

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

**REDES NEURONALES ELMAN CON VALORES
SINGULARES PARA EL DIAGNÓSTICO DE LA SEVERIDAD
DE FALLOS EN EQUIPOS DE ROTACIÓN**

Aníbal Edinson Rodríguez Carrasco

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

VALPARAÍSO
DICIEMBRE 2016

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

**REDES NEURONALES ELMAN CON VALORES
SINGULARES PARA EL DIAGNÓSTICO DE LA SEVERIDAD
DE FALLOS EN EQUIPOS DE ROTACIÓN**

Aníbal Edinson Rodríguez Carrasco

Profesor guía: **Nibaldo Rodríguez Agurto**

Carrera: **Ingeniería Civil Informática**

VALPARAÍSO
DICIEMBRE 2016

Índice

Dedicatoria.....	iv
Resumen	v
Listas de Figuras	vi
Lista de Tablas	vii
1 Introducción.....	1
1.1 Definición de objetivos.....	3
1.1.1 Objetivos generales.....	3
1.1.2 Objetivos específicos	3
2 Estado del arte.....	4
2.1 Métodos existentes para el diagnóstico de fallas de rodamientos	4
2.2 Descomposición en valores singulares	5
2.3 Redes neuronales artificiales.....	6
2.3.1 Redes neuronales recurrentes	7
2.4 Análisis de modo y efecto de fallas	8
3 Marco teórico.....	10
3.1 Valores singulares.....	10
3.2 Energía relativa.....	10
3.3 Levenberg-Marquardt	12
3.4 Funciones de transferencia.....	13
3.5 Análisis de fallas potenciales	13
4 Análisis de resultados.....	15
4.1 Modelo de detección de fallas de rodamientos	15
4.1.1 Topología del modelo	15
4.1.2 Definición de ETL	16
4.1.3 Preparación de los datos.....	17
4.1.4 Clasificación	19
4.1.5 Métricas de rendimiento.....	20
4.1.6 Resultados	21
4.2 Modelo de diagnóstico de la severidad con 2 diámetros de falla	24
4.2.1 Topología del modelo	24

4.2.2	Definición de ETL	25
4.2.3	Preparación de los datos.....	26
4.2.4	Clasificación	28
4.2.5	Métricas de rendimiento.....	28
4.2.6	Resultados	29
4.3	Modelo de diagnóstico de la severidad con 3 diámetros de falla.....	31
4.3.1	Topología del modelo	31
4.3.2	Definición ETL.....	32
4.3.3	Preparación de los datos.....	33
4.3.4	Clasificación	35
4.3.5	Métricas de rendimiento.....	35
4.3.6	Resultados	36
5	Conclusión	40
6	Referencias	41

Dedicatoria

Le dedico este logro a mis padres amorosos que me instaron día a día a alcanzar lo imposible, y a mi esposa e hijo por su paciencia y comprensión.

Resumen

En este proyecto de título, es propuesta una estrategia utilizando descomposición valores singulares y una red neuronal recurrente (RNR) Elman para diagnosticar la severidad de fallo de rodamiento bajo condiciones de operación variable. La estructura de la RNN fue calibrada usando el algoritmo de aprendizaje de Levenberg-Marquardt (LM) y la mejor topología encontrada está constituida con 5 nodos de entrada, 6 nodos ocultos y 10 nodos de salida, cada nodo de salida representa un nivel de severidad de daño del rodamiento. Durante la fase de producción el modelo propuesto obtuvo una exactitud promedio de 99.73% correspondiente a veintes ejecuciones aleatoria de las muestras de testing.

In this project, a strategy using singular values decomposition and a recurrent neural network (RNR) Elman is proposed to diagnose the severity of bearing failure under variable operating conditions. The structure of the RNN was calibrated using the learning algorithm of L-M and the best topology found is constituted with 5 input nodes, 6 hidden nodes and 10 output nodes, each output node represents a level of damage severity of the bearing. During the production phase, the proposed model obtained an average accuracy of 99.73% corresponding to twenty random executions of the testing samples.

Listas de Figuras

Figura 1 Visualización de los componentes de un rodamiento	1
Figura 2 Entorno de toma de pruebas de los rodamientos	2
Figura 3 Capas de una red neuronal artificial.....	7
Figura 4 Visualización de la estructura de una red neuronal Elman.....	8
Figura 5 Representación de alta y baja frecuencia de la señal	11
Figura 6 Descripción funcionamiento red neuronal Elman.....	13
Figura 7 Evolución de la falla en el tiempo.....	14
Figura 8 Topología: Modelo de detección de fallas de rodamientos.....	15
Figura 9 ETL: Modelo de detección de fallas de rodamientos.....	16
Figura 10 Comparación características 4 salidas.....	18
Figura 11 Diagrama de preparación de datos 4 salidas.....	19
Figura 12 Peor caso clasificación modelo detección	22
Figura 13 Mejor caso clasificación modelo detección.....	23
Figura 14 Topología: Modelo diagnóstico con 2 diámetros de falla	24
Figura 15 ETL: Modelo de diagnóstico con 2 diámetros.....	25
Figura 16 Comparación características 7 salidas.....	27
Figura 17 Preparación de datos: Modelo de diagnóstico con 2 diámetros.....	28
Figura 18 Peor caso clasificación modelo diagnóstico con 2 diámetros.....	29
Figura 19 Mejor caso clasificación modelo diagnóstico con 2 diámetros	30
Figura 20 Topología: Modelo diagnóstico con 3 diámetros.....	31
Figura 21 ETL: Modelo de diagnóstico con 3 diámetros.....	32
Figura 22 Comparación características 10 salidas.....	34
Figura 23 Preparación de datos: Modelo diagnóstico con 3 diámetros	35
Figura 24 Resultados casos de prueba: 75-25% Modelo diagnóstico con 3 diámetros	36
Figura 25 Resultados casos de prueba: 80-20% Modelo diagnóstico con 3 diámetros	37
Figura 26 Resultados casos de prueba: 85-15% Modelo diagnóstico con 3 diámetros	38

Lista de Tablas

Tabla 1 Resultados casos de prueba: Velocidad constante y diámetro variable	21
Tabla 2 Resultados casos de prueba: Velocidad variable y diámetro constante.....	21
Tabla 3 Resultados casos de prueba: Todo variable con 2 diámetros.....	29
Tabla 4 Resultados casos de prueba: Todo variable con 3 diámetros.....	36
Tabla 5 Robustez del modelo final de diagnóstico con 3 diámetros.....	39

1 Introducción

Los rodamientos son aquellos componentes mecánicos que permiten a las máquinas rotativas como la transmisión de un camión o una turbina eólica ejercer movimientos radiales o axiales. Estos elementos creados por el ingeniero Sven Gustaf existen de distintas formas, y presentan una probabilidad de falla sobre el 40%, y aunque estas fallas imposibilitan a la máquina a funcionar con normalidad, no solamente afectan su operación, sino también pueden producir interrupción de la producción, pérdidas económicas y en algunos casos víctimas mortales [1,2].

Así también, es necesario destacar que existe una gran variedad de rodamientos y cada uno de ellos tienen características diferentes que los definen. Sin embargo, este documento se centra en los rodamientos rígidos de bola como el que se puede ver en la figura 1. Es sumamente importante, saber si los daños del rodamiento se producen en bolas, en el anillo interno o en el anillo externo, ya que estrías en su superficie que no sean detectadas pueden generar un gran daño en la máquina. Esta alta probabilidad de fallo se ve generadas por las causas siguientes:

- Desgaste: Se presentan fallas de este tipo causadas por partículas abrasivas que se introducen en el rodamiento, por una lubricación inadecuada y por un desgaste producido por las vibraciones que pueda haber experimentado la máquina en producción.
- Identación: Esto se presenta cuando se montan de manera incorrecta los rodamientos, o partículas contaminantes se introducen.
- Corrosión: Se presenta cuando el rodamiento tiene óxido muy arraigado.
- Paso de corriente eléctrica
- Grietas: Esto ocurre por manipulación brusca de los rodamientos, por adherencias, y por corrosión de contacto.
- Daño en la jaula: Esto se presenta por vibraciones externas al rodamiento, una velocidad excesiva de la máquina, un desgaste natural, u otra causa de daño en la jaula.

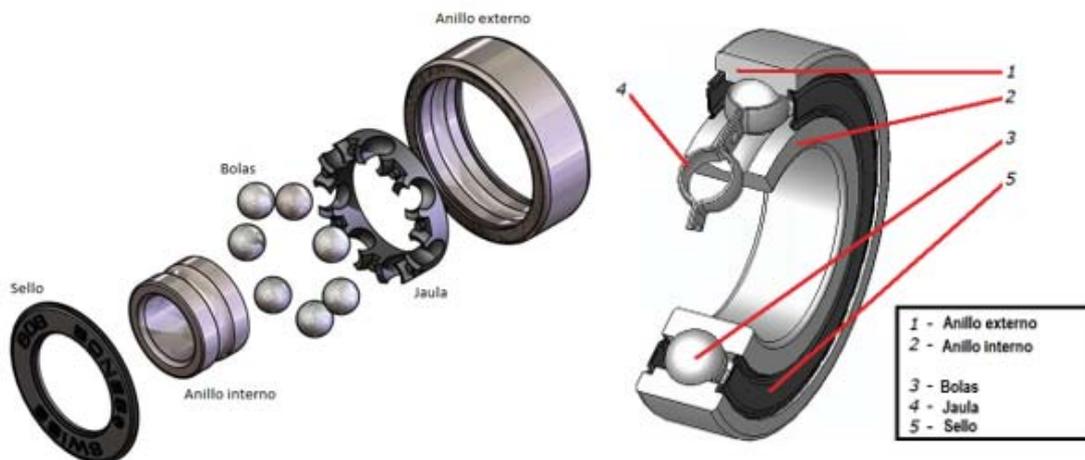


Figura 1 Visualización de los componentes de un rodamiento

Se han desarrollado una gran cantidad de técnicas de diagnóstico de fallas de rodamientos en base a vibraciones. Generalmente, estas pueden ser divididas en paramétricas y no paramétricas. Cuando se utiliza un método no paramétrico, las señales pueden ser analizadas en el dominio del tiempo, usando parámetros como la kurtosis y factores de cresta [3,4]; en el dominio de la frecuencia, con la transformada de Fourier rápida (FFT) [5], y en el dominio del tiempo-frecuencia se utilizan técnicas como la transformada Wavelet [6,7]. Por otro lado, cuando se tiene un método paramétrico, las señales de vibración se entienden más como series de tiempo, y es así como tenemos modelos autoregresivos, descomposición de valores singulares para procesar entradas para redes neuronales, entre otros.

Para la demostración de pruebas se utiliza la información que brinda la Universidad Case Western Reserve en un sitio web de acceso público del centro de datos de rodamientos [10]. En la cual, para la captura de datos se realizó como se puede visualizar en la figura 2, donde se colocó un rodamiento en el componente del extremo del rodamiento (DE) y otro en el ventilador del extremo del rodamiento (FE). Y posteriormente se colocaron 3 acelerómetros, uno en cada rodamiento y otro en la placa base de soporte del motor (BA). Estas pruebas se realizaron con un motor de 2 HP y un motor de inducción de trifásico. Una máquina de descarga eléctrica se utilizó para introducir defectos en los anillos y elementos de bolas de diferentes rodamientos con diámetros de fallo de 0,007, 0,014, y 0,021 pulgadas, y una profundidad de 0,011 pulgadas.

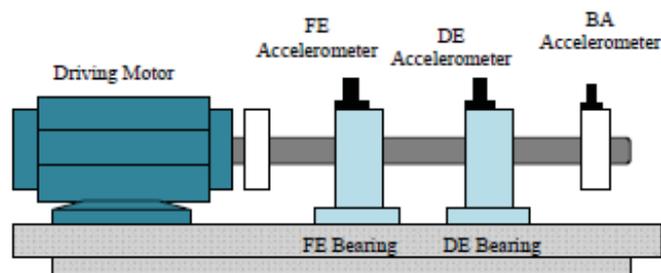


Figura 2 Entorno de toma de pruebas de los rodamientos

Este trabajo está organizado como sigue: Definición del problema e introducción, donde se abala la necesidad de un buen modelo, la definición de objetivos de este documento, luego el estado del arte y el marco teórico que brinden conocimientos teóricos para comprender el modelo, y finalmente el análisis de los resultados.

1.1 Definición de objetivos

1.1.1 Objetivos generales

Desarrollar un modelo de clasificación usando descomposición de valores singulares (SVD) y redes neuronales recurrentes Elman para diagnosticar la severidad de fallas en rodamientos de equipos rotativos bajo condiciones operación variable.

1.1.2 Objetivos específicos

- Extraer las características de fallos desde la señal de vibración usando diagonalización de matrices basada en descomposición de valores singulares.
- Diseñar e implementar la estructura de un clasificador neuronal usando el algoritmo de aprendizaje Levenberg-Marquardt.
- Evaluar el desempeño del modelo propuesto bajo condiciones de operación variable.

2 Estado del arte

Cuando hablamos del diagnóstico y detección fallas de rodamientos, es menester saber que es una práctica desarrollada por años y por distintos métodos. Como, por ejemplo, el hecho que uno de las primeras publicaciones de diagnóstico de rodamientos fue realizado por Baldeston en 1969 [11]. El reconoció que las señales generadas por las fallas de rodamientos estaban representadas por las regiones de alta frecuencia que eran generados por los impactos internos, e investigo las frecuencias de los anillos y elementos de los rodamientos.

En la actualidad, los rodamientos son componentes de suma importancia en las máquinas industriales y debido a su rol crítico es importante monitorear su condición y así evitar que fallen durante el período de producción. Se sabe que, la falla de rodamientos es una de las razones más frecuentes de avería de las máquinas. Aproximadamente el 45% de las fallas son debido a rodamientos. Además, encuestas realizadas por el instituto de investigación de energía eléctrica (EPRI) indican que las fallas relacionadas a los rodamientos están sobre el 40% entre las fallas más frecuentes en motores de inducción, lo cual es mencionado en [12].

Existen 3 métodos principales que se utilizan en la detección de fallas: el análisis de vibración, ruido y onda, análisis de temperatura y el análisis de partículas en el aceite [13]. Y en cuanto a herramientas se pueden encontrar aplicaciones que utilizan solo el álgebra lineal como la descomposición en valores singulares (SVD) y la matriz de Hankel [14], en adición encontramos la utilización de la transformada de Wavelet [15] y finalmente y no menos importantes aplicaciones que utilizan redes neuronales artificiales [12]. Sin embargo, se propone un método que a pesar de no ser tan complejo puede obtener buenos resultados, al nivel de utilizar grandes herramientas como las wavelets.

2.1 Métodos existentes para el diagnóstico de fallas de rodamientos

Recientemente, existen muchas técnicas que pueden ser usadas para monitorear la condición de un rodamiento, como el monitoreo de ruido, de temperatura, de corriente, pero la más efectiva es la de vibraciones. Porque, entre las ventajas del monitoreo de vibraciones se tiene capacidad de detectar, localizar y distinguir diferentes tipos de fallas desde su creación antes de que sean críticos y peligrosos. En cuanto a estos, podemos mencionar modelos publicados durante los últimos 10 años.

Así es como tenemos, por ejemplo, el diagnóstico de fallas múltiples para rodamientos de equipos rotativos basado en el método de descomposición de modo empírico (EEMD) y maquinas vectoriales de soporte optimizado [16]. En este caso, la señal es descompuesta de forma adaptiva en varias funciones de modo intrínseco (IMFs) por la EEMD. Luego se extraen dos tipos de características, la entropía de la energía de la EEMD y los valores singulares de la matriz cuyas filas son IMFs. La entropía de la energía de la EEMD se usa para especificar si el rodamiento tiene fallas o no. Si este tiene fallas, los valores singulares se ponen en la SVM optimizada multi-clase por la distancia inter-clúster en el espacio de características (ICDSVM) para especificar el tipo de falla. Y con este método, obtiene resultados prometedores de exactitud en sus experimentos con exactitudes

por sobre el uso de EEMD con redes neuronales artificiales de un rango de 77-99,83% dependiendo del experimento, utilizando la misma base de datos que en este trabajo.

Si ahora dejamos las máquinas vectoriales, del cual está lleno de papers con variantes, encontramos un modelo basado en la descomposición de paquetes de wavelet y una red neuronal BP (Backpropagation) [17]. A grandes rasgos, para eliminar el ruido de la señal original, se utiliza un método muy común de descomposición de la wavelet y su reconstrucción para extraer los vectores de características de la energía, los cuáles resultan útiles para la clasificación de la red. Y cuando hablamos de este método obtiene solamente un 92,5% de exactitud.

Por otro lado, tenemos las regresiones [18], con un método de pretratamiento avanzado de la señal y con autoregresión. La que puede ser dividida en dos grandes etapas para su comprensión: primero está el pretratamiento de la señal, el cual se basa en varios procedimientos de análisis, incluyendo la reducción de ruido usando SSA, la estacionalización de la señal y el modelado AR. Y segundo, el diagnóstico de la señal el cual está basado en un proceso de reconocimiento de patrones. En este caso, se logra el 100% en varios casos de prueba, correspondiente a paquetes con velocidad constante y diámetro variable, sin embargo, a velocidad constante de 1750 RPM, presenta una exactitud de 89%, lo que hace que el modelo en general, no sea totalmente confiable.

Así también tenemos, un ejemplo de un método que no ocupa la misma base de datos, se tiene un modelo utilizando Análisis multi-resolución y una red neuronal perceptrón multicapa, donde para el procesamiento de la señal ocupa descomposición de wavelets, luego para la selección de patrones ocupa la selección de coeficientes de wavelet y finalmente clasifica con la red neuronal ya mencionada. Cabe destacar este modelo, porque además de no ser la misma base de datos, se repite que el modelo no alcanza una exactitud del 100% tampoco, incluso utilizando hasta 30 nodos ocultos.

Y para terminar tenemos un paper publicado en octubre del 2017 que establece que la gran debilidad de las redes neuronales es el tiempo de entrenamiento, por lo que, propone un estrategia con SWT (Stationary Wavelet Transform) y SVD (Descomposición en valores singulares) para incrementar la exactitud del clasificador, el cuál utiliza una red neuronal feedforward ELM (Extreme Learning Machine). Y de esta forma, logran un 100% de exactitud con tan solo 5 características, lo que hace de la estrategia de este proyecto una opción más complicada en procesamiento, pero más simple de entender.

2.2 Descomposición en valores singulares

La descomposición en valores singulares (SVD) es una matriz de factorización popular que se ha utilizado ampliamente desde que se desarrolló un algoritmo eficiente para su cálculo en los 70's. Sin embargo, fue descubierta alrededor de 100 años atrás independientemente por Eugenio Beltrami (1835-1899) y Camille Jordan (1838-1921) [19]. James Joseph Sylvester (1814-1897), Erhard Schmidt (1876-1959), y Hermann Weyl (1885-1955) también descubrieron la SVD usando diferentes métodos [20]. Por otro lado, el desarrollo en los 60's de métodos para la computación para la SVD transformó el campo de la algebra lineal en lo que conocemos ahora.

Se establece en el contexto del texto, que la SVD es un método numérico en álgebra lineal que establece que una matriz $[A]$ del rango l , puede ser descompuesta como el

producto de tres matrices. Una matriz ortogonal [U], una matriz diagonal [S] y una matriz [V]^T la cuál es la transpuesta de la matriz [V], como se ha descrito en [19].

Dado que [U] y [V] son ortogonales podemos afirmar que $U \cdot U^T = I$ y $V \cdot V^T = I$. En adición, se define la matriz [S] como $(\sigma_1, \sigma_2, \dots, \sigma_L)$ donde $L = \min(m, n)$. En consecuencia, de lo anterior, los elementos σ_i ($i=1, 2, \dots, L$) son llamados los valores singulares de la matriz [A].

Cuando se utiliza la SVD, se pueden establecer métodos para aplicarla como imaginación se tenga, sin embargo, en este documento se utilizará un enfoque orientado a la energía según la investigación mencionada por Rowayda A. Sadek [20]. La cuál establece que, la SVD es un método estable y efectivo para dividir el sistema en conjunto de componentes linealmente independientes, donde cada uno de ellos tiene su aporte energético al sistema.

El concepto de orientado a la energía es una herramienta para separar señales de diferentes fuentes, o para seleccionar subespacios de señal de actividad de la señal máxima y la integridad que esta tenga. En relación al tema del documento, estaría separando la señal de las fallas y la del ruido [20].

En la práctica, el problema principal del uso de la SVD en el procesamiento de señales es la estimación del umbral del ruido para separar los datos sin contaminar de los indeseados [21]. Para el caso del diagnóstico de rodamientos se utilizará la normalización y se analizará la convergencia de la señal, y analizando así cuando la energía relativa de la señal es despreciable, y así poder establecer un umbral que traiga buenos resultados.

Finalmente, en la actualidad la SVD se ha convertido en la llave maestra de la ciencia en la pelea con gigantes conjuntos de datos y surge aparentemente en todas las disciplinas. Esta se ha aplicado en reconocimiento facial [22], para ordenar el genoma humano [23], búsqueda de base de datos textual [24], robótica [25], matemáticas financieras [26], detección comprimida [27], etc.

2.3 Redes neuronales artificiales

Las redes neuronales artificiales (ANN) son extensamente usadas en la ciencia y la tecnología. Estas, nacen de la necesidad para abordar problemas de la vida real que no podían ser resueltos mediante simples algoritmos. Es por esto, que se considera emular las características humanas como memorizar, asociar hechos y resolver situaciones acudiendo a la experiencia [20].

Su historia y cómo evolucionó para transformarse en lo que hoy conocemos es distinguida, como el hecho de que el primer personaje que investigó las características del cerebro como una ayuda a la programación fue Alan Turing en 1936. En adición, contamos con el Congreso de Dartmouth en 1956 donde afirman el nacimiento de la inteligencia artificial, concepto tan connotado estos días. Y no es hasta 1974 que se comienza la discusión por el algoritmo de aprendizaje de propagación hacia atrás (Backpropagation). Sin embargo, en 1986 el algoritmo se empieza a utilizar y es de donde han nacido grandes investigaciones hasta la actualidad [28].

Las redes neuronales artificiales como modelos inspirados en la estructura básica del cerebro están conformadas por neuronas interconectadas que podemos dividir en 3 capas: en la capa de entrada que es por donde entran la información, luego tenemos una capa

oculta que mediante una transformación (función de activación) dada una estimulación se procesa la información y en la capa oculta se obtiene la información resultante, como se ve en la figura.

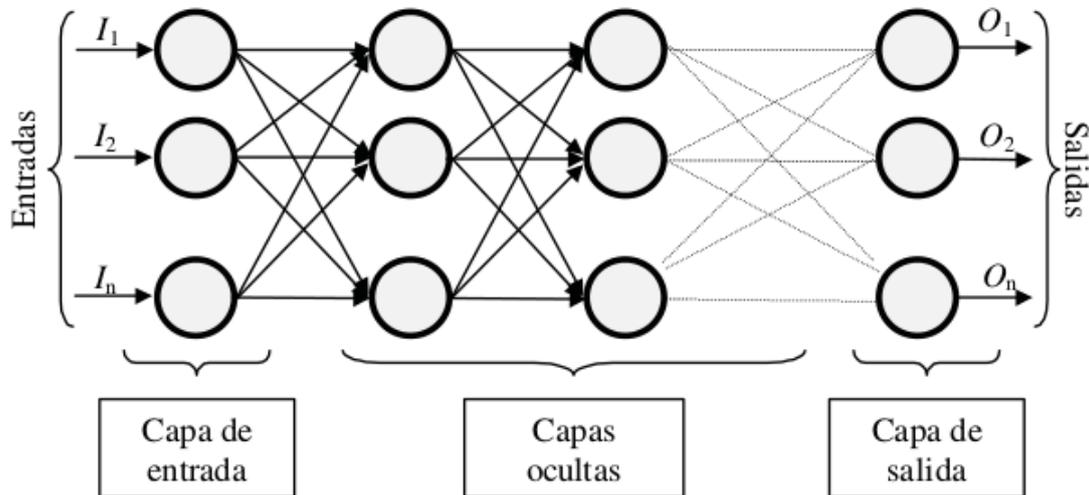


Figura 3 Capas de una red neuronal artificial

Muchos de los algoritmos usados para entrenamiento de la red neuronal artificial están empleando algún tipo de gradiente descendiente. Lo que simplemente es, tomar la derivada de la función de costo con respecto a los parámetros de la red para cambiarlos luego en la dirección relacionada al gradiente [29]. El más popular de ellos es el algoritmo Backpropagation (propagación hacia atrás) el cuál de por sí, ya tiene muchas variantes. A pesar de ser el estándar no significa que sea el más rápido para todos los casos. La forma de saber a la fecha cuál algoritmo es el apropiado es a prueba y error.

La química, la física y biología son algunas de las ramas a las que tanto ha contribuido el uso de esta herramienta. Por ejemplo, para predecir el comportamiento de reactores industriales como también para diagnosticar la tuberculosis [30]. En general, una gran cantidad de información que contenga un comportamiento a través del tiempo puede ser manejada del mismo modo. De esta forma, buscamos clasificar las fallas de los rodamientos mediante una información histórica de su funcionamiento.

2.3.1 Redes neuronales recurrentes

Las RNNs han sido usadas en un gran número de aplicaciones interesantes incluyendo memorias asociativas, clasificación de patrones espacio-temporales, control, optimización, diagnósticos, y generalización de las secuencias de patrones [31,32]. Existen las redes neuronales recurrentes completas, que utilizan arquitecturas totalmente interconectadas sin restricciones y algoritmos de aprendizaje que pueden lidiar con entradas variantes en el tiempo y/o salidas en caminos no triviales. A pesar de las modificaciones de los algoritmos de aprendizaje para reducir el costo computacional, estas redes son complicadas todavía, cuando se trata de casos complicados. Y por otro lado tenemos a las redes neuronales recurrentes simples o parciales, cuyas conexiones son principalmente de tipo feedforward, pero tienen una cantidad aceptable de conexiones feedback.

La recurrencia le permite a la red recordar pistas sobre el pasado sin complicar el aprendizaje excesivamente. La estructura propuesta por Elman en [33] es una ilustración de este tipo de arquitectura. Las RNN Elman son utilizadas y se propone ser utilizada aquí.

Una RNN Elman es una red que en principio es configurada como una red feedforward. Esto significa que todas las neuronas en la primera capa están conectadas con todas las neuronas en la siguiente capa. Sin embargo, existe otra capa llamada la capa de contexto, la cual es simplemente otra capa oculta, que en la figura 5 se puede apreciar con más claridad.

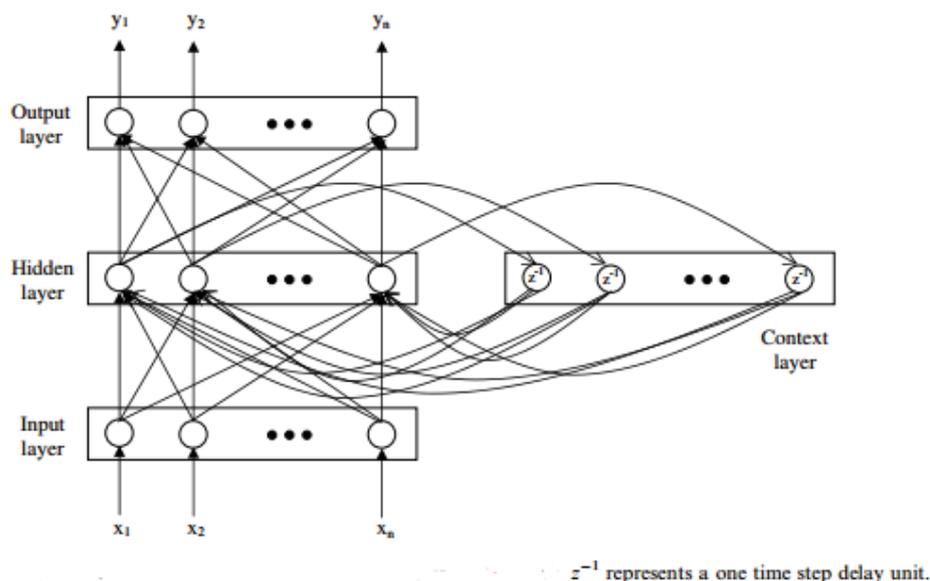


Figura 4 Visualización de la estructura de una red neuronal Elman

Las neuronas de la capa de contexto guardan una copia de la salida de la capa oculta original, o sea de las neuronal ocultas. La salida de cada neurona oculta es copiada a una neurona específica en la capa de contexto. El valor de la neurona de contexto es usado como una señal de entrada extra para todas las neuronas en la capa oculta cuando se suscita la segunda secuencia de entrada. Por lo tanto, se puede decir que las RNN Elman tienen una memoria de una secuencia de proceso de capa oculta [33].

Por último, cabe destacar que la backpropagation (o aprendizaje hacia atrás) tiene numerosos problemas para muchas aplicaciones. El algoritmo no es garantizado, sin embargo, una gran cantidad de variaciones para mejorar la convergencia del aprendizaje hacia atrás se han propuesto. Optimizaciones como métodos de segundo orden (el gradiente conjugado, quasi-Newton, Levenberg–Marquardt). En particular el algoritmo Levenberg-Marquardt erradica muchas de las limitaciones del modelo.

2.4 Análisis de modo y efecto de fallas

Esta disciplina se desarrollo en el ejercito de la Estados Unidos por los ingenieros de la National Agency of Space and Aeronautical (NASA), y era conocido como el

procedimiento militar MIL-P-1629, titulado "Procedimiento para la Ejecución de un Modo de Falla, Efectos y Análisis de criticabilidad" y elaborado el 9 de noviembre de 1949; este era empleado como una técnica para evaluar la confiabilidad y para determinar los efectos de las fallas de los equipos y sistemas, en el éxito de la misión y la seguridad del personal o de los equipos.

En 1988 la Organización Internacional para la Estandarización (ISO), publicó la serie de normas ISO 9000 para la gestión y el aseguramiento de la calidad; los requerimientos de esta serie llevaron a muchas organizaciones a desarrollar sistemas de gestión de calidad enfocados hacia las necesidades, requerimientos y expectativas del cliente, entre estos surgió en el área automotriz el QS 9000, éste fue desarrollado por la Chrysler Corporation, la Ford Motor Company y la General Motors Corporation en un esfuerzo para estandarizar los sistemas de calidad de los proveedores; de acuerdo con las normas del QS 9000 los proveedores automotrices deben emplear Planeación de la Calidad del Producto Avanzada (APQP), la cual necesariamente debe incluir AMEF de diseño y de proceso, así como también un plan de control.

Posteriormente, en febrero de 1993 el grupo de acción automotriz industrial (AIAG) y la Sociedad Americana para el Control de Calidad (ASQC) registraron las normas AMEF para su implementación en la industria, estas normas son el equivalente al procedimiento técnico de la Sociedad de Ingenieros Automotrices SAE J - 1739.

Los estándares son presentados en el manual de AMEF aprobado y sustentado por la Chrysler, la Ford y la General Motors; este manual proporciona lineamientos generales para la preparación y ejecución del AMEF.

Actualmente, el AMEF se ha popularizado en todas las empresas automotrices americanas y ha empezado a ser utilizado en diversas áreas de una gran variedad de empresas a nivel mundial.

3 Marco teórico

En pro de facilitar la comprensión del método propuesto, se brindarán definiciones para construir una base sobre lo que ya se sabe sobre las wavelets y el método para elegir su mejor configuración, para finalmente insertar los datos resultantes en la red neuronal artificial con el algoritmo de aprendizaje Levenberg-Marquardt, con la cual se espera demostrar resultados prometedores con respecto a la exactitud para diagnosticar fallas en rodamientos.

3.1 Valores singulares

Los valores singulares son objetos muy útiles en el álgebra lineal numérica y han recibido mucha atención durante los últimos años. Estos coeficientes son propios de la descomposición en valores singulares (SVD) y se definen como números reales no negativos y como las raíces cuadradas de los valores propios. Sin embargo, esto es solo en el caso en que los valores provengan de una matriz normal, lo cual quiere decir que, los valores singulares no tienen connotaciones geométricas importantes cuando se utilizan para el diagnóstico de fallas de rodamientos.

Es importante conocer que la descomposición en valores singulares es una poderosa herramienta que puede resolver problemas de mínimos cuadrados sin solución, situación donde métodos como la descomposición LU y la eliminación de Gauss fallan. En adición, cabe mencionar que el uso de la SVD brinda más precisión en estos casos, pero a un costo grande de dificultad de cómputo. Y que, además, es recomendado no usarla cuando las matrices son cuadradas y fáciles de resolver.

Tomando en cuenta que los valores singulares se obtienen de matrices bien complejas de solucionar existen sistemas sobre determinados, esto significa que existen más conexiones que imágenes, esto quiere decir que estos coeficientes pueden repetirse lo que, en el caso de este experimento, no significarán nada más que un evento aleatorio.

Por último, esta investigación aplica los valores singulares para conocer el rango de la matriz, lo cual es realmente significativo tomando en cuenta la gran cantidad de datos que se captan para esta maniobra.

3.2 Energía relativa

Con un conocimiento más acertado del informe, sabemos que la técnica PCA que utiliza la descomposición en valores singulares supone una reducción del conjunto total de datos. Ahora bien, tomamos la energía relativa del sistema porque dependerá de cada conjunto de datos la referencia para definir donde se encuentra el mayor volumen de energía concentrado.

Para proceder con el cálculo de la energía relativa, primero se debe a cada vector de valores singulares calcularse la energía total cuya fórmula es:

$$E_T = \sum_{i=1}^n \sigma_{ii}^2 \quad (3.2.1)$$

,donde
 σ_i = Valor singular i-ésimo.

Ya habiendo calculado la energía total, al vector de valores singulares le calculamos la energía relativa a cada elemento, la cual se calcula de la siguiente manera:

$$E_R(i) = \frac{\sigma_i}{E_T} * 100 \quad (3.2.2)$$

Para entender lo que se busca hacer tomando los datos con mayor energía, primero comprenderemos que la señal se compone de los siguientes componentes:

$$s(t) = X_{HF}(t) + X_{LF}(t) + n(t) \quad (3.2.3)$$

Donde,
 $s(t)$ = Señal en el tiempo t.
 $X_{HF}(t)$ = Señal alta frecuencia en el tiempo t.
 $X_{LF}(t)$ = Señal baja frecuencia en el tiempo t.
 $n(t)$ = Ruido de la señal en el tiempo t.

La figura 6, nos muestra cómo se comprende el enfoque de la frecuencia gráficamente.

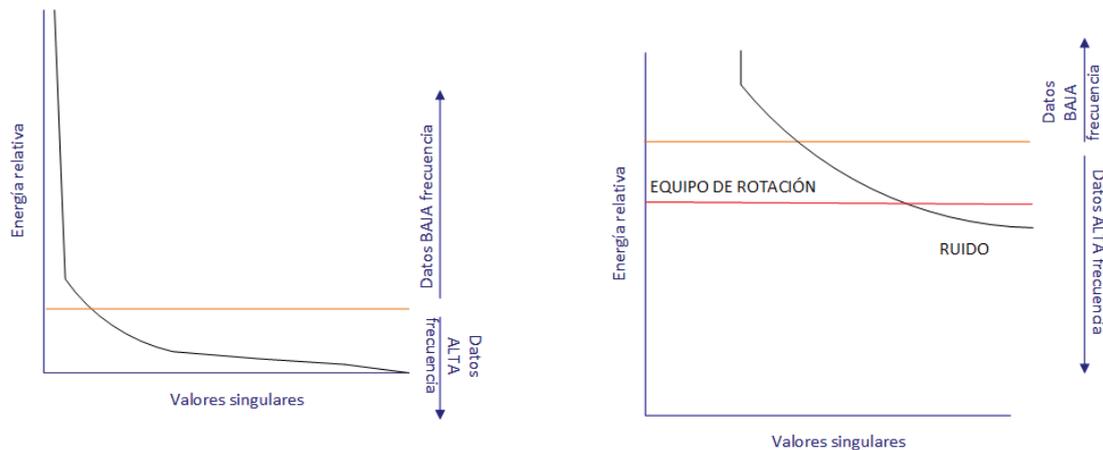


Figura 5 Representación de alta y baja frecuencia de la señal

La figura 6 busca dar a conocer que, la señal de baja frecuencia corresponde a la frecuencia de rotación, la cual es fuerte pero no es lo que queremos clasificar y tenemos la señal de alta frecuencia donde se encuentra la señal de falla y la de ruido, la cual está mezclada y es muy difícil de separar y es por esto que se genera el corte del conjunto de datos donde se

encuentre la mayor energía, dado que el remanente que quede corresponderá mayormente al ruido.

Posteriormente, con el umbral calculado que nos brinde buenos resultados de clasificación, se vuelve a componer con el rango menor.

3.3 Levenberg-Marquardt

Una red neuronal artificial que utiliza el algoritmo de backpropagation (BP) realiza entrenamiento de datos paralelos para mejorar la eficiencia de la red del perceptrón multicapa. Este es el modelo más popular, efectivo y fácil de aprender para manejar redes multicapa. Una BP es una técnica de aprendizaje supervisado, que se basa en el método del gradiente descendiente (GD) que intenta de minimizar el error de la red disminuyendo el gradiente de la curva del error. Esta se considera una generalización de la delta rule para funciones de activación no lineales y redes multicapa [34]. Para continuar, se define la ecuación de actualización de pesos:

$$W^m(k + 1) = W^m(k) - [J^T * J + \mu I]^{-1} * J^T * e \quad (3.3.1)$$

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 de los que son función, J^T 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, μ 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. [35].

Finalmente podemos decir que es el algoritmo más rápido que se ha probado para entrenar redes neuronales multicapa de tamaño moderado. Aunque su principal inconveniente es su requerimiento extensivo de memoria, que con muchos parámetros se vuelve impráctico, sin embargo, con el poder de las computadoras actuales no representa un problema con respecto al beneficio que ofrece.

3.4 Funciones de transferencia

En último caso es menester relacionar el último concepto importante, la función de transferencia. Una red neuronal recurrente simple como Elman la cual se utilizará en el método propuesto, posee típicamente dos capas, las cuales utilizan backpropagation. Por otro lado, se mencionó ya la existencia de una nueva capa: la capa de contexto. Esta capa tiene una retroalimentación hacia la entrada de la capa oculta, esto le permite aprender a reconocer y generar patrones temporales o variantes en el tiempo.

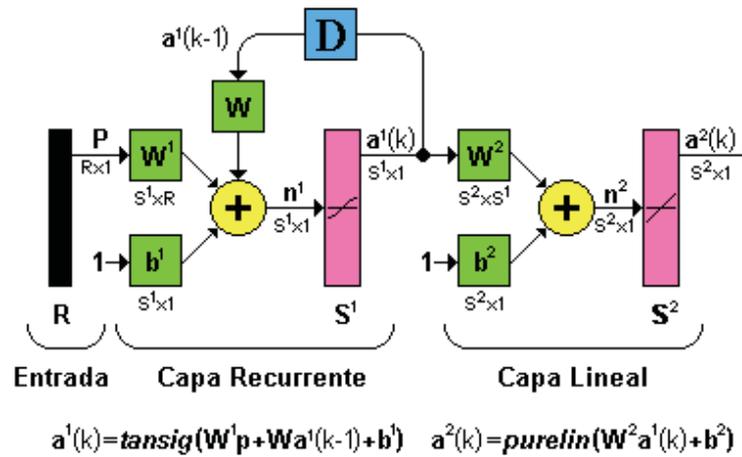


Figura 6 Descripción funcionamiento red neuronal Elman

La red de Elman generalmente posee neuronas con función transferencia sigmoideal en su capa oculta, en este caso *tansig* y neuronas con función de transferencia tipo lineal en la capa de salida, en este caso *satlins*, la ventaja de la configuración de esta red de dos capas con este tipo de funciones de transferencia, puede aproximar cualquier función con la precisión deseada mientras que esta posea un número finito de discontinuidades, para lo cual la precisión de la aproximación depende de la selección del número adecuado de neuronas en la capa oculta.

Para la red de Elman la capa oculta es la capa recurrente y el retardo en la conexión de realimentación almacena los valores de la iteración previa, los cuales serán usados en la siguiente iteración; dos redes de Elman con los mismos parámetros y entradas idénticas en las mismas iteraciones podrían producir salidas diferentes debido a que pueden presentar diferentes estados de realimentación.

3.5 Análisis de fallas potenciales

Se define como la manera en que una parte o ensamble puede potencialmente fallar en cumplir con los requerimientos de liberación de ingeniería o con requerimiento específicos del proceso. En este caso se pueden identificar los casos de falla en las siguientes categorías:

- Falla Incipiente
- Falla Medianamente Grave
- Falla Grave

Para ya obtener la severidad del daño, se debe entender la evolución de la falla funcional en el tiempo, la cual queda descrita en la figura 10.

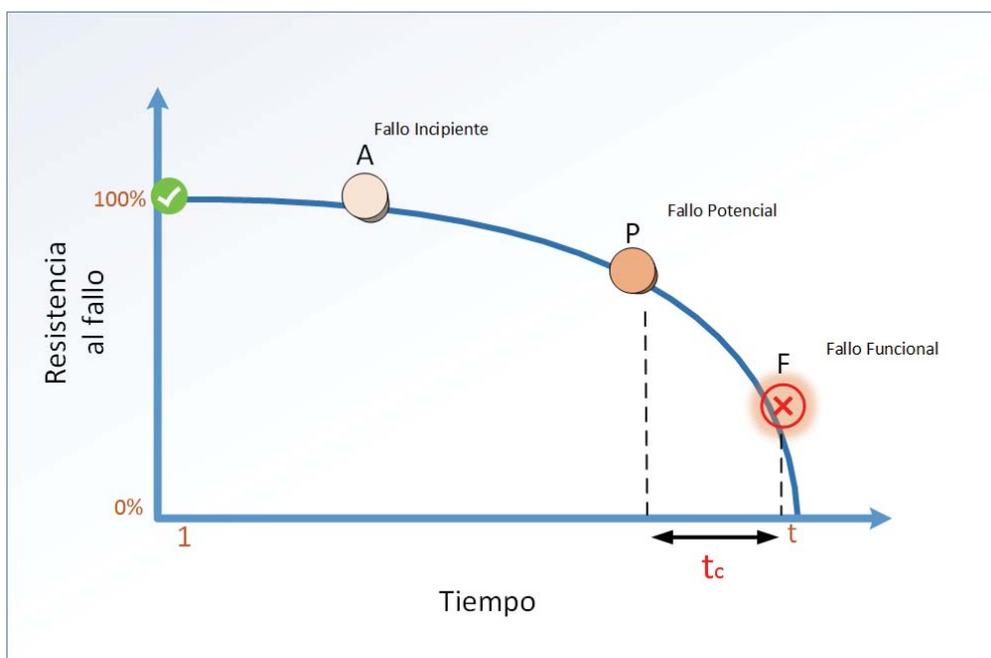


Figura 7 Evolución de la falla en el tiempo

Donde:

A: Es el punto en el que el fallo comienza a producirse (no necesariamente relacionado con la edad)

P: Punto donde podemos ver que está fallando.

F: Punto en el que falla totalmente.

Como acá se están analizando los estados de rodamientos, el hecho de que la evolución funcional se encuentre en el punto P es bastante crítico, aun cuando sea una falla leve, una gran fuerza del equipo rotativo realizada con el equipo rotativo puede saltar desde el punto P al F en poco tiempo.

4 Análisis de resultados

Habiendo expresado el conocimiento teórico necesario, se presentan los resultados obtenidos durante las pruebas, donde se comparará el modelo final de proyecto 1 con los modelos de proyecto 2, incluyendo el final.

4.1 Modelo de detección de fallas de rodamientos

En primer lugar, se pone a disposición el modelo final desarrollado en proyecto 1, el cual comprendía etapas tempranas del proyecto donde se modelaba un innovador modelo que permitiese obtener buenos resultados al solo detectar el estado del rodamiento. Donde en ese entonces, el modelo a mejorar era un conjunto de n-1 redes neuronales feedforward por estado de falla a clasificar.

4.1.1 Topología del modelo

Este modelo entrega una clasificación de 4 clases que corresponden a los 4 estados de rodamientos que entrega la base de datos utilizada; fallo de anillo interno, fallo en anillo externo, fallo en bola y estado normal.

La gran utilidad de este modelo es que se generaron situaciones más reales de las que se encuentran usualmente en las investigaciones. Se utilizaron dos tipos de casos: velocidad variable con diámetro constante, y velocidad constante con diámetro variable.

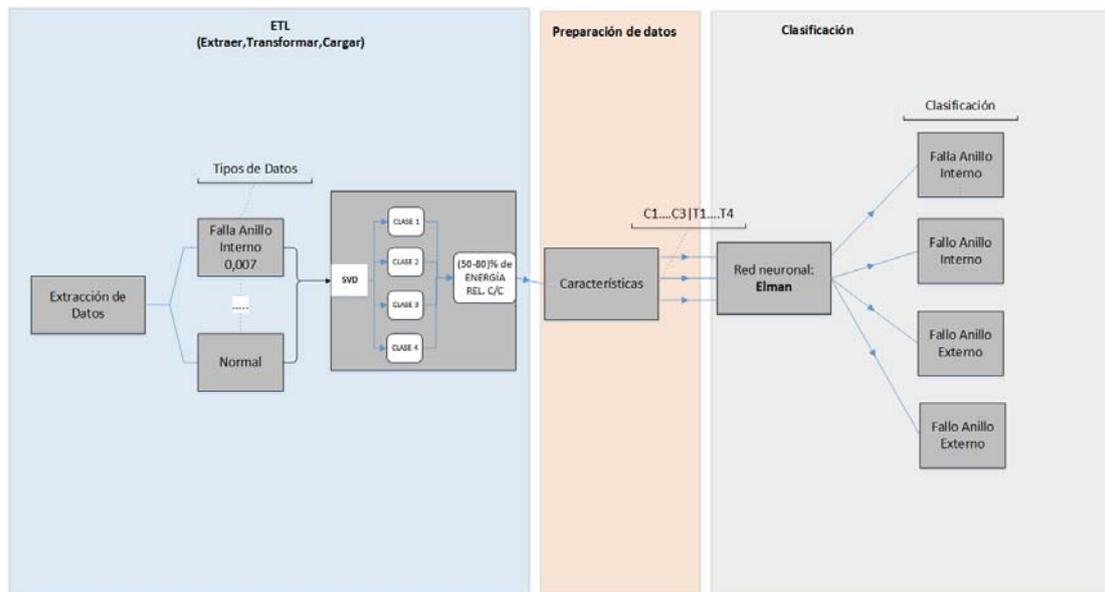


Figura 8 Topología: Modelo de detección de fallas de rodamientos

Como se puede ver en la figura superior, la topología del modelo se dividió en 3 componentes: la definición de la ETL, la preparación de datos y la clasificación. Donde cada uno será explicado a continuación.

4.1.2 Definición de ETL

Como se puede ver en la figura la ETL se compone de 3 procesos: Extraer, transformar y cargar. Con el fin, de convertir una base de datos en un conjunto o un único Datamart, que cumpla con lo que se necesita.

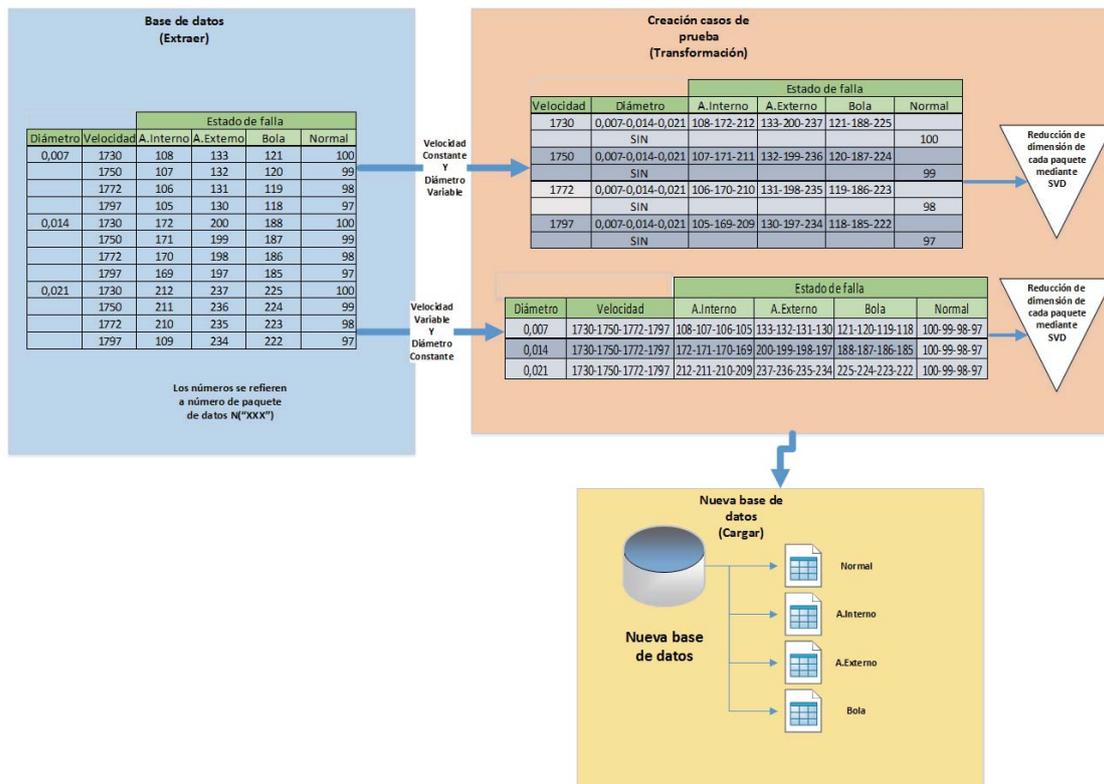


Figura 9 ETL: Modelo de detección de fallas de rodamientos

Para comenzar, tenemos los datos que tomaremos de la base de datos de la Universidad Case Western Reserve. Indexados por diámetro, la velocidad y por estado del rodamiento.

Con respecto a los números que aparecen como datos, son los nombres de los paquetes con que se identifican en la base de datos. Y de esta manera, se identificarán en todos los gráficos en este proyecto. Por otro lado, cada paquete denominado con número, por ejemplo: 108 que corresponde al anillo interno, con velocidad de 1730 y una falla de 0,007 de diámetro tienen una longitud de 120000 registros, que corresponden a las lecturas del acelerómetro.

Para continuar, se tiene la etapa de transformación donde se generarán 7 casos de prueba; 4 de velocidad constante y diámetro variable y 3 de velocidad variable y diámetro constante. En relación a los casos de velocidad constante, se toma una velocidad y se

mezclan los diámetros de falla y los datos de estado normal con respecto a esa misma, creando paquetes correspondientes a estados sin y con falla. Así también, con los casos de diámetro constante, se toma un diámetro y se mezclan las velocidades obteniendo paquetes correspondientes a estados sin y con falla.

Luego de generar los casos de prueba (7), por cada uno de ellos se obtendrá 4 paquetes: falla en anillo interno, falla en anillo externo, falla en bola y sin fallas o normal. A cada uno de ellos, se le hace una conversión donde se transforma de un vector de longitud de 120000 registros a una matriz de 120 filas y 1000 columnas, convirtiendo cada 1000 registros los que siguen en la siguiente fila de la matriz hasta terminar con la dimensión señalada.

A continuación, se le reduce la dimensión con la descomposición de valores singulares que se demostró que con el 50% de los valores singulares se alcanzan los valores con mayor energía relativa de conjunto, por lo que se disminuye cada paquete de registros de una dimensión de 120x1000 a 60x1000.

Y así, finalmente se alcanza la última etapa de la ETL, donde se generan los datamart finales para cada caso de prueba, quedando en matrices de 60x1000 por cada estado que se puede identificar en los rodamientos como se puede ver en la figura superior; falla en anillo interno, falla en anillo externo, fallo en bola y datos sin falla o normales.

4.1.3 Preparación de los datos

Como se puede ver en la imagen inferior, se tienen los 7 casos de prueba con sus datamart generados por la ETL, los cuáles serían 4 en total. Por cada caso de prueba, se tiene 4 datamart correspondiente a falla de anillo interno, falla de anillo externo, fallo en bola y sin falla o normal.

A continuación, a cada fila del datamart se le calculan 3 características: El error cuadrático medio, la entropía y la Kurtosis, las cuáles se listan aquí:

- Raíz valor cuadrático medio

$$x_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (4.1.3.1)$$

- Entropía

$$E = \sum_{i=1}^N p * \log_2(p) \quad (4.1.3.2)$$

- Kurtosis

$$K = \sum_{i=1}^N \frac{(x_i - \bar{x})^4}{N\sigma^4} \quad (4.1.3.3)$$

Estas características han demostrado ser útiles para obtener buenos resultados. Sin embargo, para ser más claros podemos ver que los valores que entregan cada una de estas características genera una diferencia intrínseca de cada datamart. Ahora bien, no siempre se generan buenos resultados por buenas características, existen casos donde depende mucho

de los datos, así es como entonces podemos ver en la figura de abajo que en los datos de falla de anillo interno es donde mejor se ve el desempeño de las características que le generará una facilidad enorme a la red neuronal para clasificar. Por otro lado, tenemos los datos de falla en bola donde la kurtosis y la entropía dan resultados similares lo que en ciertos casos aumenta la dificultad para la red neuronal para clasificar.

Con efectos prácticos se muestra a continuación las fórmulas utilizadas de las características:

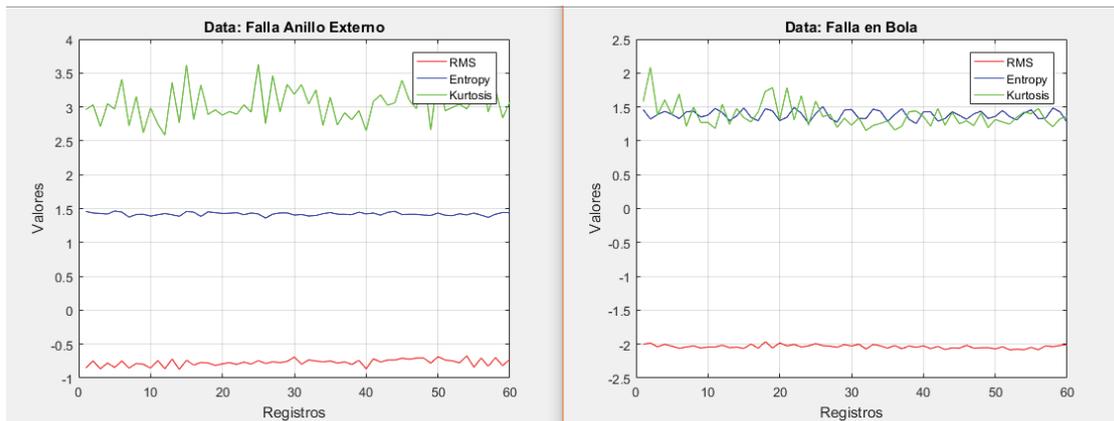


Figura 10 Comparación características 4 salidas

Después de haber calculado las 3 características a cada fila, se agregan 4 columnas con ceros a excepción de 1 que corresponderá al estado del rodamiento que pertenece. Luego de eso, se unen los 4 datamart en una sola matriz en la dirección de las filas convirtiéndose todo el caso de pruebas en una matriz de dimensión 240x7.

Cuando se tiene la matriz de dimensión 240x7, se procede a combinar las filas para que el orden de ellas no afecte en la clasificación de la red neuronal haciendo así más real el rigor del modelo. Finalmente, se debe dividir la matriz resultante en aquellos registros que servirán para entrenar a la red, de los registros que deberán ser clasificados. Así es como, dividimos proporciones que se usarán en todo el proyecto. Para cada caso de prueba tendremos 3 divisiones, 75,80 y 85% de Training y 25,20,15% de Testing respectivamente.

A continuación, se muestra un diagrama que contiene los pasos relatados aquí para la preparación de datos dando paso ya al paso denominado clasificación per sé.

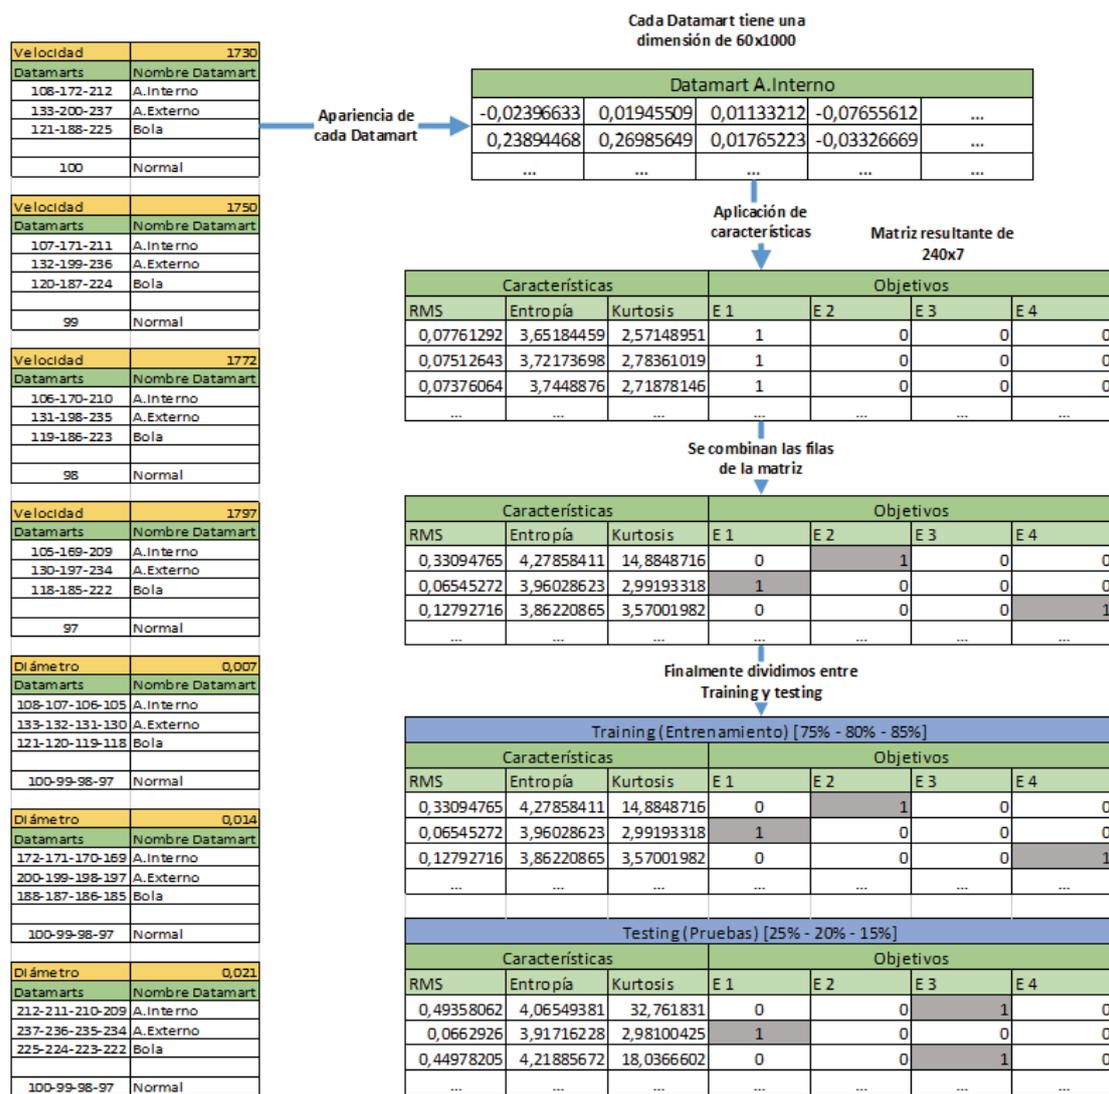


Figura 11 Diagrama de preparación de datos 4 salidas

4.1.4 Clasificación

Luego de que se tienen los datos preparados para entrar a la red neuronal recurrente simple; Elman. Tenemos que esta presenta 3 nodos de entrada que corresponden a los datos que va obteniendo de las características, el número de nodos ocultos es variable dependiendo de una evaluación que prueba de 1 a 10 nodos ocultos viendo cuál de todos obtiene menor error cuadrático medio, siendo ese el que se utiliza. Y finalmente, los nodos de salida son 4 que corresponden a las clases falla de anillo interno, falla de anillo externo, fallo en bola y datos normales, y de esta forma nos entrega cuantos registros clasificó exitosamente los que se pueden ver gráficamente con la matriz de confusión.

4.1.5 Métricas de rendimiento

Existe una forma de evaluar el proceso completo de diagnóstico, lo que resulta de gran ayuda para visualizar cuanto varían los resultados cuando se trata la misma configuración y esta se ejecuta más de una vez, también ayuda a encontrar la cantidad correcta de nodos ocultos que se necesiten e incluso determinar si los datos tienen la energía concentrada en un subconjunto pequeño del total de los datos. Es por esto, que se consideran las métricas de exactitud, sensibilidad y especificidad las cuáles 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.

$$Exactitud = \frac{VP+VN}{VN+VP+FN+FP} \quad (4.1.5.1)$$

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

$$Sensibilidad = \frac{VP}{VP+FN} \quad (4.1.5.2)$$

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

$$Especificidad = \frac{VN}{VN+FP} \quad (4.1.5.3)$$

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

$$VPP = \frac{VP}{VP+FP} \quad (4.1.5.4)$$

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

$$VPN = \frac{VN}{VN+FN} \quad (4.1.5.5)$$

Ahora bien, las métricas mencionadas generan los siguientes estados de las pruebas:

- 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.

4.1.6 Resultados

A continuación, se presentan los resultados obtenidos del modelo descrito recientemente. Sin embargo, cabe decir que no se mostrará diferencia entre la configuración de división de training y testing, porque todos los casos daban 100% de exactitud, por otro lado, para efectuar el peor y mejor caso ahí si se dirá a cuál corresponde.

Los 7 casos ya descritos se pueden dividir en dos grupos que se mostrarán a continuación:

- Velocidad constante y diámetro variable: En este grupo habrá 4 casos que corresponden cada uno a las lecturas realizadas a las 4 velocidades variando todos los diámetros existentes en la base de datos de forma de obedecer a que por acción natural u por mal uso o mantenimiento no realizado irá de un estado sin falla a diámetros de falla más grandes hasta dejar de funcionar.

		Estado de falla				
Velocidad	Diámetro	A.Interno	A.Externo	Bola	Normal	Exactitud
1730	0,007-0,014-0,021	108-172-212	133-200-237	121-188-225		100%
	SIN				100	
1750	0,007-0,014-0,021	107-171-211	132-199-236	120-187-224		100%
	SIN				99	
1772	0,007-0,014-0,021	106-170-210	131-198-235	119-186-223		100%
	SIN				98	
1797	0,007-0,014-0,021	105-169-209	130-197-234	118-185-222		100%
	SIN				97	

Tabla 1 Resultados casos de prueba: Velocidad constante y diámetro variable

- Velocidad variable y diámetro constante: En este grupo habrá 3 casos que corresponden cada uno a las lecturas realizadas que presenten un fallo de los 3 tipos de diámetros existentes en la base de datos; 0,007, 0,014, 0,021. Y de esta forma, obtener el rendimiento del algoritmo cuando una máquina trabaja a distintas velocidades con un diámetro de falla determinado.

		Estado de falla				
Diámetro	Velocidad	A.Interno	A.Externo	Bola	Normal	Exactitud
0,007	1730-1750-1772-1797	108-107-106-105	133-132-131-130	121-120-119-118	100-99-98-97	100%
0,014	1730-1750-1772-1797	172-171-170-169	200-199-198-197	188-187-186-185	100-99-98-97	100%
0,021	1730-1750-1772-1797	212-211-210-209	237-236-235-234	225-224-223-222	100-99-98-97	100%

Tabla 2 Resultados casos de prueba: Velocidad variable y diámetro constante

Ahora bien, se mostrará la mejor y peor configuración, la matriz de confusión y las métricas que apoyan la elección de las configuraciones de los casos ya mencionados. A continuación, entonces, se mostrará lo indicado:

- Caso con peor resultado: Este corresponde al caso de velocidad variable y diámetro constante, con una configuración de 75-25% de training y testing respectivamente, y este logró la clasificación con 100% de exactitud con 10 nodos ocultos y un performance regular.

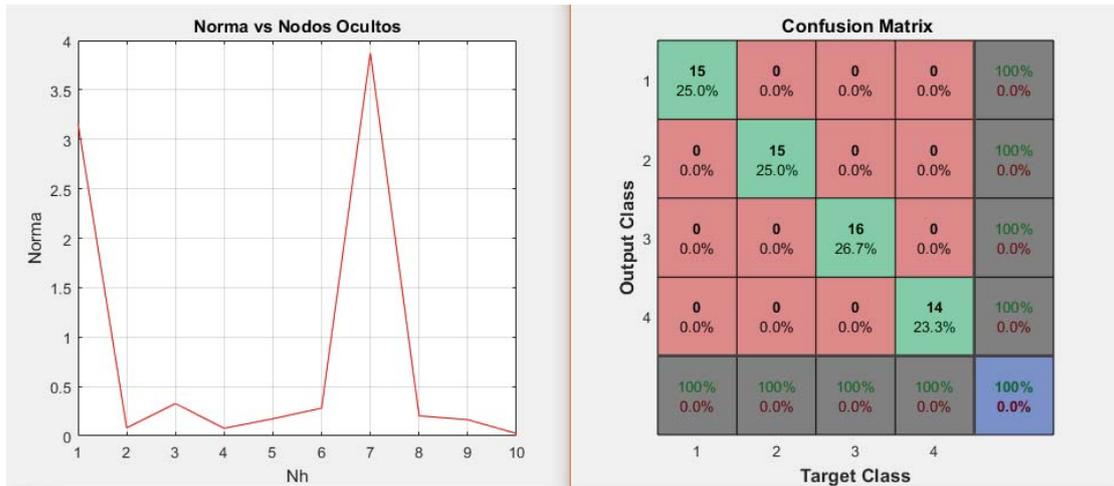


Figura 12 Peor caso clasificación modelo detección

Los valores que nos entrega la matriz de confusión de un total 60 registros, son como siguen:

- 15 registros fueron bien clasificados como normal, 15 correctamente como falla en anillo interno, 16 correctamente como falla de anillo externo y 14 correctamente como fallo en bola.
 - En cuanto a las demás clasificaciones, ninguno fue clasificado erróneamente como otra clase.
 - Se presenta 100% de exactitud en el modelo.
- Caso con mejor resultado: Este corresponde al caso de velocidad constante y diámetro variable con una configuración de 75-25% de training y testing respectivamente, que logra la clasificación con 2 nodos ocultos y una inigualable performance en la red neuronal.

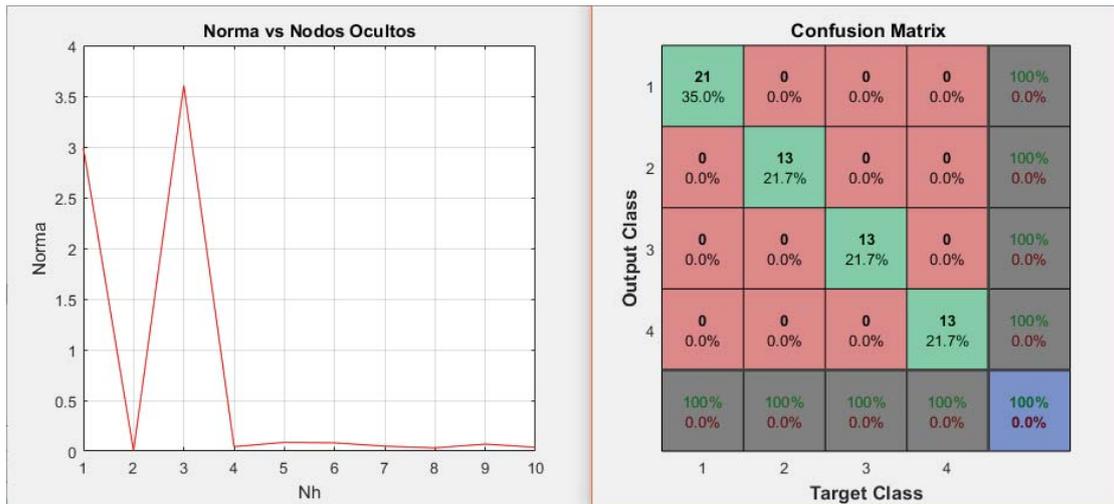


Figura 13 Mejor caso clasificación modelo detección

Los valores que nos entrega la matriz de confusión de un total 60 registros, son como siguen:

- 21 registros fueron bien clasificados como normal, 13 correctamente como falla en anillo interno, 13 correctamente como falla de anillo externo y 13 correctamente como fallo en bola.
- En cuanto a las demás clasificaciones, ninguno fue clasificado erróneamente como otra clase.
- Se presenta 100% de exactitud en el modelo.

Este modelo de detección, es el primer paso a poder obtener la severidad de falla de los rodamientos de equipos rotativos, y aunque con esta técnica no se obtiene el diámetro de falla, una clasificación perfecta con los casos de prueba utilizados es un excelente comienzo para desarrollar las etapas futuras.

4.2 Modelo de diagnóstico de la severidad con 2 diámetros de falla

Luego de haber detectado la falla en el modelo anterior, correspondiente a casos donde variaba la velocidad como si fuera aumentándola una máquina en la realidad para entender casos más reales, como también, que el diámetro fuera aumentando. Sin embargo, siempre quedaba un parámetro constante, y lo que se quiere empezar a experimentar en este modelo es generar una situación donde varíe la velocidad y valla variando el diámetro también, para generar aún más una detección más acercada a la realidad.

Así es entonces, como ahora comenzamos a entender los diámetros de falla como severidad, de la forma que sigue:

- Incipiente: Desde 0 a 0,007 de diámetro de falla.
- Moderado: Entre 0,007 y 0,014 de diámetro de falla.
- Fuerte: Entre 0,007 y 0,021 de diámetro de falla.

4.2.1 Topología del modelo

Este nuevo modelo entrega una clasificación de 7 clases que corresponden a la detección de los estados de rodamiento; falla en anillo interno, falla anillo externo, fallo en bola y sin falla o normal. Sin embargo, buscando un apego más a la realidad dado los buenos resultados obtenidos en el modelo anterior ahora se considerarán las velocidades variables y la clasificación entregará fallas, pero ahora con dos diámetros, no uno como antes.

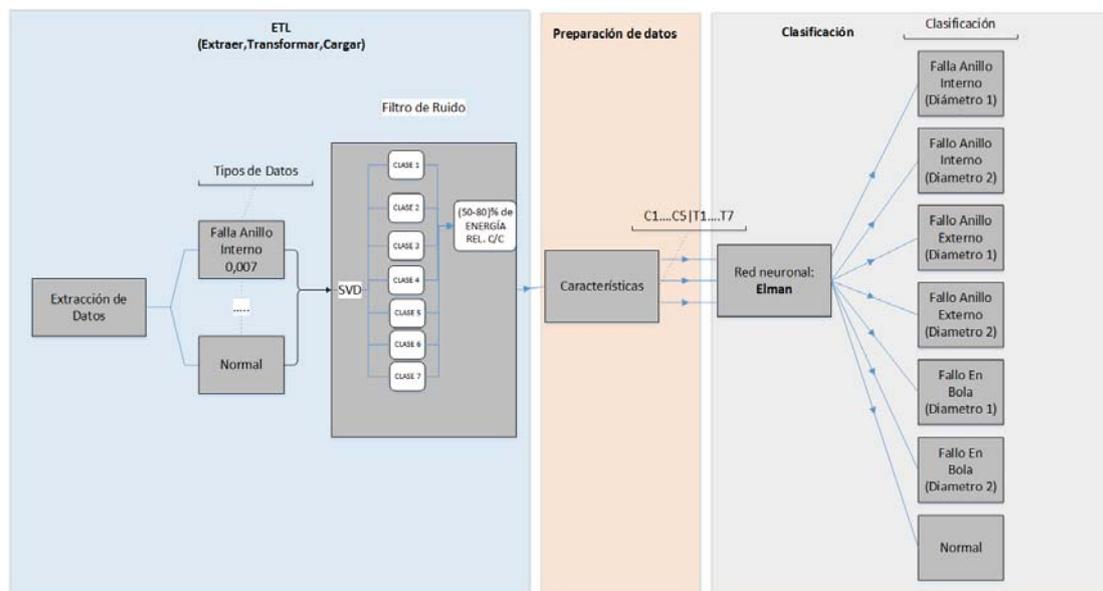


Figura 14 Topología: Modelo diagnóstico con 2 diámetros de falla

Al igual que el modelo anterior, se puede ver en la figura superior, la topología del modelo que se dividió en 3 componentes: la definición de la ETL, la preparación de datos y la clasificación. Donde cada uno será explicado a continuación.

4.2.2 Definición de ETL

Al igual que el modelo anterior, se tiene una ETL que se representa en 3 pasos y se puede ver en la figura inferior, la cual se procederá a describir ahora.



Figura 15 ETL: Modelo de diagnóstico con 2 diámetros

Como extracción al igual que el modelo anterior, se tiene los datos que tomaremos de la base de datos de la Universidad Case Western Reserve. Indexados por diámetro, la velocidad y por estado del rodamiento.

Como se dijo anteriormente, los números que aparecen como datos, son los nombres de los paquetes con que se identifican en la base de datos. Por otro lado, cada paquete denominado con número, por ejemplo: 108 que corresponde al anillo interno, con velocidad de 1730 y una falla de 0,007 de diámetro tienen una longitud de 120000 registros, que corresponden a las lecturas del acelerómetro.

Para continuar, se tiene la etapa de transformación donde se generarán 3 casos de prueba: el primero corresponde a un escenario donde varía la velocidad de 1730 a 1797 y se

encuentran diámetros de falla de 0,007 a 0,014, que se entenderá como severidad incipiente a moderada; el segundo corresponde a un escenario donde también varía la velocidad y el diámetro de falla varía de 0,014 a 0,021 que se entenderá como severidad moderada a fuerte, y finalmente el último caso corresponde cuando en un escenario donde varía la velocidad y el diámetro de falla aumenta de 0,007 a 0,021 repentinamente que se entenderá como severidad incipiente a fuerte.

Luego de generar los casos de prueba (3), por cada uno de ellos se obtendrá 7 paquetes: 2 de falla en anillo interno con 1 diámetro de falla cada uno, 2 falla en anillo externo con 1 diámetro de falla cada uno, 2 falla en bola con 1 diámetro de falla cada uno y 1 sin fallas o normal. A cada uno de ellos, se le hace una conversión donde se transforma de un vector de longitud de 120000 registros a una matriz de 120 filas y 1000 columnas, convirtiendo cada 1000 registros los que siguen en la siguiente fila de la matriz hasta terminar con la dimensión señalada.

A continuación, se le reduce la dimensión con la descomposición de valores singulares que se demostró que con el 50% de los valores singulares se alcanzan los valores con mayor energía relativa de conjunto, por lo que se disminuye cada paquete de registros de una dimensión de 120x1000 a 60x1000.

Y así, finalmente se alcanza la última etapa de la ETL, donde se generan los datamart finales para cada caso de prueba, quedando en matrices de 60x1000 por cada estado que se puede identificar en los rodamientos como se puede ver en la figura superior; falla en anillo interno, falla en anillo externo, fallo en bola y datos sin falla o normales.

4.2.3 Preparación de los datos

Como se puede ver en la imagen inferior, se tienen los 3 casos de prueba con sus datamart generados por la ETL, los cuáles serían 7 en total.

A continuación, a cada fila del datamart se le calculan 5 características: El error cuadrático medio, la entropía, la Kurtosis, el factor de forma y el peak máximo, las cuáles se listan aquí:

- Raíz valor cuadrático medio

$$x_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (4.2.3.1)$$

- Entropía

$$E = \sum_{i=1}^N p * \log_2(p) \quad (4.2.3.2)$$

- Kurtosis

$$K = \frac{\sum_{i=1}^N (x_i - \bar{x})^4}{N\sigma^4} \quad (4.2.3.3)$$

- Factor de forma

$$FF = \frac{X_{RMS}}{\bar{X}_{ABS}} \quad (4.2.3.4)$$

- Peak máximo

$$max_{peak} = \max(xi) \quad (4.2.3.5)$$

A diferencia del modelo anterior, se calculan 2 características más porque la red neuronal tiene problemas para obtener una exactitud del 100% con solo 3 características, y esto es debido a las muchas combinaciones y por el casi doble número de nodos de salida de la red neuronal.

Así es como, características mencionadas han demostrado ser útiles. Sin embargo, tenemos casos donde la naturaleza los datos influye en el resultado de la clasificación debido a que existen casos como los de abajo donde se solapan algunas características, haciendo que muchas veces en vez de ayudar a la red con 5 características, se maneje como si hubieran 4.

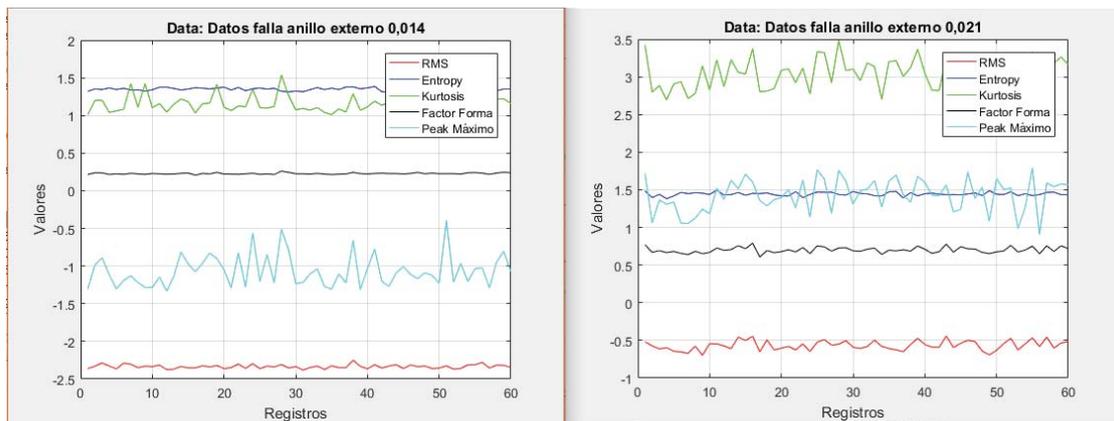


Figura 16 Comparación características 7 salidas

Después de haber calculado las 5 características a cada fila, se agregan 7 columnas con ceros a excepción de 1 que corresponderá al estado del rodamiento que pertenece. Luego de eso, se unen los 4 datamart en una sola matriz en la dirección de las filas convirtiéndose todo el caso de pruebas en una matriz de dimensión 420x12.

Cuando se tiene la matriz de dimensión 420x12, se procede a combinar las filas para que el orden de ellas no afecte en la clasificación de la red neuronal haciendo así más real el rigor del modelo. Finalmente, se debe dividir la matriz resultante en aquellos registros que servirán para entrenar a la red, de los registros que deberán ser clasificados. Así es como, dividimos proporciones que se usarán en todo el proyecto. Para cada caso de prueba tendremos 3 divisiones, 75,80 y 85% de Training y 25,20,15% de Testing respectivamente.

A continuación, se muestra un diagrama que contiene los pasos relatados aquí para la preparación de datos dando paso ya al paso denominado clasificación per sé.

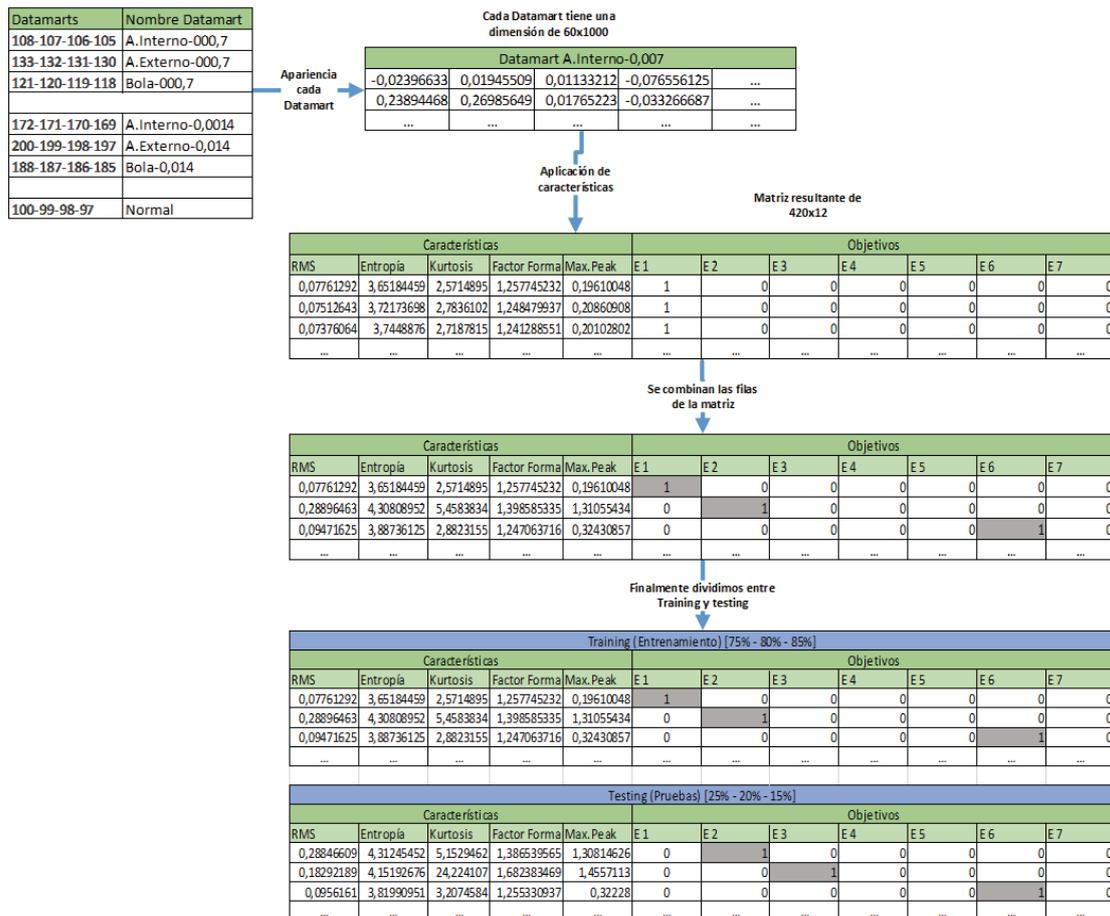


Figura 17 Preparación de datos: Modelo de diagnóstico con 2 diámetros

4.2.4 Clasificación

Luego de que se tienen los datos preparados para entrar a la red neuronal recurrente simple; Elman. Tenemos que esta presenta 5 nodos de entrada que corresponden a los datos que va obteniendo de las características, el número de nodos ocultos es variable dependiendo de una evaluación que prueba de 1 a 10 nodos ocultos viendo cuál de todos obtiene menor error cuadrático medio, siendo ese el que se utiliza. Y finalmente, los nodos de salida son 7 que corresponden a las clases ya antes descritas, y de esta forma nos entrega cuantos registros clasificó exitosamente los que se pueden ver gráficamente con la matriz de confusión.

4.2.5 Métricas de rendimiento

En cuanto a las métricas, se mantienen las definidas en el modelo final de proyecto 1.

4.2.6 Resultados

A continuación, se muestran los resultados obtenidos del modelo ya descrito, que en este caso tiene solo 3 casos. En este caso, no se pudieron lograr todos los resultados con 100% de exactitud, y es lo que se muestra a continuación:

Diámetro	Velocidad	Partes del rodamiento				Exactitud	
		A.Interno	A.Externo	Bola	Normal		
0,007	1730-1750-1772-1797	108-107-106-105	133-132-131-130	121-120-119-118		75-25%	99,0%
0,014	1730-1750-1772-1797	172-171-170-169	200-199-198-197	188-187-186-185		80-20%	98,8%
	1730-1750-1772-1797				100-99-98-97	85-15%	100,0%
0,014	1730-1750-1772-1797	172-171-170-169	200-199-198-197	188-187-186-185		75-25%	100,0%
0,021	1730-1750-1772-1797	212-211-210-209	237-236-235-234	225-224-223-222		80-20%	100,0%
	1730-1750-1772-1797				100-99-98-97	85-15%	100,0%
0,007	1730-1750-1772-1797	108-107-106-105	133-132-131-130	121-120-119-118		75-25%	100,0%
0,021	1730-1750-1772-1797	212-211-210-209	237-236-235-234	225-224-223-222		80-20%	100,0%
	1730-1750-1772-1797				100-99-98-97	85-15%	100,0%

Tabla 3 Resultados casos de prueba: Todo variable con 2 diámetros

En el modelo anterior, en todos los porcentajes training/testing daba 100% de exactitud, pero claramente aquí tenemos que la información que contiene la del diámetro de falla de 0,014 es más difícil de clasificar a pesar de que las características no están tan mezcladas.

De lo anterior podemos definir que la mejor configuración esta vez es con 85-15%. Sin embargo, se mostrará el peor y mejor resultado con respecto a la cantidad de nodos ocultos con que dio menor error durante el training.

- Caso con peor resultado: Corresponde al caso moderado-grave con la configuración de 80-20% de training y testing respectivamente.

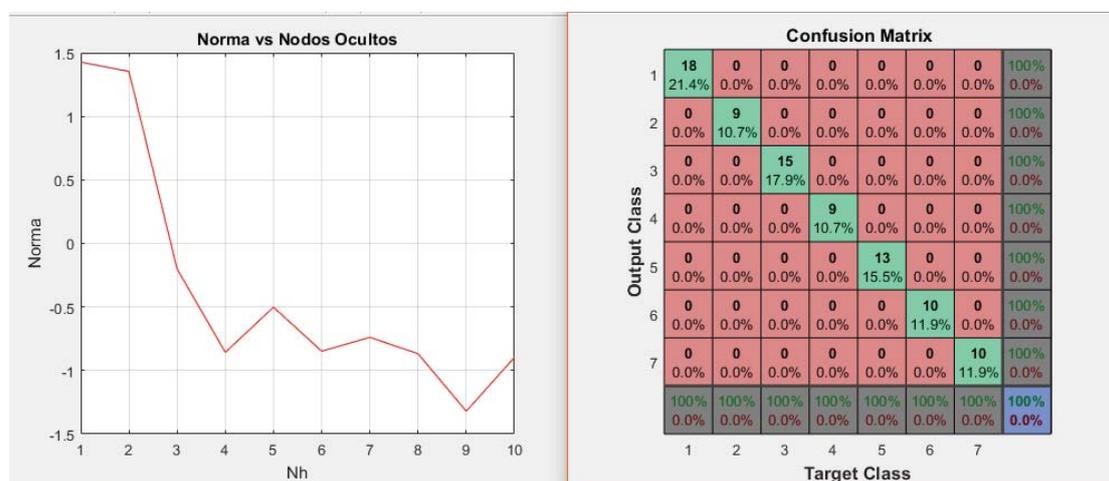


Figura 18 Peor caso clasificación modelo diagnóstico con 2 diámetros

Los valores que nos entrega la matriz de confusión de un total 84 registros, son como siguen:

- 18 registros fueron bien clasificados como normal, 9 correctamente como falla en anillo interno 0,014, 15 correctamente como falla en anillo interno 0,021, 9 correctamente como falla de anillo externo de diámetro 0,014, 13 correctamente como falla de anillo externo de diámetro 0,021, 10 correctamente como fallo en bola de diámetro 0,014, y 10 correctamente como fallo en bola de diámetro 0,021.
 - En cuanto a las demás clasificaciones, ninguno fue clasificado erróneamente como otra clase.
 - Se presenta 100% de exactitud en el modelo.
- Caso con mejor resultado: Corresponde al caso leve-moderado con la configuración 80-20% de training y testing respectivamente. Además por tener el número de nodos ocultos menor para clasificar con 100% de exactitud, tenía un performance de la red neuronal más bajo que todos los casos.

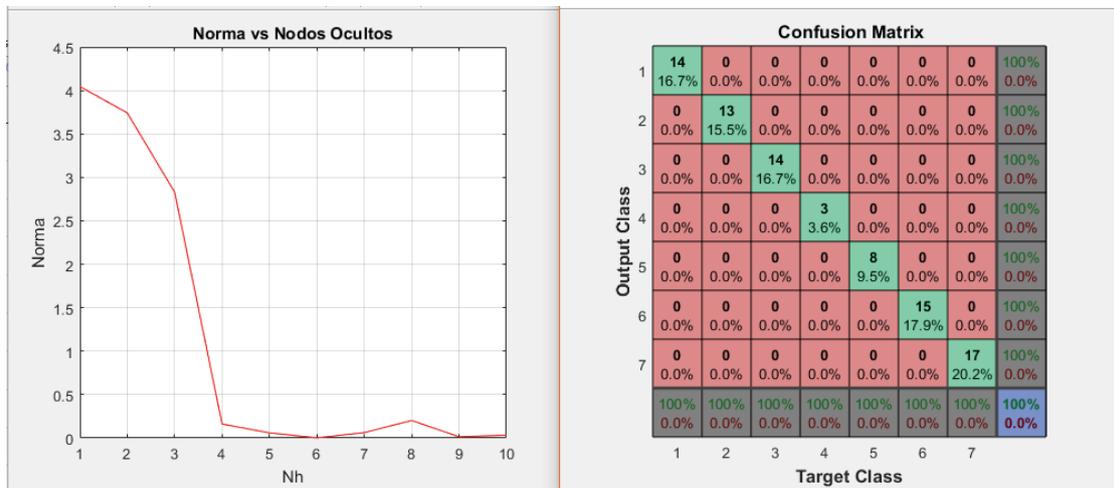


Figura 19 Mejor caso clasificación modelo diagnóstico con 2 diámetros

Los valores que nos entrega la matriz de confusión de un total 84 registros, son como siguen:

- 18 registros fueron bien clasificados como normal, 11 correctamente como falla en anillo interno 0,007, 11 correctamente como falla en anillo interno 0,014, 5 correctamente como falla de anillo externo de diámetro 0,007, 12 correctamente como falla de anillo externo de diámetro 0,014, 14 correctamente como fallo en bola de diámetro 0,007, y 12 correctamente como fallo en bola de diámetro 0,014.
 - En cuanto a las demás clasificaciones, ninguno fue clasificado erróneamente como otra clase.
 - Se presenta 100% de exactitud en el modelo.

Con este modelo, se ha alcanzado encontrar la severidad de falla con sólo 2 diámetros, sin embargo, con perfecta exactitud. Sin embargo, aún queda un diámetro que agregar, y es lo que se buscará en el siguiente modelo.

4.3 Modelo de diagnóstico de la severidad con 3 diámetros de falla

El modelo final de este proyecto contempla todo, esto quiere decir que además de detectar el estado del rodamiento, también detecta su severidad en los 3 niveles ya mencionados; incipiente, moderado y fuerte. Por lo que se tiene ahora un solo caso de prueba que estaría simulando el caso real de tener las lecturas de un rodamiento y que mediante un sistema genere la condición de este.

4.3.1 Topología del modelo

Este nuevo modelo entrega una clasificación de 10 clases que corresponden a la detección de los estados de rodamiento; falla en anillo interno, falla anillo externo, fallo en bola y sin falla o normal. Sin embargo, cada existirán 3 tipos de cada fallo correspondiente a los 3 tipos de severidad ya mencionados.

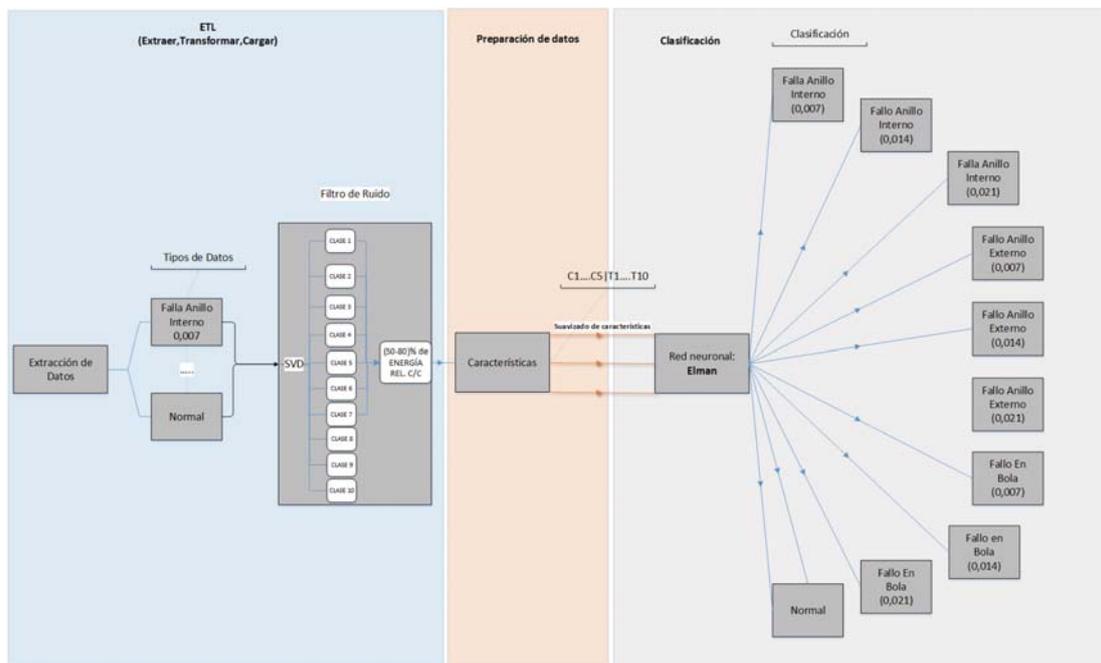


Figura 20 Topología: Modelo diagnóstico con 3 diámetros

Como ya se ha mencionado, se sigue mostrando la topología del modelo en 3 fases; el proceso de la ETL, la preparación de los datos y finalmente la clasificación de las 10 clases. Y cada uno de estos procesos se explicarán a continuación.

4.3.2 Definición ETL

Al igual que el modelo anterior, se tiene una ETL que se representa en 3 pasos y se puede ver en la figura inferior, la cual se procederá a describir ahora.

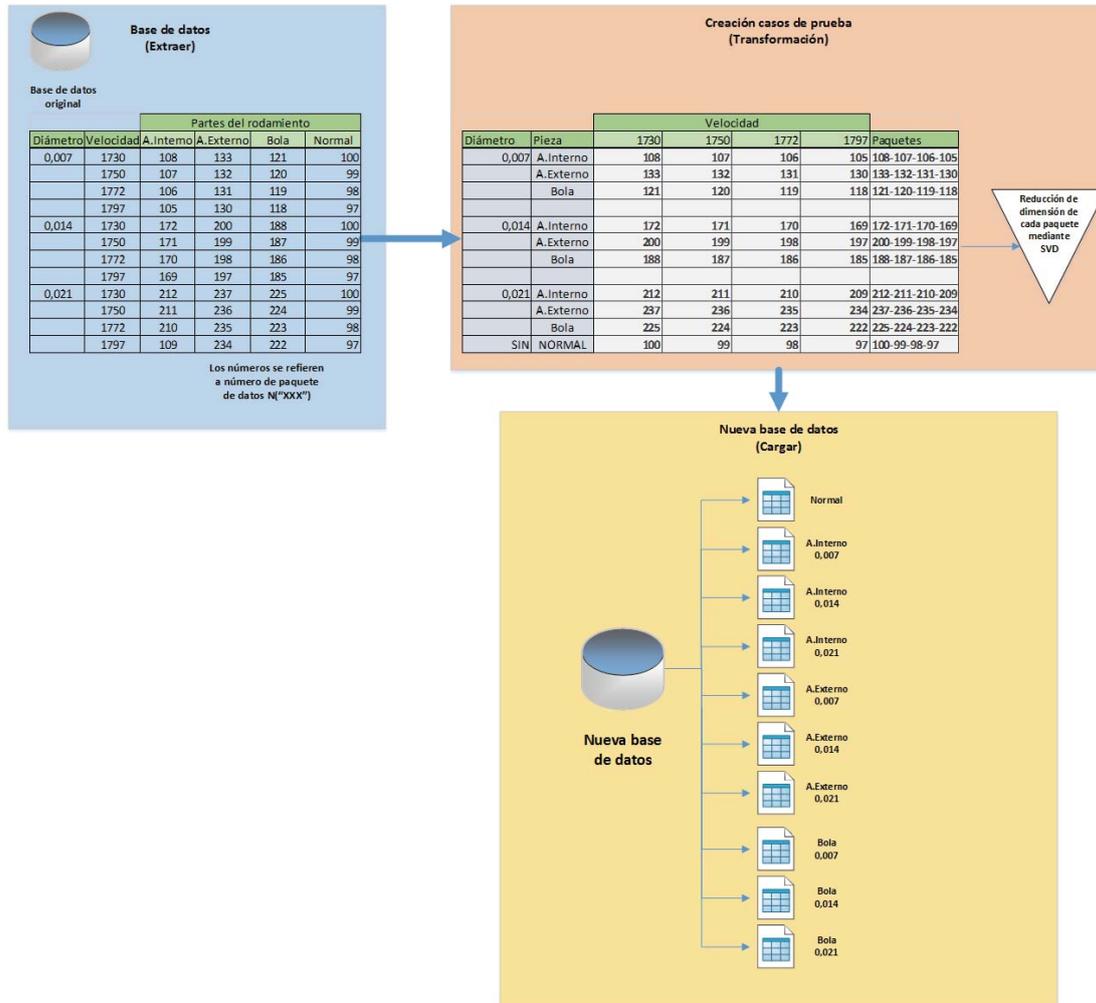


Figura 21 ETL: Modelo de diagnóstico con 3 diámetros

Como ya se ha dicho, se tienen los datos que tomaremos de la base de datos de la Universidad Case Western Reserve. Indexados por diámetro, la velocidad y por estado del rodamiento. Así también entonces, los números que aparecen como datos, son los nombres de los paquetes con que se identifican en la base de datos.

Para continuar, se tiene la etapa de transformación donde se generará en esta ocasión 1 solo caso de prueba, el cual corresponde a un escenario donde varía la velocidad y el diámetro a la vez mezclando todo. Luego, se crearán 10 paquetes que se componen de: 3 de falla en anillo interno con 1 diámetro de falla cada uno, 3 falla en anillo externo con 1 diámetro de falla cada uno, 3 falla en bola con 1 diámetro de falla cada uno y 1 sin fallas o normal. A cada uno de ellos, se le hace una conversión donde se transforma de un vector de

longitud de 120000 registros a una matriz de 120 filas y 1000 columnas, convirtiendo cada 1000 registros los que siguen en la siguiente fila de la matriz hasta terminar con la dimensión señalada.

A continuación, se le reduce la dimensión con la descomposición de valores singulares que se demostró que con el 50% de los valores singulares se alcanzan los valores con mayor energía relativa de conjunto, por lo que se disminuye cada paquete de registros de una dimensión de 120x1000 a 60x1000.

Y así, finalmente se alcanza la última etapa de la ETL, donde se generan los datamart finales para cada caso de prueba, quedando en matrices de 60x1000 por cada estado que se puede identificar en los rodamientos como se puede ver en la figura superior; falla en anillo interno, falla en anillo externo, fallo en bola y datos sin falla o normales.

4.3.3 Preparación de los datos

Como se puede ver en la imagen inferior, se tiene 1 caso de prueba con sus datamart generados por la ETL, los cuáles serían 10 en total.

A continuación, a cada fila del datamart se le calculan 5 características: El error cuadrático medio, la entropía, la Kurtosis, el factor de forma y el peak máximo, las cuáles se listan aquí:

- Raíz valor cuadrático medio

$$x_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (4.3.3.1)$$

- Entropía

$$E = \sum_{i=1}^N p * \log_2(p) \quad (4.3.3.2)$$

- Kurtosis

$$K = \sum_{i=1}^N \frac{(x_i - \bar{x})^4}{N\sigma^4} \quad (4.3.3.3)$$

- Factor de forma

$$FF = \frac{X_{RMS}}{\bar{X}_{ABS}} \quad (4.3.3.4)$$

- Peak máximo

$$max_{peak} = \max(x_i) \quad (4.3.3.5)$$

En este modelo final, también se calculan las 5 características que con 10 salidas no alcanzaron el 100% de exactitud. Sin embargo, en este caso se utilizó la herramienta smooth de Matlab para suavizar las características usando un filtro de media móvil de lapso 5.

Como se había dicho anteriormente, era muy importante que las características no se solaparan, sino no tendrían mucha incidencia mejorando el resultado del modelo, sin embargo, a continuación, se puede ver una demostración de lo útil que resulta el suavizado utilizado.

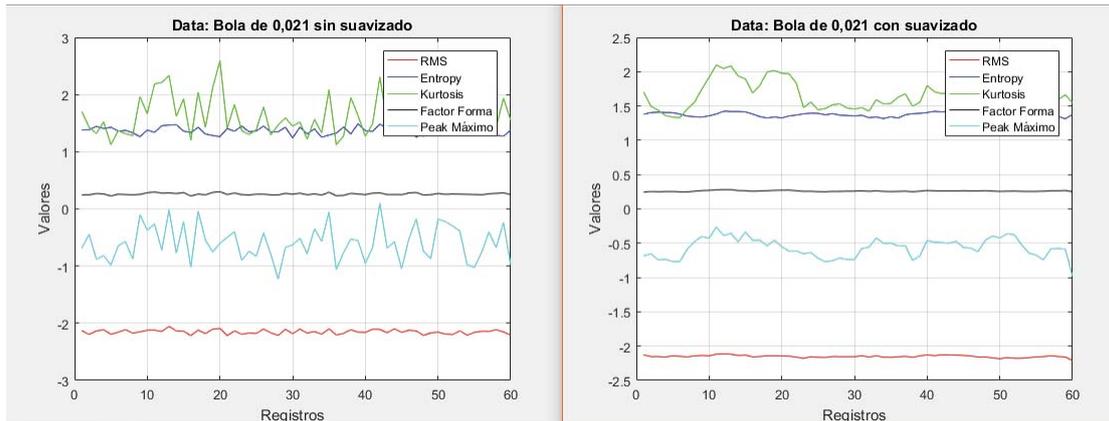


Figura 22 Comparación características 10 salidas

Luego de lo anterior, se agregan 10 columnas con ceros a excepción de 1 que corresponderá al estado del rodamiento que pertenece. Luego de eso, se unen los 4 datamart en una sola matriz en la dirección de las filas convirtiéndose todo el caso de pruebas en una matriz de dimensión 600x15.

Cuando se tiene la matriz de dimensión 600x15, se procede a combinar las filas para que el orden de ellas no afecte en la clasificación de la red neuronal haciendo así más real el rigor del modelo. Finalmente, se debe dividir la matriz resultante en aquellos registros que servirán para entrenar a la red, de los registros que deberán ser clasificados. Así es como, dividimos proporciones que se usarán en todo el proyecto. Para cada caso de prueba tendremos 3 divisiones, 75,80 y 85% de Training y 25,20,15% de Testing respectivamente.

A continuación, se muestra un diagrama que contiene los pasos relatados aquí para la preparación de datos dando paso ya al paso denominado clasificación per sé.

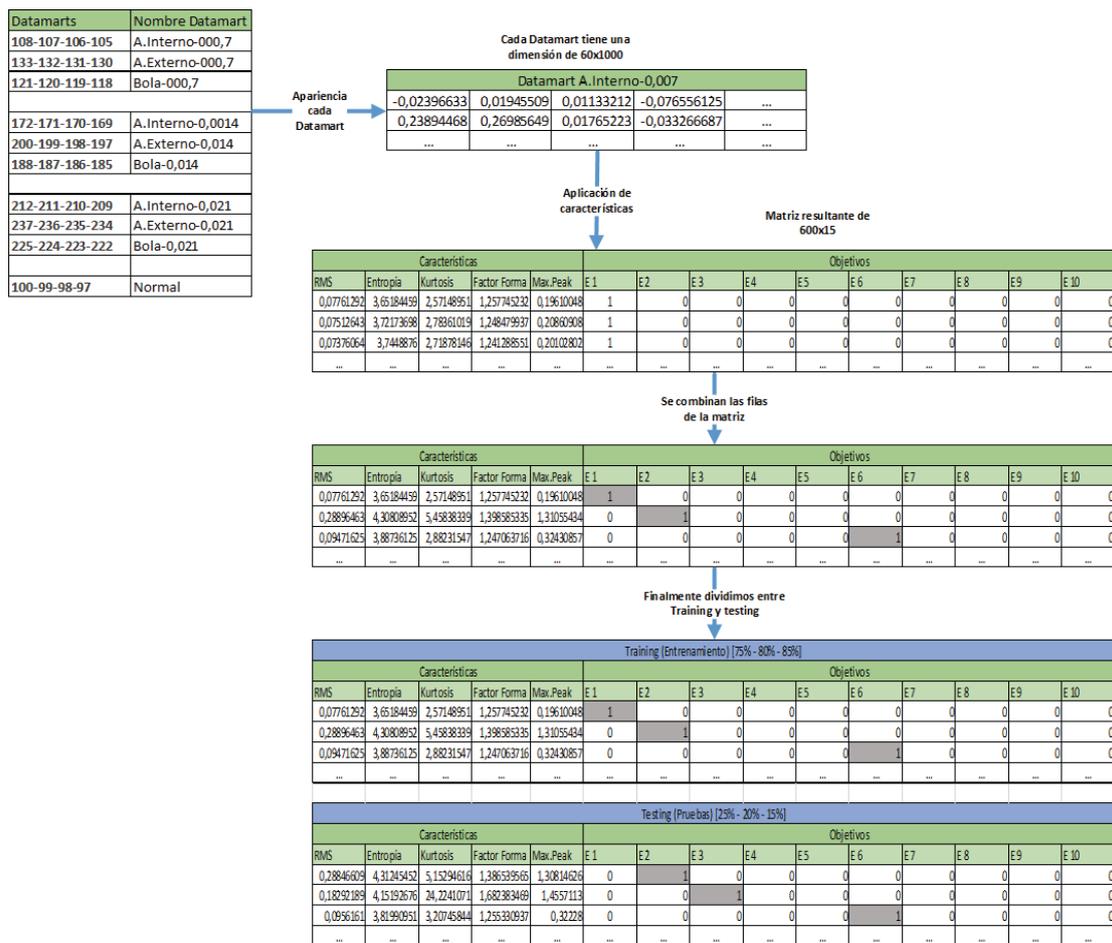


Figura 23 Preparación de datos: Modelo diagnóstico con 3 diámetros

4.3.4 Clasificación

Luego de que se tienen los datos preparados para entrar a la red neuronal recurrente simple; Elman. Tenemos que esta presenta 5 nodos de entrada que corresponden a los datos que va obteniendo de las características, el número de nodos ocultos es variable dependiendo de una evaluación que prueba de 1 a 10 nodos ocultos viendo cuál de todos obtiene menor error cuadrático medio, siendo ese el que se utiliza. Y finalmente, los nodos de salida son 10 que corresponden a las clases ya antes descritas, y de esta forma nos entrega cuantos registros clasificó exitosamente los que se pueden ver gráficamente con la matriz de confusión.

4.3.5 Métricas de rendimiento

En cuanto a las métricas, se mantienen las definidas en el modelo final de proyecto 1.

4.3.6 Resultados

Los resultados del modelo final contemplan un solo caso como se ha descrito anteriormente, donde se tiene toda la base de datos acotada que se tomó para efectos de este proyecto de forma mezclada tratando de simular un rodamiento de la vida real que puede presentar cualquier tipo de fallo, lo que sí se sabe es que estos fallan de manera progresiva hasta la falla funcional, sin embargo, con este modelo se podría conocer fallas incipientes que es muy importante si se sabe que el tiempo entre que ocurra esto hasta la falla funcional es corto.

Como es el modelo final, se hará una muestra más específica de todos los resultados obtenidos donde por ejemplo tenemos la siguiente tabla resumen.

Diámetro	Pieza	Velocidad				Paquetes		Exactitud	
		1730	1750	1772	1797				
0,007	A.Interno	108	107	106	105	108-107-106-105			
	A.Externo	133	132	131	130	133-132-131-130			
	Bola	121	120	119	118	121-120-119-118			
							75-25%	100%	
0,014	A.Interno	172	171	170	169	172-171-170-169		80-20%	100%
	A.Externo	200	199	198	197	200-199-198-197		85-15%	100%
	Bola	188	187	186	185	188-187-186-185			
0,021	A.Interno	212	211	210	209	212-211-210-209			
	A.Externo	237	236	235	234	237-236-235-234			
	Bola	225	224	223	222	225-224-223-222			
SIN	NORMAL	100	99	98	97	100-99-98-97			

Tabla 4 Resultados casos de prueba: Todo variable con 3 diámetros

Así entonces, se expresan los casos obtenidos individualmente:

- Caso con 75-25% de training y testing respectivamente:

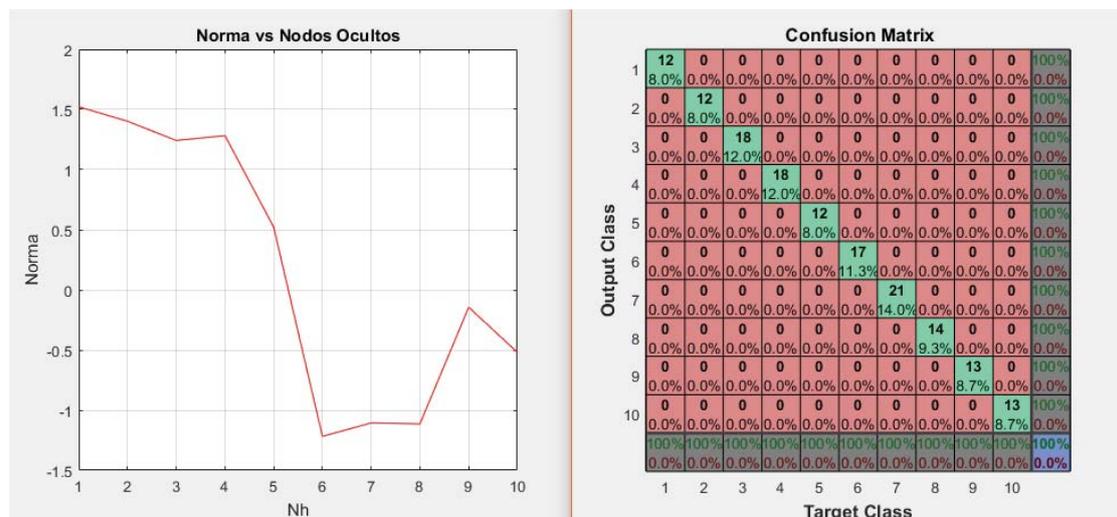


Figura 24 Resultados casos de prueba: 75-25% Modelo diagnóstico con 3 diámetros

Los valores que nos entrega la matriz de confusión de un total 150 registros, son como siguen:

- 12 registros fueron bien clasificados como normal, 12 correctamente como falla en anillo interno 0,007, 18 correctamente como falla en anillo interno 0,014, 18 correctamente como falla en anillo interno 0,021, 12 correctamente como falla de anillo externo de diámetro 0,007, 17 correctamente como falla de anillo externo de diámetro 0,014, 21 correctamente como falla de anillo externo de diámetro 0,021, 14 correctamente como fallo en bola de diámetro 0,007, 13 correctamente como fallo en bola de diámetro 0,014 y 13 correctamente como fallo en bola de diámetro 0,021.
- En cuanto a las demás clasificaciones, ninguno fue clasificado erróneamente como otra clase.
- Se presenta 100% de exactitud en el modelo.

- Caso con 80-20% de training y testing respectivamente:

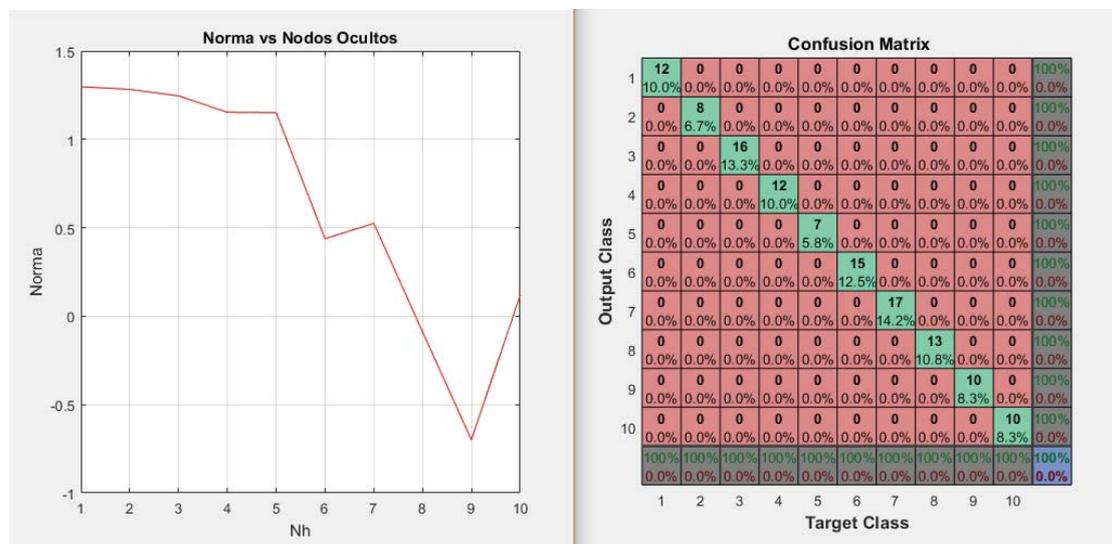


Figura 25 Resultados casos de prueba: 80-20% Modelo diagnóstico con 3 diámetros

Los valores que nos entrega la matriz de confusión de un total 120 registros, son como siguen:

- 12 registros fueron bien clasificados como normal, 18 correctamente como falla en anillo interno 0,007, 16 correctamente como falla en anillo interno 0,014, 12 correctamente como falla en anillo interno 0,021, 17 correctamente como falla de anillo externo de diámetro 0,007, 15 correctamente como falla de anillo externo de diámetro 0,014, 17 correctamente como falla de anillo externo de diámetro 0,021, 13 correctamente como fallo en bola de diámetro 0,007, 10 correctamente como fallo en bola de diámetro 0,014 y 10 correctamente como fallo en bola de diámetro 0,021.
- En cuanto a las demás clasificaciones, ninguno fue clasificado erróneamente como otra clase.
- Se presenta 100% de exactitud en el modelo.

- Caso con 85-15% de training y testing respectivamente:

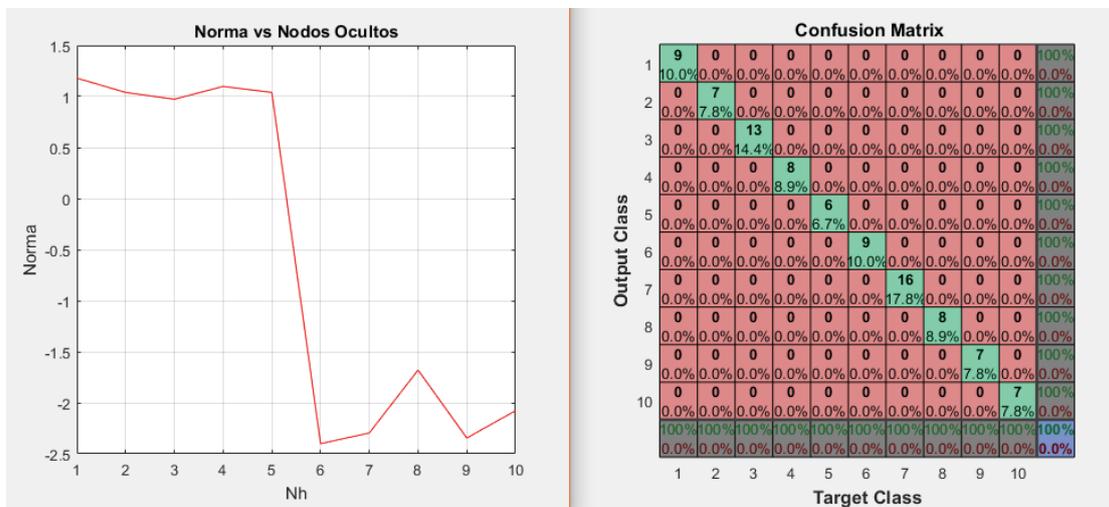


Figura 26 Resultados casos de prueba: 85-15% Modelo diagnóstico con 3 diámetros

Los valores que nos entrega la matriz de confusión de un total 90 registros, son como siguen:

- 9 registros fueron bien clasificados como normal, 7 correctamente como falla en anillo interno 0,007, 13 correctamente como falla en anillo interno 0,014, 8 correctamente como falla en anillo interno 0,021, 6 correctamente como falla de anillo externo de diámetro 0,007, 9 correctamente como falla de anillo externo de diámetro 0,014, 16 correctamente como falla de anillo externo de diámetro 0,021, 9 correctamente como fallo en bola de diámetro 0,007, 7 correctamente como fallo en bola de diámetro 0,014 y 7 correctamente como fallo en bola de diámetro 0,021.
- En cuanto a las demás clasificaciones, ninguno fue clasificado erróneamente como otra clase.
- Se presenta 100% de exactitud en el modelo.

El modelo en cuestión, cumple con la necesidad de obtener la severidad de fallo de rodamientos en equipos de rotación, y con una cantidad mínima de registros siendo utilizados en testing gracias al proceso con descomposición en valores singulares en la ETL. Este algoritmo, representa una técnica importante en el área del diagnóstico de rodamientos, dado que contiene herramientas no tan complejas como otros algoritmos que se encuentran en los papers de investigación.

Para terminar, se presenta una tabla con una prueba de rigor sobre la robustez del algoritmo en cuestión, sin ejercer iteraciones para encontrar el mejor resultado. Esto quiere decir, que se verá reflejado en una cantidad rigurosa de iteraciones (20) cuanto puede fallar el algoritmo en el tiempo. Esto sucede, porque las redes neuronales no siempre entregan un buen resultado, debido a que son funciones que ejercen operaciones sobre los registros que entran y las combinaciones no siempre son las mismas.

Iteración	Presición	Recall	F-score	Exactitud
1	1	1	1	100
2	1	1	1	100
3	1	1	1	100
4	1	1	1	100
5	1	1	1	100
6	1	1	1	100
7	1	1	1	100
8	1	1	1	100
9	1	1	1	100
10	1	1	1	100
11	1	1	1	100
12	1	1	1	100
13	1	1	1	100
14	0,9937	0,9950	0,9942	99,3333
15	0,9937	0,9950	0,9933	99,3333
16	1	1	1	100
17	1	1	1	100
18	1	1	1	100
19	1	1	1	100
20	1	1	1	100
Promedio	0,9994	0,9995	0,9994	99,9333
Desviación Estándar	0,0019	0,0015	0,0019	0,2052

Tabla 5 Robustez del modelo final de diagnóstico con 3 diámetros

La tabla 5, presenta el promedio de las características de precisión, Recall y F-score de las 10 clases que clasifica la red neuronal, y podemos ver que de 20 iteraciones tan solo 2 obtienen bajo 100% de exactitud y sobre 99%. Lo que se repite para las otras métricas. También se puede ver, que de las 20 iteraciones el promedio de la precisión es 0,9994 y los datos están dispersos un 0,0019 de la media, y si miramos las demás métricas la que tiene mayor distancia de la media es la exactitud. Aunque, esos valores de desviación estándar son ínfimos para un modelo de estas características, lo que convierte al modelo en una técnica muy poderosa de diagnóstico.

5 Conclusión

Se ha desarrollado en este proyecto, un nuevo método para diagnosticar la severidad de fallos en equipos de rotación, utilizando descomposición en valores singulares en la ETL y redes neuronales recurrentes simples Elman para la clasificación. Estas herramientas, no son muy complejas, sin embargo, entran a competir con los tantos papers que se encuentran en la comunidad científica con respecto a esta área, los cuáles han buscado distintos métodos y a la fecha, aquellos que han logrado modelos de diagnóstico con 100% de exactitud, utilizan herramientas y técnicas muy complejas, que dejan a este trabajo como la solución simple y eficaz.

Al desarrollar el primer modelo, se pudo inferir que una limpieza de los datos de entrada, en la ETL, puede mejorar significativamente los resultados, y esto fue debido a la descomposición en valores singulares y a un conocimiento más acertado de la naturaleza de los rodamientos. Así como decía Balden, los datos provenientes de partes internas del rodamiento se encuentran en zonas de alta frecuencia, y esto sirvió para conocer donde colocar el umbral. Puesto que se pasa del dominio del tiempo al dominio de los valores singulares, hay que conocer donde se encuentra la información de alta y baja frecuencia. Si bien es cierto no es un método muy complejo, el entendimiento de ese gran avance permitió que el modelo tuviera menos trabajo que clasificar y de esta manera se pudo pasar a el modelo objetivo de diagnóstico de rodamientos.

Luego de lograr con éxito un buen modelo para detectar, se implementó una ETL que entregase los datos, pero ahora los datamart traerían los mismos estados, falla en anillo interno, externo, en bola y sin falla, pero con dos diámetros de falla. De esta forma, se introdujo el concepto de falla potencial y funcional, que es de suma importancia en el área de mantenimiento. Esto condujo, a que al tener una clasificación de falla de anillo interno de 0,007 y de 0,014 por ejemplo, se simulaba el ciclo de vida del rodamiento cuando va pasando de una falla potencial a una funcional. Sin embargo, los datos al ser de laboratorio no permiten abordar este concepto de manera estricta, y es por esto que elementos como el tiempo en que demora en tener una falla funcional no son válidos en este modelo.

Al agregar la kurtosis y factor de forma a las características, permitió que el algoritmo de diagnóstico de 7 clases de salida, llegara a la exactitud máxima, sin embargo, todo el código aparte no cambió nada, liberando así la importancia de las características.

En el modelo de diagnóstico de la severidad de fallos con todos los diámetros, fue más complejo poder lograr el éxito, ya que las características que quería introducir se solapaban con las ya existentes quedando su aporte inútil en los resultados finales. A lo más, terminaba subiendo de 95 a 97% de exactitud, no obstante, se adquirió el conocimiento de una herramienta que permitía suavizar las características, el promedio móvil. Esta técnica permitió que las características que se repetían en varios valores se suavizaran, alejándolas entre sí, mejorando considerablemente los resultados, y de esta forma llegar a la exactitud máxima requerida.

6 Referencias

- [1] V. Girondin et al, Bearings fault detection in helicopters using frequency readjustment and cyclostationary analysis, *Mech. Syst. Signal Process.* 38 (2013) 499–514.
- [2] J. Chen et al, Compound faults detection of rotating machinery using improved adaptive redundant lifting multiwavelet, *Mech. Syst. Signal Process.* 38 (2012) 36–54.
- [3] F.Bolaers , O . Cousinard , P . Marconnet , L . Rasolo fondraibe , Advanced detection of rolling bearings palling from de-noising vibratory signals, *Control Engineering Practice* 12 (2004)181–190.
- [4] J. Dron ,F .Bolaers ,Improvement of the sensitivity of the scalar indicators (crestfactor , kurtosis) using a de-noising method by spectral subtraction: application to the detection of defects in ball bearings, *Journal of Sound and Vibration* 270 (2004) 61–73
- [5] P. McFadden, J.Smith, Vibration monitoring of rolling element bearings by the high-frequency resonance technique—a review, *Tribology International* 17 (1984) 3–10.
- [6] S.U.Lee, D.Robb ,C.Besant ,The directional Choi–Williams distribution for the analysis of rotor-vibration signals, *Mechanical Systems and Signal Processing* 15(2001)789–811.
- [7] N. Nikolaou ,I.Antoniadis ,Rolling element bearing fault diagnosis using wavelet packets, *NDT & E International* 35(2002)197–205.
- [8] Revista Área minera (http://www.aminera.com/pdf_revistas/am030.pdf)
- [9] Angelo, Martin, "Vibration Monitoring of Machines," *Bruel &Kjaer Technical Review* No. 1-1987, pp. 1-36.
- [10] Case Western Reserve University Bearing Data Center Website (<http://cseggroups.case.edu/bearingdatacenter/home>)
- [11] H.L. Balderston, The detection of incipient failure in bearings, *Material Evaluation* 27 (June) (1969) 121–128.
- [12] Jaouher Ben Ali , Nader Fnaiech, Lotfi Saidi , Brigitte Chebel-Morello, Farhat Fnaiech. Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals.23 August 2014.
- [13] Estupiñan, Edgar - Saavedra, Pedro, *Técnicas de diagnóstico para el análisis de vibraciones.* Universidad de Concepción 2012.
- [14] Reza Golafshan n , Kenan Yuce Sanliturk. SVD and Hankel matrix based de-noising approach for ball bearing fault detection and its assessment using artificial faults. 21 April 2015
- [15] Hongrui Cao, Fei Fan, Kai Zhou, Zhengjia He. Wheel-bearing Fault Diagnosis of Trains using Empirical Wavelet Transform. 9 January 2016
- [16] Xiaoyuan Zhang, Jianzhong Zhou.Multi fault diagnosis forrolling element bearings based on ensemble empirical mode decomposition and optimized support vector machines.2011
- [17] Liangpei Huang. Fault pattern recognition of rolling bearing based on wavelet packet decomposition and BP network. 2015
- [18] Hussein Al-Bugarbee. A fault diagnosis methodology for rolling element bearings based on advanced signal pretreatment and autoregressive modelling. 2015
- [19] Carla D. Martin and Mason A. Porter. *The Extraordinary SVD.*
- [20] Rowayda A. Sadek. *SVD Based Image Processing Applications: State of The Art, Contributions and Research Challenges.* 2012

- [21] Reza Golafshan, Kenan Y. Şanlıtürk. The Effect of SVD Based Noise Elimination Methods Applied For Ball Bearing Fault Detection. 2015
- [22] Ying Tai, Jian Yang n, Lei Luo, Fanlong Zhang ,Jianjun Qian. Learning discriminative singular value decomposition representation for face recognition
- [23] Alter O, Brown PO, Botstein D. (2000) Singular value decomposition for genome-wide expression data processing and modeling.
- [24] M. W. Berry, S. T. Dumais, G. W. O'Brien, Using linear algebra for intelligent information retrieval, *SIAM Review* 37 (1995) 573–595, available at <http://dx.doi.org/10.1137/1037127>.
- [25] C. Belta, V. Kumar, An SVD-based projection method for interpolation on $SE(3)$, *IEEE Transactions on Robotics and Automation* 18 (2002) 334–345, available at <http://dx.doi.org/10.1109/TRA.2002.1019463>.
- [26] D. J. Fenn, M. A. Porter, S. Williams, M. McDonald, N. F. Johnson, N. S. Jones, Temporal evolution of financial market correlations, *Physical Review E* 84 (2011) 026109, available at <http://dx.doi.org/10.1103/PhysRevE.84.026109>.
- [27] L. Xu, Q. Liang, Computation of the singular value decomposition, in *Wireless Algorithms, Systems, and Applications 2010, Lecture Notes in Computer Science, Vol. 6221*, Edited by G. Pandurangan, V. S. A. Kumar, G. Ming, Y. Liu, and Y. Li, Springer-Verlag, Berlin, 2010, 338–342.
- [28] Carlos Alberto Ruiz, Marta Susana Basualdo. *Redes Neuronales: Conceptos Básicos y Aplicaciones*. 2001.
- [29] Rasit Ata. Artificial neural networks applications in wind energy systems: a review. 2015.
- [30] Filippo Amato, Alberto López, Eladia María Peña-Méndez, Petr Vaňhara, Aleš Hampl, Josef Havel. *Artificial neural networks in medical diagnosis*.2013
- [31] Petrosian, A.A., Prokhorov, D.V., Lajara-Nanson, W., Schiffer, R.B., 2001. Recurrent neural network-based approach for early recognition of Alzheimer's disease in EEG. *Clin. Neurophysiol.* 112 (8), 1378– 1387.
- [32] Shieh, J.-S., Chou, C.-F., Huang, S.-J., Kao, M.-C., 2004. Intracranial pressure model in intensive care unit using a simple recurrent neural network through time. *Neurocomputing* 57, 239–256.
- [33] JEFFREY L. ELMAN. *Finding Structure in Time*. 1990
- [34] S.Sapna, Dr.A.Tamilaras and M.Pravin Kumar. Backpropagation learning algorithm based on Levenberg Marquardt algorithm7
- [35] Daniel Valenzuela. *Diagnóstico de fallas en rodamientos y engranajes de equipos de rotación utilizando redes neuronales artificiales*.2015.
- [36] Nibaldo Rodríguez, Guillermo Cabrera, Carolina Lagos y Enrique Cabrera. Stationary Wavelet Singular Entropy and Kernel Extreme Learning for Bearing Multi-Fault Diagnosis. Vol 19, 2017.