

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

**VALORES SINGULARES DE HANKEL Y  
REGRESIÓN SOFTMAX PARA DIAGNOSTICO  
DE SEVERIDAD DE FALLOS EN  
RODAMIENTOS**

**FELIPE IGNACIO TORRICO RAMOS**

INFORME DE AVANCE DE PROYECTO  
PARA OPTAR AL TÍTULO PROFESIONAL DE  
INGENIERO CIVIL INFORMÁTICA

JUNIO, 2017

## Resumen

Los rodamientos son una parte fundamental en equipos rotatorios necesarios en aviones, brazos robóticos de líneas de ensamblajes, camiones de carga mineros o de bienes y vehículos urbanos. Se sabe que no solo son la segunda parte más importante luego del motor, sino que su rotura conlleva a un arreglo costoso desde el punto de vista de tiempo y de coste de oportunidad.

Por eso se propone un modelo de diagnóstico en tiempo real de fallo en los rodamientos, para así poder realizar una mantención preventiva eficiente. El modelo consta de una primera parte de extracción de características, las cuales son señales de vibración captadas por un acelerómetro. Estas señales son segmentadas en muestras más pequeñas. Luego se divide esta nueva base de datos en dos partes iguales; una de entrenamiento y una de pruebas. Cada muestra es entonces pasada a una matriz de Hankel para así poder calcular sus  $L$  valores singulares, los cuales finalmente pasan al clasificador que realiza una regresión Softmax para decidir en que categoría de fallo, o normalidad, se encuentra.

Los resultados obtenidos para una ventana de segmentación de 1200 datos y 20 valores singulares de Hankel otorgaron el mejor promedio de exactitud con 99,91%. Con esto, el estudio demostró que una técnica de extracción de características efectivo es suficiente para dar buenos resultados incluso utilizando un clasificador tan simple como lo es la regresión Softmax.

**Palabras Clave:** Diagnóstico de falla inteligente, Rodamientos, Valores singulares, Matriz de Hankel.

# Contents

<b>1</b>	<b>Introducción</b>	<b>1</b>
<b>2</b>	<b>Definición de Objetivos</b>	<b>3</b>
2.1	Objetivos Generales . . . . .	3
2.2	Objetivos Específicos . . . . .	3
<b>3</b>	<b>Estado del Arte</b>	<b>4</b>
3.1	Descomposición de Valores Singulares y la matriz de Hankel . . . . .	4
3.2	Diagnóstico de severidad en rodamientos . . . . .	4
<b>4</b>	<b>Marco Teorico</b>	<b>6</b>
4.1	Matriz de Hankel . . . . .	6
4.1.1	Incrustación . . . . .	6
4.2	Descomposición de Valores Singulares . . . . .	7
4.3	Clasificador Softmax . . . . .	7
4.3.1	Aprendizaje . . . . .	8
4.3.2	Función de costo . . . . .	8
4.3.3	Scaled Conjugate Gradient Descent (SCG) . . . . .	9
<b>5</b>	<b>Análisis de Resultados</b>	<b>10</b>
5.1	Datos Utilizados . . . . .	10
5.2	El modelo . . . . .	13
5.3	Segmentación de la señal . . . . .	14
5.4	Extracción de características . . . . .	15
5.5	Resultados obtenidos . . . . .	15
5.6	Comparación de resultados . . . . .	19
<b>6</b>	<b>Conclusión</b>	<b>21</b>

## Lista de Figuras

1	Despiece de un rodamiento . . . . .	2
2	Estructura del clasificador. . . . .	7
3	El motor y los acelerómetros de medición. . . . .	10
4	Diagrama de flujo del modelo. . . . .	13
5	Resultados obtenidos . . . . .	16

## Lista de Tablas

1	Datos normales . . . . .	11
2	Datos con falla de 0.007" . . . . .	11
3	Datos con falla de 0.014" . . . . .	12
4	Datos con falla de 0.021" . . . . .	12
5	Segmentación de la señal. . . . .	15
6	Matriz de Hankel. . . . .	15
7	Resumen de métricas con ventana 800 . . . . .	17
8	Resumen de métricas con ventana 1000 . . . . .	18
9	Resumen de métricas con ventana 1200 . . . . .	19
10	Comparación numérica. . . . .	19

# 1 Introducción

La detección y diagnóstico oportuno de fallas en maquinarias es vital para planificar su mantención. Entre los componentes del vehículo, uno de los más importantes son los rodamientos. Estos permiten la rotación de elementos minimizando su desgaste, dando una mayor durabilidad y control de la temperatura en los puntos de fricción. Existen varios tipos de rodamientos dependiendo de las necesidades de carga o de disposición, como lo son cilíndricos, los de rodillos a rótula y los que se utilizarán para esta investigación, los rodamientos de bolas[1].

Los rodamientos son ampliamente usados en la industria, desde maquinaria pesada hasta pequeños dispositivos rotatorios. Después de todo, cuando estos presentan daños, representan entre un 45% y un 55% de las averías del equipo completo [2]. Para poder monitorear el estado del rodamiento, los estudios han propuesto el uso de sensores de vibración que capturan a distintas velocidades el comportamiento de la pieza [3]. El desafío que se ha presentado ha sido el de encontrar un umbral desde el cual se considere correctamente el daño y su severidad sin tener una tasa de falsas alarmas muy alta, además de no identificar el daño cuando ya es demasiado tarde[4]. Existen diferentes tipos de rodamientos en la industria para los variados trabajos que necesita hacer cada máquina, sin embargo para el caso de esta investigación se analizarán los rodamientos de bola con anillo exterior fija y anillo interna móvil.

Dentro de las fallas que pueden incurrirse en los rodamientos, las más comunes son las de bola, anillo interior y exterior, por lo que serán el objeto de estudio en la investigación. Los datos a utilizar fueron recopilados por Bearing Data Center de Case Western Reserve University[5], los cuales son señales de vibración captados por acelerómetros montados en el rodamiento. Los daños percibidos por el rodamiento son realizados mediante choques eléctricos que aseguran cierta falla en cierto lugar del rodamiento.

Para eliminar los datos redundantes o poco significativos se utilizarán los valores singulares de la matriz de Hankel. Esta técnica además reduce la dimensión de las características acelerando el tiempo de computo. Basándose en este método, los datos que se utilizarán son los recibidos por sensores de vibraciones, los cuales son modelados como series de tiempo finitas[6]. La salida de este proceso se utilizará en un clasificador para poder determinar si hay fallo o no y donde se encuentra. Para el diagnóstico se comparará el uso de un clasificador softmax con el de una red neuronal convencional y con el uso de redes Autoencoders para disminuir la dimensión con red neuronal Elman para el clasificador[7].

Este documento estará enfocado en describir el modelo propuesto y los datos utilizados. También se mostrarán los resultados obtenidos con la mejor combinación encontrada, además de analizar estos resultados y realizar comparaciones para poder sacar conclusiones.




Figura 1: Despiece de un rodamiento de bola. Las partes que están incluidas en el estudio son el anillo externo (carcasa exterior), bolas y anillo interno (carcasa interior).

## **2 Definición de Objetivos**

### **2.1 Objetivos Generales**

Desarrollar un algoritmo de extracción de características integrado con Redes Neuronales Artificiales para mejorar la exactitud de diagnóstico de fallo de rodamiento bajo condición de operación de velocidad variable.

### **2.2 Objetivos Específicos**

- Extraer características desde la señal de vibración utilizando la Descomposición de Valores Singulares de Hankel
- Implementar un clasificador de regresión Softmax usando algoritmo de aprendizaje Scaled Conjugate Gradient Descent.
- Evaluar el desempeño del modelo propuesto y comparar su rendimiento con modelos publicados en revistas científicas.



## 3 Estado del Arte

### 3.1 Descomposición de Valores Singulares y la matriz de Hankel

Como se mencionó previamente en el presente documento, el uso de valores singulares lleva más de una década siendo utilizado en el área de diagnóstico de fallas de elementos rotatorios. En [8], se ha optado por utilizar algoritmos aleatorizados en el cálculo de los valores singulares, en donde estos son uniformemente aleatorios. [9] presenta una herramienta de descomposición de valores singulares pre acondicionada, permitiendo el procesamiento de grandes cantidades de datos en tiempos razonables. En [10] se detalla el uso de este método en la eliminación de ruido en procesamiento de imágenes. Se puede ver algo parecido en [11] donde también se está utilizando para eliminar ruido, e interferencia en este caso, sin embargo en este caso es en señales magnéticas.

De la mano de lo anterior se encuentran las matrices de Hankel, las cuales son una transformada del mismo nombre que convierte un vector con los datos de una señal en una matriz con ciertas propiedades [12]. Los últimos avances y usos de esta herramienta se pueden ver en [13], donde se baja la complejidad de cómputo y hace innecesario un pre procesamiento para algoritmos complejos. En [14] se puede ver su utilidad cuando se necesita reconstruir las señales originales.

### 3.2 Diagnóstico de severidad en rodamientos

Para la investigación, se utilizarán las herramientas previamente descritas, las cuales en conjunto ayudan a realizar un diagnóstico rápido y certero. Antes de hablar de los últimos avances, es necesario mostrar las distintas aproximaciones con las que se ha atacado este problema, de los cuales esta investigación se centrara en la técnica de monitoreo de condición [15]. Como se ve en [16], se utilizan otras técnicas para eliminar ruido y detectar fallas, descomponiendo la señal en componentes no densos y un componente ruido que será apartado del cómputo. También se ve en [17] como se buscan otras maneras de obtener características de la señal de vibración para poder diagnosticar con más precisión y en un tiempo razonable la falla en un rodamiento.

Sin embargo, un acercamiento más parecido al que se realizará en esta investigación se puede ver en [18, 19]. En el primero se utilizan los valores singulares de la matriz de Hankel para extraer estas como características. De entre estas se hace un corte para disminuir su dimensionalidad y por lo

tanto, eliminar ruido de la señal. Para este caso, se utilizan como algoritmos de entrenamiento los descritos en el Modelo Escondido de Markov (HMM). Para el segundo caso, se utilizan las técnicas de SVD en la matriz de Hankel, sin embargo solo se estudia su efecto en la reducción de ruido y no en el diagnóstico de fallas o de severidad.

Para esta investigación, se realizará una comparación con el estudio realizado en [20] donde se trabajó con aprendizaje extremo (ELM) y se explicaron otras técnicas. A diferencia del presente informe en el cual se utilizó valores singulares de la matriz de Hankel, en este se calculó la transformada de Fourier rápida (FFT) para cada muestra, dando como resultado 1024 características. Estas tienen la propiedad de ser simétricas, por lo que solo fue necesario usar 512, la mitad. Después se dividió la base de datos en partes iguales; una para entrenamiento y la otra para las pruebas. Luego armó una red Auto encoder ELM para la reducción de la dimensionalidad de las características. La cantidad de nodos ocultos para las 3 capas fue de 650, 150 y 30. Finalmente, para realizar la clasificación, se implementó un perceptrón multicapa ELM.

## 4 Marco Teorico

### 4.1 Matriz de Hankel

Una matriz infinita es llamada matriz de Hankel si tiene la forma:

$$H = \begin{bmatrix} \alpha_0 & \alpha_1 & \alpha_2 & \dots \\ \alpha_1 & \alpha_2 & \alpha_3 & \dots \\ \alpha_2 & \alpha_3 & \alpha_4 & \dots \\ \vdots & \vdots & \vdots & \ddots \end{bmatrix} \quad (1)$$

Donde  $a = [a_j] ; j \leq 0$  es una secuencia de números complejos. En términos matemáticos, se puede definir como toda matriz que cumpla:

$$\forall a_{i,j} \in H \longrightarrow a_{i,j} = a_{i-1,j+1} \quad (2)$$

#### 4.1.1 Incrustación

Dada una señal discreta  $X = [x_1, x_2, \dots, x_N]$  se forma la matriz de Hankel como:

$$H = \begin{bmatrix} x_1 & x_2 & x_3 & \dots & x_m \\ x_2 & x_3 & x_4 & \dots & x_{m+1} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & x_{L+2} & \dots & x_N \end{bmatrix} \quad (3)$$

Donde:

$$L = N - m + 1 \quad (4)$$

$$1 < m < L$$

Dentro de esta, se ven los componentes:

$$R = [x_1, x_2, \dots, x_n] \quad (5)$$

$$C = [x_{L+1}, x_{L+2}, \dots, x_N]^t \quad (6)$$

Los cuales juntos forman la vibración original  $X$  de la forma:

$$X = R + C^t \quad (7)$$

## 4.2 Descomposición de Valores Singulares

La descomposición de valores singulares de una matriz  $A_{m \times n}$  es la factorización de  $A$  en el producto de tres matrices:

$$A = U * S * V^t \quad (8)$$

Donde  $U$  y  $V$  son columnas ortonormales,  $I$  la matriz identidad y  $S$  una matriz diagonal con valores reales positivos.

$$s = \text{Diag}(S) = [s_1, s_2, \dots, s_L] \quad (9)$$

Con  $L$  siendo el rango de la matriz. Estos elementos son conocidos como los valores singulares de la matriz  $A$ .  $L$  por lo tanto pasa a ser la cantidad de valores singulares y por ende la entrada al clasificador Softmax.

## 4.3 Clasificador Softmax

Para este estudio se utilizará la regresión Softmax como mecanismo para poder encontrar en que categoría de fallo, o normalidad, se encuentra una muestra de señal. Este consiste en un red neuronal artificial de una sola capa usando el algoritmo de entrenamiento Scaled Conjugate Gradient Descent explicado en la sección 4.3.3.




Figura 2: Estructura del clasificador.

Como se ve en la figura 2, dada la entrada  $s$  de  $L$  valores singulares, se realiza una combinación lineal entre estos y la ponderación, o peso, que el clasificador le da a cada uno.

$$z_k = w_{k,j} \cdot s_j \quad (10)$$

$$\text{softmax}(k) = y_k = \frac{e^{z_k}}{\sum_{k=1}^{10} e^{z_k}} \quad (11)$$

$$j = 1, 2, \dots, M$$

$$k = 1, 2, \dots, 10$$

Entonces, el clasificador toma los valores singulares  $s$  de la muestra  $j$

### 4.3.1 Aprendizaje

Las redes neuronales aprenden ciertos patrones de los datos para poder pronosticar algún resultado dado un nuevo conjunto de entradas. Para esto, ajustan los pesos de las conexiones entre una neurona y otra para así ir cambiando el resultado que esta arroja al pasar la entrada por la función de transferencia. En cuanto a entrenar la red, se tienen dos tipos: feed forward y back propagation. La primera se recorre y ajusta sus pesos mientras va avanzando, mientras que la de back propagation realiza una pasada hacia adelante para luego devolverse actualizando los valores. Se utiliza el termino propagación debido a que al terminar de hacer la pasada hacia adelante, se obtiene un cierto error que será propagado hacia atrás, o sea, se actualizarán los pesos en base a este error.

### 4.3.2 Función de costo

Se mencionó que se ajustarán los pesos de la red para enseñarle los patrones de la red. Para este efecto, se utiliza la función de costo. Esta se define como cuánto cuestan los errores realizados y tienen un par de propiedades que una función candidata idóneamente debe poseer.

- Ser simétrica en torno al 0. Esto para que errores positivos y negativos sean penalizados igualmente.
- Debe penalizar errores grandes y errores muy grandes casi por igual.

Al tener la función de costo, el siguiente desafío radica en minimizarla, pues al hacer esto, se asegura que la red está cometiendo un error muy pequeño al pronosticar resultados. La función de costo más comúnmente utilizada es la del error cuadrático medio, la cual se define con la siguiente expresión:

$$MSE = \frac{1}{M} \sum_{j=1}^M \sum_{i=1}^k [t_{i,j} - y_{i,j}]^2 \quad (12)$$

Donde  $t_{i,j} - y_{i,j}$  corresponde al error entre el resultado esperado  $t_{i,j}$  y el valor de pronostico  $y_{i,j}$  realizado por la red dado los valores singulares  $s$  provenientes de la ecuación 6.

### 4.3.3 Scaled Conjugate Gradient Descent (SCG)

A grandes rasgos, SCG es un algoritmo de entrenamiento para redes neuronales y es un parte de los metodos de gradiente conjugado. Estos, análogamente al descenso del gradiente (SG), calculan el gradiente de la función de costo para poder corregir los pesos de la red en función de este. La diferencia radica en que se se busca que el siguiente paso, incremento o decremento de los pesos, sea conjugado del anterior. Además, SCG agrega el escalado de dicho resultado, dando. Cada iteración  $k$  calcula el peso  $w_i$  de CG.

$$e = MSE \quad (13)$$

$$c = k * L \quad (14)$$

$$p = \begin{bmatrix} \frac{\delta^2 e}{\delta w_1^2} & \frac{\delta^2 e}{\delta w_1 \delta w_2} & \cdots & \frac{\delta^2 e}{\delta w_1 \delta w_c} \\ \frac{\delta^2 e}{\delta w_2 \delta w_1} & \frac{\delta^2 e}{\delta w_2 \delta w_2} & \cdots & \frac{\delta^2 e}{\delta w_2 \delta w_c} \\ \vdots & \vdots & \vdots & \ddots \\ \frac{\delta^2 e}{\delta w_c \delta w_1} & \frac{\delta^2 e}{\delta w_c \delta w_2} & \cdots & \frac{\delta^2 e}{\delta w_c^2} \end{bmatrix} \quad (15)$$

$$w_{k+1} = w_k + \alpha_k p_k \quad (16)$$

La ecuación 16 representa el tamaño del paso en una dirección. En realidad.  $p_k$  es la matriz Hessiana de la función de costo, llamada también la matriz de segundas derivadas. A diferencia de otros algoritmos CG, SCG si realiza el cálculo complejo de la Hessiana, el escalar  $\alpha_k$  y el procedimiento de búsqueda de línea. Para más detalle respecto al funcionamiento de SCG vease [21].

## 5 Análisis de Resultados

### 5.1 Datos Utilizados

La base de datos que se utilizó fue creada por el Bearing Data Center de la Case Western Reserve University y es de dominio público. Las señales recopiladas fueron captadas luego de un choque eléctrico para forzar un fallo específico en los rodamientos medidos. Los datos fueron recopilados a dos velocidades de muestreo, de las cuales se eligió la de 12.000 muestras por segundo. La base de datos fue capturada no solo para distintos tamaños de daños en distintas zonas del rodamiento, sino que también para diferentes velocidades de motor.




Figura 3: El motor y los acelerómetros de medición.

En la base de datos, se encuentran diferentes mediciones de rodamientos que están posicionados en diferentes lugares. En el ventilador (FE, Fan End), en el extremo de la transición (DE, Drive End) y en la base (BE, Base End). Para esta investigación se usaron los datos correspondientes al rodamiento DE.

RPM	DB asociada	Largo señal	Frecuencia muestreo (Hz)
1797	X097	243.938	12.000
1772	X098	483.903	12.000
1750	X099	483.903	12.000
1730	X100	485.643	12.000

Tabla 1: Señales que no presentan ningún tipo de falla.

RPM	DB asociada	Lugar falla	Largo señal	Frecuencia muestreo (Hz)
1797	X105	Anillo interno	121.265	12.000
1797	X130	Anillo externo	121.991	12.000
1797	X118	Bola	122.571	12.000
1772	X106	Anillo interno	121.991	12.000
1772	X131	Anillo externo	122.426	12.000
1772	X119	Bola	121.410	12.000
1750	X107	Anillo interno	122.136	12.000
1750	X132	Anillo externo	121.410	12.000
1750	X120	Bola	121.556	12.000
1730	X108	Anillo interno	122.917	12.000
1730	X133	Anillo externo	122.571	12.000
1730	X121	Bola	121.556	12.000

Tabla 2: Señales que presentan fallas de diámetro 0.007" en el anillo interno, externo o en alguna bola.



RPM	DB asociada	Lugar falla	Largo señal	Frecuencia muestreo (Hz)
1797	X169	Anillo interno	121.846	12.000
1797	X197	Anillo externo	121.846	12.000
1797	X185	Bola	121.846	12.000
1772	X170	Anillo interno	121.846	12.000
1772	X198	Anillo externo	122.136	12.000
1772	X186	Bola	122.136	12.000
1750	X171	Anillo interno	121.846	12.000
1750	X199	Anillo externo	121.846	12.000
1750	X187	Bola	121.991	12.000
1730	X172	Anillo interno	121.701	12.000
1730	X200	Anillo externo	121.991	12.000
1730	X188	Bola	122.136	12.000

Tabla 3: Señales que presentan fallas de diámetro 0.014" en el anillo interno, externo o en alguna bola.

RPM	DB asociada	Lugar falla	Largo señal	Frecuencia muestreo (Hz)
1797	X209	Anillo interno	122.136	12.000
1797	X234	Anillo externo	122.426	12.000
1797	X222	Bola	121.991	12.000
1772	X210	Anillo interno	121.556	12.000
1772	X235	Anillo externo	121.991	12.000
1772	X223	Bola	121.701	12.000
1750	X211	Anillo interno	121.846	12.000
1750	X236	Anillo externo	121.281	12.000
1750	X224	Bola	121.136	12.000
1730	X212	Anillo interno	121.991	12.000
1730	X237	Anillo externo	121.991	12.000
1730	X225	Bola	121.136	12.000

Tabla 4: Señales que presentan fallas de diámetro 0.021" en el anillo interno, externo o en alguna bola.

## 5.2 El modelo

Para poder discriminar entre la normalidad o los diferentes tipos de daños posibles, se hará uso de un clasificador Softmax entre los diferentes estados en los que se puede encontrar el rodamiento, los cuales serían:

1. Sin fallo, o normal
2. Daño en anillo interno de 0.007 pulgadas de diámetro.
3. Daño de bola 0.007 pulgadas de diámetro.
4. Daño en anillo externo de 0.007 pulgadas de diámetro.
5. Daño en anillo interno de 0.014 pulgadas de diámetro.
6. Daño en anillo externo de 0.014 pulgadas de diámetro.
7. Daño de bola 0.014 pulgadas de diámetro.
8. Daño en anillo interno de 0.021 pulgadas de diámetro.
9. Daño en anillo externo de 0.021 pulgadas de diámetro.
10. Daño de bola 0.021 pulgadas de diámetro.

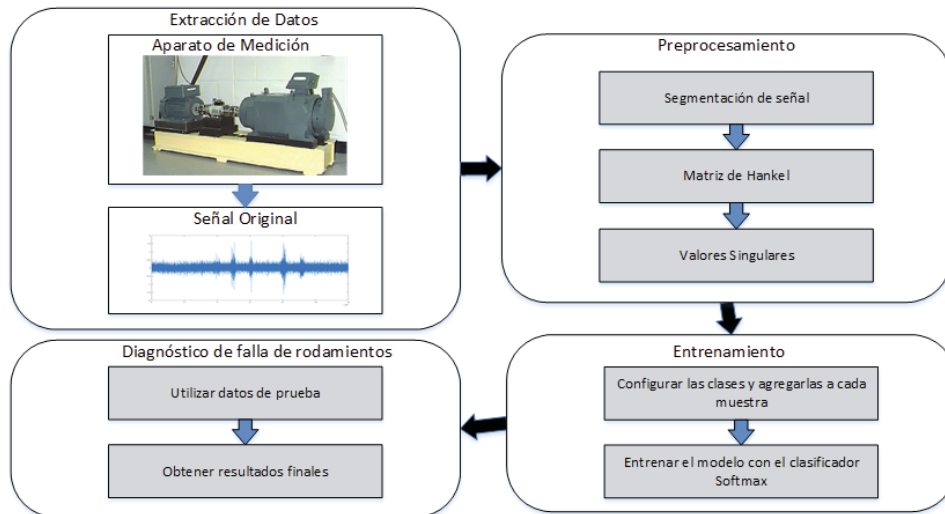


Figura 4: Diagrama de flujo del modelo.

Primero se realiza la segmentación de las señales. Después se divide aleatoriamente la base de datos entre datos de entrenamiento y datos de prueba. Estos son transformados con los valores singulares de la matriz de Hankel correspondiente, pasándolos de la dimensión de la ventana que se tomó a  $L$  como se ve en la ecuación 9. Estos valores singulares pasan a ser las características que recibe el clasificador softmax y discrimina a cuál de las 10 clases previamente mencionadas corresponde. A continuación se explicará con más detalle cada proceso, detallando cada salida que entrará al proceso siguiente hasta conseguir el diagnóstico de la severidad de fallo.

### 5.3 Segmentación de la señal

Se tienen las 40 mediciones de datos descritas anteriormente. Sea  $X_i$  la señal de la base de datos  $i$  y  $x_{i,j}$  un dato cualquiera de dicha señal. Entonces, se trunca cada señal en el dato número 120.000 para así poder tener señales de mismo largo y por lo tanto una distribución más homogénea.

$$\begin{aligned} X_i &= [x_{i,1}; x_{i,2}; x_{i,3}; \dots; x_{i,N}] \\ i &= [1, 2, \dots, 40] \\ N &= 120.000 \end{aligned} \tag{17}$$

Luego se decide una ventana  $V$ , un nuevo largo de señal, que decidirá la cantidad de muestras que producirá cada señal. Esta segmentación es importante ya que disminuye el tiempo de computo a la vez que crea muestras que serán usadas más tarde en el entrenamiento y prueba del clasificador. No obstante cabe recalcar que una ventana demasiado pequeña podría dejar fuera, o incompleta, la falla; una ventana demasiado grande podría causar el mismo efecto, además de llegar a no proveer suficientes muestras para el clasificador. Como se ve en la ecuación 18, se divide la señal completa en la ventana escogida. Esto se realiza para cada una de las 40 capturas realizadas descritas por la tabla ??.

$$\begin{aligned} X_i &\rightarrow Muestra_k \\ Muestra_k &= [m_{k,1}; m_{k,2}; \dots; m_{k,V}] \\ M &= N * \frac{40}{V} \end{aligned} \tag{18}$$

Muestra 1	$m_{1,1}$	$m_{1,2}$	$\dots$	$m_{1,V}$
Muestra 2	$m_{2,1}$	$m_{2,2}$	$\dots$	$m_{1,V}$
$\dots$	$\dots$	$\dots$	$\dots$	$\dots$
Muestra M	$m_{M,1}$	$m_{M,2}$	$\dots$	$m_{M,V}$

Tabla 5: Segmentación de la señal.

#### 5.4 Extracción de características

Finalizada la segmentación se pasa cada muestra a una matriz de Hankel de largo  $L$  y ancho  $K$ . Dada entonces una señal segmentada de largo  $M$ , la matriz de Hankel resultante tiene dimensiones  $L \times K$ , donde  $L + k + 1 = M$ .


1	$l_{1,1}$	$l_{1,2}$	$\dots$	$l_{1,K}$
2	$l_{2,1}$	$l_{2,2}$	$\dots$	$l_{1,K}$
$\dots$	$\dots$	$\dots$	$\dots$	$\dots$
L	$l_{L,1}$	$l_{L,2}$	$\dots$	$l_{L,K}$

Tabla 6: Matriz de Hankel.


Para cada matriz de Hankel se calculan entonces  $L$  valores singulares  $S$ . Estos valores son una representación de los datos originales en una dimensión menor, ayudando así a eliminar redundancia que podría nublar el juicio del clasificador. El vector de valores singulares  $S$  pasará como entrada al clasificador.

#### 5.5 Resultados obtenidos


A continuación se presentan los resultados obtenidos en las pruebas propuestas.



(a)



(b)



(c)

Figura 5: Se utilizaron largos de 800 (a), 1000 (b) y 1200 (c) para la ventana de la señal y se probó con 20, 30, 40 y 50 valores singulares para cada una a través de 30 ejecuciones.

El comportamiento del modelo con las distintas configuraciones demuestra mantenerse dentro del margen del 99,5% excepto por excepciones puntuales. Estos escenarios fueron probados a través de 30 ejecuciones para encontrar su comportamiento estadísticamente normal y así poder afirmar que se comportará de manera similar para una ejecución cualquiera.

Métrica		20 SV	30 SV	40 SV	50 SV
Exactitud	Mínimo(%)	97,79	97,79	<b>99,82</b>	97,65
	Máximo(%)	<b>99,93</b>	<b>99,93</b>	<b>99,93</b>	99,87
	Promedio(%)	99,81	99,79	<b>99,88</b>	99,73
	Desv. estándar	0,0038	0,0038	<b>0,0003</b>	0,0039
Precision	Mínimo(%)	88,93	88,93	<b>99,10</b>	88,27
	Máximo(%)	99,63	<b>99,67</b>	99,63	99,37
	Promedio(%)	99,03	98,96	<b>99,39</b>	98,67
	Desv. estándar	0,0191	0,0190	<b>0,0013</b>	0,197
Recall	Mínimo(%)	88,93	88,93	<b>99,10</b>	88,27
	Máximo(%)	99,63	<b>99,67</b>	99,63	99,37
	Promedio(%)	99,03	98,96	<b>99,39</b>	98,67
	Desv. estándar	0,0191	0,0190	<b>0,0013</b>	0,197
Fscore	Mínimo(%)	88,93	88,93	<b>99,10</b>	88,27
	Máximo(%)	99,63	<b>99,67</b>	99,63	99,37
	Promedio(%)	99,03	98,96	<b>99,39</b>	98,67
	Desv. estándar	0,0191	0,0190	<b>0,0013</b>	0,197

Tabla 7: Resultados obtenidos para ventanas 1000. Con 20, 30, 40 y 50 valores singulares.

El mejor resultado, usando una ventana de 800 datos, fue utilizando 40 valores singulares. Como se ve en la tabla 7, esta configuración dio como resultado un promedio de 99,88% de aciertos con una baja desviación estándar.

Métrica		20 SV	30 SV	40 SV	50 SV
Exactitud	Mínimo(%)	<b>98,01</b>	97,86	97,75	97,75
	Máximo(%)	99,96	<b>99,98</b>	99,96	99,82
	Promedio(%)	99,83	<b>99,84</b>	99,77	99,78
	Desv. estándar	<b>0,0035</b>	0,0037	0,0052	0,0039
Precisión	Mínimo(%)	<b>90,04</b>	89,29	88,75	88,75
	Máximo(%)	99,79	<b>99,88</b>	99,79	99,58
	Promedio(%)	99,14	<b>99,17</b>	98,87	98,90
	Desv. estándar	<b>0,0173</b>	0,0187	0,0260	0,193
Recall	Mínimo(%)	<b>90,04</b>	89,29	88,75	88,75
	Máximo(%)	99,79	<b>99,88</b>	99,79	99,58
	Promedio(%)	99,14	<b>99,17</b>	98,87	98,90
	Desv. estándar	<b>0,0173</b>	0,0187	0,0260	0,193
Fscore	Mínimo(%)	<b>90,04</b>	89,29	88,75	88,75
	Máximo(%)	99,79	<b>99,88</b>	99,79	99,58
	Promedio(%)	99,14	<b>99,17</b>	98,87	98,90
	Desv. estándar	<b>0,0173</b>	0,0187	0,0260	0,193

Tabla 8: Resultados obtenidos para ventanas 1000. Con 20, 30, 40 y 50 valores singulares.

En la tabla se puede avistar que el mejor promedio de exactitud se logra para la configuración de ventana 1000 con 30 valores singulares con 99,84%. Como se puede apreciar, aumentar la ventana a este valor disminuyó los resultados obtenidos para todas las pruebas realizadas.

Métrica		20 SV	30 SV	40 SV	50 SV
Exactitud	Mínimo(%)	<b>98,83</b>	97,84	97,85	97,73
	Máximo(%)	99,95	99,96	<b>99,97</b>	99,96
	Promedio(%)	<b>99,91</b>	99,84	99,84	99,80
	Desv. estándar	<b>0,0003</b>	0,0038	0,0038	0,0039
Precision	Mínimo(%)	<b>99,15</b>	89,20	89,25	88,65
	Máximo(%)	99,75	99,80	<b>99,85</b>	99,80
	Promedio(%)	<b>99,54</b>	99,18	99,21	98,99
	Desv. estándar	<b>0,0014</b>	0,0189	0,0189	0,197
Recall	Mínimo(%)	<b>99,15</b>	89,20	89,25	88,65
	Máximo(%)	99,75	99,80	<b>99,85</b>	99,80
	Promedio(%)	<b>99,54</b>	99,18	99,21	98,99
	Desv. estándar	<b>0,0014</b>	0,0189	0,0189	0,197
Fscore	Mínimo(%)	<b>99,15</b>	89,20	89,25	88,65
	Máximo(%)	99,75	99,80	<b>99,85</b>	99,80
	Promedio(%)	<b>99,54</b>	99,18	99,21	98,99
	Desv. estándar	<b>0,0014</b>	0,0189	0,0189	0,197

Tabla 9: Resultados obtenidos para ventanas 1000. Con 20, 30, 40 y 50 valores singulares.

Finalmente, al probar con una ventana de 1200 datos, se obtuvo que el mejor promedio de aciertos fue de 99,91% usando 20 valores singulares. Esto, sumado a la baja desviación estándar y valores de precisión mejores que los obtenidos en la tabla 7, hacen de esta la mejor configuración encontrada para el modelo propuesto.

## 5.6 Comparación de resultados

En esta última sección se comparará la mejor configuración de ventana y valores singulares con los resultados obtenidos en [20]. El modelo propuesto será abreviado como HSV-S (Hankel Singular values- Softmax).

	SAEs	AE-ELM	HSV-S
Exactitud(%)	99,80	98,53	99,91
Tiempo(s)	49,19	0,75	10,11

Tabla 10: Comparación numérica.

Como se ve en la tabla, existe una mejora de más del 1% con respecto



a la investigación comparada, en detrimento del tiempo de computo. Más importante aún, se logró superar la técnica SAE tanto en tiempo como en exactitud. Esta fue el mejor rival de AE-ELM comparado con otras técnicas que no pudieron acercarse significativamente ni en exactitud ni en tiempo de computo.

## 6 Conclusión

La investigación realizada ha expuesto la importancia de diagnosticar a tiempo las fallas que se pueden generar en rodamientos. El costo de oportunidad que genera en la industria parar una maquina para poder reemplazar la pieza defectuosa es considerable tomando en cuenta que una revisión preventiva tomaría mucho menos esfuerzo y dinero. El modelo que se propuso tiene como objetivo permitir el monitoreo en tiempo real de el estado del rodamiento y probó dar resultados aceptables en tiempos de ejecución que lo permiten. El tipo de rodamiento que se estudió fue el del sistema de transmisión, el cual es parte de un sistema cuya importancia solo es superada por la del motor mismo. La base de datos utilizada realizó fallos controlados y medidos en el rodamiento, los cuales fueron captados por un acelerómetro funcionando con ruido e interferencia mínimos. En contraste, las máquinas suelen funcionar en distintos terrenos y con variadas cargas, otorgando una aleatoriedad al momento en el que el fallo se presentará. Empero, las conclusiones obtenidas por esta investigación son aplicables a cualquier tipo de análisis y clasificación de muestras.

Se extrae del trabajo la importancia de las características a la hora de crear un modelo de diagnostico. Utilizando una extracción que llevó a las señales originales a una dimensión menor mediante los valores singulares de Hankel se entregaron características relevantes que la regresión Softmax pudo clasificar adecuadamente para la mayoría de los casos. Cabe recalcar que este clasificador posee una baja complejidad tanto de implementación como de calculo, comprobando aún más la importancia de cuales características se usan a la hora de diseñar un modelo de diagnostico.

Se probaron distintas configuraciones, entre tamaño de ventana de segmentación de señal y cantidad de valores singulares de Hankel. La que demostró ser la más efectiva a la hora de pronosticar que tipo de fallo, o normalidad, poseía el rodamiento fue de 1200 datos de ventana y 20 valores singulares, dando como resultado un promedio de aciertos del 99,1%. Un incremento en la cantidad de valores singulares demostró una baja en las métricas de rendimiento. Las distintas pruebas se realizaron para intentar clasificar en las 10 categorías posibles a través de 30 ejecuciones con 1000 iteraciones cada una, asegurando así que el promedio real de aciertos se encuentre muy cercano a este valor. De este número además se concluye que las revoluciones por minuto (RPM) del motor no influyen en una medida significativa a la hora de diagnosticar una señal.

Para comprobar la relevancia de esta investigación, se comparó el mejor resultado obtenido con el mejor de un estudio comparativo realizado recién-

temente en el cual se utilizó una red profunda Auto encoder extremo (AE-ELM). Si bien se logró mejorar el resultado de exactitud obtenido en dicho estudio (98,53%), el tiempo de computo fue mucho menor para este; 10,1 y 0,75 segundos respectivamente. Cabe recalcar que de utilizarse cualquiera de los dos modelos en una señal de 10 segundos, ambos serían capaces de pronosticar antes de que terminara la siguiente medición, permitiendo entonces que el sistema funcionase monitoreando en tiempo real.

## Referencias

- [1] C. P. Chaudhari, B. B. Thakare, S. R. Patil, and S. Gunjal, "Study of bearing and its types," *International Journal of Advance Research In Science And Engineering*, 2015.
- [2] A. Rai and S. Upadhyay, "A review on signal processing techniques utilized in the fault diagnosis of rolling element bearings," *Tribology International*, vol. 96, pp. 289–306, 2016.
- [3] D. H. Pandya, S. H. Upadhyay, and S. Harsha, "Ann based fault diagnosis of rolling element bearing using time-frequency domain feature," *International Journal of Computational Engineering Science*, 2013.
- [4] L. C. K. Reuben and D. Mba, "Bearing time-to-failure estimation using spectral analysis features," *Structural health monitoring*, vol. 13, no. 2, pp. 219–230, 2014.
- [5] K. Lotaro, "Case western reserve university, bearing data center (seeded fault test data)." <http://csegroups.case.edu/bearingdatacenter/home>, 2012.
- [6] X. Zhao and BangyanYe, "Similarity of signal processing effect between hankel matrix-based svd and wavelet transform and its mechanism analysis," *Mechanical Systems and Signal Processing*, vol. 23, no. 4, pp. 1062–1075, 2009.
- [7] W. Mao, J. He, Y. Li, and Y. Yan, "Bearing fault diagnosis with auto-encoder extreme learning machine: A comparative study," *Journal of Mechanical Engineering Science*, 2016.
- [8] G. Martinsson, N. Halko, V. Rokhlin, and S. Hao, "Randomized methods for computing the singular value decomposition (svd) of very large matrices," *Works. on Alg. for Modern Mass. Data Sets*, 2010.
- [9] L. Wu, E. R. Alcalde, and A. Stathopoulos, "Primme svds: A high-performance preconditioned svd solver for accuratelarge-scale computations," *Technical Report, 1607.01404*, 2016.
- [10] Q. Guo, C. Zhang, Y. Zhang, and H. Liu, "An efficient svd-based method for image denoising," *IEE Transactions on Circuits and Systems for Video Technology*, vol. 26, no. 5, 2016.

- [11] W. Chen, H. Ma, D. Yu, and H. Zhang, "Svd-based technique for interference cancellation and noise reduction in nmr measurement of time-dependent magnetic fields," *Sensors*, 2016.
- [12] V. Speller, *An Introduction to Hankel Operators. Hankel Operators and Their Applications*, 2003.
- [13] A. Townsend, M. Webb, and S. Olver, "Fast polynomial transforms based on toeplitz and hankel matrices," *Math. Comp.*, 2017.
- [14] D. H. Hubler and T. N. Wiesel, "Receptive fields and functional architecture of monkey striate cortex," *The Journal of physiology*, 1968.
- [15] C. Senthilraja and L. Vinoth, "A review on fault diagnosis of ball bearing using sound and vibration signals," *International Journal of Innovative Research in Science Engineering and Technology*, vol. 4, no. 13, 2015.
- [16] W. He, Y. Ding, Y. Zi, and I. W. Selesnick, "Repetitive transients extraction algorithm for detecting bearing faults," *Mechanical Systems and Signal Processing*, vol. 84, pp. 227–244, 2017.
- [17] Q. Xiong, W. Zhang, T. Lu, and S. Liang, "A fault diagnosis method for rolling bearings based on feature fusion of multifractal detrended fluctuation analysis and alpha stable distribution," *Shock and Vibration*, 2016.
- [18] H. Jiang, J. Chen, G. Dong, T. Liu, and G. Chen, "Study on hankel matrix-based svd and its application in rolling element bearing fault diagnosis," *Mechanical Systems and Signal Processing*, 2015.
- [19] R. Golafshan and K. Y. Sanliturk, "Svd and hankel matrix based denoising approach for ball bearing fault detection and its assessment using artificial faults," *Mechanical Systems and Signal Processing*, 2015.
- [20] W. Mao, J. He, Y. Li, and Y. Yan, "Bearing fault diagnosis with auto-encoder extreme learning machine: A comparative study," *Journal of Mechanical Engineering Science*, 2016.
- [21] M. F. Møller, "A scaled conjugate gradient algorithm for fast supervised learning," vol. 6, pp. 525–533.