

PONTIFICIA UNIVERSIDAD CATÓLICA DE VALPARAÍSO  
FACULTAD DE INGENIERÍA  
ESCUELA DE INGENIERÍA INFORMÁTICA

**DIAGNÓSTICO DE FALLAS DE RODAMIENTOS DE  
EQUIPOS DE ROTACIÓN UTILIZANDO REDES  
NEURONALES ARTIFICIALES**

**DIEGO ALEJANDRO LÓPEZ CATALDO**

INFORME FINAL DEL PROYECTO  
PARA OPTAR AL TÍTULO PROFESIONAL DE  
INGENIERO CIVIL EN INFORMÁTICA

Enero de 2016

***Dedicatoria***

*A los tres pilares de mi vida: mis padres, quienes no escatimaron en costos ni esfuerzos para brindarme la oportunidad de poder estudiar, y a mi novia, quien fue la que estuvo en todo momento apoyándome..*

### ***Agradecimientos***

*A mi amigo y compañero universitario, con quien trabajé a la par en el desarrollo de nuestros proyectos de título. A mi profesor guía, quien desde un principio estuvo dispuesto a enseñarme y ayudarme, y a todos aquellos quienes de alguna u otra forma aportaron en la realización de este proyecto tan importante para mí.*

# Índice

Resumen.....	v	
Lista de abreviaturas o siglas.....	vi	
Lista de figuras.....	vii	
Lista de tablas .....	viii	
1	Introducción .....	9
2	Definición de objetivos .....	12
2.1	Objetivo general.....	12
2.2	Objetivos específicos .....	12
3	Estado del arte .....	13
3.1	Redes neuronales artificiales.....	15
4	Marco Teórico .....	17
4.1	Levenberg-Marquardt .....	18
4.2	Funciones de transferencia.....	18
4.2.1	Sigmoidal .....	18
4.2.2	Softmax .....	19
5	Análisis de resultados.....	20
5.1	Topología de la red .....	20
5.2	Especificaciones datos utilizados.....	24
5.3	Características de la señal de vibración .....	26
5.4	Métricas de rendimiento .....	27
5.5	Resultados.....	28
5.5.1	Modelo clasificación normal .....	28
5.5.2	Modelo clasificación con tipos de fallos.....	28
5.5.3	Modelo clasificación en cascada .....	29
5.6	Matriz de confusión .....	32
5.7	Aproximación valores de salida RNA .....	35
5.8	Influencia velocidad del motor .....	36
6	Conclusiones .....	39
7	Referencias .....	41

## Resumen

El presente proyecto de título plantea la problemática que surge en relación a diagnosticar las fallas de los rodamientos utilizados en equipos de rotación, lo cual genera un impacto directo e importante en los planes de mantenimiento de las máquinas afectadas. La solución al tema se aborda mediante la implementación de una red neuronal artificial feed-forward de 3 capas, la cual utiliza una función de transferencia sigmoideal en su capa oculta y una función de transferencia softmax en su capa de salida. Esto junto al algoritmo de Levenberg-Marquardt, el cual es utilizado para realizar la distribución de los pesos de la red. Como entradas se utilizan características estadísticas de datos obtenidos a través de mediciones de señales de vibración del rodamiento a analizar, y como salida se consigna de forma binaria la pertenencia a cada uno de los tipos de fallos. La evaluación de las salidas se realiza a través de métricas de rendimiento, principalmente la denominada exactitud. En primera instancia se implementó la red para detectar si el rodamiento posee fallos. Luego, la implementación de la red fue variando de acuerdo a los resultados obtenidos, logrando a través de un modelo de tres redes en cascada diagnosticar de manera efectiva todos los tipos de fallos posibles en un rodamiento de rotación.

*Palabras claves: redes neuronales, diagnóstico y detección de fallos, rodamientos.*

## Abstract

In this paper a problem is reviewed which arises from making a fault diagnosis on bearings that are used on rotary machines, these faults generate a significant and direct impact on maintenance management of affected machines. The solution of this subject it is faced through a three layer feed-forward artificial neural network (ANN) implementation, which uses a sigmoid transfer function on its hidden layer and a Softmax transfer function on its output layer. Combined with Levenberg-Marquardt algorithm, which is used to make the weight distribution of the ANN. The entries of the ANN are statistic characteristics obtained from measures of the analyzed bearing vibration signal, and the ANN output is a binary output which belong to every kind of failure. The output evaluation is made through some performance metrics, based mainly on the accuracy. On the first stages, an ANN was implemented to detect if a bearing has faults. Afterwards, the network implementation suffer several variation according to the achieved results, accomplishing through a three level cascade ANN model an effective way of diagnose every possible bearing fault in a rotary machinery.

*Keywords: artificial neuronal networks, faults diagnosis, faults detection, bearings*

## **Lista de abreviaturas o siglas**

ANN : Artificial Neuronal Network  
DE : Drive End  
FE : Fan End  
FN : Falsos Negativos  
FP : Falsos Positivos  
MSE : Mean Squared Error  
RNA : Red Neuronal Artificial  
RPM : Revoluciones Por Minuto  
VP : Verdaderos Positivos  
VN : Verdaderos Negativos

# Lista de figuras

Figura 1-1 Componentes de un rodamiento .....	9
Figura 1-2 Estructura de los rodamientos y acelerómetros .....	11
Figura 3-1 Representación de una neurona biológica .....	14
Figura 3-2 Sinapsis neuronal.....	14
Figura 3-3 Representación de la neurona biológica a la neurona artificial.....	15
Figura 5-1 Diagrama de bloques RNA.....	20
Figura 5-2 Procesamiento datos señal de vibración.....	21
Figura 5-3 Generación de entradas a RNA .....	22
Figura 5-4 Training y Testing de la RNA .....	23
Figura 5-5 Matriz de exactitud con 5 características y un tipo de fallo .....	28
Figura 5-6 Matriz de exactitud con 5 características y dos tipos de fallos .....	28
Figura 5-7 Matriz de exactitud con 7 características y dos tipos de fallos .....	29
Figura 5-8 Estructura modelo clasificación en cascada .....	30
Figura 5-9 Archivos de datos usados en prueba 1.....	30
Figura 5-10 Archivos de datos usados en prueba 2.....	31
Figura 5-11 Archivos de datos usados en prueba 3.....	31
Figura 5-12 Archivos de datos usados en prueba 4.....	32
Figura 5-13 Matriz de confusión primera red modelo cascada.....	33
Figura 5-14 Matriz de confusión segunda red modelo cascada .....	34
Figura 5-15 Matriz de confusión tercera red modelo cascada .....	34
Figura 5-16 Matriz de confusión ejemplo modelo cascada .....	35
Figura 5-17 Valores reales de salida RNA.....	36
Figura 5-18 Resultados exactitud 1ª etapa evaluación.....	37
Figura 5-19 Resultados exactitud 2ª etapa evaluación.....	37
Figura 5-20 Resultados exactitud 3ª etapa evaluación.....	38

## Lista de tablas

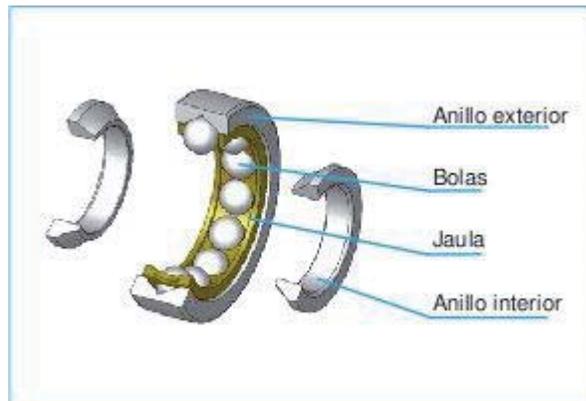
Tabla 5-1 Especificaciones de los datos usados.....	25
---	----

# 1 Introducción

Los rodamientos son dispositivos ampliamente utilizados en las industrias para minimizar la fricción en las partes giratorias de las máquinas. Son uno de los componentes más críticos que tienen las máquinas rotativas ya que cuentan con un alto porcentaje de fallos en comparación con otros componentes, [1] de hecho, sobre la base de estudios anteriores, se sabe que los rodamientos son la causa de entre un 40% y un 50% de los fallos de las máquinas. [2] Debido a que los rodamientos se utilizan en muchos equipos, sus desperfectos pueden provocar una descompostura total de la máquina, lo cual conduce al fracaso de la máquina y por ende a la generación de pérdida en la productividad de forma imprevista para las instalaciones de producción. Por lo tanto, es muy importante considerar la detección y el diagnóstico de fallos como una parte integral de los procedimientos de mantenimiento preventivo, aumentando así su eficiencia y disminuyendo considerablemente las probabilidades de inutilización de las maquinarias. Es por esto que el diagnóstico de las condiciones de los sistemas de rodamientos y engranajes es hoy en día un requisito en el campo de la industria. [3]

Las condiciones de los rodamientos comúnmente son reflejadas por datos de señales de vibración. En el diagnóstico de los múltiples estados de los rodamientos, se implican muchos tipos de datos de señales de vibración, de este modo en consecuencia, se necesitarán muchas características de extracción para obtener diagnósticos de condición precisos. Sin embargo, el contar con un gran número de características de extracción hace que aumente la complejidad del sistema de diagnóstico. [4]

Dentro de las fallas que se pueden generar tanto en los rodamientos como en los engranajes de las máquinas, las que ocurren con más frecuencia son las fallas de bola, del anillo de rodadura interior, del anillo de rodadura exterior y de la jaula. La siguiente figura muestra la estructura de un rodamiento para comprender de mejor forma los tipos de fallas.



**Figura 1-1 Componentes de un rodamiento**

Los 4 componentes que se pueden apreciar en la figura anterior son los principales elementos de un rodamiento, por lo que son los que generan los principales tipos de fallos de los mismos. Estos pueden ser debido a daños en la superficie de la rodadura, a fracturas y ludimiento o a un factor de riesgo. [5] A continuación, se detallan las causas de los distintos tipos de fallos posibles en un rodamiento:

Debido a daños en la superficie de la rodadura:

- **Fatiga superficial:** Se desarrolla en servicio un agrietamiento en las superficies con posterior pérdida de material, el cual puede ser poco profundo (micropicado) o generar descascaramiento de áreas grandes y profundas (macropicado).
- **Descarga eléctrica:** Por paso de corriente eléctrica AC o DC a través del rodamiento se generan arcos eléctricos entre los elementos rodantes, las pistas y las jaulas, que erosionan las superficies debido a fusión a pequeña escala. Producto de los arcos se pueden generar patrones de estrías o cráteres profundos si la corriente es alta.
- **Desgaste abrasivo:** Se presenta en servicio la generación de un rayado abrasivo sobre las superficies de rodadura y también sobre las jaulas, indicando que se está perdiendo material por abrasión. Normalmente está acompañado el proceso por la indentación.
- **Desgaste adhesivo:** Se presenta en servicio pérdida de material por contacto metal - metal entre las partes en rodamiento incluyendo las jaulas, producto de la pérdida parcial o total de la película lubricante. Si la pérdida de lubricación es parcial las zonas de contacto se pulen y si es total se eleva fuertemente la temperatura quemando el lubricante, oxidándose las partes o incluso fundiéndose.
- **Corrosión:** Se genera ataque corrosivo sobre las superficies de rodadura o las jaulas, por la acción del lubricante o de otro fluido que entra en contacto con el rodamiento, generándose daño superficial y depósitos.
- **Indentación:** Se trata de generación de cráteres o hendiduras sobre las superficies de rodadura, producto de la deformación plástica derivada de fuerzas de contacto excesivas entre los elementos del rodamiento (macroindentaciones) y/o por presencia de partículas contaminantes entre ellos (microindentaciones).

Debido a fracturas o ludimiento:

- **Fractura:** Las pistas o las jaulas presentan agrietamiento o fractura en montaje o servicio, llevando algunas veces a destrucción total del rodamiento.
- **Ludimiento:** Se presentan depósitos oscuros en las superficies de apoyo con el eje o su alojamiento, indicando que en servicio se dieron pequeños movimientos oscilantes entre las partes (desgaste y/o oxidación).

Debido a un factor de riesgo:

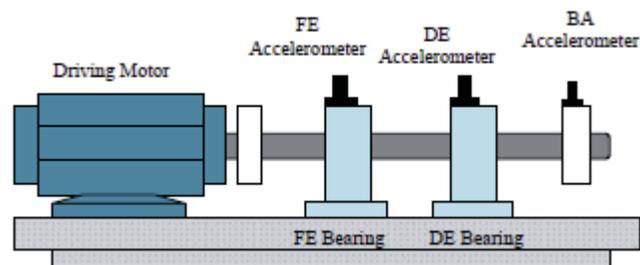
- **Rodadura irregular:** El rodamiento presenta un camino oblicuo de rodadura de sus elementos rodantes sobre las pistas.

El fallo que se quiere evitar a toda costa es el de fractura en el rodamiento, ya que si ocurre, el mecanismo queda inutilizable y, por ende, la máquina en la que se encuentra también lo queda. Se entiende por fractura el quiebre físico en alguno de los componentes del rodamiento.

Los datos a utilizar para el desarrollo del mecanismo de diagnóstico propuesto son obtenidos desde Bearing Data Center de Case Western Reserve University, una base de datos de dominio público que contiene toda la información relacionada con las fallas de rodamientos y engranajes como las características físicas de los rodamientos, incluyendo sus tamaños, diámetros internos, externos, de bolas y las especificaciones de las fallas de los engranajes, como la posición en la que se encuentran en la máquina, el lugar del rodamiento donde ocurre la falla o fractura, el diámetro de la falla, entre otras.

Esta base de datos cuenta con una alta confiabilidad debido a su gran utilización por parte de muchas organizaciones e investigaciones, lo que genera un mayor grado de certeza en los resultados que se obtengan. [6-13]

Los datos de las señales de vibración fueron capturados a partir de un sistema de dos rodamientos, que consiste en la unidad del extremo del rodamiento (DE) y el ventilador del extremo del rodamiento (FE). Para los efectos de la captura de los datos de las señales de vibración, se colocan tres acelerómetros, uno en cada rodamiento y otro en la placa base de soporte del motor (BA). Esto se puede apreciar con mayor claridad en la siguiente figura:



**Figura 1-2 Estructura de los rodamientos y acelerómetros**

Los datos digitales se obtuvieron de 12.000 muestras por segundo, y los datos también se recogieron de 48.000 muestras por segundo para las fallas de rodamientos del final del conductor (DE).

En específico, se analizarán las 7 posibles condiciones que pueden tener los rodamientos de la estructura a utilizar y que fueron descritos anteriormente. Estas son:

- FE y DE normales
- FE normal y DE con falla en el anillo interior
- FE normal y DE con falla de bola
- FE normal y DE con falla en el anillo exterior
- FE con falla en el anillo interior y DE normal
- FE con falla de bola y DE normal
- FE con falla en el anillo exterior y DE normal

## **2 Definición de objetivos**

### **2.1 Objetivo general**

Generar un modelo basado en redes neuronales artificiales con algoritmo de aprendizaje Levenberg-Marquardt, función de transferencia sigmooidal en la capa oculta y softmax en la capa de salida, para diagnosticar las fallas de un rodamiento de 2,5 cms. de diámetro con 8 bolas de un motor de rotación mediante la medición de señales de vibración obtenidas a una frecuencia de 12 KHz.

### **2.2 Objetivos específicos**

- Analizar la importancia del diagnóstico de fallas de rodamientos dentro de los procesos de mantenimiento en la industria.
- Seleccionar al menos 7 indicadores estadísticos para evaluar el comportamiento de una señal de vibración.
- Implementar una red neuronal artificial cuyos parámetros de entrada sean indicadores estadísticos de la señal de vibración y sus salidas reflejen la pertenencia a cada tipo de falla mediante una representación binaria.
- Estimar la mejor combinación de parámetros de la red usando el algoritmo de aprendizaje de Levenberg-Marquardt.
- Evaluar el comportamiento del modelo a través de métricas de rendimiento basadas en el acierto obtenido en la clasificación de las salidas de la red neuronal.
- Modificar el modelo en busca de obtener el mejor rendimiento posible.
- Verificar la sensibilidad del modelo en relación a la variación de las características bajo las cuales son capturadas las señales de vibración.

### 3 Estado del arte

Como la problemática a abordar se enfrenta y busca solucionar utilizando redes neuronales artificiales (RNA), se hace imprescindible el comprender debidamente su funcionamiento, dando un vistazo histórico desde sus inicios hasta la actualidad. Así, al conocer mucho más sobre este paradigma de tratamiento de la información, se podrá enfrentar de mejor forma el tema a tratar, debido a los mayores conocimientos que estarán disponibles para su utilización y aplicación.

Una Red Neuronal Artificial (RNA) es un sistema de procesamiento de información [14] basado en las características principales del funcionamiento de las redes neuronales biológicas existentes en el sistema nervioso. El sistema nervioso puede comprenderse a varios niveles, los cuales van desde las propiedades de las células individuales hasta las características del encéfalo entero. Dentro de las divisiones generales del sistema nervioso está el sistema nervioso central y el sistema nervioso periférico. En el primero se encuentra el encéfalo, el cual es una masa gelatinosa, que pesa un poco más de un kilo, de forma plegada y contorsionada. Está ubicado en la cavidad craneal y a su vez se divide en dos hemisferios cerebrales. Al cortar el encéfalo, ya sea de forma transversal o de forma horizontal, se pueden apreciar dos tipos de tonalidades, las cuales representa la estructura celular que posee. En una de las tonalidades, la más oscura, se evidencian las áreas más próximas a la superficie, las cuales son ricas en cuerpos de células nerviosas. En la otra tonalidad, la más clara, se evidencian las áreas compuestas de las ramificaciones de estas células que sirven como vías de comunicación, las cuales por lo general son axones.

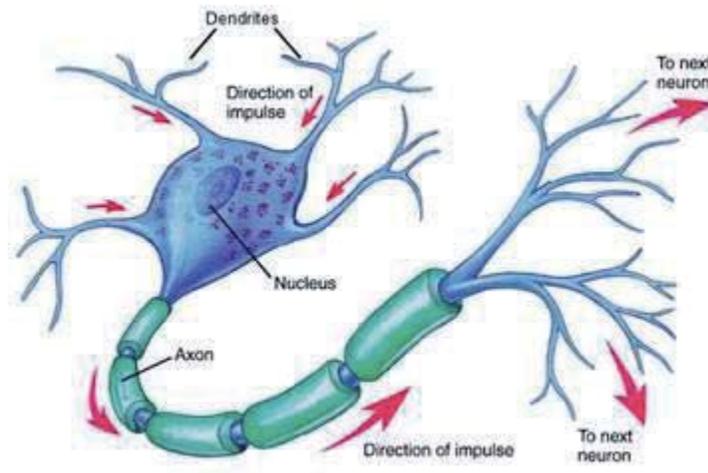
Las células nerviosas mencionadas anteriormente se llaman neuronas y son las unidades básicas del sistema nervioso. Tienen una gran variedad de formas y tamaños, lo cual refleja la forma en que procesan la información. Además, entre ellas se encuentran separadas estructural y funcionalmente. Están especializadas en la recepción de estímulos y conducción de impulsos nerviosos (en forma de potencial de acción) entre ellas o con otros tipos celulares. Altamente diferenciadas, la mayoría de las neuronas no se dividen una vez alcanzada su madurez; no obstante, una minoría sí lo hace. [15]

Las neuronas se interconectan entre ellas formando redes de comunicación que transmiten señales por zonas definidas del sistema nervioso. Las funciones complejas del sistema nervioso son consecuencia de la interacción entre redes de neuronas, y no el resultado de las características específicas de cada neurona individual. Las funciones producidas por las redes neuronales varían de acuerdo a la región del encéfalo donde se encuentren. Este proceso va más allá de un simple intercambio de información, ya que las neuronas típicas recogen señales de varias fuentes, las integran y transforman, codificándolas en complejas señales de salida que distribuyen a un gran número de otras células. [16]

Especificando más la estructura y funcionalidad de las neuronas biológicamente, podemos determinar y visualizar tres partes principales de una neurona:

- Ramas de extensión o dendritas: reciben estímulos de entrada.
- Cuerpo de la neurona: procesa estímulos de entrada.
- Axón: emite estímulos de salida a las dendritas de otras neuronas.

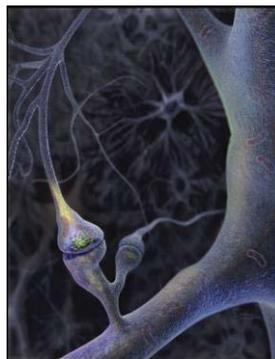
La estructura visual de una neurona biológica se puede apreciar en la siguiente figura:



**Figura 3-1** Representación de una neurona biológica

Una neurona recibe estímulos de entrada mediante las dendritas, estos estímulos son procesados en el cuerpo, para posteriormente emitir un estímulo de salida a través del axón. [17]

La neurona utiliza dos tipos de señales: las que se generan y transportan a través del axón son impulsos eléctricos. La señal transmitida entre los terminales axónicos y las dendritas de otra neurona es de origen químico. Esta conexión entre el axón de una neurona y las dendritas de otra se llama sinapsis y se da gracias a que existen dos tipos de neuronas: aquellas que suministran el impulso, denominadas presinápticas y las que reciben el impulso, que son conocidas como postsinápticas.



**Figura 3-2** Sinapsis neuronal

Cuando la información enviada a través de un impulso eléctrico llega al terminal de un axón se liberan transmisores que son alojados en una hendidura muy pequeña que separa la célula presináptica de la postsináptica; durante este proceso son liberados también neurotransmisores “que se enlazan con receptores postsinápticos”, lo que da origen a la comunicación entre dos neuronas. [18]

La sinapsis es direccional, es decir en un solo sentido. Su principal influencia se debe a que altera la efectividad de la señal transmitida debido a un parámetro, el peso. El aprendizaje es el resultado de la modificación de estos pesos y junto con el procesamiento de la información se genera el mecanismo básico de la memoria. [19] Esta eficiencia sináptica es la que resulta modificada cuando se dice que el cerebro aprende. Puede decirse que las sinapsis, combinadas con el proceso de información de la neurona, forman el mecanismo básico de la memoria. [16]

### 3.1 Redes neuronales artificiales

Una red neuronal artificial consiste en unidades de procesamiento interconectadas de manera densa, llamadas neuronas, por tener un comportamiento similar al de las neuronas biológicas. Las unidades de procesamiento reciben, procesan y transmiten señales, tal como las neuronas biológicas. Las redes neuronales artificiales tratan de imitar la funcionabilidad de un cerebro biológico, aunque el sistema artificial no alcanza la complejidad del mismo. [18]

Se puede decir que la función básica de una neurona es sumar sus entradas y producir una salida si la suma es mayor que un umbral determinado. El tipo (excitatorio o inhibitorio) y la efectividad de estas entradas, es función de la cantidad de señal recibida en las sinapsis, así como el tipo de éstas. La conexión de varias neuronas forma lo que comúnmente se denomina una red de neuronas.

Un ejemplo de las analogías existentes entre las redes neuronales biológicas y las redes neuronales artificiales se puede ver a continuación:

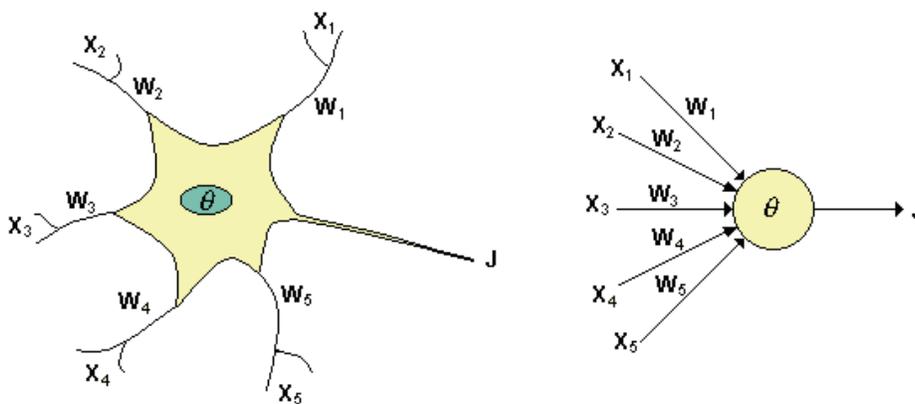


Figura 3-3 Representación de la neurona biológica a la neurona artificial

El diseño de una red neuronal está determinado por las conexiones entre sus neuronas. En la neurona biológica se observa que la información llega a las dendritas, esta es evaluada por el núcleo, pasa el por axón y la transmite a otras células.

A grandes rasgos, podemos decir que las RNA están compuestas por muchos elementos sencillos denominados neuronas que operan en paralelo y son diseñadas para mostrar una función particular mediante el ajuste de los valores de peso  $w_i$  de las conexiones, que actúan con determinada polarización  $b$ , conocida como “bias”, sobre la función de activación  $f$ . Así se obtiene la salida adecuada en respuesta a la señal de entrada recibida.

Actualmente las redes neuronales han encontrado aplicación en multitud de campos de la ciencia y la ingeniería que van desde el tratamiento de señales hasta los negocios. Se puede afirmar que las redes neuronales son una buena alternativa a gran número de métodos que se aplican en numerosos campos. En la mayoría de los casos, incluso para problemas que se han resuelto por otros medios y gracias a diferentes teorías, las redes neuronales han encontrado a su vez, otras formas de resolución más eficientes.

## 4 Marco Teórico

Especificando lo visto anteriormente con más profundidad y detalles, señalamos que en una neurona artificial, las entradas  $x_i$  representan vectores o señales provenientes del exterior que son capturadas de otras neuronas. Los pesos  $w_i$  representan la intensidad de la sinapsis. Tanto  $x_i$ , como  $w_i$  son valores escalares. A esta señal ponderada se le adiciona el denominado “bias” y se obtiene una entrada total que actúa sobre el núcleo de la neurona para activarla.  $x_{neta}$  es la función umbral o de transferencia, que evaluada para esta entrada total, produce la respuesta de la neurona al estímulo recibido en forma similar como ocurre en las células nerviosas biológicas. Siendo  $J$  la función de salida, podemos decir que, en términos matemáticos, este proceso se presenta de forma sencilla como:

$$J = \theta(x_{neta} + b) \quad (4.1)$$

Tanto el vector de pesos  $w_i$  como el “bias”  $b$  son parámetros escalares ajustables de la neurona. La idea central de una red neuronal es que estos parámetros puedan ser ajustados de forma tal que la red reproduzca el comportamiento observado. El entrenamiento es precisamente eso; un proceso de ajuste de los parámetros en la red para que pueda realizar un trabajo en particular. [19]

Una red neuronal artificial consiste en varios elementos de proceso conectados de alguna forma, generalmente organizados en grupos denominados capas.

En toda red neuronal existen dos capas típicas, que tienen conexión con el exterior; éstas son la capa de entrada, a través de la cual los datos son presentados a la red, y la capa de salida, la cual muestra la respuesta de la red a una entrada dada. El resto de las capas existentes entre estas dos se denominan capas ocultas. Las RNA, al igual que las redes de neuronas biológicas, almacenan la información en los pesos asociados a las conexiones entre elementos de proceso. Podría decirse que una red diseñada para un fin específico, consta de un número determinado de elementos de proceso conectados en una estructura concreta y adecuada a tal fin, de unos pesos generalmente fijos en las conexiones entre estos elementos de proceso, y de una dinámica de funcionamiento que permita a la red obtener la salida deseada a una entrada dada.

Esto hace que se pueda estudiar las características principales de una RNA atendiendo a su topología (estructura de la red), su ley de aprendizaje (determinación de los pesos adecuados) y a su dinámica de funcionamiento, además de otras características.

La información pasa de la capa de entrada a través de las capas ocultas hasta la capa de salida de una forma sencilla, usando la suma y la función de activación de la red en particular. [16]

## 4.1 Levenberg-Marquardt

A la fecha existen diferentes algoritmos de entrenamiento supervisado que han surgido del *Back-Propagation* y que muestran velocidades mucho más rápidas de convergencia del MSE hacia el mínimo absoluto. Uno de ellos es el algoritmo de Levenberg-Marquardt.

El algoritmo de Levenberg-Marquardt se aplica principalmente a redes neuronales multicapa con un número grande de *patterns* ya que tiene la velocidad de convergencia del MSE más rápida hasta ahora, principalmente en problemas de aproximación de funciones a pesar de que su complejidad en cálculos es mayor [20, 21]. Usa la metodología del *Back-Propagation* empleando el cálculo del gradiente mediante la matriz Jacobiana de los errores de las neuronas de salida. La ecuación con la que se actualizan los pesos es la siguiente [8]:

$$w(n + 1) = w(n) - \alpha * w(n - 1) - (J^T * e) * (J^T * J + \mu * I)^{-1} \quad (4.1.1)$$

donde  $J$  es la matriz Jacobiana de los errores de las neuronas de salida, es decir, la matriz de las primeras derivadas de dichos errores con respecto a los pesos y umbrales ( $\theta$ ) de los que son función,  $J^T$  es la transpuesta de la matriz Jacobiana,  $I$  es la matriz identidad (unos en la diagonal y ceros en las demás localidades) del mismo tamaño que la matriz Jacobiana,  $e$  es el vector de errores de las neuronas de salida,  $\alpha$  es la *momentum constant*, y  $\mu$  es una constante que es decrecida en cada iteración en la que se observa una reducción del MSE, o incrementada y se descartan los pesos actualizados cuando se obtiene un aumento en el MSE. Este algoritmo, aunque requiere de mayor número de cálculos que el *Back-Propagation*, evita más las oscilaciones del MSE, y la matriz Jacobiana es la que hace que se tenga una convergencia demasiado rápida, incluso hasta más de 100 veces más rápida que la obtenida por el *Back-Propagation* con su *gradient-descent* [20, 21].

## 4.2 Funciones de transferencia

Las funciones de transferencia son aquellas que modifican o transforman el resultado de la función de propagación en una salida real de la neurona. El valor de la salida de combinación puede ser comparado con algún valor umbral para determinar la salida de la neurona.

### 4.2.1 Sigmoidal

Esta función toma los valores de entrada, los cuales pueden oscilar entre  $]-\infty; +\infty[$  y restringe la salida a valores entre cero y uno, de acuerdo a la siguiente expresión:

$$a = \frac{1}{1 + e^{-N}} \quad (4.2.1.1)$$

Siendo  $x_i$  una entrada del nodo y  $w_i$  su peso, se tiene que:

$$N = \sum_{i=1}^n x_i * w_i \quad (4.2.1.2)$$

Es una función diferenciable lo que es útil en algoritmos de entrenamiento basados en derivadas. Esta función es comúnmente usada en redes multicapa.

## 4.2.2 Softmax

En las simulaciones de redes neuronales, la función softmax se implementa a menudo a la capa final de una red utilizada para la clasificación de las salidas. Esta función tiene la siguiente forma:

$$y(x) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (4.2.2.1)$$

Donde  $n$  es el número de nodos de la capa de salida. Esta función asegura que todos los valores de salida están entre cero y uno, y que su suma vale uno.

## 5 Análisis de resultados

### 5.1 Topología de la red

La implementación de lo analizado y estipulado anteriormente en este trabajo se centra en poder cumplir el objetivo principal de diagnosticar los fallos de un rodamiento a través de señales de vibración tomadas por medio de acelerómetros. A grandes rasgos la idea es, una vez obtenidos los datos, analizarlos a través de características matemáticas e ingresarlos a una red neuronal.

Para comprender visualmente la estructura general implementada se presenta el siguiente diagrama de bloques:

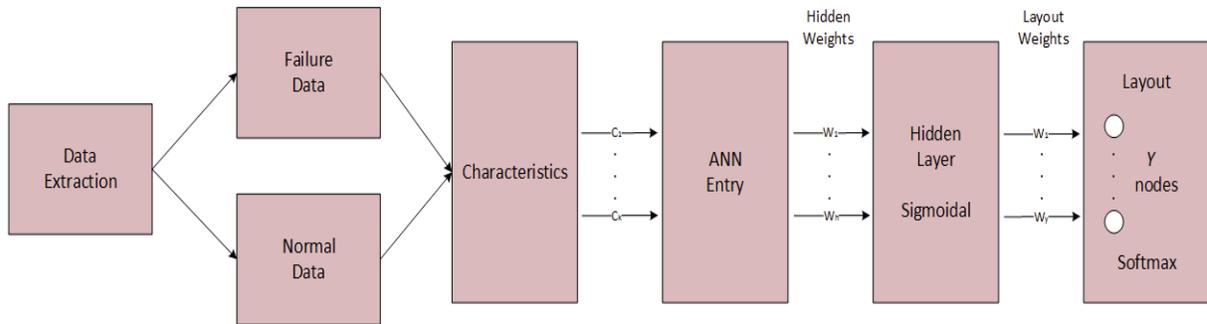


Figura 5-1 Diagrama de bloques RNA

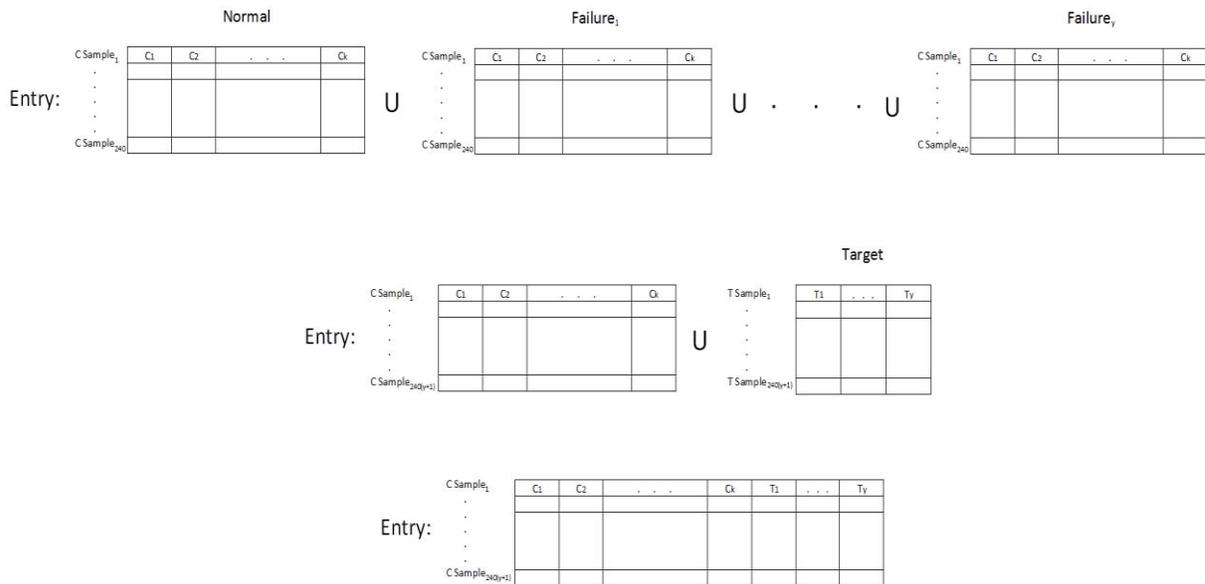
Como se aprecia en este diagrama, para ingresar los datos de entrada a la red neuronal primero se extraen los datos desde la señal de vibración a analizar, tanto aquellos que contienen fallas como aquellos que no contienen fallas. Luego, a estos datos se le calculan  $k$  características estadísticas, las cuales pasan a ser las entradas de la red. Una vez ingresados los datos en la red neuronal, estos ingresan a la capa oculta donde pasan por una función de transferencia sigmoideal. Finalmente, llegan a la capa de salida donde pasan por una función de transferencia softmax. Para el ajuste de los pesos se utiliza el algoritmo de Levenberg-Marquart. Tanto las funciones de transferencia como el algoritmo de aprendizaje se encuentran explicados en el marco teórico de este trabajo.

Una explicación más detallada sobre el procesamiento completo de los datos se puede apreciar en las siguientes figuras:



matriz *Samples*) se le calcularán  $k$  características estadísticas. Estas características son agrupadas en una matriz llamada  $C$  compuesta de 240 filas y  $k$  columnas. Así, para cada conjunto de datos (normales o con fallas) se realiza el mismo procedimiento.

Una vez procesados los datos, es necesario tener claro los datos que serán ingresados en la red neuronal. Esto se puede visualizar en la siguiente figura:

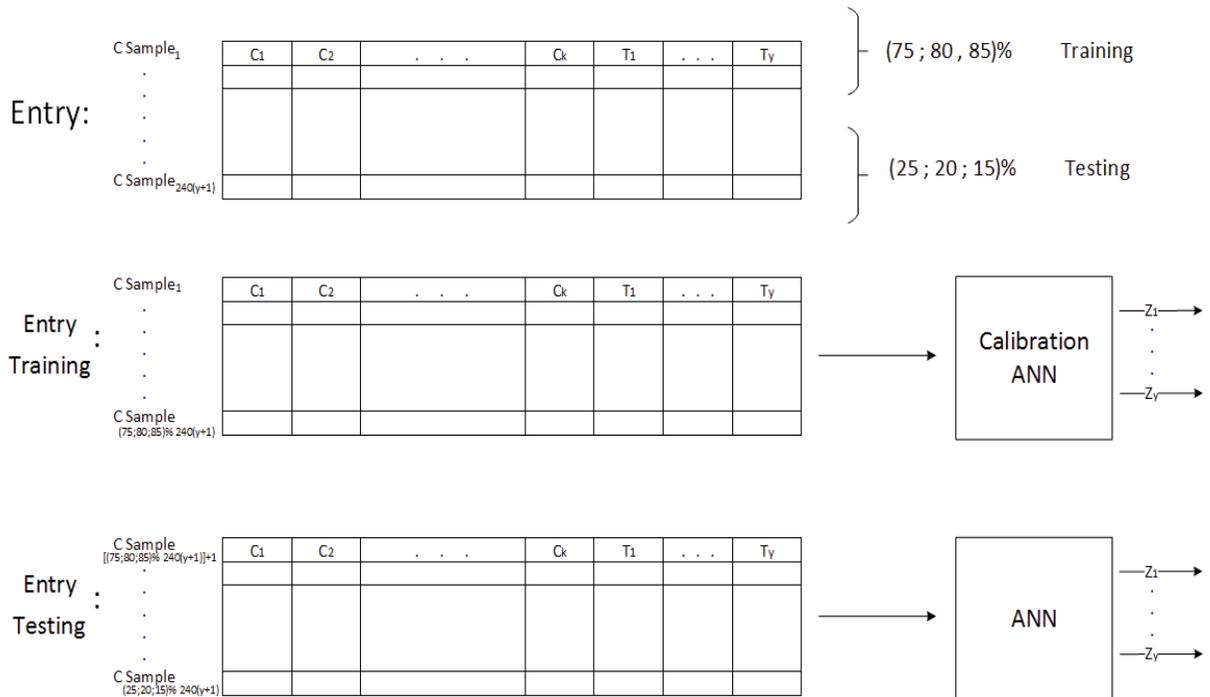


**Figura 5-3 Generación de entradas a RNA**

Como se mencionó anteriormente, el proceso de modelamiento de los datos de la señal de vibración se realiza tanto para aquellos datos que no presentan fallas como aquellos que si presentan fallas, lo cual genera más de una matriz de características. Entonces, la matriz de datos de entrada a la RNA, llamada *Entry*, se compone de la unión de todas las matrices de características tanto de datos normales, llamada *Normal*, como de las de datos con fallas, llamadas *Failure*. Se denomina  $y$  a la cantidad de fallas distintas que se quieren analizar, lo que refleja la existencia de  $y$  matrices *Failure*. Luego, la matriz *Entry* queda compuesta de  $240*(y+1)$  filas y de  $k$  columnas.

Una vez unidos los datos con y sin fallos, se confecciona una matriz de objetivos llamada *Target*, la cual indica en cada columna si las características calculadas corresponden a un tipo de falla. Esto se indica a través de un 1 si es que la fila correspondiente proviene de datos con un tipo de falla y 0 si es que no corresponde a ese tipo de falla. La matriz *Target* se compone de la misma cantidad de filas que la matriz *Entry* y de  $y$  columnas, lo cual representa el número de tipos de fallos que se quieren diagnosticar. Cabe destacar que si se trata de una fila proveniente de datos normales, su fila correspondiente del *Target* tendrá 0 en todas sus casillas. En el caso que provenga de datos con fallas, su fila correspondiente en el *Target* tendrá un 1 en la columna correspondiente al tipo de fallo y 0 en el resto de las columnas. Finalmente, se une la matriz *Entry* con *Target*, se reordenan las filas aleatoriamente y se obtiene la matriz final para ser utilizada como entrada en la red neuronal.

Luego de tener la matriz *Entry* con las entradas de la red, basta con definir los datos de training y de testing para ejecutar la red neuronal. Esto se puede apreciar en la siguiente figura:



**Figura 5-4 Training y Testing de la RNA**

El último paso antes de ejecutar la red neuronal consiste en separar la matriz *Entry* en dos matrices, una matriz llamada *Entry Training* para realizar la calibración (Testing) de la red y una matriz llamada *Entry Testing* para realizar el diagnóstico propiamente tal de los datos. La proporción con la que se trabajó fue la de seleccionar el 75% o el 80% o el 85% de los datos para realizar el Training, dejando el resto para el Testing.

Finalmente, la red genera y salidas, el mismo número de tipos de fallos con los que se comenzó a trabajar. Cada salida entrega un 0 o un 1 dependiendo de si la red decide si corresponde al tipo de fallo asociado al nodo de salida o no. En el caso de que todas las salidas den 0, se interpreta como que no es un fallo.

## 5.2 Especificaciones datos utilizados

Los datos específicos que fueron utilizados para el desarrollo de este trabajo se encuentran detallados en la siguiente tabla:

Nombre archivo	Rodamiento	Frecuencia muestreo (Hz)	Diámetro falla (pulgadas)	RPM	Zona de fallo	Cantidad de datos
<b>X097</b>	DE	12k	-	1797	-	243938
<b>X098</b>	DE	12k	-	1772	-	483903
<b>X099</b>	DE	12k	-	1750	-	485063
<b>X100</b>	DE	12k	-	1730	-	485643
<b>X105</b>	DE	12k	0.007''	1797	Anillo interno	121265
<b>X106</b>	DE	12k	0.007''	1772	Anillo interno	121991
<b>X111</b>	DE	12k	0.007''	1750	Anillo interno	485643
<b>X112</b>	DE	12k	0.007''	1730	Anillo interno	485643
<b>X169</b>	DE	12K	0.014''	1797	Anillo interno	121846
<b>X209</b>	DE	12K	0.021''	1797	Anillo interno	122136
<b>X130</b>	DE	12K	0.007''	1797	Anillo externo	121991
<b>X198</b>	DE	12K	0.014''	1772	Anillo externo	122136
<b>X236</b>	DE	12K	0.021''	1750	Anillo externo	122281
<b>X237</b>	DE	12K	0.021''	1730	Anillo externo	121991
<b>X118</b>	DE	12K	0.007''	1797	Bola	122571

<b>X186</b>	DE	12K	0.014''	1772	Bola	122136
<b>X224</b>	DE	12K	0.021''	1750	Bola	122136
<b>X3008</b>	DE	12K	0.028''	1730	Bola	120984

**Tabla 5-1 Especificaciones de los datos usados**

Para una mejor comparación de los datos, se decidió utilizar información sobre un único rodamiento, manteniendo la misma frecuencia de muestreo, variando lo relacionado a la potencia del motor, al diámetro de la falla y a la zona donde se produce la misma.

### 5.3 Características de la señal de vibración

Luego de un análisis y estudio sobre las características estadísticas que más información aportan a las redes neuronales aplicadas en trabajos similares, se decidió utilizar las siguientes: [22]

- Raíz valor cuadrático medio

$$x_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (5.3.1)$$

- Desviación estándar

$$\sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (5.3.2)$$

- Valor medio absoluto

$$\bar{x}_{abs} = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (5.3.3)$$

- Skewness

$$\sum_{i=1}^N \frac{(x_i - \bar{x})^3}{N\sigma^3} \quad (5.3.4)$$

- Valor máximo de peak

$$\hat{x} = \max(x_i) \quad (5.3.5)$$

- Factor de forma

$$\frac{x_{rms}}{\bar{x}_{abs}} \quad (5.3.6)$$

- Kurtosis

$$\sum_{i=1}^N \frac{(x_i - \bar{x})^4}{N\sigma^4} \quad (5.3.7)$$

## 5.4 Métricas de rendimiento

[23] El poder evaluar de buena forma el funcionamiento y los resultados que genera la red al ejecutar los datos procesados previamente resulta de gran importancia para poder conocer el grado de exactitud en el diagnóstico de las fallas analizadas. Para esto, en este trabajo se consideran las métricas de exactitud, sensibilidad y especificidad. Estas métricas se generan en base a los siguientes errores de prueba:

- Verdaderos Positivos (VP): número de éxitos. En este contexto corresponden al número de fallas detectadas correctamente.
- Verdaderos Negativos (VN): número de rechazos correctos. En este contexto corresponden al número de inexistencia de fallas detectadas correctamente.
- Falsos Positivos (FP): número de falsas alarmas. En este contexto corresponden al número de fallas detectadas, siendo que en realidad no eran fallas.
- Falsos Negativos (FN): En este contexto corresponden al número de inexistencia de fallas detectadas, siendo que en realidad si eran fallas.

Las métricas a utilizar se definen de la siguiente forma:

- Exactitud: corresponde al total de datos bien clasificados, ya sea con falla o sin falla, dentro del total de datos clasificados.

$$\text{Exactitud} = \frac{VP + VN}{VN + VP + FN + FP} \quad (5.4.1)$$

- Sensibilidad: corresponde a la probabilidad de que un rodamiento realmente fallado sea detectada como tal por la prueba.

$$\text{Sensibilidad} = \frac{VP}{VP + FN} \quad (5.4.2)$$

- Especificidad: corresponde a la probabilidad de que un rodamiento sin falla sea detectado como tal por la prueba.

$$\text{Especificidad} = \frac{VN}{VN + FP} \quad (5.4.3)$$

- Valor Predictivo Positivo: corresponde a la probabilidad de que un rodamiento tenga una falla si se obtiene un resultado positivo en el test.

$$VPP = \frac{VP}{VP + FP} \quad (5.4.4)$$

- Valor Predictivo Negativo: corresponde a la probabilidad de que un rodamiento con un resultado negativo en la prueba realmente no presente falla.

$$VPN = \frac{VN}{VN + FN} \quad (5.4.5)$$

## 5.5 Resultados

### 5.5.1 Modelo clasificación normal

La implementación y puesta en marcha de la red neuronal se llevó a cabo utilizando distintos valores para las variables participantes e involucradas en la red. Así, se varió el número de nodos en la capa oculta entre {3,5,7,9}, el número de épocas varió entre {1000,1500,2000} y el porcentaje de training varió entre {75%,80%,85%}, haciendo variar también el porcentaje de testing.

Se comenzó utilizando 5 características (raíz valor cuadrático medio, desviación estándar, valor medio absoluto, skewness y valor máximo de peak) para la entrada de la red y trabajando con un solo tipo de fallo (anillo interno), por lo que la red cuenta con 2 nodos de salida.

Luego, al probar con cada una de las combinaciones posibles, la red generó los siguientes valores de exactitud para cada caso:

Hidden Nodes \ Epoch		% Training								
		0.75			0.80			0.85		
		1000	1500	2000	1000	1500	2000	1000	1500	2000
3	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
5	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
7	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
9	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0

Figura 5-5 Matriz de exactitud con 5 características y un tipo de fallo

En todas las combinaciones de esta situación, la red neuronal diagnosticó con un 100% de exactitud la existencia o inexistencia de fallos a través de los datos.

### 5.5.2 Modelo clasificación con tipos de fallos

Al obtener estos resultados, se optó por agregar un tipo de fallo (anillo externo) en la problemática, manteniendo el resto de las variables y condiciones exactamente igual. Con esto, se mantuvieron los nodos de salida cambiando la interpretación de sus valores entregados. Esto se hizo modificando el Target del Entry agregando una nueva columna para identificar el nuevo tipo de fallo. Luego, al probar con cada una de las combinaciones posibles, la red generó los siguientes valores de exactitud para cada caso:

Hidden Nodes \ Epoch		% Training									Prom. Nh
		0.75			0.80			0.85			
		1000	1500	2000	1000	1500	2000	1000	1500	2000	
3	0,6333330	0,6333330	0,6333330	0,7013890	0,7013890	0,6388890	0,7129630	0,7083330	0,7037040	<b>0,6740740</b>	
5	0,7166670	0,7138890	0,6333330	0,7048610	0,7013890	0,7013890	0,7129630	0,6620370	0,7129630	<b>0,6954990</b>	
7	0,7166670	0,6361110	0,6333330	0,6388890	0,7013890	0,6701390	0,7129630	0,7129630	0,7083330	<b>0,6811986</b>	
9	0,6333330	0,6972220	0,6333330	0,6701390	0,6979170	0,6979170	0,7129630	0,7083330	0,7129630	<b>0,6849022</b>	
Prom. c/epoch	<b>0,6750000</b>	<b>0,6701388</b>	<b>0,6333330</b>	<b>0,6788195</b>	<b>0,7005210</b>	<b>0,6770835</b>	<b>0,7129630</b>	<b>0,6979165</b>	<b>0,7094908</b>		
Prom. Training	0,6594906			0,6854747			0,7067901				

Figura 5-6 Matriz de exactitud con 5 características y dos tipos de fallos

Al agregar otro tipo de fallo, la red neuronal bajó considerablemente sus valores de exactitud. Se destacan con un tono rojo aquellas combinaciones donde el nivel de exactitud fue menor a un 65%, con un tono celeste aquellas donde el nivel de exactitud fue mayor a un 70%. Finalmente, se destacan en azul aquellas combinaciones que generaron el mejor nivel de exactitud. En este caso, se obtuvieron los mejores resultados (71,66% de exactitud) utilizando un 75% de Training, 1000 epochs y 5 o 7 nodos ocultos. A pesar de lo anterior, se aprecia que con un 85% de Training, el 91,6% de las combinaciones obtuvo un nivel mayor al 70% de exactitud, lo cual indica que a medida que se va aumentando el porcentaje de Training en general va mejorando la exactitud.

Con esta disminución considerable de exactitud al agregar un tipo de fallo, se buscó mejorar a través de la inclusión de más características en el modelo, agregando el factor de forma y la kurtosis, manteniendo el resto de las variables y condiciones exactamente igual.

Posteriormente, al probar con cada una de las combinaciones posibles, la red generó los siguientes valores de exactitud para cada caso:

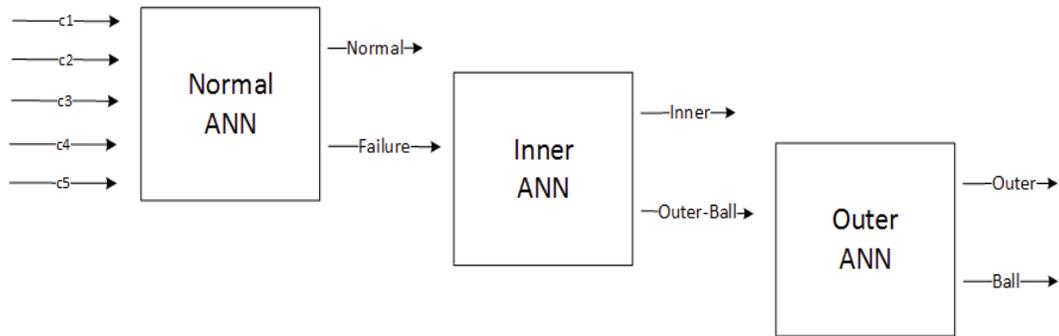
		% Training									Prom. Nh
		0.75			0.80			0.85			
Hidden Nodes \ Epoch		1000	1500	2000	1000	1500	2000	1000	1500	2000	
3		0,7000000	0,7000000	0,7000000	0,6944440	0,6666670	0,6944440	0,6944440	0,6944440	0,7037040	0,6942386
5		0,7000000	0,7000000	0,7000000	0,6944440	0,6944440	0,6631940	0,6898150	0,6851850	0,6944440	0,6912807
7		0,6694440	0,6972220	0,6444440	0,6944440	0,6666670	0,6493060	0,6898150	0,6805560	0,6944440	0,6762602
9		0,6694440	0,6416670	0,6444440	0,6736110	0,7048610	0,6944440	0,7407410	0,6990740	0,6990740	0,6852622
Prom. c/epoch		0,6847220	0,6847223	0,6722220	0,6892358	0,6831598	0,6753470	0,6913580	0,6898148	0,6979165	
Prom. Training		0,6805554			0,6825808			0,6930298			

Figura 5-7 Matriz de exactitud con 7 características y dos tipos de fallos

Al agregar dos características, se puede apreciar que la mejor combinación aumenta en cerca de 2,4% la exactitud que en el caso anterior donde se utilizaban 5 características. También se puede apreciar que la mayoría de las combinaciones tiende a neutralizarse en cuanto a su nivel de exactitud en comparación a la situación anterior donde se apreciaban valores muy altos y muy bajos. A nivel de promedio, sigue siendo en general mejor la opción de utilizar un 85% de Training. La combinación que alcanza el mejor nivel de exactitud (74,07%) es aquella donde se utilizan 9 nodos en la capa oculta, 1000 epochs y un 85% de Training.

### 5.5.3 Modelo clasificación en cascada

Al reducir considerablemente la exactitud obtenida en el segundo modelo al intentar diagnosticar de qué tipo de falla son los datos no clasificados como normales, se instaló la inquietud sobre generar un nuevo modelo que fuera capaz de clasificar distintos tipos de fallas de buena manera. Para esto se tomó en consideración la buena clasificación que se logró con el primer modelo, el cual era capaz de diagnosticar bien de forma binaria, esto quiere decir que clasifica correctamente al discriminar si los datos en cuestión pertenecen o no a una clase. Teniendo esto en consideración, la mejor opción encontrada fue la de realizar más de una red de clasificación, diagnosticando en cada una de ellas un tipo de falla. Con esto, se tienen  $n-1$  redes, siendo  $n$  la cantidad de tipos de datos a diagnosticar. Lo anterior se puede ver reflejado en la siguiente figura:



**Figura 5-8 Estructura modelo clasificación en cascada**

Así, la entrada del modelo siguen siendo las características matemáticas trabajadas en los modelos anteriores. La salida de la primera red neuronal (Normal ANN) clasifica los datos en normales y con fallas. Con esto, ya se obtienen todos los datos ingresados al modelo que no corresponden a una falla, el resto ingresa a la segunda red (Inner ANN), la cual se encarga de diagnosticar los datos que corresponde al tipo de falla de anillo interno. Los que no son considerados de ese tipo pasan a la siguiente red ya que no corresponden a datos normales ni a datos de fallas de anillo interno. Ya en la última red (Outer ANN) se realiza la discriminación de los datos entre los tipos de fallo de anillo externo y de bola, con lo cual todos los datos en algún momento son clasificados por el modelo.

Para realizar las pruebas de este modelo se utilizaron 7 nodos ocultos, 2000 épocas y un porcentaje de training del 85%, teniendo así un testing del 15%. Todos estos valores fueron utilizados luego de encontrarlos como los más óptimos después de analizar diferentes combinaciones de valores. Cabe destacar que se utilizaron las mismas características del primer modelo.

Normal	Interno	Externo	Bola
X097	X106	X130	X118
X098	X111	X198	X186
X099	X112	X236	X224
X100	X169	X237	X3008

**Figura 5-9 Archivos de datos usados en prueba 1**

Primero, se comenzó utilizando en el modelo 4 archivos de datos de cada tipo de condición posible del rodamiento, teniendo así un ingreso equitativo de información para la red. Con esto, se obtuvieron 3840 datos en cada una de las 5 características matemáticas que ingresan a la red. Luego de procesar la información, el modelo entrega como resultado una exactitud del 100%.

Con esta exactitud en la clasificación, se decidió realizar más pruebas enfocadas en testear las distintas combinaciones resultantes al ingresar proporciones distintas de archivos de datos para cada tipo de falla a diagnosticar.

En la prueba 2, el objetivo fue comprobar la sensibilidad del modelo al ingresar solo un archivo de datos de un tipo de fallo y 4 archivos de datos en el resto de los tipos de fallos. Lo

anterior pudiendo pensar en que la red pudiera obviar de cierta forma el tipo de falla con menor información. Así, cada característica contempla 3120 datos para ingresar en cada red. Las combinaciones de archivos ingresadas fueron las siguientes:

Normal	Interno	Externo	Bola
X097	X106	X130	X118
X098	X111	X198	
X099	X112	X236	
X100	X169	X237	

Normal	Interno	Externo	Bola
X097	X106	X130	X118
X098		X198	X186
X099		X236	X224
X100		X237	X3008

Normal	Interno	Externo	Bola
X097	X106	X130	X118
X098	X111		X186
X099	X112		X224
X100	X169		X3008

Normal	Interno	Externo	Bola
X097	X106	X130	X118
	X111	X198	X186
	X112	X236	X224
	X169	X237	X3008

**Figura 5-10 Archivos de datos usados en prueba 2**

En cada una de las 4 combinaciones mostradas en la figura anterior, el modelo diagnosticó con un 100% de exactitud los datos ingresados.

Siguiendo con la misma idea de la prueba anterior, se realizó una nueva prueba, esta vez ingresando un archivo de datos en dos tipos de fallas y 4 archivos en los restantes tipos, generando 2400 datos por entrada a cada red. La combinación de archivos para la prueba 3 fue la siguiente:

Normal	Interno	Externo	Bola
X097	X106	X130	X118
X098	X111		
X099	X112		
X100	X169		

Normal	Interno	Externo	Bola
X097	X106	X130	X118
	X111	X198	
	X112	X236	
	X169	X237	

Normal	Interno	Externo	Bola
X097	X106	X130	X118
X098		X198	
X099		X236	
X100		X237	

Normal	Interno	Externo	Bola
X097	X106	X130	X118
	X111		X186
	X112		X224
	X169		X3008

Normal	Interno	Externo	Bola
X097	X106	X130	X118
X098		X198	X186
X099		X236	X224
X100		X237	X3008

Normal	Interno	Externo	Bola
X097	X106	X130	X118
		X198	X186
		X236	X224
		X237	X3008

**Figura 5-11 Archivos de datos usados en prueba 3**

Nuevamente, el modelo volvió a clasificar correctamente la información entregada en cada una de las combinaciones que se pueden apreciar en la figura anterior.

Finalmente, se realizó una última prueba ingresando solo un archivo de datos en 3 tipos de fallas y 4 archivos para la falla restante. Todo esto pensando en que la desproporción de información a utilizar generara una clasificación muy tendenciosa hacia el tipo de falla con mayores datos. En cuanto a las entradas de la red, cada característica contempla 1920 datos. Las combinaciones de archivos que se probaron fueron las siguientes:

Normal	Interno	Externo	Bola
X097	X106	X130	X118
X098			
X099			
X100			

Normal	Interno	Externo	Bola
X097	X106	X130	X118
	X111		
	X112		
	X169		

Normal	Interno	Externo	Bola
X097	X106	X130	X118
		X198	
		X236	
		X237	

Normal	Interno	Externo	Bola
X097	X106	X130	X118
			X186
			X224
			X3008

**Figura 5-12 Archivos de datos usados en prueba 4**

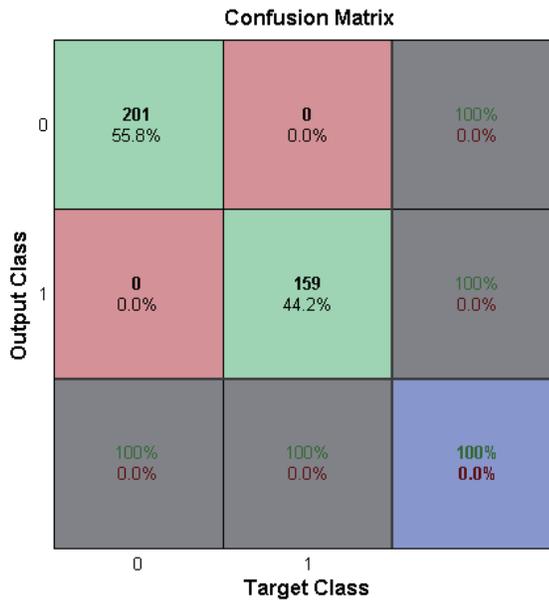
Como en todas las pruebas anteriores, para cada una de las combinaciones expresadas previamente se obtuvo un 100% de exactitud en la clasificación de las 4 categorías posibles de los datos.

Con las pruebas realizadas se puede concluir que en el modelo propuesto no influye la cantidad de información que se utilicen, ya que independiente del número de datos que se le ingresen por cada tipo de fallo las redes que son parte del modelo son capaces de clasificar de forma binaria correctamente.

## 5.6 Matriz de confusión

Para analizar las salidas de cada red del modelo propuesto, se analiza la matriz de confusión que genera cada una de ellas luego de realizar la clasificación de los datos. Ejemplificando, se utiliza una combinación donde se requieren clasificar 360 datos en normal, fallo interno, fallo externo y fallo de bola, todo esto en la fase de testing.

De acuerdo al modelo, la primera red neuronal se encarga de clasificar los datos entre normales y con fallas. Los resultados se pueden ver expresados en la siguiente matriz de confusión:



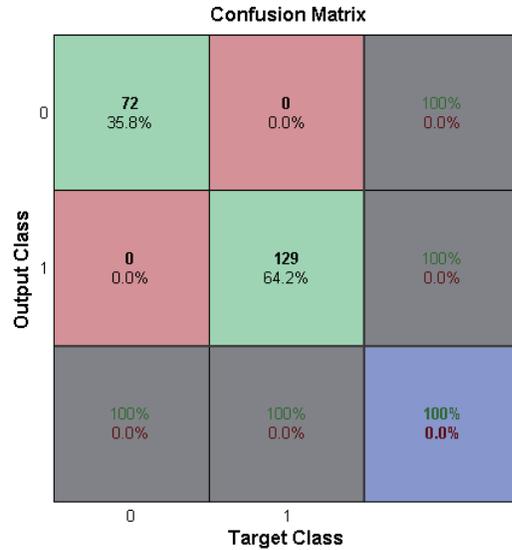
**Figura 5-13 Matriz de confusión primera red modelo cascada**

La matriz de confusión muestra visual y gráficamente la clasificación que realiza la red neuronal, mostrando las asignaciones correctas e incorrectas, lo cual refleja el nivel de “confusión” que el sistema tuvo realizando el diagnóstico.

En el ejemplo que se muestra, las filas (Output Class) hacen referencia a las salidas que generó la red por cada clase, en este caso 0 corresponde a datos con fallas y 1 a datos normales (sin fallas). Las columnas (Target Class) hacen referencia a las salidas que debería haber generado la red de acuerdo a cada clase. Con esto, se busca la mayor cantidad de datos en la diagonal, ya que ahí se encuentran los verdaderos positivos (VP, posición (1,1) en la matriz) y los verdaderos negativos (VN, posición (0,0) en la matriz). Por consecuencia, el ideal es contar con el mínimo de valores en el resto de las casillas. En este caso, se clasificaron 159 datos como normales y 201 con fallas, generando un 100% de exactitud en la clasificación. Esto se aprecia en la casilla correspondiente en la última fila y columna de la matriz.

Los valores de la última fila hacen referencia a la sensibilidad y los de la última columna a la especificidad. Ambas detalladas en la sección de este trabajo llamada Métricas de rendimiento.

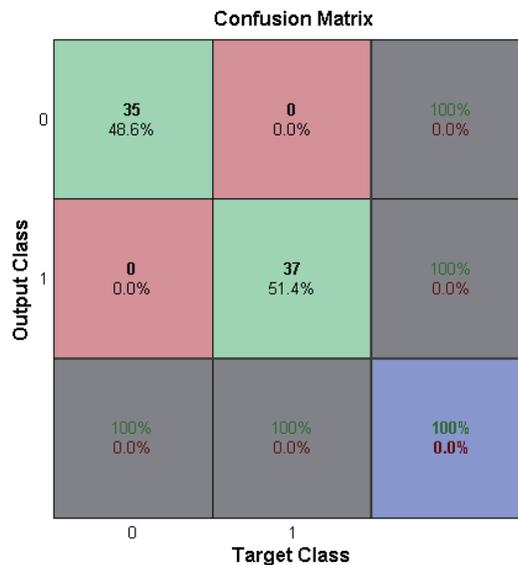
Siguiendo con el ejemplo, los 201 datos que no fueron clasificados como normales pasan a la segunda red del modelo, la cual se encarga de evaluar si dichos datos pertenecen o no al tipo de fallo de anillo interno. La matriz de confusión que generó esta red es la siguiente:



**Figura 5-14 Matriz de confusión segunda red modelo cascada**

Como se aprecia en la figura, de los 201 datos que pasaron a la segunda red, 129 fueron clasificados como de tipo de falla de anillo interno. Aquí se obtiene también un 100% de precisión en la clasificación de cada clase, obteniendo el mismo valor para la sensibilidad y la especificidad.

El resto de los datos (72), no han sido clasificados ni como normales ni como pertenecientes al tipo de falla de anillo interno, por lo cual pasan a la tercera y última red, la que genera la siguiente matriz de confusión:



**Figura 5-15 Matriz de confusión tercera red modelo cascada**

Finalmente, en la última matriz se aprecia la clasificación de aquellos datos que no pertenecían a las clases vistas previamente. Aquí se diagnostican 37 datos como pertenecientes al tipo de falla de anillo externo, los cuales corresponden a la casilla central de la matriz. Por lo tanto, el resto de los datos, al no ser clasificados como normales, de falla de anillo interno ni externo, terminan siendo catalogados como datos de tipo de falla de bola. Nuevamente, los valores de precisión, sensibilidad y especificidad son de un 100% para cada clase.

En resumen, y considerando cada una de las matrices de confusión obtenidas con las redes del modelo, la matriz final que generaliza toda la clasificación y que obtiene los mismos valores en cada métrica de rendimiento que las anteriores, se presenta en la siguiente figura:

**Confusion Matrix**

Output Class	1	159 44,167%	0 0%	0 0%	0 0%	100% 0%
	2	0 0%	129 35,833%	0 0%	0 0%	100% 0%
	3	0 0%	0 0%	37 10,278%	0 0%	100% 0%
	4	0 0%	0 0%	0 0%	35 9,722%	100% 0%
	100% 0%	100% 0%	100% 0%	100% 0%	100% 0%	100% 0%
		1	2	3	4	
		<b>Target Class</b>				

Figura 5-16 Matriz de confusión ejemplo modelo cascada

## 5.7 Aproximación valores de salida RNA

Al trabajar en clasificación de manera binaria, lo que se espera es poder decidir si un dato pertenece o no a una clase determinada, lo cual se hace a través de la asignación de un 1 en el caso que corresponda a la clase y un 0 en el caso contrario. En este sentido, la red neuronal no siempre entrega el valor exacto de 1 o de 0, en algunos casos genera valores muy cercanos, por lo cual se aproximan al estar tan cerca de lo requerido. Los valores reales que la red genera se pueden visualizar en el siguiente ejemplo:

Salida	Normal	Con falla
1	1	0
2	0.9894	0.0106
3	0.9931	0.0069
4	1	0
5	0.9958	0.0042
6	0	1
7	0	1
8	0.0205	0.9795
9	0.0092	0.9908
10	0	1

**Figura 5-17 Valores reales de salida RNA**

Como se observa en la figura, se tomó una muestra aleatoria de 10 salidas generadas por la primera red del modelo, la que distingue si un dato proviene de una falla o no. En muchos casos la red neuronal entrega valores exactos en la clasificación, pero en otros llega a cifras que están en un vecindario muy acotado en relación a los objetivos. En estos casos se aproximan dichas cifras, ya que al estar tan cercas de lo esperado no revierten mayor importancia ni diferencia en la clasificación final, lo cual se puede comprobar con el correcto diagnóstico entregado por el modelo, evaluaciones que se realizaron de distintas formas y que se encuentran expresadas previamente.

## 5.8 Influencia velocidad del motor

Una vez probada la red en el modelo anterior con distintas características y variables, cabe cuestionarse la influencia que tienen los datos en este modelo en relación a las características bajo las cuales son obtenidos. Esto es sumamente importante al momento de evaluar el tipo de información que se ingresa a la red para poder obtener buenos resultados. Lo anterior se puede apreciar evaluando las respuestas (salidas) que genere la red de acuerdo a los estímulos (entradas) que se le otorguen.

La evaluación se realizó en tres etapas. Primero, comparando los valores resultantes al ingresar un conjunto de datos sin fallas obtenidos con una velocidad fija de rotación del motor y diversos conjuntos de datos con fallas obtenidos con distintas velocidades de rotación del motor, todo esto de forma independiente. Después, se realizó el mismo procedimiento, en esta ocasión con los datos mezclados, es decir, ingresando un conjunto de datos sin fallas y diversos datos con fallas al mismo tiempo. Finalmente, se realizó ingresando una mezcla de varios conjuntos de datos sin fallas con varios conjuntos de datos con fallas, todos obtenidos con distintas velocidades de rotación del motor.

Cabe destacar que todos los datos, tanto los normales (sin fallas) como los con fallas, cuentan con la misma frecuencia de muestreo (12k hz) y pertenecen a la lectura del

acelerómetro ubicado en el mismo rodamiento (DE). Además, todos los datos con fallas utilizados para esta evaluación corresponden al mismo tipo (anillo interno) y tamaño de falla (0.007”). Todo esto con el fin de mantener todas estas propiedades constantes y variar solamente la velocidad con la que rota el motor, pudiendo así obtener conclusiones claras sobre esta última propiedad.

Para comenzar se fueron probando todas las posibles combinaciones entre un archivo de datos sin fallas y 4 diversos conjuntos de datos con fallas, cada uno de estos últimos con distintas velocidades de rotación del motor (RPM). Estas combinaciones, al ingresarlas al modelo, generaron los siguientes resultados de exactitud:

		Con fallas				
Archivo		X112	X111	X106	X105	
RPM		1730	1750	1772	1797	
Sin fallas	X097	1797	1.0	1.0	1.0	1.0
	X098	1772	1.0	1.0	1.0	1.0
	X099	1750	1.0	1.0	1.0	1.0
	X100	1730	1.0	1.0	1.0	1.0

**Figura 5-18 Resultados exactitud 1ª etapa evaluación**

Los resultados indicaron que, independiente de la combinación que se utilizara para ingresar como entrada al modelo, éste genera una exactitud del 100%. En otras palabras y a modo de ejemplo, al mezclar datos sin fallas obtenidos bajo una velocidad de 1797 rpm con datos con fallas obtenidos bajo una velocidad de 1730 rpm e ingresarlos al modelo, éste funciona correctamente diagnosticando si un dato proviene o no de una falla. Lo mismo al variar cada una de las velocidades.

Luego de realizar la primera etapa, se pensó en realizar una segunda etapa, esta vez mezclando todos los datos con fallas, generando así un único conjunto de datos con fallas. Luego, se probó juntando un archivo de datos sin fallas con el conjunto de datos mezclado con anterioridad. Esto se realizó con cada uno de los archivos de datos sin fallas. Los resultados fueron los siguientes:

		Con fallas	
Archivo		X112 - X111 - X106 - X015	
RPM		1730 - 1750 - 1772 - 1797	
Sin fallas	X097	1797	1.0
	X098	1772	1.0
	X099	1750	1.0
	X100	1730	1.0

**Figura 5-19 Resultados exactitud 2ª etapa evaluación**

Si bien esto generó un aumento considerable en la cantidad de datos a trabajar en el modelo, sólo supuso un aumento en el tiempo de ejecución del sistema, no así en los

resultados que este generó. La exactitud en cada una de las combinaciones fue, al igual que en la primera prueba, de un 100%.

Para terminar de confirmar los resultados y poder dar una clara y fundamentada opinión con respecto a la influencia de la velocidad de rotación del motor en el modelo, se pensó en mezclar todos los datos, tanto con y sin fallas, generando así un único archivo con datos. Este archivo sirve como entrada al modelo. Al realizar esto, se obtiene lo siguiente:

			Con fallas
	Archivos		X112 - X111 - X106 - X015
		RPM	1730 - 1750 - 1772 - 1797
Sin fallas	X097 - X098 - X099 - X100	1797 - 1772 - 1750 - 1730	1.0

**Figura 5-20 Resultados exactitud 3ª etapa evaluación**

En la última etapa de la evaluación, nuevamente se obtiene un 100% de exactitud en el diagnóstico de los datos, pudiendo así discriminar sobre si un dato obtenido de una señal proviene de una falla o no. Con esto, una vez mezclados todos los datos posibles (que cumplen con ser obtenidos bajo las mismas condiciones) se puede confirmar que la variación de la velocidad de rotación del motor no influye en el modelo, el cual sigue entregando el mismo nivel de exactitud.

## 6 Conclusiones

Primero, se entiende de manera general la importancia del poder lograr diagnosticar a tiempo las fallas que generan los rodamientos y engranajes, debido principalmente a que afectan en parte importante a las máquinas y estructuras en las cuales se encuentran. En esto son varios los factores que influyen, y al entender sus estructuras, sus características y principales tipos de fallas que sufren, se sustenta una base inicial de conocimiento necesario para el desarrollo posterior del diagnóstico de estas fallas. Esto hace concluir en primera instancia la importancia que tiene el diagnóstico de fallos dentro de los procesos de mantención en la industria. En base a esto, se comprende la forma en que se afronta la problemática, teniendo claridad sobre los datos que se utilizarán, la forma en que fueron obtenidos y además, la veracidad con la que cuentan los mismos al ser utilizados en muchos otros proyectos de este tipo.

De la misma forma en que se concluyó la importancia del lograr comprender de muy buena manera el contexto de la problemática, se hace importante el lograr comprender el funcionamiento del mecanismo a utilizar para afrontar el diagnóstico de fallas en maquinarias. Es así que al analizar amplia y detalladamente las redes neuronales artificiales se puede obtener la información necesaria para su útil, correcta y posterior utilización. Con esto se concluye que las redes neuronales artificiales son una herramienta muy poderosa para el procesamiento de datos dentro de la inteligencia artificial, y en particular, al tratamiento de datos de fallas en general. Se logra comprender la importancia que tiene tanto la problemática en sí, así como los beneficios que puede traer para quienes apliquen el diagnóstico de fallas en todo ámbito.

Otro punto importante tiene relación con la implementación de la red neuronal, donde se hace relevante la comprensión de la red propiamente tal para así poder ocuparla de la mejor manera posible obteniendo resultados mejores. En primera instancia, se obtiene un 100% de exactitud en el diagnóstico de la señal en relación a discriminar si se está en presencia o no de un fallo. Luego, se logra obtener un 74% de exactitud al diagnosticar dos tipos de fallas distintas de un mismo rodamiento. Si bien es cierto que dicho valor fue el mejor encontrado luego de probar una gran cantidad de combinaciones en los factores influyentes en la red neuronal, también se hace relevante en la parte de ejecución el aporte significativo que generan las características estadísticas obtenidas desde la señal de vibración de los rodamientos, lo cual se ve reflejado en el aumento de la exactitud al agregar más características. Esto hace pensar que una buena alternativa sería centrarse en mejorar el modelamiento de dichas características para obtener mejores resultados finales con la red neuronal.

Una de las situaciones más relevantes durante el proceso de desarrollo fue la de estar constantemente buscando una mejor solución utilizando lo adquirido en cuanto a conocimientos a medida que avanzaba el proyecto. Esto fue de vital importancia para llegar a dar con el último modelo propuesto, denominado modelo en cascada, el cual finalmente es el que mejores resultados entrega y satisface lo requerido y planteado inicialmente en la problemática a solucionar, logrando una clasificación del 100% en cuanto a exactitud de los diferentes tipos de fallas a los que se puede ver expuesto un rodamiento.

Finalmente es importante evaluar no sólo la red neuronal en sí, sino que también el comportamiento y la sensibilidad que tienen los datos en el modelo de acuerdo a sus características y propiedades con las que son capturados por los acelerómetros. Esto es muy relevante, ya que una mala evaluación en este sentido haría que probablemente se genere una mala influencia en la red neuronal y por ende, en los resultados que se obtengan. Bajo esta perspectiva, se logró concluir que la velocidad de rotación del motor no influye en este modelo, algo que genera mayor seguridad al capturar los datos, ya que independiente de la variación en las RPM del motor que pueda generar una falla en el rodamiento, el modelo no variará en su diagnóstico.

## 7 Referencias

- [1] P. V. J. Rodriguez and A. Arkkio. "*Detection of Stator Winding Fault in Induction Motor Using Fuzzy Logic*". Applied Soft Computing vol. 8, pp. 1112-1120, 2008.
- [2] S. Nandi and H. A. Toliyat. "*Fault diagnosis of electrical machines-a review*". In Electric Machines and Drives, 1999. International Conference IEMD '99, 1999, pp. 219-221.
- [3] Kumar H, Dr. Srinivasa Pai, Dr. Sriram N, Vijay G, *ANN based evaluation of performance of wavelet transform for condition monitoring of rolling element bearing*, Department of Mechanical Engineering, NMAM Institute of Technology, Nitte University, India, Department of Mechanical Engineering, Vidya Vikas Institute of Engineering and Technology, India, Department of Mechanical and Manufacturing Engineering, M I T, Manipal University, India.
- [4] Lili A. Wulandhari, Antoni Wibowo and Mohammad I. Desa. *Improvement of Adaptive GAs and Back Propagation ANNs Performance in Condition Diagnosis of Multiple Bearing System using Grey Relational Analysis*. Bina Nusantara University, Indonesia. UUM College of Arts and Sciences, Universiti Utara, Malaysia. Advanced Informatics School, Universiti Teknologi Malaysia, Malaysia.
- [5] Edgar Espejo Mora y Jim Gonzalo García. *Modos de fallas comunes en rodamientos*. Departamento de Ingeniería Mecánica y Mecatrónica, Universidad Nacional de Colombia, Bogotá, Colombia. 2008
- [6] Marc Thomas. *A Numerical Model to Predict Damaged Bearing Vibrations*. Journal of Vibration and Control, 2007.
- [7] Shaohui Zhang and Weihua Li. *Bearing Condition Recognition and Degradation Assessment under Varying Running Conditions Using NPE and SOM*. South China University of Technology, China. Xi'an Jiaotong University, China, May 2014.
- [8] Edward Max Bertot, Pierre-Philippe Beaujean, and David Vendittis. *Refining Envelope Analysis Methods using Wavelet De-Noising to Identify Bearing Faults*. Florida Atlantic University, Boca Raton, FL, United States.
- [9] Zhongqing WEI, Zhinong JIANG, Bo MA, Xin ZHONG, Jinji GAO. *Incipient Fault Diagnosis of Rolling Element Bearing Based on Wavelet Packet Transform and Energy Operator*. Beijing University of Chemical Technology, Beijing, China. The First Research Institute of the Ministry of Public Security, Beijing, China.
- [10] Segla M, Shaoping Wang and Fang Wang. *Bearing fault diagnosis with an improved high frequency resonance technique*. Sch. of Autom. & Electr. Eng., Beihang Univ., Beijing, China. July 2012.

- [11] Zhanguo Xia, Shixiong Xia, Ling Wan, and Shiyu Cai. *Spectral Regression Based Fault Feature Extraction for Bearing Accelerometer Sensor Signals*. School of Computer Science and Technology, China University of Mining and Technology, Xuzhou, Jiangsu, China. 2012.
- [12] Qingbo He, Xiangxiang Wang and Qiang Zhou. *Vibration Sensor Data Denoising Using a Time-Frequency Manifold for Machinery Fault Diagnosis*. Department of Precision Machinery and Precision Instrumentation, University of Science and Technology of China, Hefei, China. Department of Systems Engineering and Engineering Management, City University of Hong Kong, Tat Chee Avenue, Hong Kong, China. 2012.
- [13] Shuen-De Wu, Po-Hung Wu, Chiu-Wen Wu, Jian-Jiun Ding, and Chun-Chieh Wang. *Bearing Fault Diagnosis Based on Multiscale Permutation Entropy and Support Vector Machine*. Department of Mechatronic Technology, National Taiwan Normal University, Taipei, Taiwan. Department of Electrical Engineering, National Taiwan University, Taipei, Taiwan. Mechanical and Systems Research Laboratories, Industrial Technology Research Institute, Hsinchu, Taiwan. July 2012.
- [14] S. Haykin. *Neural Networks. A Comprehensive Foundation*. Macmillan Publishing Company, 1994.
- [15] Myriam Cayre, Jordane Malaterre, Sophie Scotto-Lomassese, Colette Strambi and Alain Strambi. *The common properties of neurogenesis in the adult brain: from invertebrates to vertebrates*. Comparative Biochemistry and Physiology Part B: Biochemistry and Molecular Biology. Volume 132, Issue 1, May 2002, Pages 1-15
- [16] Leocadio Hontoria García, *Generación de series sintéticas de radiación solar combinando herramientas estadísticas y redes neuronales*, Universidad de Jaén Escuela Politécnica Superior, 2002.
- [17] El Prisma, Redes Neuronales, fecha de recuperación: 18 de junio de 2012, [http://www.elprisma.com/apuntes/ingenieria\\_de\\_sistemas/redesneuronales/default.asp](http://www.elprisma.com/apuntes/ingenieria_de_sistemas/redesneuronales/default.asp)
- [18] Eva Andrade Tepán, *Estudio de los principales tipos de redes neuronales y las herramientas para su aplicación*, Universidad Politécnica Salesiana, Febrero de 2013.
- [19] O. Stephan and A. Zomaya. *Handbook Of Bioinspired Algorithms And Applications*. CHAPMAN and HALL/CRC, 2005.
- [20] HAGAN, Martin T., DEMUTH, Howard B, and BEALE, Mark H, *Neural Network Design*, Brooks/Cole Publishing Company, USA, 1996.
- [21] WILAMOWSKI, Bogdan M., KAYNAK, Okyay, IPLIKCI, Serdar and EFE, M. Onder. *An Algorithm for Fast Convergence in Training Neural Networks*, IEEE, 2001.
- [22] Weihua Li Tielin Shi Guanglan Liao Shuzi Yang. "Feature extraction and classification of gear faults using principal component analysis", Journal of Quality in Maintenance Engineering, Vol. 9 Iss 2 pp. 132 – 143, 2003.

[23] Cecilia Montt, Nibaldo Rodríguez. *Análisis de accidentes de tránsito con máquinas de soporte vectorial LS-SVM*. Escuela de Transporte, Escuela de Informática, Facultad de Ingeniería PUCV, Chile. XV Chileno de Ingeniería de Transporte, 2011.