel, el control del túnel y la adquisición de datos.




Figura 3. 3 Componentes utilizados.

En la parte posterior del túnel de viento se encuentra el aerogenerador, este se encuentra fijado a una base y a su vez la base esta fija al piso de forma independiente al túnel de viento como se muestra en la Figura 3. 4, esto se realizó para asegurarse que el aerogenerador no se moviera y no se viera afectado por las vibraciones externas a las generadas por las condiciones de viento.



Figura 3. 4 Base del aerogenerador.

Se utiliza un acelerómetro triaxial para la adquisición de las señales de vibraciones y se coloca en la parte superior de la góndola del aerogenerador como se muestra en Figura 3. 5. El acelerómetro es triaxial de Tipo IEPE (*Integrated Electronics Piezo-Electric*) marca KISTLER modelo 8395A10 y se especializa en el análisis de vibraciones, contiene un rango de medición de ± 10 g, una resolución de 500mV/g, y un ancho de Banda de 1000 Hz. Las señales generadas por el acelerómetro se envían a la tarjeta de adquisición y se generará una base de datos dependiendo de la condición de daño utilizada.



Figura 3. 5 Ubicación del acelerómetro.

Los datos adquiridos se guardaron y se separaron por tipo de daño y en el caso del desbalance se separó también por el nivel de severidad. Las señales de vibraciones serán procesadas por un espectrograma con el fin de obtener su imagen de frecuencia y luego se realiza un procesamiento de la imagen, primero realizando un recorte de la imagen y después una reducción de la imagen ya recortada.

Como se vio en la Figura 3. 2 los datos se dividen en dos secciones una en la cual es enviada para el entrenamiento de la CNN y la otra para la comprobación de la aplicación, ambas secciones tienen el mismo procesamiento, la diferencia que se tiene es dentro de la aplicación ya que esta se diseñó de una manera que se pueda hacer el paso a paso del procesamiento o un análisis completo, para ello la aplicación cuenta con 3 pestañas llamadas obtención, diseño e identificación respectivamente.

En la Figura 3. 6 se muestra la pestaña de obtención la cual es utilizada para la regulación del túnel de viento y la captura de la señal a guardar, en esta pestaña se observa un selector de velocidad del túnel de viento, al usar el botón de analizar se obtienen una prueba del estado estable del caso a analizar con los parámetros registrados, después la señal se muestra en sus 3 ejes y es guardada en una carpeta a elección.

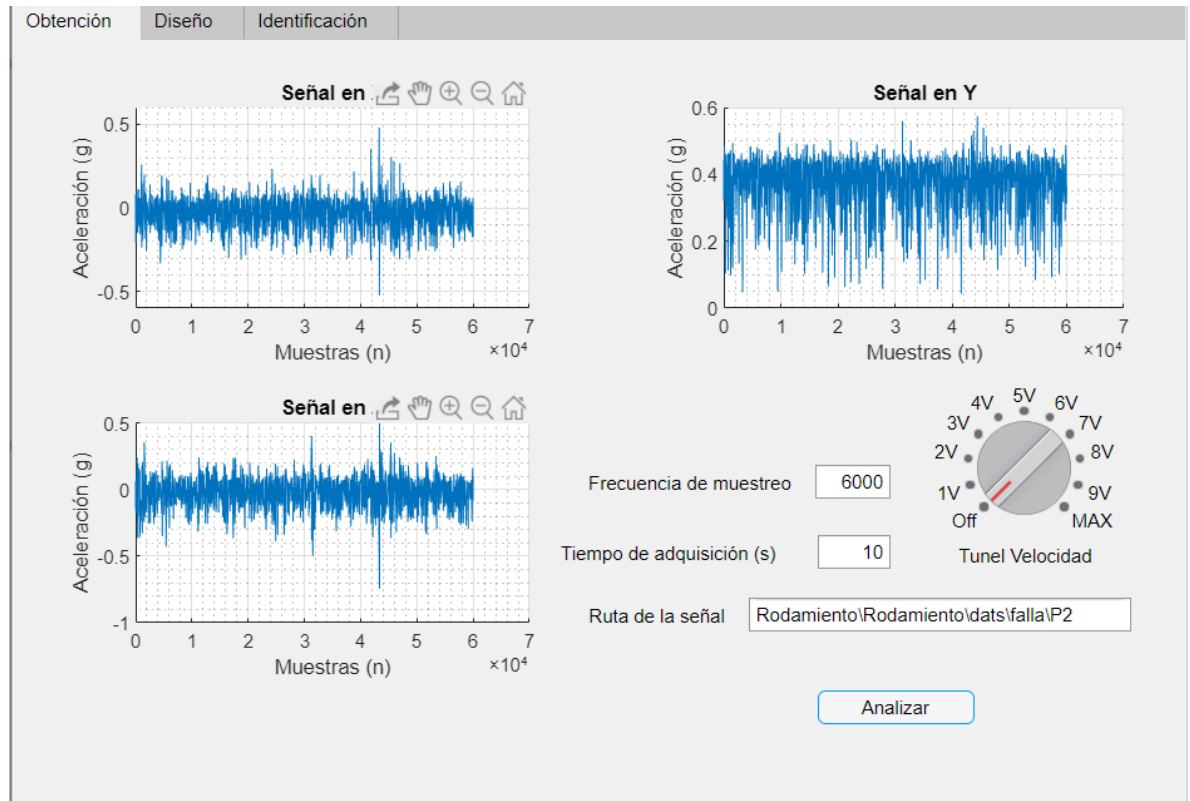


Figura 3. 6 Primera pestaña de la aplicación.

En la Figura 3. 7 se muestra la segunda pestaña la cual corresponde al procesado de la señal seleccionada, al iniciar el proceso mediante el botón se selecciona la señal a ser procesada, esta señal es mostrada en cada una de las partes de este procesado, iniciando por la señal sin procesar, después la imagen del espectrograma, luego se realiza una selección predefinida de la zona a recortar y por último se muestra la imagen reducida a la escala seleccionada, mostrando también la cantidad de pixeles en X y Y para la comprobación del tamaño deseado.

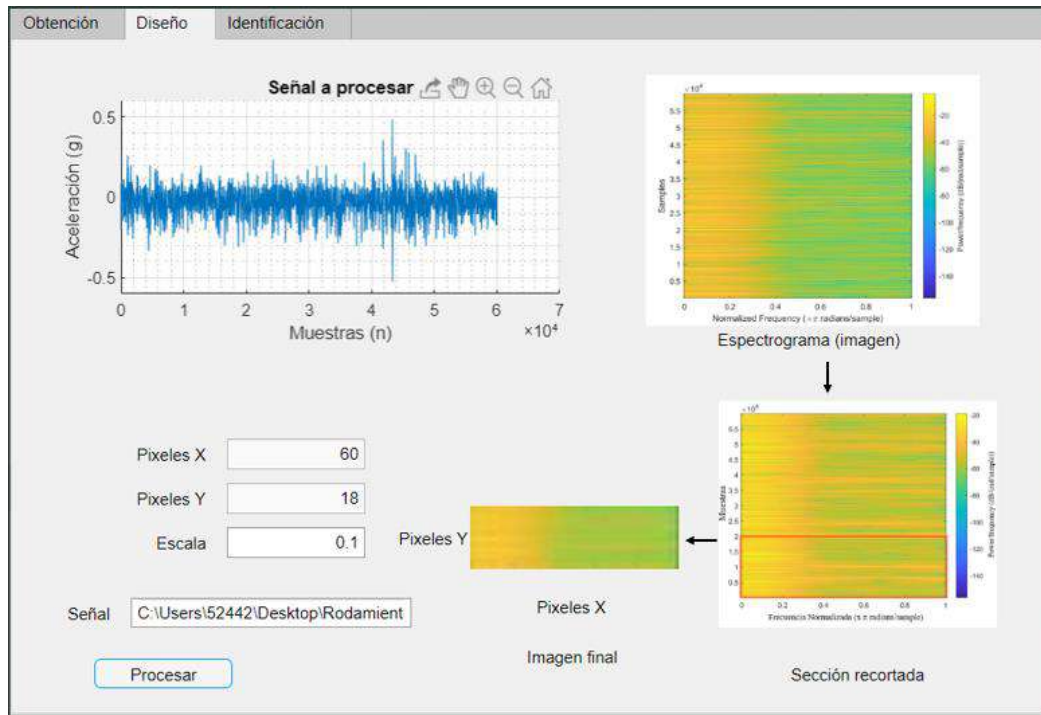


Figura 3. 7 Pestaña de diseño.

En la Figura 3. 8 se muestra la última pestaña de la APP utilizada la cual da el diagnóstico de las señales por unos focos de colores iluminando de color verde la condición a la cual corresponde la señal, en esta sección se tienen 3 configuraciones dependiendo del tipo de análisis seleccionado, la primera selección es Señal en tiempo el cual a partir de una señal en el tiempo realiza el procesamiento de la señal y el diagnóstico mostrando la condición en la que se encuentra mediante la CNN ya entrenada. En el tipo de análisis de imagen procesada se selecciona la imagen ya reducida y es diagnosticada por la CNN, y por último el análisis completo como su nombre lo indica realiza la captura de la señal, realiza su procesamiento y da un diagnóstico utilizando valores predeterminados que fueron obtenidos durante el desarrollo del análisis y entrenamiento de la CNN.



Figura 3. 8 Pestaña de identificación.

4. RESULTADOS

Para realizar el entrenamiento y un ajuste de la red neuronal convolucional, se realiza el daño por desbalance con sus distintos niveles de severidad, posteriormente se realiza el daño en los rodamientos, con estos daños se ajustará la CNN para el diagnóstico y para realizarlo de forma automática se realiza una aplicación en Matlab.

4.1 Desbalance

Como se ha mencionado anteriormente, el daño de desequilibrio para la experimentación en este trabajo se genera artificialmente como se muestra en la Figura 4. 1. Se consideran cuatro condiciones diferentes: sano y tres niveles de desequilibrio: ligero, medio y severo. Estos niveles se obtuvieron según la masa total de la pala, siendo inferior al 10% para la ligero (10 gr), del 10% al 20% para el medio (20 gr) y superior al 30% para el severo (40 gr). Vale la pena señalar que no hay ninguna directiva o regla para determinar o etiquetar la gravedad del error; en este sentido, estos valores se proponen bajo el hecho de que cuanto mayor es la masa, mayor es el desequilibrio. El principal propósito de este trabajo es demostrar que la propuesta es sensible a los diferentes niveles de severidad donde la

señalización de esta puede ajustarse de acuerdo con la necesidad. Por otro lado, vale la pena señalar que la masa se coloca en el extremo del aspa porque el momento mecánico ejercido es mayor que el generado si la masa se encuentra cerca de la góndola; sin embargo, se pueden explorar diferentes ubicaciones y valores de masa.




Figura 4. 1 Masas por nivel de severidad a) Grave b) Medio c) Ligero.

El número de pruebas se escoge de acuerdo con las recomendaciones de Hernández, 2018 y para ello se realiza una matriz de pruebas como se ve en la Tabla 1 donde se muestran las cuatro condiciones analizadas del aerogenerador y la cantidad de pruebas por condición de viento.

Tabla 1 Matriz de pruebas (Desbalance).

Condición	Pruebas V1	Pruebas V2
Sano	30	30
Ligero (c)	30	30
Medio (b)	30	30
Grave (a)	30	30

4.2 Daños por desbalance

Una vez obtenidas las señales, se analizan mediante la función de espectrograma para obtener su plano de frecuencia temporal. Para ilustrar los propósitos, la Figura 4.2. 1 muestran los espectrogramas para condiciones de desequilibrio severas y saludables, respectivamente. Los espectrogramas corresponden a las señales de vibración del eje X, ya que este eje presentó los mejores resultados.

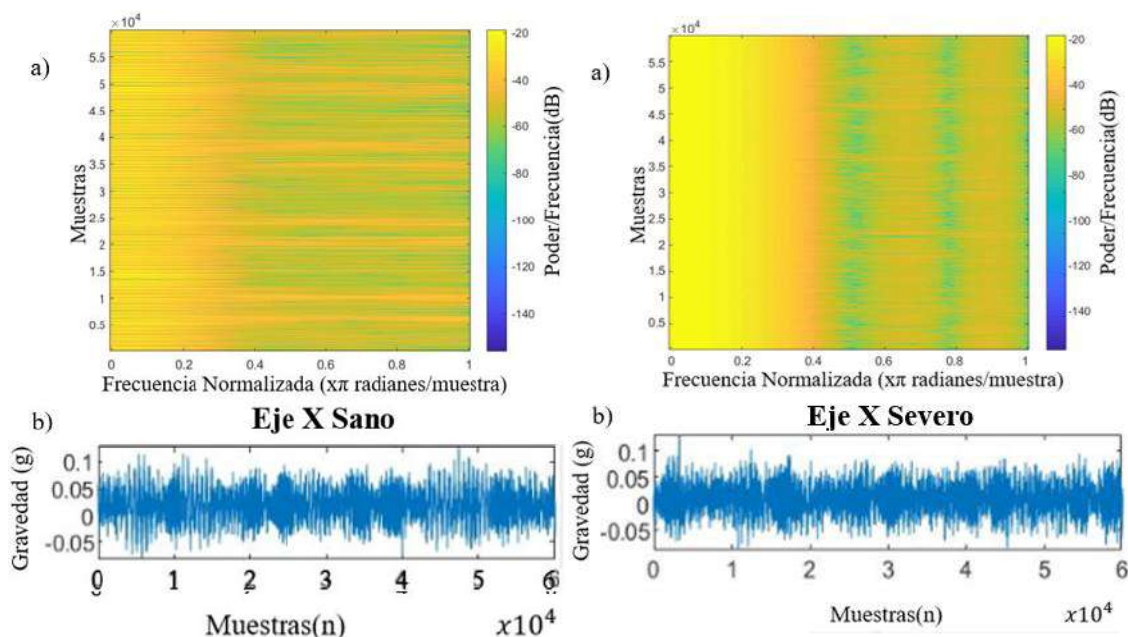


Figura 4.2. 1 Espectrograma y tiempo-frecuencia de las condiciones ligero (izquierda) y severo (derecha).

Para el diseño y entrenamiento de la CNN, las imágenes se separaron en tres carpetas dependiendo del eje X, Y y Z, y dentro de cada carpeta las clases se dividieron en 4 carpetas dependiendo de las condiciones de daño saludable, ligero, medio y severo. Por lo tanto, para cada velocidad del viento, el total de las imágenes por eje es de 120. Para el entrenamiento, se seleccionan 2/3 del conjunto de datos, es decir, 80 imágenes. Para la configuración de CNN, la tasa de aprendizaje inicial es 0.0005, la época máxima es 20 y la validación de frecuencia es 30. Estos valores

se seleccionan por ensayo y error buscando la mejor exactitud (los resultados de otros valores se presentan en la siguiente sección). Además, la arquitectura CNN se determinó por ensayo y error, lo que resulta en 4 capas convolucionales utilizando 4 como tamaño de filtro y 8, 16, 32 y 64 como número de filtros, respectivamente. La capa de agrupación máxima se utiliza con regiones de agrupación no superpuestas. La Tabla 2 muestra de una mejor manera la arquitectura utilizada.

Tabla 2 Estructura de la CNN.

Nombre	Tipo	Activación	Descripción
Imagen de entrada	Image Input	18x60x3	18x60x3 imágenes con 'zero-center' normalización
conv_1	Convolution	18x60x8	8 4x4x3 convoluciones con stride [1 1] and padding 'same'
batchnorm_1	Batch Normalization	18x60x8	Batch normalización con 8 canales
relu_1	ReLU	18x60x8	ReLU
maxpool_1	Max Pooling	9x30x8	2x2 max pooling con stride [2 2] and padding [0 0 0 0]
conv_2	Convolution	9x30x16	16 4x4x8 convoluciones con stride [1 1] and padding 'same'
batchnorm_2	Batch Normalization	9x30x16	Batch normalización con 16 canales
Relu_2	ReLU	9x30x16	ReLU
Maxpool_2	Max Pooling	4x15x16	2x2 max pooling Batch Normalization stride [2 2] and padding [0 0 0 0]
Conv_3	Convolution	4x15x32	32 4x4x16 convoluciones con stride [1 1] and padding 'same'
Batchnorm_3	Batch Normalization	4x15x32	Batch normalización con 32 canales
Relu_3	ReLU	4x15x32	ReLU
Maxpool_3	Max Pooling	2x7x32	2x2 max pooling con stride [2 2] and padding [0 0 0 0]
Conv_4	Convolution	2x7x64	64 4x4x32 convoluciones con stride [1 1] and padding 'same'
Batchnorm_4	Batch Normalization	2x7x64	Batch normalización con 64 canales
Relu_4	ReLU	2x7x64	ReLU
fc	Fully Connected	1x1x2	4 fully connected layer
SoftMax	SoftMax	1x1x2	SoftMax
Class output	Classification Output		Cross-entropy con 'Severe' y otras 3 clases

Como se mencionó anteriormente, se probaron diferentes parámetros de CNN. La Tabla 3 muestra la exactitud y los resultados de tiempo para la arquitectura CNN presentada en la Tabla 2 para diferentes tasas de aprendizaje. En la Tabla 3, se observa que los mejores resultados se obtienen para tasas de aprendizaje de 0,0005 y 0,0001, manteniendo un tiempo de cálculo adecuado. El *learning rate* de 0.0001 se selecciona porque busca mejorar la exactitud moviendo el valor de época máxima, en comparación con el valor de 0.005 que tiene una mayor exactitud en busca de un valor más preciso para las pruebas.

Tabla 3 Selección del Learning rate.

Valor de aprendizaje inicial	Exactitud (%)	Tiempo (s)
0.1	57	7
0.05	100	3
0.01	100	2
0.005	100	3
0.001	100	2
0.0005	100	3
0.0001	70 - 83.3	3
0.00005	48.33	3
0.00001	29.17	3

Con las tasas de aprendizaje antes mencionadas, también se analiza el impacto del número de Max Epochs. La Tabla 4 muestra los resultados obtenidos. Se encuentra que para la tasa de aprendizaje inicial de 0.0001 los valores de las épocas máximas aumentan si se desean mejores resultados de exactitud; sin embargo, un aumento en las épocas máximas conduce a un aumento en la carga computacional.

Tabla 4 Resultados con distinto Max Epochs.

Valor inicial de aprendizaje	Épocas máximas	Exactitud (%)	Tiempo(s)
0.0005	5	48.33	1
	10	93.33-95	2
	15	95-100	2
	20	100	3
	25	100	3
	30	100	3
0.0001	5	42.5	2
	10	50	2
	15	61.67	2
	20	70	3
	25	90-100	3
	30	100	3

Aunque estos resultados pueden considerarse satisfactorios, se obtiene un mejor rendimiento con una tasa de aprendizaje inicial de 0,0005 ya que se obtiene una exactitud del 100% con un menor número de épocas, es decir, 20.

Por último, con la arquitectura presentada en la Tabla 2 y los parámetros seleccionados, se obtiene el 100% de exactitud para la detección de tres niveles de desequilibrio. A pesar de obtener resultados prometedores, es evidente la necesidad de aplicar un proceso de optimización para determinar los mejores parámetros en la arquitectura CNN.

La Figura 4.2.2 muestra red neuronal propuesta con la estructura que aparece en la Tabla 2, para la entrada de la CNN entra la imagen y es separada en sus matrices, posteriormente se realizan convoluciones de cada una de las secciones y al final se realiza el diagnóstico del daño.

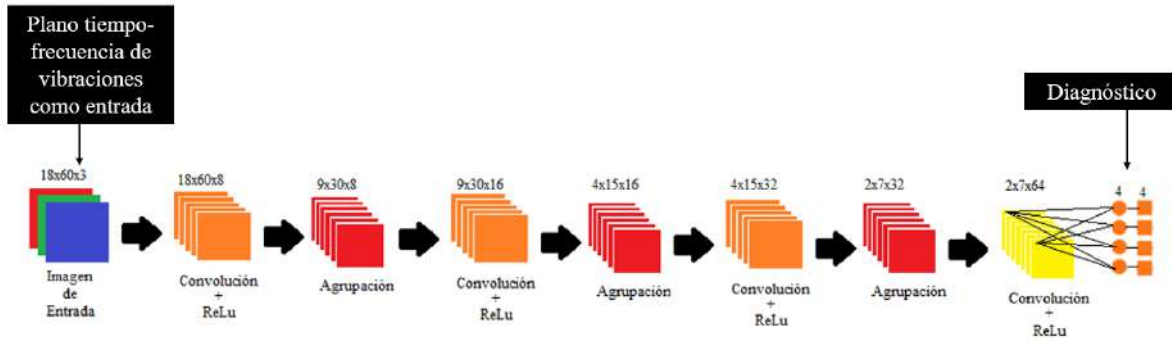


Figura 4.2. 2 Red Neuronal Convolutacional propuesta.

Una vez obtenidos los parámetros a utilizar en la CNN, se llevan a cabo los experimentos con una segunda velocidad de viento, la cual es mayor, para confirmar que su aprendizaje y detección de cada uno de los niveles de severidad es correcta. La primera parte se realizó con una velocidad baja (2.87 m/s) debido a que la vibración ocasionada por el desbalance es menor, de esta manera se asegura que los parámetros elegidos sean capaces de detectar el daño en condiciones con poco viento. La segunda parte se utiliza una velocidad de viento de 4.38 m/s para la obtención de una segunda base de datos con las cuatro condiciones de daño (sano, ligero, medio, grave), y se realiza una comparative como se puede apreciar en la Figura 4.2.3 las vibraciones se van haciendo más notorias lo que genera que a mayor velocidad sean más fácil identificar la existencia del daño, en este mismo sentido el poder detectar los niveles de severidad a baja velocidades nos da un sistema que al tener mayores velocidades sea más fácil la detección de los daños.

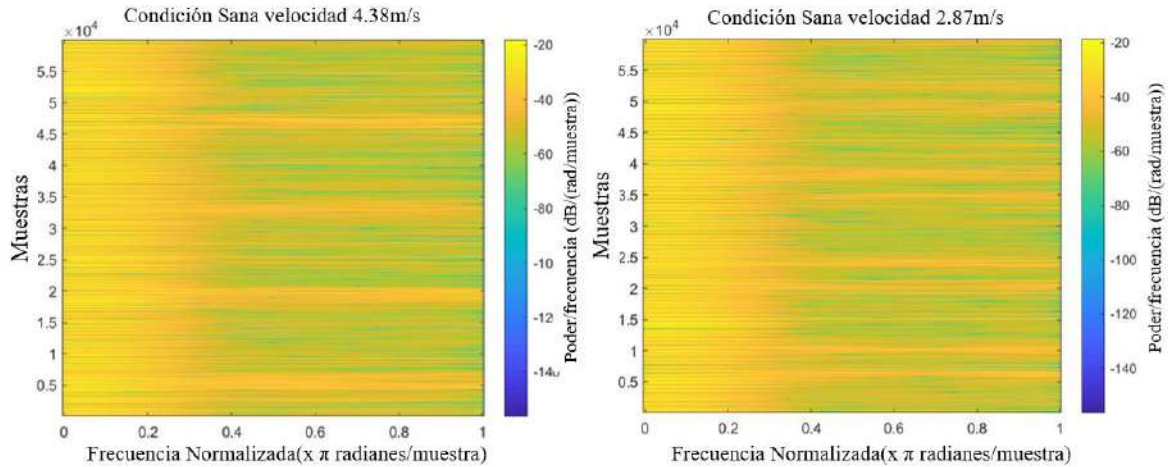


Figura 4.2. 3 Comparativa entre velocidades.

Una vez realizada la base de datos con la segunda velocidad de viento se lleva a cabo el acondicionamiento de las señales de forma que puedan ser leídas por la CNN.

Siguiendo con el procedimiento que se llevó a cabo en la anterior velocidad y utilizando la configuración obtenida, la CNN demostró tener una efectividad del 100% para la detección de los niveles de severidad esto se puede apreciar en la Figura 4.2. 4.

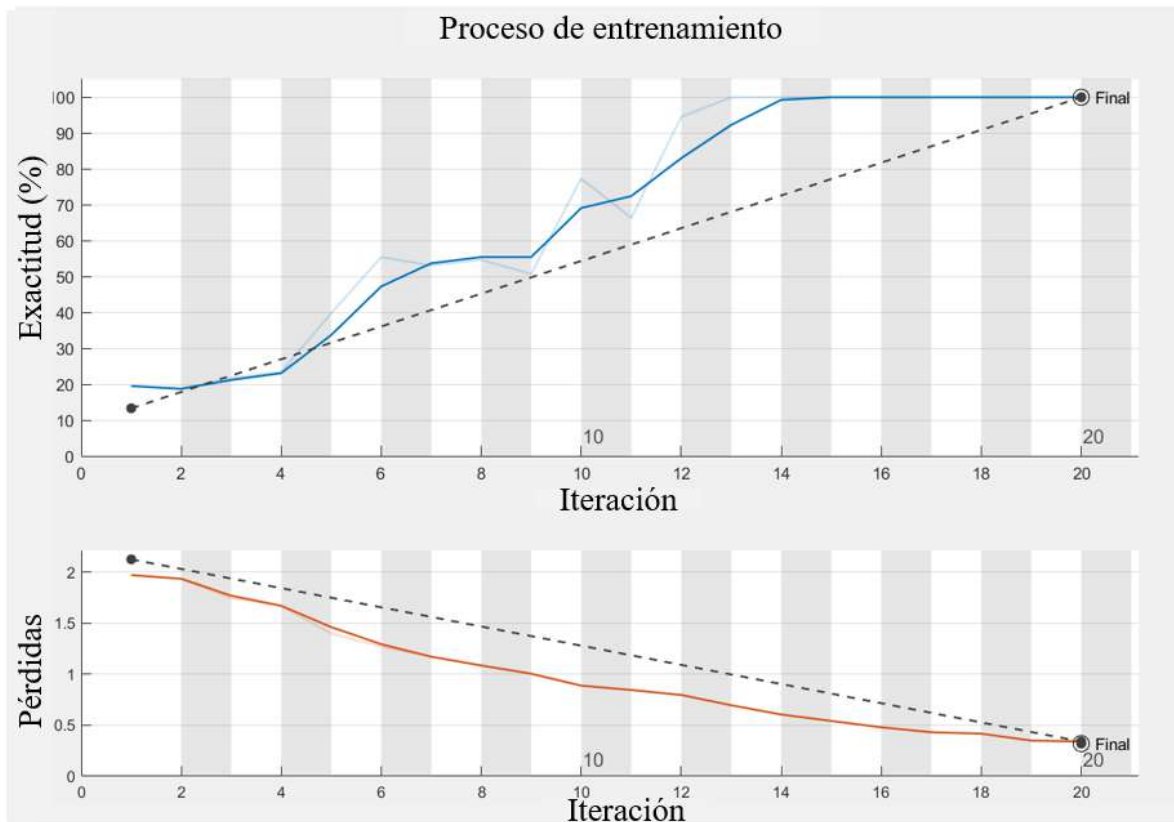


Figura 4.2. 4 Entrenamiento de CNN segunda velocidad.

4.3 Daños en rodamientos

Para la realización de este tipo de daño solo se realizó sin niveles de severidad debido a que este tipo de daño es destructivo, si se realiza a diferentes niveles afecta de manera permanente al aerogenerador. De esta manera se realizó un daño en uno de los rodamientos el cual consiste en una pequeña perforación en el anillo externo como se muestra en la Figura 4.3. 1.



Figura 4.3. 1 Daño en rodamiento.

La perforación que se realizó tiene un diámetro de 1.5mm, debido a que anteriormente se realizaron pruebas con desbalance en la segunda velocidad se realizaron las pruebas en rodamientos con esa misma velocidad. La base de datos que se obtuvo fue de 30 pruebas en sano y 30 pruebas en condición de falla como se muestra en la Tabla 5.

Tabla 5 Matriz de pruebas con rodamientos.

Condición	Perforación (Diámetro)	Pruebas
Sano	0	30
Daño	1.5mm	30

Para comprobar de manera visual se tomó al azar una prueba del sano y una prueba del daño y se compararon mediante la transformada de Fourier como se muestra en la Figura 4.3. 2. A simple vista se distingue un incremento considerable de componentes frecuenciales entre 1000Hz y 2500Hz.




Figura 4.3. 2 Comparativa FFT Sano vs Daño.

Al realizar el acondicionamiento de las señales para ser procesadas en la CNN se notó una diferencia notable en el espectrograma, para la configuración de la CNN se utilizó la configuración definida en el desbalance debido a que esta muestra buenos resultados en los análisis. Como se muestra en la Figura 4.3. 3 los componentes frecuenciales que se incrementaron durante la falla se concentraron en un grupo de frecuencias, esto hace que la imagen sea de un color más azul a comparativa del estado sano, este cambio de color en la imagen debido a las frecuencias permite identificar de una manera más fácil la condición de daño en rodamientos.

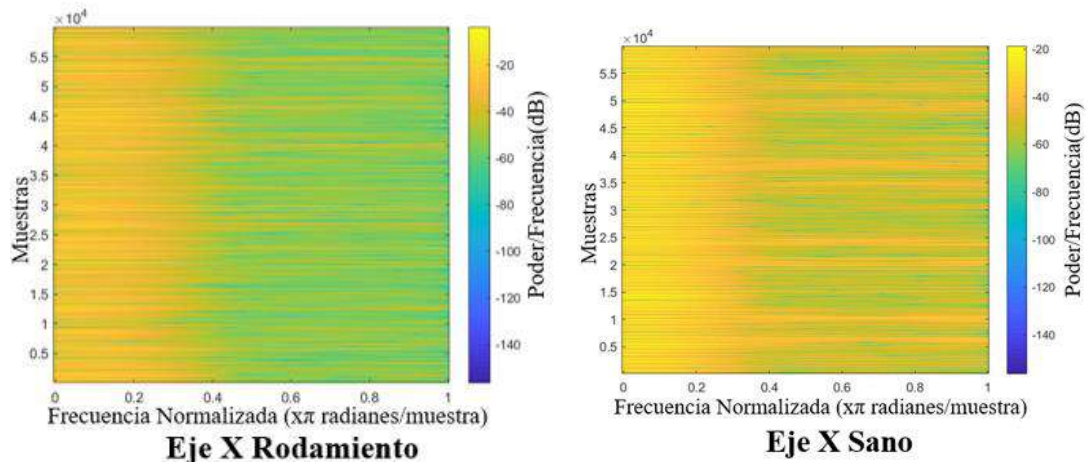


Figura 4.3. 3 Comparativa espectrograma daño vs sano.

Al mantener las configuraciones de la CNN obtenidas durante las primeras pruebas del trabajo, y realizando las pruebas como señala la matriz de pruebas de la Tabla 5 se obtuvo un total de 30 pruebas para la condición de daño y 30 pruebas para la condición de sano. Como se muestra en la Figura 4.3. 3




Figura 4.3. 4 Resultados con daño en rodamientos.

Los resultados obtenidos con la CNN son del 100% con la configuración que se obtuvo para la condición de daño por rodamientos. A diferencia del daño por desbalance los daños por rodamientos los detecto de una forma más rápida, sin embargo, se buscó tener un sistema robusto para evitar los posibles falsos positivos de las señales.

4.4 Detección del daño

Como se puede observar en los gráficos de robustez de cada uno de los análisis realizados en el trabajo se obtuvo un 100% en la detección de cada nivel de severidad en el caso de desbalance, para el caso de rodamientos al ser una prueba destructiva no se analizaron diferentes niveles de severidad sin embargo también se obtuvo una robustez del 100%.

De los datos obtenidos de la red neuronal se observa que se tiene buenos resultados, mediante la utilización de Matlab se realizó una interfaz en la cual como datos de entrada se tomaron las señales X, Y y Z de una de las señales, y posteriormente se procesaría y analizaría con la red neuronal convolucional obtenida.

Los datos obtenidos de la interfaz son plasmados en la siguiente matriz de confusión (Tabla 6), en la cual se puede observar que se mantuvo la detección al 100% de cada uno de los casos estudiados en el trabajo.

Tabla 6 Matriz de confusión

Sano	60	0	0	0	0	100% 0%
Rodamientos	0	30	0	0	0	100% 0%
Desbalance ligero	0	0	60	0	0	100% 0%
Desbalance Medio	0	0	0	60	0	100% 0%
Desbalance Grave	0	0	0	0	60	100% 0%
	100% 0%	100% 0%	100% 0%	100% 0%	100% 0%	100% 0%
	Sano	Rodamientos	Desbalance ligero	Desbalance Medio	Desbalance Grave	

Como parte de la discusión y análisis de resultados, la Tabla 7 muestra una comparativa con otros trabajos reportados en la literatura. En ella se observa que a diferencia de otros trabajos que utilizan software de simulación o una emulación con un motor-generator, el presente trabajo si utiliza un aerogenerador lo cual es más acercado a la realidad.

Dentro de las variables utilizadas se demuestra que el análisis de vibraciones es uno de los que mejores resultados otorgan. Como principales contribuciones se observa que en el presente trabajo se consideran distintas velocidades de rotación lo cual es más correcto en las condiciones naturales de operación de un aerogenerador y la implementación de los niveles de severidad de daño lo cual permite detectar daños de menor severidad o incipiente, contribuyendo a minimizar los gastos de mantenimiento preventivo/correctivo. Finalmente se observa que se obtiene una eficiencia del 100%, similar a otros trabajos, pero la propuesta considera diferentes daños y diferentes condiciones de viento.

Tabla 7 Comparativa de trabajos.

	Tipo de análisis			Variable analizada			Tipo de daño analizado			Diferentes velocidades de rotación	Niveles de severidad
	Aerogenerador	Motor/generador	Software	Vibraciones	Fonética	Eléctrica	Caja de engranes	Desbalance	Rodamientos		
Wenxin, 2018			x		x		x	x	x		
Cao et al, 2019			x	x				x			
Salinas et al., 2017			x	x					x		
Ortiz et al., 2018		x				x		x			
Hernández, 2018	x			x				x	x		x
Guo et al., 2018		x		x				x	x		
Chen et al., 2019		x		x			x				
Propuesta	x			x				x	x	x	x

5. Conclusiones

El presente trabajo permitió encontrar una metodología basada en el análisis de vibraciones, espectrograma y una red neuronal convolucional para diagnosticar de forma automática la condición de un aerogenerador de baja potencia bajo diferentes condiciones de operación, considerando daño por desbalance a diferentes severidades y daño por rodamientos, encontrando así que la hipótesis planteada en este trabajo es afirmativa.

La STFT permitió obtener un espectrograma que muestra los cambios frecuenciales en el plano tiempo-frecuencia, los cuales fueron caracterizados por la red neuronal convolucional para diagnosticar adecuadamente los daños mecánicos estudiados.

Para todas las condiciones de daño estudiadas (desbalance y rodamientos), se obtuvo el 100 % de efectividad. Para este resultado, se utilizó una tasa de aprendizaje de 0.0005, un valor de Max Epochs de 20 y la arquitectura CNN presentada en la sección anterior.

Debido a que el daño por rodamientos es una prueba destructiva para el equipo solo se desarrolló un solo nivel de daño, ya que para realizar otros niveles de severidad del daño se requieren contar con una mayor cantidad de equipos.

Como prospectivas de este trabajo se buscará estudiar otras severidades de daño en rodamiento, así como otros tipos de daño mecánicos y eléctricos. También, se considerarán diferentes velocidades de viento tanto en estado estacionario como en perfiles dinámicos de velocidad. Además, se buscará mejorar el túnel de viento tanto en software, control y diseño estructural requiriendo perfiles de viento no turbulentos. Finalmente, la arquitectura de la red utilizada puede ser eficientizada mediante algoritmos de optimización.

Finalmente, la sección de anexos muestra las contribuciones científicas derivadas y publicadas de este trabajo.

6. REFERENCIAS

Afrasiabi, S., Afrasiabi, M., Parang, B., Mohammadi, M., Arefi, M. M., & Rastegar, M. (2019). Wind Turbine Fault Diagnosis with GenerativeTemporal Convolutional Neural Network. Iran.

Amezquita-Sanchez, J. P., Basurto-Hurtado, J., De-Santiago-Perez, J., Granados-Lieberman, D., Rivera-Guillen, J. R., & Valtierra Rodriguez, M. (2020). Convolutional Neural Network and Motor Current Signature Analysis during the Transient State for Detection of Broken Rotor Bars in Induction Motors. México.

Association, D. W. (10 de mayo de 2003). Windpower. Recuperado el 25 de agosto de 2019, de Windpower: <http://xn--drmsttre-64ad.dk/wp-content/wind/miller/windpower%20web/es/tour/design/concepts.htm>

Astolfi, D., Castellani, F., Daga, A. P., Garibaldi, L., & Natali, F. (Julio de 2019). Diagnosis of Faulty Wind Turbine Bearings Using Tower Vibration Measurements. Francia.

Aulafacil. (2020). Aulafacil. Obtenido de <https://www.aulafacil.com/cursos/medio-ambiente/energia-eolica/partes-de-un-aerogenerador-l37049>

Beer, F. P., Johnston, E. R., & J., C. P. (2010). Mecánica vectorial para ingenieros: Dinámica, 9 ed. Mc Graw Hill Educación.

Byll Brey, A. B. (2019). Aprovechamiento de energía eólica para mejorar la calidad de vida en el centro poblado de Ilicua alta, Amarilis Huanuco 2019. Huánuco, Perú.

Canseco, M. (Julio de 2010). Energías renovables en Latinoamérica. Energías renovables en Latinoamérica. Madrid.

Cao, Z., Xu, J., Xiao, W., Gao, Y., & Wu, H. (2019). A Novel Method for Detection of Wind Turbine Blade Imbalance Based on Multi-Variable Spectrum Imaging and Convolutional Neural Network. China.

Catuogno, G., De Angelo, C. H., Serra, F., & Bossio, G. R. (enero de 2008). Detección de desbalances en generadores eólicos de baja potencia mediante variables eléctricas. Córdoba, Argentina.

Chávez Campos, G. M., Escobar Jiménez, R. F., Gutiérrez Gneccchi, J. A., Sánchez Soto, J. R., & Téllez Anguiano, A. d. (2019). Vibration analysis system applied to fault detection in wind turbines. México.

Chen, H., Hu, N., Cheng, Z., Zhang, L., & Zhang, Y. (2019). A deep convolutional neural network based fusion method of twodirection vibration signal data for health state identification of planetary gearboxes. China.

Chen, P., Li, Y., Wang, K., Zuo, M. J., Heyns, P. S., & Baggeröhr, S. (2020). A threshold self-setting condition monitoring scheme for wind turbine generator bearings based on deep convolutional generative adversarial networks. China.

di Prátula, H. R., Rossi, A. P., E. G., & Bocero, R. (septiembre de 2011). Turbinas Eólicas: Optimización en el Pre-Diagnóstico de fallas en el generador. Bahía Blanca, Buenos Aires, Argentina.

DODERO, J. B., & GARCIA FERNANDEZ, M. (noviembre de 2012). Generador eólico de baja potencia. Buenos Aires, Argentina.

Donders, S. (Junio de 2002). Fault Detection and Identification for Wind Turbine Systems: a closed-loop analysis. Enschede, Países Bajos.

Garduño Ramírez, R., Rodríguez Martínez, A. A., Sánchez Parra, M., Martínez Morales, M. A., Hernández Cuellar, M. A., Alcaide Godínez, I. X., y otros. (abril-junio de 2012). Investigación, desarrollo e innovación tecnológica de sistemas de control de aerogeneradores. Divulgación, 47-55.

Guo, S., Yang, T., Gao, W., & Zhang, C. (2018). A Novel Fault Diagnosis Method for Rotating Machinery Based on a Convolutional Neural Network. China.

He, G., Ding, K., Li, W., & Jiao, X. (marzo de 2016). A novel order tracking method for wind turbine planetary gearbox vibration analysis based on discrete spectrum correction technique. China.

Hernández Michel, S. Z. (abril de 2018). Análisis de vibraciones para detección de fallas en aerogeneradores de baja. San Juan del Río, Querétaro, México.

Ingeniería Aeronáutica. (18 de octubre de 2010). Ingeniería Aeronáutica: Haciendo posible el sueño de volar. Recuperado el 16 de septiembre de 2019, de <https://ingaeronautica.wordpress.com/2010/10/18/tunel-de-viento-2d/>

Instruments, N. (2019). National Instruments. Recuperado el 25 de agosto de 2019, de LabVIEW: <https://www.ni.com/es-mx/shop/labview.html>

Jia, F., Lei, Y., Lu, N., & Xing, S. (2018). Deep normalized convolutional neural network for imbalanced fault classification of machinery and its understanding via visualization. China.

Jiang, G., He, H., Yan, J., & Xie, P. (2018). Multiscale Convolutional Neural Networks for Fault Diagnosis of Wind Turbine Gearbox. China.

Kong, Z., Tang, B., Deng, L., Liu, W., & Han, Y. (2019). Condition monitoring of wind turbines based on spatio-temporal fusion of SCADA data by convolutional neural networks and gated recurrent units. China.

Lima Menjivar, F. J., Orellana Ramos, F. J., & Valencia Gómez, E. B. (junio de 2017). Diseño y construcción de un prototipo de aerogenerador de baja potencia. EL SALVADOR.

Minas, M. d. (2004). Manual de instalación, reparación y mantenimiento de aerogeneradores de baja potencia. Lima, Perú.

Ortiz, F., & Cáceres, P. (diciembre de 2015). Generación de energía eólica por la empresa BLUE POWER & ENERGY S.A. Revista Senderos Universitarios, 36-44.

Ortiz-Medina, R. A., Villalobos-Piña, F. J., Álvarez-Salas, R., Esparza-González, M., Saucedo-Zarate, C. H., & Maldonado-Ruelas, V. A. (octubre de 2018). Detección de fallas de un aerogenerador basado en un PMSG. México.

Puruncajas, B., Vidal, Y., & Tutivén, C. (2020). Vibration-Response-Only Structural Health Monitoring for Offshore Wind Turbine Jacket Foundations via Convolutional Neural Networks. España.

Qiu, G., Cai, Q., & Gu, Y. (2019). A deep convolutional neural networks model for intelligent fault diagnosis of a gearbox under different operational conditions. China.

Rangel Rodríguez, A. H. (2020). Detección de desbalance en aerogeneradores de baja potencia usando vibraciones y transformada de Fourier. San Juan del Rio, Querétaro, México.

S.L., O. O. (2020). opex-energy. Recuperado el 2020, de http://opex-energy.com/eolica/tipos_aerogeneradores.html#:~:text=Los%20aerogeneradores%20horizontales%20tienen%20una,de%20la%20velocidad%20del%20viento

Salinas-Hernández, A., Rico-Espino, J. G., Jiménez-Grajales, M. Á., & Ramírez-López, R. (noviembre de 2017). Análisis de la calidad de ajuste de una red neuronal autoajustable aplicada en la predicción de fallas en un aerogenerador de baja potencia. México.

Sánchez-Soto, J. R., Téllez-Anguiano, A. d., Escobar-Jiménez, R. F., Chávez-Campos, G. M., & Gutiérrez-Gnecchi, J. A. (2019). Vibration analysis system applied to fault detection in wind turbines. México: Sci-Elo.

Semeria, M. (diciembre de 2015). Los tres teoremas: Fourier - Nyquist - Shannon. Recuperado el agosto de 2020, de econstor: <https://www.econstor.eu/bitstream/10419/130833/1/844215546.pdf>

TUV, C. &. (2019). Owner's Manual. Wind Turbine Generator Installation Operation Maintenance.

Ulmer, M., Jarlskog, E., G. P., Manninen, J., & Huber, L. G. (2020). Early Fault Detection Based on Wind Turbine SCADA Data Using Convolutional Neural Networks. Suecia.

Umbarila Valencia, L. P., Alfonso Moreno, F. L., & Rivera Rodríguez, J. C. (Julio-diciembre de 2015). Importancia de las energías renovables en la seguridad energética y su relación en el crecimiento económico.

Xu, Z., Li, C., & Yang, Y. (2020). Fault diagnosis of rolling bearing of wind turbines based on the Variational Mode Decomposition and Deep Convolutional Neural Networks. China.

Yang, L., & Zhang, Z. (2020). A Conditional Convolutional Autoencoder Based Method for Monitoring Wind Turbine Blade Breakages. China.

Yang, Z., Ma, X., & Ma, Y. (2018). A Fault Diagnosis Model Based on Convolution Neural Network for Wind Turbine Rolling Bearing. China: ESMA.

Yu, W., Huang, S., & Xiao, W. (2019). Fault Diagnosis Based on an Approach Combining a Spectrogram and a Convolutional Neural Network with Application to a Wind Turbine System. China.

Zhao, D., Wang, T., & Chu, F. (2019). Deep convolutional neural network-based planet bearing fault classification. China.

ANEXO