



Universidad Autónoma de Querétaro
Facultad de Ingeniería
Doctorado en Ingeniería

**DESARROLLO DE UN SISTEMA INTELIGENTE PARA MONITOREO DE FALLA EN
PROCESOS DE FRESADO EN MÁQUINA CNC**

Tesis

Que como parte de los requisitos para obtener el Grado de
Doctor en Ingeniería

Presenta:

Georgina del Carmen Mota Valtierra

Dirigido por:

Dr. Gilberto Herrera Ruíz

Centro Universitario, Querétaro, Qro.
Diciembre 2019
México



Universidad Autónoma de Querétaro

Facultad de Ingeniería

"DESARROLLO DE UN SISTEMA INTELIGENTE PARA MONITOREO DE FALLA EN PROCESOS DE FRESADO EN MÁQUINAS CNC"

Tesis

Que como parte de los requisitos para obtener el título de Doctor en Ingeniería

Presenta:

Georgina del Carmen Mota Valtierra

Dirigido por:

Dr. Gilberto Herrera Ruíz

Dr. Gilberto Herrera Ruíz
Presidente

Firma

Dr. Juvenal Rodríguez Reséndiz
Secretario

Firma

Dr. Edgar Alejandro Rivas Araiza
Vocal

Firma

Dr. Mariano Garduño Aparicio
Suplente

Firma

Dr. Gonzalo Macías Bobadilla
Suplente

Firma

Centro Universitario
Querétaro, Qro.
Octubre 2019

ÍNDICE GENERAL

ÍNDICE GENERAL	3
1 RESUMEN.....	6
ABSTRACT	7
CAPÍTULO I.....	8
1 Antecedentes.....	8
1.1 Proceso de fresado.....	8
1.2 Sistemas de adquisición.....	9
1.3 Acondicionamiento de señales.....	15
1.4 Sistemas de monitoreo	19
1.4.1 Sistemas de monitoreo clásicos.....	19
1.4.2 Sistemas de monitoreo inteligente.....	21
1.5 Justificación	23
1.6 Hipótesis.....	23
1.7 Objetivo.....	23
1.7.1 Objetivos Particulares.....	24
1. CAPÍTULO II.....	25
2 Fundamentación teórica.....	25
2.1 Adquisición de señales y filtrado.....	25
2.2 Transformada Wavelet	26
2.2.1 Transformada Wavelet continua (TWC).....	27
2.2.2 Transformada Wavelet discreta (TWD).....	28
2.3 Redes neuronales artificiales (RNA)	36
2.3.1 Mecanismos de aprendizaje.....	37
2.3.2 Topología de las RNA	38
2.3.2.1 Perceptrón Multicapa (MLP).....	38
2.3.2.2 Mapas auto organizados (SOM)	39
3. CAPÍTULO III.....	42
3 Metodología.....	42
3.1 Proceso de fresado.....	43
3.2 Adquisición de señales.....	44
3.3 Acondicionamiento de las señales	46
3.4 Proceso de Filtrado.....	47
3.5 Transformada Wavelet	49

3.6 Red neuronal	53
3.6.1 Parámetros del MLP	53
3.6.2 Parámetros de la red SOM	55
4. CAPÍTULO IV	59
4 Resultados	59
4.1 Adquisición	59
4.2 Filtrado	60
4.3 Transformada Wavelet	60
4.4 Red Neuronal Artificial	60
4.2 Discusión de los resultados	68
Referencias.	70
ANEXOS	46

INDICE DE TABLAS

Tabla 3.1 Etapas del proceso de fresado	42
Tabla 3.2 Parámetros de corte utilizados en este experimento	43
Tabla 3.3 Principales familias de Wavelets	48
Tabla 3.4 Promedios de las eproximaciones	51
<i>Tabla 3.5 Parámetros de las RNA tipo MLP con entrenamiento no supervisado</i>	53
Tabla 3.6 Parámetros de la RNA tipo SOM con entrenamiento no supervisado	55
Tabla 3.7 Relación de vecindad entre neuronas de redes tipo SOM de 4x4 y 4x8	55
Tabla 3.8 Relación de vecindad entre neuronas de redes tipo SOM de 8x8	56
Tabla 4.1 Especificaciones de las RNA de topología MLP utilizadas	61
Tabla 4.2 error en la red MLP	61
Tabla 4.3 Clasificación de señales por neuronas de una red SOM 4x4 supervisada	64
Tabla 4.4 Clasificación de señales por neuronas de una red SOM 4x4 No supervisada	66
Tabla 4.5 Error alcanzado por la red del tipo SOM supervisada y no supervisada durante el entrenamiento	67

ÍNDICE DE FIGURAS

Figura 1.1 Posibles parámetros a considerar en un sistema de monitoreo de máquinas rotativas	8
Figura 1.2 Dinamómetro estacionario 9139AA marca Kistler [20]	11
Figura 2..2 Transformada wavelet rápida	32
Figura 2.3 Función de entrenamiento de Perceptrón.	39
Figura 2.4 a) SOM de estructura rectangular b) SOM de estructura Hexagonal	40
Figura 2.5 Diagrama que muestra la función de entrenamiento de la SOM	41
Figura 3.1 Etapas del sistema de monitoreo propuesto.	42
Figura 3.2 Etapas del proceso de fresado	43
Figura 3.3 Señales presentes en las señales adquiridas	45
Figura 3.4 Corrientes de monitoreo que proporciona la fresadora	46
Figura 3.5 Señales adquiridas usando 2 insertos en buenas condiciones y posteriormente un inserto desgastado y 1 en buen estado	47
Figura 3.6 Filtro FIR pasa banda	47
Figura 3.7 Respuesta en magnitud del filtro FIR pasa banda	49
Figura 3.8 Respuesta en fase del filtro FIR pasa banda	49
Figura 3.9 Señal de corriente obtenido del husillo con dos cortadores están en buenas condiciones sin filtrar y filtrada	49
Figura 3.10 Familia de wavelets	50
Figura 3.11 Señal a transformar y las aproximaciones y detalles obtenidos de la transformación.	51
Figura 3.12 Señales transformadas utilizando la familia Daubechies	51
Figura 3.13 Señales transformadas utilizando las familias Symlet y Coiflet	52
Figura 3.14 Señales resultantes de diversos niveles de transformación, utilizando una wavelet madre Daubechies 5	53
Figura 3.15 Estructura del MLP utilizada. Es un MLP totalmente conectado	54
Figura 3.16 función sigmoide	55
Figura 3.17 Red neuronal tipo SOM de estructura [4,8], con vecindad de 1 y conexión vertical y horizontal.	55
Figura 4.1 Adquisición de señales en el proceso de fresado, se muestra una señal con ambos insertos en buen estado y posteriormente con un inserto gastado y uno en buen estado.	60
Figura 4.2 Señal resultante del proceso de filtrado, utilizando un filtro FIR pasa banda, la señal es producida por un cortador en buen estado	61
Figura 4.3 muestra la señal filtrada y posteriormente con un nivel de transformación.	61
Figura 4.4. Error en la red MLP	63
Figura 4.6 Modificación de la relación de distancia entre las entradas y los vectores de pesos	65

RESUMEN

Uno de los objetivos principales de cualquier empresa es satisfacer las necesidades del cliente mediante la producción de productos de alta calidad, la optimización de costos al mejorar los procesos de fabricación. Para lograr las especificaciones de calidad es importante eliminar las variaciones durante los procesos de producción. Para las empresas manufactureras, el uso de sistemas de monitoreo de condición de herramientas en línea es esencial para detectar roturas o artículos de herramientas para evitar piezas de producción de baja calidad debido al estado de las herramientas de corte e incluso evitar daños a las máquinas. Las redes neuronales artificiales es uno de los métodos más comunes e informados utilizados en los sistemas de monitoreo que clasifica el estado de la herramienta, es ampliamente utilizado debido a su aprendizaje adaptativo, auto organización, tolerancia a fallas y operación en tiempo real, proporcionando buenas soluciones para la clasificación o problemas para tomar decisiones.

Existe una correlación entre las fuerzas de corte (estáticas y dinámicas) y el desgaste de la herramienta, y esos parámetros pueden estudiarse en varias formas, como la basada en los cambios de la fuerza de fricción entre las herramientas de corte y las piezas de trabajo. En varios trabajos se ha decidido analizar las fuerzas de corte para determinar el nivel de desgaste de la herramienta. Para evaluar las fuerzas de corte se desarrollaron modelos de simulación que determinan las fuerzas de corte con más precisión que los modelos analíticos debido a la aplicación del Perceptrón de múltiples capas.

El uso de sensores es común, sin embargo, su aplicación es limitada debido al estrecho rango operativo definido por el fabricante, y generalmente los diseños de los sistemas se realizan considerando condiciones de trabajo específicas, que no permiten ajustes de las operaciones de fabricación. En muchas ocasiones es necesario realizar modificaciones en la máquina para colocar sensores. Todos esos aspectos negativos no se presentan en el sistema propuesto debido a su funcionamiento sin sensores. Se presenta la propuesta de un sistema inteligente, de bajo costo y fácil incorporación al proceso original para clasificar la condición física de la herramienta de corte en una máquina fresadora, ayudando a prevenir defectos en las piezas de trabajo y evitando daños severos en la máquina herramienta.

Palabras clave: Máquina CNC, Transformación Wavelet, Mapas auto organizados, Perceptrón multicapa, sistema de monitoreo.

ABSTRACT

One of the main objectives of any company is to meet the needs of the customer through the production of high quality products, cost optimization by improving manufacturing processes. To achieve quality specifications it is important to eliminate variations during production processes. For manufacturing companies, the use of online tool condition monitoring systems is essential to detect breakage or tool articles to avoid low quality production parts due to the state of the cutting tools and even prevent damage to the machines.

Artificial neural networks is one of the most common and informed methods used in monitoring systems that classifies the state of the tool, it is widely used due to its adaptive learning, self organization, fault tolerance and operation in real time, providing good solutions for classification or problems to make decisions.

There is a correlation between the cutting forces (static and dynamic) and the wear of the tool, and these parameters can be studied in several ways, such as that based on changes in the friction force between the cutting tools and the work pieces . In several works it has been decided to analyze the cutting forces to determine the level of wear of the tool. To evaluate the cutting forces, simulation models were developed that determine the cutting forces more accurately than the analytical models due to the application of the multilayer Perceptron.

The use of sensors is common, however, their application is limited due to the narrow operating range defined by the manufacturer, and generally the designs of the systems are made considering specific working conditions, which do not allow adjustments of manufacturing operations. On many occasions it is necessary to make modifications to the machine to place sensors. All these negative aspects are not presented in the proposed system due to its operation without sensors. The proposal of an intelligent system is presented, of low cost and easy incorporation to the original process to classify the physical condition of the cutting tool in a milling machine, helping to prevent defects in the work pieces and avoiding severe damages in the machine too

Keywords: CNC Machine, Wavelet Transformation, Self-organized Maps, Multilayer Perceptron, Monitoring System I.

CAPÍTULO I

1 Antecedentes

El verbo monitorear hace referencia a supervisar o controlar las variables de un proceso, y un sistema de monitoreo es aquel que analiza y determina las variables que es necesario observar para mantenerlas dentro de ciertos parámetros. De acuerdo a la literatura, referente a las máquinas rotativas los sistemas de monitoreo se pueden clasificar, por maquinaria, parámetros a medir, sistemas de acondicionamiento utilizados y técnicas de clasificación, lo anterior se muestra en la figura 1.1.



Figura 1.1 Posibles parámetros a considerar en un sistema de monitoreo de máquinas rotativas

A lo largo de esta sección se mencionarán algunos de los artículos revisados referente a los sistemas de monitoreo existentes, las técnicas de procesamiento de señales, y técnicas de clasificación.

1.1 Proceso de fresado

El proceso de corte de metal es un proceso industrial en que las piezas de metal se forma por el desbaste de material no deseado, generalmente a través de procesos como el torneado, fresado, rectificado, y el proceso de perforación. En todos estos procesos el correcto establecimiento de los parámetros de funcionamiento de la máquina son de suma importancia, como lo demuestran Krishnamoorthy, 2012, Kumar, 2014, Soepangkat, 2013, Rajmohan, 2013, Pandey, 2014, Razavykia 2015 entre otros.

La operación de fresado es un proceso de mecanizado que es muy versátil, capaz de producir una superficie plana o curva, o partes geométricas complejas, por la alimentación de la pieza de trabajo contra un cortador giratorio que contiene un uno o más cortadores; el proceso de la fresadora es diferente al de un taladro o un

torno, ya que en el torneado y perforación las herramientas se mantienen continuamente en contacto con el material a cortar, pero en el fresado el proceso es intermitente; hay un movimiento en la herramienta de corte mientras que el torno y el taladro es fijo.

El proceso de fresado es algo complejo por lo mismo existen muchos factores que afectan el acabado de los productos, lo cual repercute de manera directa a la productividad, algunos de ellos son: el desgaste o ruptura de la herramienta, dureza del material, velocidad del husillo, material del cortador motivo por el cual se suelen usar insertos de carburo sólido que debido a su elasticidad contribuyen a lograr una mayor precisión dimensional Biswajit Das, 2015; Kumar, 2014; Anandkrishnan, 2011; Tamiloli, 2016.

Si no se mantienen dentro de ciertos rangos estas variables se degrada la calidad de las piezas mecanizadas y causan errores dimensionales o de acabado. Bajo ciertas condiciones, cuando el desgaste de herramientas, la ruptura o la vibración excesiva durante el proceso de fresado, pueden causar inclusive que la máquina tenga fallos e inclusive tenga que pararse.

El tiempo de paro de una máquina siempre tiene un efecto significativo en la productividad y provoca un aumento de los costes de producción. De acuerdo a la literatura el paro de la maquina contribuye hasta 6,8%.

Algunos de estos fallos pueden prevenirse con la implementación de un sistema de monitoreo para determinar el desgaste de la herramienta. Este sistema intenta mantener la calidad de las piezas mecanizadas y para evitar un fallo considerable no solo de la herramienta sino de la maquina misma, mediante la detección de estado de desgaste, vibración, rotura de la herramienta e incluso la colisión de la herramienta.

Anteriores estudios informaron que la aplicación de un sistema de monitoreo fiable aumenta la productividad en alrededor de 10 a 50% y aumenta el ahorro de hasta un 40% (Rehorn et al, 2005).

1.2 Sistemas de adquisición

La adquisición de señales para los sistemas de monitoreo se han clasificado en dos categorías, los métodos directos e indirectos. El método directo tiene un alto grado de precisión y consiste en un método tradicional en el que se determina el desgaste a través de la medición directa en el cortador, sin embargo se requiere más tiempo, ya que se requiere desmontar la herramienta y se debe realizar en laboratorios para mantener condiciones constantes (iluminación, instrumentos calibrados, uso de fluidos de corte, etc) Teti et al., 2010.

Los instrumentos usados con mayor frecuencia son: microscopios, una cámara CCD (dispositivo de carga acoplada), isótopos radiactivos, rayos láser y la resistencia eléctrica (Wang et al., 2007).

Los métodos indirectos utilizan correlaciones o supuestos determinados empíricamente, o a través del uso del sensor adecuado que determine el desgaste de la herramienta o las señales de mecanizado como la fuerza de corte, el par, la vibración, la emisión acústica, la corriente del motor o la potencia, temperatura, sonido y así sucesivamente (Biswajit, 2015; Tamiloli, 2016; Kumar, 2014; Modi, 2013).

Obviamente al ser indirectos son menos complicados y generalmente más rápidos, ya que no es necesario desmontar el cortador, lo que también permite que pueda realizarse el monitoreo en línea lo que también repercute en la disminución de costos ya que no es necesario detener la máquina; aunque es menos preciso que el método directo (Teti et al., 2010).

Como se mencionó anteriormente el proceso de fresado es un proceso complejo y diferente al proceso de taladrado y torneado, por lo mismo existen diferentes parámetros que influyen. En la actualidad se ha desarrollado un sin número de sensores comerciales que se han aplicado en los procesos de fresado para determinar las variables antes descritas, pero sin duda los más utilizados o reportados en la literatura son los enfocados a medir las fuerzas de corte, vibraciones, emisión acústica, torque, corriente / potencia del motor, y la temperatura de corte.

De acuerdo a la literatura se establece que la fuerza de corte está directamente relacionada con el desgaste de los cortadores, y es de las variables más sensibles a los cambios en los cortadores (Shoba, 2015; Karabulut, 2015; Razavykia, 2015; Anandakrishnan, 2011; Kumar, 2014).

La extracción de este parámetro se realiza utilizando diferentes técnicas, uno de los más comunes es el uso del dinamómetro, el cual mediante el uso de materiales piezoeléctricos determinan la presión. El material piezoeléctrico más conocido es de cristal de cuarzo (SiO_2).

Los dinamómetros usados más comúnmente son los giratorios y los fijos o de mesa, sin embargo, el dinamómetro giratorio tiene varias ventajas sobre el fijos o dinamómetros de mesa, tales como las fuerzas de corte se pueden medir en la herramienta de rotación independientemente del tamaño de la pieza de trabajo y la medición se puede realizar en cualquier posición espacial (cuatro o cinco ejes) (Kaya et al., 2011).

Algunos de los dinamómetros que podemos encontrar en el mercado son los ofrecidos por la marca Kistler, que entre otros, cuenta con un dinamómetro estacionario tipo 9139AA que tiene un diseño estructural compacto y extremadamente duro, así como un amplio rango de medición de 30 KN en las tres direcciones que mide fuerzas en el proceso de corte con una calidad de señal

excepcionalmente alta, permitiendo un análisis preciso de procesos de corte o estrategias de mecanizado y optimización de equipos auxiliares como las herramientas de corte (Kistler, 2016) Figura 1.2. Sin embargo el uso de este tipo de equipo resulta costoso y es necesario realizar mantenimiento al mismo.



Figura 1.2 Dinamómetro estacionario 9139AA marca Kistler [20]

En otro estudio, Kuljanic et al. (2009) utilizaron el dinamómetro de rotación para la detección de chatter mediante la medición de la fuerza axial F_a , la fuerza de avance F_f y la alimentación perpendicular fuerza f_{FN} . Además de medir la fuerza de corte en el proceso de fresado.

Se han utilizado gálgas extensiométricas para determinar las fuerzas de corte a través de la deformación del material. La resistencia de la galga de tensión cambia debido a la deformación que se produce en un material bajo carga mecánica. Un medidor de deformación es un bajo costo, un sensor que se puede montar directamente sobre la superficie del soporte de herramienta para medir la fuerza de corte en la transformación de (Ghani et al., 2011). Sin embargo, la fresadora necesita componentes a base de metal, tales como un dinamómetro de mesa, en él se coloca un medidor de deformación.

Por otro lado la flexión de la herramienta debido a la fuerza de corte en la operación de fresado también se puede medir mediante el uso de un sensor de deformación piezoeléctrica delgada película PVDF y un sistema de transmisión inalámbrica de datos.

Yaldiz et al., 2007 Desarrollaron un dinamómetro para medir la mesa de tres componentes de la fuerza de corte perpendiculares y par motor. El sistema combina el medidor de tensión y el acelerómetro piezoeléctrico para medir fuerzas de corte estático y dinámico. El anillo sensor de orientación se encuentra detrás del empuje del cojinete delantero medición de los componentes de la fuerza en la dirección de alimentación.

También se han utilizado anillos ortogonales hechos de varios materiales, los cuales se colocan en el husillo y miden la deformación, sin embargo estos incluyen la posibilidad de debilitamiento de la dinámica del husillo, el aumento de la deriva debido a los cambios de temperatura en el interior del husillo, mayor la diafonía

entre X, Y y Z canales debido a la deformación estructural y el efecto de las fuerzas de huso interno en la señal medida.

Andersson et al., 2011 Desarrollaron un dinamómetro de rotación, sobre la base de indicadores de tensión, la medición de la fuerza de corte principal y alimentación de corte componentes de fuerza en cada borde de corte. Los medidores de deformación se montaron en un molino de cara estándar modificado, con un diámetro de 125 mm y los bordes originalmente ocho de corte. Cada segunda posición del borde de corte se eliminó, dando espacio para el montaje de medidores de deformación, así como un debilitamiento de la herramienta a fin de que los medidores de deformación a ser sometidos a una tensión más grande. Las señales procedentes de los medidores de tensión se procesaron en una corriente en serie y se envían a través de un cable de fibra óptica a un LED (diodo emisor de luz). A continuación, las señales se transmiten por medio de señales de infrarrojos (IR) de luz sobre un espacio de aire en la parte trasera del husillo hueco, a una velocidad de 1,28 Mbps. Este equipo ha sido utilizado para los estudios experimentales de la variación de la fuerza de corte en el fresado frontal

Totis et al., 2010 utilizaron tres direcciones piezoeléctrico (3D) para la medición de componentes triaxiales de la fuerza de corte. Cada borde de corte está provisto de un sensor integrado de fuerza triaxial. Kistler 9251A, sujeto entre el cartucho modular y el cuerpo de la fresa por medio del tornillo de precarga. La transmisión de señales es a través de un sistema de telemetría con una resolución de 12 bits y una frecuencia de muestreo de 13 kHz. El resultado de la prueba de impulso de rotación muestra que el ancho de banda de frecuencia es mayor que 1,5 kHz.

La vibración es otro método sugerido para poder determinar el desgaste de los cortadores durante el proceso de fresado, cuando se utiliza este tipo de señales los sensores más utilizados son los acelerómetros piezoeléctricos. La ventaja de utilizar este método es que es posible realizar mediciones sin contacto a distancia en una herramienta giratoria de fresado muy cerca de los cortadores.

Kalvoda y Hwang, 2010a utilizaron acelerómetros aplicado un acelerómetro para TCM para detectar desgaste de la herramienta y roturas en el proceso de fresado mediante la colocación del acelerómetro en varios lugares, tales como en la superficie lateral de la pieza de trabajo en la dirección de alimentación, sobre las mordazas del accesorio y en el cojinete inferior de la carcasa de husillo, lo cual resulta costoso debido a la cantidad de acelerómetros. Y ese mismo año presentaron un sistema que utilizaba técnicas ópticas como sensores de desplazamiento láser para la detección de la vibración también se han utilizado en el proceso de molienda para TCM (Kalvoda y Hwang, 2010b).

De acuerdo a la literatura revisada se ha observado que otra de las señales a analizar para poder determinar el desgaste de los cortadores de en el proceso de fresado, es la medición del torque de torsión, ya que tienen una relación directa con

el husillo, ya que esta se obtiene de la velocidad de rotación y el consumo de energía del mismo (Sevilla-Camacho, 2011).

Lo anterior se puede relacionar a través de la siguiente fórmula (Schmitz y Smith, 2009):

$$P = \omega T \quad (1.1)$$

Donde P es la potencia expresada en W, ω es la velocidad medida en rad/seg y T es el torque medido en Nm.

Los dinamómetros también se utilizan para medir el torque como Kaya et al., 2011 y Tansel et al., 2011 midieron corte del par, utilizando un dinamómetro par de rotación comercial (Montronix sensor Accu TorqueTM) montado en un ISO40 estándar, DIN69871-A portaherramientas. Se suministra la energía al sistema de detección por el efecto de la inducción y la señal se transmite por telemetría inalámbrica al estator, correctamente colocado cerca del eje. El soporte de la herramienta se modificó mediante la reducción del diámetro exterior de 48 a 26 mm para una longitud total de 24 mm, por lo que las frecuencias naturales del soporte de la herramienta modificada disminuyeron desde 1867 hasta 1028 Hz. Un elemento de material compuesto piezoeléctrico.

Por su parte Tansel et al., 2012 diseñaron un sistema para determinar el desgaste a través de un equipo mecánico a través de la medición del torque; el sistema consiste en un piezoeléctrico que se llevó a cabo entre dos extensiones fijados por separado a las mitades superior e inferior. El sistema se llama un monitor de mecanizado (TBMM) basada en el torque para la detección del desgaste.

Suprock y Nichols 2009 presentaron un sensor basado en un indicador de tensión para la medición de par de torsión en una herramienta de corte de fresado, el cual tiene un transmisor Bluetooth A2DP y un amplificador de instrumentación AD 623 están integrados en una cubierta de plástico ABS montado en el exterior de un portaherramientas de tipo tornillo C 40 set. El sistema contiene un filtro de paso de banda analógico de 10 a 20 kHz, sin embargo aunque ofrece buenos resultados para su colocación es necesario modificar la fresadora para incorporar el instrumento y los cables.

Los sensores de emisión acústica (AE) también suelen ser utilizados debido a su alta sensibilidad y respuesta, éstos pueden detectar movimientos de onda que causan desplazamiento de material para después convertir este desplazamiento en una señal eléctrica. El rango de frecuencia en un transductor AE varía entre 20 kHz y 1 MHz y la información significativa de las señales AE en el mecanizado son en su mayoría por encima de 100 kHz.

Los transductores de AE se han aplicado con éxito para detectar desgaste de la herramienta en la operación de microfresado extremo, El lugar más común para la colocación de los sensores AE es en el husillo tal como lo hicieron Xiqing y Chuangwen, 2009.

Una de las desventajas de usar sensores de emisión acústica es que las señales AE tienen alta frecuencia y baja amplitud, lo que resulta en algunos estudios que se centran en el sistema de transmisión de señal de EA. Por otro lado su uso en un proceso de fresado no ha mostrado resultados evidentes, debido a que la operación de fresado es una operación de corte interrumpido con la herramienta de corte girando causando la carga de choque del pulso durante la entrada y salida de cada diente individual a la pieza de trabajo.

El sonido generado a partir de un proceso de mecanizado es un resultado común de la fricción entre la herramienta y la pieza de trabajo, el cual cambia cuando se ha producido desgaste de la herramienta, debido a que se cambia la presión entre el cortador y la pieza a trabajar, por lo cual se puede utilizar como un medio para la detección de las condiciones de los cortadores; generalmente, las señales de sonido pueden ser medidas por un micrófono eléctrico para posteriormente ser analizadas. En 2012 Ai utilizó parámetros característicos del espectro acústico y lo analizó con un Linear Predictive Cepstrum Coeficiente (LPCC) para correlacionar el desgaste de la herramienta. Por lo general, las señales de sonido se suelen combinar tal como lo hicieron Abbas et al en 2011, donde combinaron las señales acústicas, las corrientes, las vibraciones y fuerzas de corte.

Por lo general, las señales de sonido se combinan con AE, la fuerza, la corriente, la vibración de corte como lo hicieron Abbas et al. En 2011. Es por eso que generalmente no se utilizan de manera aislada.

Como se ha mencionado ya, cuando los cortadores están en mal estado, se incrementa la presión y por lo tanto se incrementa la temperatura y provoca la deformación plástica en la superficie, motivo por el cual se considera la medición de la temperatura un factor a través del cual se pueden determinar las condiciones de los cortadores. Sin embargo, el uso de la temperatura para determinar el estado de los cortadores son poco frecuentes, además, pocos estudios se refieren al proceso de giro.

Para poder determinar la temperatura que requiere el sensor que esté en contacto, que interprete la energía radiante de una fuente de calor en forma de energía emitida.

Los sensores más utilizados son los sensores de temperatura resistivos (RTD), cuyo valor cambia cuando la temperatura lo hace, generalmente son instalados en la parte posterior de los insertos y transmiten los datos de manera inalámbrica.

Los termopares también se usan, estos cambian su tensión cuando la unión de los dos metales se enfría o se calienta. Los termopares tipo K fueron usados por Coz et al. en el 2012 los utilizaron en conjunto con un sistema de conexión inalámbrica que correlacionaba la temperatura con el desgaste.

Utilizando técnicas de infrarrojos en la herramienta en periodos de corte y no corte, y realizando un mapeo a través de un pirómetro de colores fue realizado en 2011 por Sato et al.

Por todo lo mencionado anteriormente es que podemos decir que existen diferentes puntos donde podemos adquirir diferentes señales para caracterizar el estado de los cortadores de la fresadora, las cuales son adquiridas con el uso de sensores con características específicas, y en muchos de los casos para la adquisición de las señales es necesario realizar modificaciones a máquina para su inserción, todo esto ocasiona gastos adicionales para su uso.

Por otro lado la misma literatura sugiere algunas desventajas al utilizar ciertas señales para la caracterización del sistema; por ejemplo las AE pueden estar contaminadas con ruidos provenientes de otras máquinas, inclusive se han registrado casos que la voz de personas hablando cerca de la maquinaria puede interferir de manera considerable con el sistema; y que algunas veces para evitarlo se requiere de micrófonos, filtros o sensores especiales, lo que incrementaría el costo del sistema de manera significativa.

Por otra parte el análisis a través de vibraciones, al igual que el análisis de señales AE también puede ser afectado por vibraciones de máquinas cercanas a estas, lo que lo vuelve un método no confiable.

Para la caracterización utilizando la temperatura se debe colocar sensores en los cortadores, y en algunas ocasiones el uso de refrigerantes intervienen en el sistema. Y generalmente se utilizan en combinación con otros métodos de caracterización.

Por su parte las fuerzas de corte son las señales más comúnmente usadas, aunque en los artículos encontrados se adquieren con el uso de sensores, de tal manera que si se adquieren estas señales sin el uso de sensores permitirá caracterizar el sistema de manera adecuada, sin costos adicionales, y sin modificaciones en la fresadora.

1.3 Acondicionamiento de señales

En el ámbito de las ciencias aplicadas usualmente una señal física es representada mediante una función del tiempo. Sin embargo la mayoría de las veces la información importante que contiene la señal no puede ser fácilmente visible en este dominio y se vuelve necesario emigrar a otros para extraerla. Con este propósito transformaciones matemáticas, como es el caso de las transformadas de espacio, son aplicadas a la señal.

Estas transformaciones son representaciones que en cierto sentido no se consideran naturales debido al habitual modo de enfocar el universo real. Visto de esta manera, las transformaciones aplicadas contienen exactamente la misma

información sobre la señal pero respondiendo a enfoques distintos; enfoques que de algún modo pueden ser considerados complementarios del dominio original. Los sistemas de monitoreo no son ajenos a esto, ya que frecuentemente para la extracción de las características dinámicas las señales es de suma importancia realizar un cambio en el dominio; las transformaciones más frecuentes es transformarlas al dominio de la frecuencia.

De acuerdo a la literatura existen diferentes técnicas para realizar ese cambio de dominio de las señales, entre las principales se encuentran: La transformada de Fourier (TF), la transformada de Fourier con ventana (STFT), la transformada Wavelet (TW) y quizá la menos conocida la distribución Wigner-Ville (WVD).

Aunque sin duda alguna la técnica más usada pudiera ser la TF, en este apartado podemos encontrar investigaciones que utilizaron una o más de estas técnicas para el correcto monitoreo del estado de los cortadores en los procesos de maquinado.

Al-Baldour et al 2011, realizaron un análisis tiempo- frecuencia de vibración en máquinas rotativas, las técnicas utilizadas incluyendo TW y la FFT. Durante su experimento trabajaron bajo 3 condiciones diferentes. Los resultados obtenidos de este análisis demostraron El WPT (Wavelet Packet Transform) es una poderosa herramienta para la extracción de características de las señales de vibración, que las diferentes técnicas de WT son eficaces para el análisis y detección de fallos en máquinas rotativas, sin embargo es de suma importancia la correcta elección de la Wavelet madre, ya que afecta en gran medida los resultados de detección de fallo. Aunque reconoce que no hay una forma óptima. Las Wavelet madre utilizadas fueron Wavelet Gaussiana y La Wavelet Daubechies DB10, aunque sugiere que cualquier Wavelet Daubechies de orden superior al 10 también son una buena alternativa.

Hui et al, 2011; presentan un algoritmo para el control automático de calibres para la producción de acero, el sistema debe determinar el espesor de la banda para poder garantizar u el producto cumpla con las especificaciones requeridas. En este trabajo combinaron múltiples SVM de mínimos cuadrados para reducir el tiempo de cálculo. Los datos de la muestra se dividen en diferentes grupos y a cada uno de ellos se aplicó SVMs mínimos cuadrados. La suma de las salidas ponderadas de todas las SVMs da el espesor previsto. El procedimiento fue probado en un tren de laminación en caliente de verdad. Se utilizan un total de 300 conjuntos de datos que consta de fuerza de laminación, el valor de ajuste de separación del rodillo, el grosor de entrada, velocidad de laminación, y la temperatura de entrada.

En 2012, Hase et. Al, publicaron un artículo donde correlacionaban las características de las señales de emisión acústica con el desgaste de los mecanismos, en su experimento adquirieron las señales producidas por la fricción mediante un sensor AE, debido al bajo nivel del voltaje de la señal, estas se procesaban realizando una etapa de amplificación, se filtraban y digitalizaban, para posteriormente ser analizadas utilizando la STFT. A través de este experimento

pudo demostrar que, efectivamente cada nivel de desgaste provee de características únicas a las señales de acústicas obtenidas de máquina.

En Lee 2013 se presenta un método de tiempo-frecuencia de adaptación rápida para el análisis de señales de vibración estacionarios y no estacionarios con transitorios. El método se desarrolló sobre la base de la frecuencia instantánea (IF) - las variaciones en el dominio del tiempo. La longitud de la ventana variable se determina mediante una estimación local. El experimento concluye que el método propuesto puede recuperar con éxito las señales transitorias en una relación de señal a ruido de 3 dB, y mejorar la resolución de la señal estacionaria y no estacionaria en los dominios de tiempo y frecuencia. El esquema propuesto ofrece una mejor resolución en comparación con el estándar de la STFT, y el coste de computación es sólo ligeramente mayor que esquema STFT.

Zhanwei en 2013 publicó un análisis comparativo entre una transformada rápida de Fourier y una Transformada Wavelet, el análisis consistía en determinar las características de forma de los cortadores. Algunas de las características que se analizaban eran: Tamaño, forma, rugosidad, etc.

Dentro del experimento la primera parte consistía en determinar la forma geométrica (elipse, círculo, triángulo, cuadrado y rectángulo) determinar los centroides utilizando técnicas de procesamiento de imágenes, entre las que se incluyen binarización, erosión y dilatación; las cuales eran analizadas utilizando FFT y TW.

De acuerdo a los resultados al utilizar la FFT se presentaron problemas al momento de determinar la orientación y la simetría.

Posteriormente en Baccar y Söffker presentaron en 2015 un sistema de monitoreo basado en la combinación de la STFT y la Transformada Wavelet Continua (CWT) el cual puede identificar entre diferentes tipos de desgaste. Las AEs fueron adquiridas a través de un sensor piezoeléctrico en un rango de frecuencias de 100 kHz a 900KHz; las señales fueron analizadas utilizando STFT, posteriormente el rango de frecuencias se dividió en 4 rangos: de 100 a 300KHz, 300 a 500KHz, 500 a 700KHz y finalmente de 700KHz a 900 KHz, cada uno de estos rangos fueron analizados con la CWT, y se encontró que cada señal tenía características diferentes, las cuales se pudieron correlacionar diferentes niveles de desgaste.

Lamraoui et al. 2014, utilizaron WVD con un enfoque ciclo estacionario para el desgaste de la herramienta de fresado. Donde adquirieron los datos de un acelerómetro experimental, donde dichos valores son analizados para a través de ellos poder establecer las condiciones de las herramientas.

Como se ha mencionado a lo largo de este capítulo, el uso del análisis tiempo-frecuencia es una herramienta poderosa para poder determinar las condiciones de los cortadores en máquinas rotativas. También observamos que existen diferentes técnicas que ofrecen diferentes características.

La Transformada de Fourier detecta la presencia de una determinada frecuencia pero no brinda información acerca de la evolución en el tiempo de las características

espectrales de la señal. Muchos aspectos temporales de la señal, tales como el comienzo y el fin de una señal finita y el instante de aparición de una singularidad en una señal transitoria, no pueden ser analizados adecuadamente por el análisis de Fourier.

Para los casos de señales no estacionarias y transitorias se utiliza generalmente, la Transformada rápida de Fourier (FFT), la cual muestran los componentes de frecuencia con amplitudes suficiente para sobresalir por el ruido. Para extraer los impactos con muy bajo consumo de energía y, por tanto, características ocultas, sin embargo no siempre es adecuada o suficiente.

Esta limitación importante de la FFT ha llevado a la introducción de herramientas de procesamiento de señales de tiempo y frecuencia, como el Short-Time Fourier Transform (STFT) que trata de dotar a la transformada de Fourier con técnicas de localización temporal; la STFT ofrece una función de dos dimensiones (2D) de tiempo y frecuencia. La dificultad en el uso del STFT es que la precisión de la información de frecuencia de la extracción está limitada por la longitud de la ventana con relación a la duración de la señal. Una vez que se define la función de ventana, el área (producto de tiempo de ancho de banda) de la función de ventana en el plano tiempo-frecuencia permanece fijo, lo que significa que las resoluciones de tiempo y frecuencia no se pueden aumentar al mismo tiempo. En consecuencia, para una STFT, hay un equilibrio entre el tiempo y las resoluciones de frecuencia.

También existe la distribución de Wigner-Ville (WVD) que históricamente es la primera técnica que busca obtener información sobre una señal, consiguiendo simultáneamente localización temporal y frecuencial. Cuando se la aplica a oscilaciones puras, proporciona una localización óptima. El buen comportamiento se mantiene también a señales que son ciertas transformaciones simples de una única oscilación pura (por. ej. chirps lineales). Pero aparecen problemas al analizar señales más complejas, por ejemplo la suma de señales simples. En estos casos el resultado no es la suma de las WVD de aquellas, sino que aparecen "términos de interferencia". En definitiva, la WVD no es lineal y adolece de términos de interferencia que aparecen en el mismo plano y tienden a inducir a error al análisis de la señal.

Motivo por el cual se considera que la mejor opción es la TW, la cual es capaz de realizar un análisis local de una señal, o para ampliar en cualquier intervalo de tiempo sin perder la información espectral contenida en el mismo. Como lo ha mostrado hasta este momento la literatura, que afirma que un sistema de monitoreo que determine los estados de los cortadores es de gran ayuda, debido a que puede prevenir daños mayores a la maquinaria, también evita defectos en las piezas maquinadas. Motivo por el cual desde hace años se han hecho investigaciones al respecto.

Son variadas las técnicas para determinar el desgaste de los cortadores en una fresadora, a través de las fuerzas de cortes, emisiones acústicas, vibraciones,

torque entre otras, y los sistemas de monitoreo existentes utilizan una o varias de estas técnicas, en este capítulo dividiremos los sistemas de monitoreo en dos clases, los sistemas de monitoreo clásicos y los que utilizan alguna técnica de inteligencia artificial.

1.4 Sistemas de monitoreo

Los sistemas de monitoreo en esta sección se dividirán en dos, los sistemas de monitoreo clásicos e inteligentes, considerando a los sistemas de monitoreo clásicos aquellos que no utilizan alguna técnica de inteligencia artificial.

1.4.1 Sistemas de monitoreo clásicos

En Abbas et al 2011 se muestra un sistema de monitoreo que analiza las señales acústicas, fuerzas de corte y la vibración. Una combinación de sensores de desplazamiento y termopares instalados en la estructura de husillo fue sugerido por Sarhan, en 2015, para caracterizar la máquina de husillos, donde se concluye que, la relación entre el desplazamiento del husillo y la fuerza de corte a diferentes velocidades de husillo se puede aproximar linealmente.

Turchetta et al., 2011 utiliza la medición de las componentes de la fuerza de corte componentes en las direcciones tangencial y normal y analiza como esto afecta las condiciones de desgaste de las herramientas. Para su estudio utilizó mármol coreano Royal y el cortador contenía una punta de diamante.

Aggarwal et al. 2012, consideraban que en el proceso de maquinado, todos los procesos y variables están relacionados, motivo por el cual decidieron analizar la corriente eléctrica y el par de un motor de husillo, a manera de determinar el desgaste de los cortadores Certal (AlZnMgCu 0,5), las señales fueron adquiridas usando un dinamómetro, a través de su estudio pudieron correlacionar la potencia del husillo con el nivel de desgaste de los cortadores.

Lu y Wan, 2012 desarrollaron un sistema de monitoreo para determinar las condiciones de los cortadores en un proceso de micro fresado utilizando acero SK2, las señales eran adquiridas a través de un micrófono con ancho de banda de hasta 80 kHz (más alta que la tradicional micrófono con ancho de banda de hasta 20 kHz). La señal obtenida es normalizada y analizada con la FFT, y normalizada y usando la topología Markov Hidden (HMM) para clasificar las señales, se logró una clasificación del 100 %. Sin embargo Una desventaja de este método es que en la región de entre 0 y 2 kHz la influencia del entorno y del ruido de las máquinas adyacentes, motores, transportadores, o procesos pueden influir en las señales.

Rafezi et al, 2012 investigaron la perforación en el Al 7075 aleación de aluminio utilizando HSS y sin aplicación de refrigerante. Observaron que los componentes de frecuencia inferior a 10 kHz se ven afectados por el desgaste de la herramienta y otras regiones del espectro de frecuencias son similares a las de un cortador desgastado. También comentaron que los ruidos ambientales (Máquinas herramientas, ventiladores, voz humana, y otros) deberían ser eliminado. Ellos calcularon que el espectro de frecuencias del ruido en la proximidad de la maquina en estudio sólo tiene componentes de frecuencia de menos de 2 kHz

En 2012 se utilizó la señal de sonido producido en el proceso de fresado, para posteriormente extraer las características del espectro acústico utilizando Linear Predictive Coeficientes Cepstral (LPCC), para posteriormente ser analizado y poder correlacionado con diferentes niveles de desgaste de la herramienta. (Ai et. Al, 2012).

Gok et al. 2013 investigaron los parámetros de corte óptimos, a través de la fuerza de corte para una fresadora AISI H13 (50-54 HRC), en superficies inclinadas convexas y cóncavas utilizando una herramienta de punta esférica. Y pudieron determinar que había una diferencia significativa en los parámetros dependiendo del tipo de superficie.

Hase et al., 2013 estudiaron la correlación entre la AE y los fenómenos de corte en el torneado de AISI O1. Utilizaron un piezoeléctrico titanato zirconato de plomo, un sensor de cerámico con frecuencia de resonancia de 1 MHz y una banda de frecuencia de 50 kHz a 2 MHz. Aplicaron un filtro pasa altas 500kHz para eliminar el ruido y las señales causadas por fenómenos ajenos al proceso. Observaron que la amplitud de la señal cambia a causa de las fracturas o daños en el cortador, también observaron una correlación negativa entre el desgaste del cortador y el ángulo de distorsión.

Técnicas como la máquina de relevancia vector clasificado (RVM), también se han utilizado en los sistemas de monitoreo, se propone la función de dividir en categorías niveles de desgaste de cortadores. El proceso se realiza en línea. (Wang, 2014).

El método propuesto por Nouri et al, 2015 para la monitorización de los cortadores de la fresadora, esta basado en el seguimiento de 4 parámetros de corte, La velocidad del husillo, inmersión radial, inmersión axial y tasa de alimentación, Índice de entrada, las cuales correlaciona a través de un método probabilístico, trabajaron utilizando carburo insertos de acero, aluminio.

Por otro lado Muhammad et. Al presentaron en 2015, un dinamómetro de rotación basada en el medidor de tensión capaz de medir la fuerza de corte principal arriba de 3000N , y rotación de 5000 rpm que tiene una dirección paralela con la velocidad de corte del husillo, la fuerza de empuje y también la fuerza de corte perpendicular.

El dinamómetro de rotación desarrollado incluye los efectos estáticos, dinámicos, y térmicos.

lo cual se puede resolver utilizando técnicas de inteligencia artificial, cuando un sistema hace uso de cualquiera de estas técnicas se consideran sistemas inteligentes; y es que debido a las grandes ventajas que ofrecen estas técnicas es que día a día son más utilizados.

1.4.2 Sistemas de monitoreo inteligente

La inteligencia artificial se divide en tres ramas diferentes: Redes neuronales, lógica difusa y los métodos heurísticos. Dentro de los métodos heurísticos la técnica más conocida es el algoritmo genético (AG).

El uso de técnicas heurísticas dentro de los sistemas de monitoreo han brindado grandes resultados, debido a la naturaleza propia de los métodos, las cuales consisten en la observación de cómo la naturaleza actúa y tratando de imitar ese comportamiento para ofrecer una solución adecuada con un tiempo de entrenamiento menor comparado con el tiempo de entrenamiento de las redes neuronales.

Los métodos basados en AG mejoran de manera considerable los sistemas de monitoreo, pero desafortunadamente debemos recordar que los AG solo pueden proporcionar una buena solución pero no la solución óptima debido a que sólo utilizan una muestra de las señales de entrada, lo cual le permite acelerar su etapa de entrenamiento.

Vladimir 2014 utiliza una la temperatura y un sistema difuso para determinar el tiempo de vida de los cortadores. También hay sistemas de monitoreo que utilizan la combinación de diversas técnicas como Ramanujam 2014 que combina la lógica difusa y técnica de Taguchi para determinar las condiciones de cortadores de carbono.

Sheth 2015, realizó un sistema de monitoreo comparativo entre 3 técnicas diferentes, los parámetros de entrada la velocidad del husillo, velocidad de avance y profundidad de corte, debido a que contribuyen con 20,73%, 33,52% y 40,72% respectivamente. Las técnicas a comparar son un modelo de regresión, una red neuronal y un sistema difuso, cuyos errores alcanzados son 3,7726%, 4,7852% y 2,32%, respectivamente.

Los valores predichos y medidos fueron bastante cercanos, lo que indica que los modelos desarrollados pueden ser utilizados eficazmente para predecir la aceleración en el monitoreo de vibraciones con más de 95% de intervalo de confianza.

Por su parte Huang et al. 2015, utilizó una red neuronal probabilística no supervisado, con función de transferencia sigmoïdal, con una estructura [3,2,4], en el que utiliza las fuerzas de corte obtenidas a través de un dinamómetro y también tres parámetros de mecanizado que son velocidad del husillo, profundidad de corte, velocidad de avance. Para determinar la ruptura del cortador.

Beruides et. Al, 2016 presenta un sistema de monitoreo en lía para determinar rugosidad y la calidad dimensional en el proceso de fresado, el cual esta basado en una estructura ANFIS (Adaptive Network-based Fuzzy Inference System) y regresión lineal. Las condiciones establecidas para el experimento son 50,00 rpm, un herramental de 0.5 mm y 0.1 mm de diámetro, y cortadores de tungsteno y cobre. Las señas a analizar son la vibraciones obtenidas durante el proceso de fresado. También se menciona la aplicación de un AG para optimizar los parámetros de corte. Este sistema de monitoreo ofrece un error de 9.5%.

Jesudoss et. Al, 2016 presentan un sistema de monitoreo que utiliza técnicas de lógica difusa, el estudio se realizó utilizando acero AA6063 y AISI1030. El sistema difuso contaba con funciones de membresía triangular, y tres entradas: Velocidad rotacional, tiempo de fricción y presión de fricción. Los valores de La resistencia al impacto y el acortamiento axial son las salidas del sistema difuso, los cuales se compararon con los datos experimentales. Los coeficientes de correlación entre los valores predichos y experimentales son el 99,15% de resistencia al impacto y 98.05% para axiales acortamiento de longitud respectivamente. Por otra parte a través optimizador de respuesta, para lograr la resistencia al impacto de 206.46 KJ/m² y axiales longitud de acortamiento 7,3798 mm condiciones óptimas se predicen como velocidad de rotación 1.063 rpm, 7 segundos el tiempo fricción y 300 presión por fricción KPa.

Por otro lado Tamiloli 2016 determina la cantidad de material removido y posibles defectos en los acabados debido a las condiciones de los cortadores basado en un sistema de lógica difusa, con cinco funciones de pertenencia y veintisiete reglas. Gris Fuzzy Razonamiento Grado (GFRG) se desarrolla y los valores óptimos se encontraron fuera del grado de relación gris. El resultado del análisis de varianzas (ANOVA) muestra que la contribución máxima de la profundidad de corte es (31,785%), seguido de alimentación (28.212%). Por otra parte, el modelo de adaptación Neuro-Fuzzy sistema de inferencia (ANFIS) se ha desarrollado con la ayuda de los mismos valores de entrada en comparación con el rendimiento del modelo de lógica difusa. Con la ayuda de un análisis detallado, se ha encontrado que el modelo basado en la lógica difusa da resultados más razonables en comparación con modelo ANFIS.

En la literatura también se pueden encontrar sistemas de monitoreo que utilizan técnicas de lógica difusa (LD), como lo muestra Sheth 2014, Kovac 2013 y Rajasekaran 2011 para determinar la rugosidad debido a las condiciones del cortador. Aunque los sistemas mencionados anteriormente ofrecen resultados

satisfactorios, no se debe olvidar que una de las principales desventajas que presentan los sistemas difusos es que solo están diseñados para trabajar dentro de ciertos parámetros, pero que si en determinado momento por variaciones del sistema este se encontrara fuera de los mismos el sistema no funcionaría.

Es por esto que surgen sistemas que utilizan técnicas que pueden eliminar las desventajas que presentan los AG es que solo ofrecen una solución aproximada o buena pero no garantizan la mejor, y como la literatura sugiere, éstos solo se han utilizado para la optimización más no para la clasificación o determinación de niveles de desgaste., así que la mejor opción es la utilización de una red neuronal artificial.

1.5 Justificación

Uno de los objetivos principales de cualquier empresa es satisfacer las necesidades del cliente mediante la producción de productos de alta calidad, la optimización de costos al mejorar los procesos de fabricación. Para lograr las especificaciones de calidad es importante eliminar las variaciones durante los procesos de producción. Para las empresas manufactureras, el uso de sistemas de monitoreo de condición de herramientas es esencial para detectar roturas o desgaste de herramientas para evitar piezas de producción de baja calidad debido al estado de las herramientas de corte e incluso evitar daños a las máquinas, ya que esto repercute de manera directa a las empresa, por las pérdidas económicas.

Por estas razones expuestas anteriormente es que se considera importante la implementación de un sistema de monitoreo que permita a las empresas determinar las condiciones de sus cortadores para no afectar el proceso de producción o incluso sus maquinarias.

1.6 Hipótesis

Es posible el desarrollo de un sistema de monitoreo inteligente que permita clasificar entre el desgaste, la ruptura y las buenas condiciones del cortador, usado en una fresadora CNC, mediante el uso de técnicas de procesamiento de señales y redes neuronales artificiales.

1.7 Objetivo

Implementación de un sistema de monitoreo inteligente para la determinación de niveles de desgaste, rotura o buenas condiciones del cortador sin el uso de sensores a través del análisis de las fuerzas de corte.

1.7.1 Objetivos Particulares

Adquirir las señales necesarias para la correcta clasificación de los estados de los cortadores sin el uso de sensores.

Determinar la o las técnicas de procesamiento de señales adecuada para la extracción de las características necesarias para lograr dicha clasificación.

Establecer la estructura adecuada de la RNA para la correcta clasificación de las señales provenientes de la máquina

Dirección General de Bibliotecas UAQ

CAPÍTULO II

Con formato: Espacio Antes: 0 pto, Interlineado: Múltiple 1.15 lín., Esquema numerado + Nivel: 1 + Estilo de numeración: 1, 2, 3, ... + Iniciar en: 1 + Alineación: Izquierda + Alineación: 0.63 cm + Sangría: 1.27 cm

2 Fundamentación teórica

En esta sección se expondrán los fundamentos matemáticos y teóricos que sustentan la aplicación de las técnicas utilizadas en este proyecto. Este capítulo se dividirá en 2 partes principales, el fundamento de la transformada wavelet y las redes neuronales.

Se abarcará de manera breve el proceso de filtrado y las razones por las cuales se optó por esa metodología

2.1 Adquisición de señales y filtrado

Como se mencionó en el capítulo anterior, el análisis de las fuerzas de corte proporciona la información suficiente para determinar las condiciones de los cortadores de una fresadora, adicionalmente a esto se considera que para la adquisición de las misma no es necesario el uso de sensores adicionales, que implicarían no solo un costo adicional sino también posible modificaciones a la maquinaria.

De acuerdo a Romero-Troncoso et al, 2003, Totis et al., 2010 entre otros, han demostrado que el ruido se encuentra en la altas frecuencias, y que la señal proveniente de los servo controladores se encuentra en frecuencias de alrededor de los 1.5 KHz, por lo tanto es conveniente la utilización de un filtro pasa bajas para asegurar que el contenido espectral de la señal de corte es conservado, al mismo tiempo que el ruido es eliminado.

Se optó por un filtro FIR, debido a su estabilidad (En su función de transferencia todos son ceros) y su respuesta de fase lineal.

El algoritmo de un filtro FIR es una convolución discreta de la señal de entrada $x(n)$ con un conjunto de coeficientes de filtro b_k . En general, el sistema FIR se describe con la ecuación de diferencias.

$$y(n) = \sum_{k=0}^{N-1} b_k x(n-k) \quad (2.1)$$

Aplicando la transformada Z a la ecuación (6) se obtiene:

$$Y(z) = b_0 X(z) + b_1 X(z)z^{-1} + \dots + b_{N-1} X(z)z^{N-1} \quad (2.2)$$

De esta última ecuación se obtiene la función de transferencia de la estructura FIR:

$$H(z) = \frac{Y(z)}{X(z)} = b_0 + b_1 z^{-1} + \dots + b_{N-1} z^{N-1} = \sum_{k=0}^{N-1} b_k z^{-k} \quad (2.3)$$

De la ecuación (2.3) es claro que la función solamente contiene ceros pues los polos se ubican en el origen, y por esta razón un filtro del tipo FIR siempre es estable.

2.2 Transformada Wavelet

Como se mencionó en el capítulo anterior, en algunas ocasiones no es fácil extraer la información de una señal en el dominio en el que se encuentra, y que es necesario emigrar a otros dominios para extraerla, ya que aunque la información es la misma responde a enfoques distintos.

Sin duda alguna el dominio al que con más frecuencia se transforma, es al dominio de la frecuencia, y la transformada más conocida es la Transformada de Fourier (TF), en la que la señal puede ser expresada como la suma de una serie de senos y cosenos; pero la desventaja de una expansión de Fourier es que solamente tiene resolución en la frecuencia y no en el tiempo, esto significa que aunque es posible determinar todas las frecuencias presentes en una señal, no se puede conocer el momento en que se presentan.

Para resolver esta problemática 1982 surgió una técnica matemática llamada Transformada Wavelet (TW), también conocida como Transformada de ondoletas, que es capaz de representar una señal en el dominio del tiempo y de la frecuencia de manera simultánea.

The diagram shows the equation for the Continuous Wavelet Transform (CWT) with labels pointing to its parts:

- Parámetro de traslación, medición del tiempo**: points to τ in the denominator of the kernel.
- Parámetro de escala, medición de frecuencia**: points to s in the denominator of the kernel.
- Constante de normalización**: points to $\frac{1}{\sqrt{|s|}}$.
- Señal a ser analizada**: points to $x(t)$.
- Transformada Wavelet Continua de la señal $x(t)$ usando la wavelet de análisis $\Psi()$** : points to the entire left side of the equation.
- La Wavelet madre. Todos los kernels son obtenidos por traslación y/o escalamiento de la wavelet madre.**: points to the kernel $\Psi^*\left(\frac{t-\tau}{s}\right)$.

$$CWT_x^\Psi(\tau, s) = \Psi_x^\Psi(\tau, s) = \frac{1}{\sqrt{|s|}} \int_t x(t) \Psi^*\left(\frac{t-\tau}{s}\right) dt$$

Figura 2.1. Transformada wavelet continua

La manera en la que funciona dicha transformada es a través de un análisis multi resolución con ventanas dilatadas. El análisis de alta frecuencia es hecho con ventanas angostas y el análisis de baja frecuencia se hace con ventanas anchas.

La Transformación se realiza generando una función wavelet madre (onda patrón ó básica), la cual se dilatará o contraerá. Una diferencia considerable entre la TF y la TW es que en el TW la wavelet madre no está definida como lo es en la TF.

La wavelet madre debe cumplir ciertas especificaciones:

- 1.- Condición de admisibilidad, es decir la transformada de Fourier de la wavelet debe ser a cero en la frecuencia cero, esto permite que al utilizar la transformada inversa se pueda recuperar la señal original.
- 2.- Condición de regularidad, haciendo que el número de coeficientes de la transformada se disminuya rápidamente cuando la escala también lo hace.

También tiene propiedades generales como:

- 1.- Admisibilidad
- 2.- Regularidad
- 3.- Ortogonalidad

Las ondoletas pueden ser dadas como funciones analíticas o numéricas. Pueden ser ortonormales o no ortonormales, continuas o discretas. Uno puede elegir o incluso construir su propia ondoleta base para una aplicación específica. Por todo lo anterior cuando se habla de la Transformada Wavelet, se debe especificar que función ondoleta es utilizada en la transformación.

2.2.1 Transformada Wavelet continua (TWC)

La TWC de una función $f(t) \in \mathbf{Z}$ es una descomposición de $f(t)$ dentro de un conjunto de funciones kernel $h_{s,\tau}(t)$ llamadas wavelets:

$$W_f(s, \tau) = \int f(t) h_{s,\tau}^*(t) dt \quad (2.4)$$

donde * denota el conjugado complejo, aunque la mayoría de las funciones wavelets son reales. Las wavelets se generan de una función base (la wavelet madre) $h(t)$ por medio de escalamiento y traslación:

$$h_{s,\tau}(t) = \frac{1}{\sqrt{s}} h\left(\frac{t-\tau}{s}\right) \quad (2.5)$$

donde s es el factor de escala y τ es el factor de traslación. Usualmente solo se consideran los factores positivos de escala, $s > 0$. Las ondoletas son dilatadas cuando la escala $s > 1$ y se contraen cuando $s < 1$. Todas las wavelets $h_{s,\tau}(t)$ generadas de la misma función base tienen diferentes escalas s y posiciones τ , pero con la misma forma. La constante $s^{-1/2}$ en la expresión (3) es para normalización de la energía. Las wavelets son normalizadas como:

$$\int |h_{s,\tau}(t)|^2 dt = \int |h(t)|^2 dt = 1 \quad (2.6)$$

De este modo todas las wavelets escaladas por el factor s tienen la misma energía. Las funciones wavelet también pueden ser normalizadas en términos de la amplitud:

$$\int |h_{s,\tau}(t)| dt = 1 \quad (2.7)$$

En este caso, la constante de normalización es s^{-1} en vez de $s^{-1/2}$, y las wavelets son generadas como:

$$h_{s,\tau}(t) = \frac{1}{s} h\left(\frac{t-\tau}{s}\right) \quad (2.8)$$

2.2.2 Transformada Wavelet discreta (TWD)

La Transformada Wavelet continua mapea una señal en su dimensión tiempo a una representación bidimensional tiempo-escala. El ancho de banda producto de la transformada continua es el cuadrado del correspondiente a la señal original. Para la mayoría de las aplicaciones, sin embargo, la meta del procesamiento de señales es representar la señal eficientemente con una cantidad menor de parámetros. El uso de la DWT provee suficiente información para el análisis y síntesis de la señal original, con una reducción significativa en el tiempo de cálculos.

El procedimiento comienza pasando una señal (secuencia) a través de un filtro pasa-baja de media banda con respuesta al impulso $h[n]$, el cual remueve todas las frecuencias que están por arriba de la mitad del valor de la frecuencia más alta en la señal. Esto corresponde a la operación matemática de convolución de la señal con la respuesta al impulso del filtro. Esto elimina la mitad de las muestras, debido a que ahora se tiene una frecuencia de $\pi/2$ rad en lugar de π radianes.

La mitad de las muestras pueden ser descartadas sin pérdida de información. En resumen, el filtro pasa-baja divide en dos la resolución, pero deja la escala intacta. La señal es entonces sub-muestreada por dos ya que la mitad de las muestras es redundante. Esto dobla la escala.

Este procedimiento puede ser expresado matemáticamente como:

$$y[n] = \sum_{k=-\infty}^{\infty} h[k] \cdot x[2n - k] \quad (2.9)$$

Posteriormente la señal original $x[n]$ es pasada primero por un filtro pasa-altas de media banda $g[n]$ y un filtro pasa-baja $h[n]$. Después del filtrado la mitad de las muestras pueden ser eliminadas de acuerdo a la regla de Nyquist, ya que la señal ahora tiene una frecuencia máxima de $\pi/2$ radianes en vez de π . La señal puede ser sub-muestreada por dos, simplemente descartando una de cada dos muestras. Esto constituye un nivel de descomposición y puede ser expresado matemáticamente como sigue:

$$\begin{aligned} y_{high}[k] &= \sum_n x[n] \cdot g[2k - n] \\ y_{low}[k] &= \sum_n x[n] \cdot h[2k - n] \end{aligned} \quad (2.10)$$

Donde $y_{high}[k]$ y $y_{low}[k]$ son las salidas de los filtros pasa-altas y pasa-baja respectivamente, después de sub-muestrear por dos. Esta descomposición divide en dos la resolución en tiempo pues ahora solo la mitad de muestras caracterizan la señal completa. Sin embargo, esta operación dobla la resolución en frecuencia, pues la banda de frecuencia de la señal ahora solo abarca la mitad de la banda de frecuencia anterior, efectivamente reduciendo la incertidumbre en la frecuencia por mitad. El procedimiento anterior, que es también conocido como codificación sub-banda, puede ser repetido para descomposiciones posteriores. En cada nivel, el filtrado y sub-muestreo resultará en la mitad del número de muestras (y por lo tanto divide la resolución temporal) y divide a la mitad la banda de frecuencia abarcada (y dobla la resolución en frecuencia).

Las frecuencias que son más prominentes en la señal original aparecerán como amplitudes altas en esa región de la señal TWD que incluyen esas frecuencias particulares.

Las bandas de frecuencia que no son muy prominentes en la señal original tendrán amplitudes muy bajas, y esa parte de la señal TWD puede ser descartada sin

pérdida importante de información, permitiendo la reducción de datos. La figura 6 ilustra un ejemplo de cómo luce la TWD y el porqué es posible la reducción de datos.

Coeficientes de la transformada wavelet rápida

Las wavelets discretas están asociadas con las funciones de escalamiento y sus ecuaciones de dilatación. La función de escala tiene la misma forma que la wavelet madre y puede ser convolucionada con la señal de entrada para producir los coeficientes de aproximación de la siguiente manera:

$$S_{m,n} = \int_{-\infty}^{\infty} x(t)\phi_{m,n}(t)dt \quad (2.11)$$

de esta ecuación se puede definir que los coeficientes de aproximación en la escala $m + 1$ son dados por:

$$S_{m+1,n} = \int_{-\infty}^{\infty} x(t)\phi_{m+1,n}(t)dt \quad (2.12)$$

que puede ser escrita como:

$$S_{m+1,n} = \int_{-\infty}^{\infty} x(t) \left[\frac{1}{\sqrt{2}} \sum_k c_k \phi_{m,2n+k}(t) \right] dt \quad (2.13)$$

y a su vez puede ser re-escrita como:

$$S_{m+1,n} = \frac{1}{\sqrt{2}} \sum_k c_k \left[\int_{-\infty}^{\infty} x(t)\phi_{m,2n+k}(t)dt \right] \quad (2.14a)$$

La integral en los corchetes proporciona los coeficientes de aproximación $S_{m,2n+k}$ para cada k . Por lo que la ecuación (11) puede escribirse como:

$$S_{m+1,n} = \frac{1}{\sqrt{2}} \sum_k c_k S_{m,2n+k} = \frac{1}{\sqrt{2}} \sum_k c_{k-2n} S_{m,k} \quad (2.14b)$$

De este modo, mediante (12) se determinan los coeficientes de aproximación en la escala $m + 1$ utilizando los coeficientes de la escala anterior. De manera similar los coeficientes wavelet pueden ser calculados a partir de los coeficientes de aproximación de la escala previa, utilizando los coeficientes reordenados b_k de la siguiente manera:

$$T_{m+1,n} = \frac{1}{\sqrt{2}} \sum_k b_k S_{m,2n+k} = \frac{1}{\sqrt{2}} \sum_k b_{k-2n} S_{m,k} \quad (2.15)$$

Un ejemplo del algoritmo multiresolución es presentado a continuación. Una vez que se obtiene la secuencia o señal de entrada $S_{0,n}$ es posible calcular $S_{m,n}$ y $T_{m,n}$ utilizando las ecuaciones (2.12) y (2.13). Esto puede ser hecho para los índices de escalamiento $m > 0$ hasta una escala máxima determinada por la longitud de la señal de entrada. El procedimiento interactivo es de la siguiente manera. Primero se calcula $S_{1,n}$ y $T_{1,n}$ usando los coeficientes de entrada $S_{0,n}$, es decir:

$$S_{1,n} = \frac{1}{\sqrt{2}} \sum_k c_k S_{0,2n+k} \quad (2.16a)$$

y

$$T_{1,n} = \frac{1}{\sqrt{2}} \sum_k b_k S_{0,2n+k} \quad (2.16b)$$

del mismo modo $S_{2,n}$ y $T_{2,n}$ son calculados utilizando los coeficientes de aproximación $S_{1,n}$ de la siguiente manera:

$$S_{2,n} = \frac{1}{\sqrt{2}} \sum_k c_k S_{1,2n+k} \quad (2.17a)$$

Y

$$T_{2,n} = \frac{1}{\sqrt{2}} \sum_k b_k S_{1,2n+k} \quad (2.17b)$$

Lo siguiente es encontrar $S_{3,n}$ y $T_{3,n}$ a partir de los coeficientes de aproximación $S_{2,n}$ y así sucesivamente hasta los coeficientes de escala M , donde solo un coeficiente de aproximación y uno de detalle son calculados. La descomposición de los coeficientes de aproximación en coeficientes de aproximación y detalle a través de varios niveles, nótese que la descomposición completa se alcanza en el último vector mostrado (Figura 2.2).

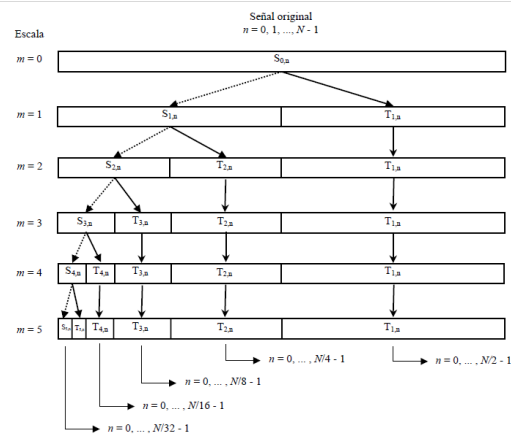


Figura 2..2 Transformada wavelet rápida

El ejemplo anterior puede visualizarse como una serie de multiplicaciones con matrices, el siguiente ejemplo lo muestra. Sean c y b los filtros de análisis y síntesis, respectivamente:

$$C = C_0, C_1, \dots, C_{D-1} \quad (2.18a)$$

y

$$b = b_0, b_1, \dots, b_{D-1} \quad (2.18b)$$

donde $D = 4$ y la señal de entrada o secuencia de datos original es $X = X_0, X_1, \dots, X_{N-1} = S_{0,0}, S_{0,1}, \dots, S_{0,N-1}$, para $N = 16$ el primer nivel de transformación puede ser hecho de la siguiente manera: $W^1 X = T_1$, donde W^1 es la matriz de transformación en la escala uno, formada con los coeficientes de análisis y síntesis.

Nótese en (2.19) que el número de renglones en W^1 depende del tamaño del vector de entrada que se está analizando, y ésta es una matriz cuadrada con los filtros de análisis y síntesis bien localizados dentro del arreglo.

El segundo nivel de transformación es calculado de la siguiente manera, en esta operación el vector de entrada son los coeficientes de análisis producidos en la etapa anterior mientras que los de síntesis son mantenidos y no utilizados en esta segunda transformación.

$$\begin{bmatrix} C_0 & C_1 & C_2 & C_3 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & C_0 & C_1 & C_2 & C_3 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & C_0 & C_1 & C_2 & C_3 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & C_0 & C_1 & C_2 & C_3 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & C_0 & C_1 & C_2 & C_3 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & C_0 & C_1 & C_2 & C_3 & 0 \\ C_2 & C_3 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & C_0 & C_1 & C_2 \\ b_0 & b_1 & b_2 & b_3 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & b_0 & b_1 & b_2 & b_3 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & b_0 & b_1 & b_2 & b_3 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & b_0 & b_1 & b_2 & b_3 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & b_0 & b_1 & b_2 & b_3 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & b_0 & b_1 & b_2 & b_3 & 0 \\ b_2 & b_3 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & b_0 & b_1 & b_2 \end{bmatrix} \begin{bmatrix} S_{0,0} \\ S_{0,1} \\ S_{0,2} \\ S_{0,3} \\ S_{0,4} \\ S_{0,5} \\ S_{0,6} \\ S_{0,7} \\ S_{0,8} \\ S_{0,9} \\ S_{0,10} \\ S_{0,11} \\ S_{0,12} \\ S_{0,13} \\ S_{0,14} \\ S_{0,15} \end{bmatrix} = \begin{bmatrix} S_{1,0} \\ S_{1,1} \\ S_{1,2} \\ S_{1,3} \\ S_{1,4} \\ S_{1,5} \\ S_{1,6} \\ S_{1,7} \\ T_{1,0} \\ T_{1,1} \\ T_{1,2} \\ T_{1,3} \\ T_{1,4} \\ T_{1,5} \\ T_{1,6} \\ T_{1,7} \end{bmatrix} \quad (2.19)$$

La matriz de transformación W^2 se forma arreglando los coeficientes de manera similar a W^1 pero el número de columnas es de la mitad.

$$\begin{bmatrix} C_0 & C_1 & C_2 & C_3 & 0 & 0 & 0 & 0 \\ 0 & 0 & C_0 & C_1 & C_2 & C_3 & 0 & 0 \\ 0 & 0 & 0 & 0 & C_0 & C_1 & C_2 & C_3 \\ C_2 & C_3 & 0 & 0 & 0 & 0 & C_0 & C_1 \\ b_0 & b_1 & b_2 & b_3 & 0 & 0 & 0 & 0 \\ 0 & 0 & b_0 & b_1 & b_2 & b_3 & 0 & 0 \\ 0 & 0 & 0 & 0 & b_0 & b_1 & b_2 & b_3 \\ b_2 & b_3 & 0 & 0 & 0 & 0 & b_0 & b_1 \end{bmatrix} \begin{bmatrix} S_{1,0} \\ S_{1,1} \\ S_{1,2} \\ S_{1,3} \\ S_{1,4} \\ S_{1,5} \\ S_{1,6} \\ S_{1,7} \end{bmatrix} = \begin{bmatrix} S_{2,0} \\ S_{2,1} \\ S_{2,2} \\ S_{2,3} \\ T_{2,0} \\ T_{2,1} \\ T_{2,2} \\ T_{2,3} \end{bmatrix} \quad (2.20)$$

Los coeficientes wavelet generados en la segunda etapa son utilizados como secuencia de entrada para el tercer nivel, como el tamaño del vector de entrada se reduce a la mitad también el tamaño de las matrices de transformación (en su número de renglones y columnas) se reduce a la mitad por cada nivel de análisis.

$$\begin{bmatrix} C_0 & C_1 & C_2 & C_3 \\ C_2 & C_3 & C_0 & C_1 \\ b_0 & b_1 & b_2 & b_3 \\ b_2 & b_3 & b_0 & b_1 \end{bmatrix} \begin{bmatrix} S_{2,0} \\ S_{2,1} \\ S_{2,2} \\ S_{2,3} \end{bmatrix} = \begin{bmatrix} S_{3,0} \\ S_{3,1} \\ T_{3,0} \\ T_{3,1} \end{bmatrix} \quad (2.21)$$

Debido a que la transformación de ondoletas será utilizada como herramienta de compresión de datos, en el caso específico de esta aplicación solamente se requiere

de los coeficientes de análisis pues no se necesita hacer la transformación inversa por medio de los coeficientes de síntesis, es decir que las matrices de transformación pueden disminuir sus dimensiones; su número de renglones es reducido por la mitad y en consecuencia los cálculos son simplificados.

Las dimensiones de las nuevas matrices de transformación por escala son de 8x16, 4x8 y 2x4, respectivamente:

$$W^1_{8 \times 16} \quad (2.22a)$$

$$W^2_{4 \times 8} \quad (2.22b)$$

$$W^3_{2 \times 4} \quad (2.22c)$$

Ante esta nueva perspectiva la transformación se puede simplificar considerablemente al expresarse como una sola operación de la siguiente manera:

$$W^1_{8 \times 16} W^2_{4 \times 8} W^3_{2 \times 4} X_{16 \times 1} = T_{1 \times 2} \quad (2.23)$$

Pues debido a la reducción de renglones en cada uno de los arreglos, y por asociación las matrices de transformación pueden representarse como una matriz única, W^T :

$$W^T_{2 \times 16} X_{16 \times 1} = T_{1 \times 2} \quad (2.24)$$

Donde

$$W^T_{2 \times 16} = W^1_{8 \times 16} W^2_{4 \times 8} W^3_{2 \times 4} \quad (2.25)$$

Aunque se requiere del cómputo previo de las matrices correspondientes a cada nivel de escala para la estimación de esta matriz W^T , la Transformada Wavelet Discreta puede realizarse con solo una matriz de transformación y es posible calcular el vector resultante con una multiplicación matricial más simple. Tal como lo muestra (2.26).

En este punto se tienen varias opciones para implementar el algoritmo. Una forma directa consiste de adquirir el vector de entrada completo y después realizar la multiplicación, el inconveniente de esta aproximación se hace evidente cuando el tamaño N de la secuencia de entrada es muy grande pues el tamaño de la matriz W aumenta hasta $N^2 / 2$ y la cantidad de memoria necesaria para manejar las matrices se vuelve muy grande. Otro método, tomando ventaja del hecho que los datos son adquiridos de manera serial, es adquirir el primer dato de la secuencia de entrada, $X_{0,0}$, multiplicarlo por la columna.

$$\begin{bmatrix} W_{0,0} & W_{0,1} & W_{0,2} & W_{0,3} & W_{0,4} & W_{0,5} & W_{0,6} & W_{0,7} & W_{0,8} & W_{0,9} & W_{0,10} & W_{0,11} & W_{0,12} & W_{0,13} & W_{0,14} & W_{0,15} \\ W_{1,0} & W_{1,1} & W_{1,2} & W_{1,3} & W_{1,4} & W_{1,5} & W_{1,6} & W_{1,7} & W_{1,8} & W_{1,9} & W_{1,10} & W_{1,11} & W_{1,12} & W_{1,13} & W_{1,14} & W_{1,15} \end{bmatrix} \begin{bmatrix} X_{0,0} \\ X_{1,0} \\ X_{2,0} \\ X_{3,0} \\ X_{4,0} \\ X_{5,0} \\ X_{6,0} \\ X_{7,0} \\ X_{8,0} \\ X_{9,0} \\ X_{10,0} \\ X_{11,0} \\ X_{12,0} \\ X_{13,0} \\ X_{14,0} \\ X_{15,0} \end{bmatrix} = \begin{bmatrix} T_{0,0} \\ T_{1,0} \end{bmatrix} \quad (2.26)$$

En este punto se tienen varias opciones para implementar el algoritmo. Una forma directa consiste de adquirir el vector de entrada completo y después realizar la multiplicación, el inconveniente de esta aproximación se hace evidente cuando el tamaño N de la secuencia de entrada es muy grande pues el tamaño de la matriz W aumenta hasta $N^2 / 2$ y la cantidad de memoria necesaria para manejar las matrices se vuelve muy grande. Otro método, tomando ventaja del hecho que los datos son adquiridos de manera serial, es adquirir el primer dato de la secuencia de entrada, $X_{0,0}$, multiplicarlo por la columna correspondiente de la matriz W^T y almacenar de manera temporal el resultado parcial, cuando el segundo dato ingrese al sistema se multiplicará por la segunda columna de W^T y el resultado deberá sumarse con el producto anterior. Este procedimiento de multiplicar y acumular se repetirá de manera ordenada hasta completar la secuencia de entrada, como lo describen las ecuaciones (33a) y (33b), respectivamente.

$$T_{0,0} = \sum_{k=0}^{15} W_{0,k} \cdot X_{k,0} \quad (2.27a)$$

$$T_{1,0} = \sum_{k=0}^{15} W_{1,k} \cdot X_{k,0} \quad (2.27b)$$

Con esta segunda opción se reduce la cantidad de memoria utilizada para realizar las operaciones, pues gracias a la operación de acumulación solamente se necesita una cantidad pequeña de registros que mantengan los productos parciales.

2.3 Redes neuronales artificiales (RNA)

Sin duda alguna la inteligencia artificial ha tenido muchísimo auge en áreas que van desde la industria de los juegos hasta las cadenas de producción de varias empresas. Para ello se han desarrollado múltiples técnicas, las más conocidas son la lógica difusa (aprendizaje inductivo), algoritmos genéticos y redes neuronales. En este sentido, se utilizan las RNAs como una herramienta que podrá utilizarse para resolver problemas difíciles.

¿Qué es una red neuronal?

El cerebro humano continuamente recibe señales de entrada de muchas fuentes y las procesa para obtener una respuesta apropiada de salida. Nuestro cerebro cuenta con millones de neuronas, las cuales están conectadas entre sí generando un gran número de conexiones (10^{15}), lo que lo convierte en una red con una complejidad muy superior a cualquier producto humano.

En una neurona biológica, la información se transmite en forma de señal eléctrica o química, y el proceso de comunicación entre neuronas se produce gracias a los neurotransmisores liberados por la neurona emisora y captados por la neurona receptora. La facilidad de transmisión de señales se altera mediante la actividad del sistema nervioso. Esta habilidad de ajustar señales es un mecanismo de aprendizaje. Actualmente existen trabajos de investigación y estudio, enfocados al control de velocidad y al modelado de un MI para predecir su comportamiento; sus diferentes técnicas para controlarlo son de un amplio interés originado por el comportamiento no lineal y a su naturaleza que vuelve al motor de inducción cambiante en condiciones trabajo debido a factores como la temperatura, velocidad de operación, carga y saturación.

Ventajas y desventajas de las RNAs

Ventajas

- Al probar todas las posibles soluciones nos ofrecen la solución óptima.
- Ideales para solución de problemas que no sean linealmente separables.
- Aprendizaje: Las RNA tienen la habilidad de aprender mediante una etapa que se llama etapa de aprendizaje. Esta consiste en proporcionar a la RNA datos como entrada a su vez que se le indica cuál es la salida (respuesta) esperada.
- Auto organización: Una RNA crea su propia representación de la información en su interior, descargando al usuario de esto.

- Tolerancia a fallos: Debido a que una RNA almacena la información de forma redundante, ésta puede seguir respondiendo de manera aceptable aun si se daña parcialmente.
- Flexibilidad: Una RNA puede manejar cambios no importantes en la información de entrada, como señales con ruido u otros cambios en la entrada (ej. si la información de entrada es la imagen de un objeto, la respuesta correspondiente no sufre cambios si la imagen cambia un poco su brillo o el objeto cambia ligeramente)
- Tiempo real: La estructura de una RNA es paralela, por lo cuál si esto es implementado con computadoras o en dispositivos electrónicos especiales, se pueden obtener respuestas en tiempo real.
- Aplicables a muchas áreas del conocimiento.
- Pueden suponer información faltante a la entrada.

Desventajas

- Tiempo de aprendizaje elevado, debido a que prueba todas las soluciones posibles.
- Alto consumo de recursos computacionales comparado si se usa otras técnicas de inteligencia artificial.

2.3.1 Mecanismos de aprendizaje

El aprendizaje es el proceso por el cual una red neuronal modifica sus pesos como consecuencia de las señales de entrada. Los cambios que se producen durante el proceso de aprendizaje se reducen a la eliminación, modificación y creación de conexiones. En los modelos de redes neuronales artificiales, la creación de una nueva conexión implica que el peso de la misma pasa a tener un valor distinto de cero.

Durante el proceso de aprendizaje, los pesos de las conexiones de la red sufren modificaciones, por tanto se puede afirmar que este proceso ha terminado (la red ha aprendido) cuando los valores de los pesos permanecen estables o el margen de error es menor o igual al que se ha definido como aceptable. Es necesario conocer cuáles son los criterios que se siguen para cambiar el valor asignado a las conexiones cuando se pretende que la red aprenda una nueva información.

Se suelen considerar dos tipos de reglas o aprendizajes: supervisado y no supervisado. La diferencia entre ambos tipos de aprendizaje está en la existencia o no de un agente externo (supervisor) que controle el proceso de aprendizaje de la red.

Aprendizaje supervisado

La técnica consiste en ajustar los pesos de la red en función de la diferencia entre los valores deseados y los obtenidos en la salida de la red; es decir, una función de error cometido en la salida.

El perceptrón fue el primer modelo de red neuronal artificial supervisado OFF LINE con conexiones hacia delante, desarrollado por Rosenblatt en 1958, el cual fue utilizado para diferenciar elementos de dos clases diferentes.

Aprendizaje no supervisado

Las redes con aprendizaje no supervisado no recibe ninguna información por parte del entorno que le indique si la salida generada en respuesta a una determinada entrada es o no es correcta; por ello, suele decirse que estas redes son capaces de auto organizarse. Estas redes deben encontrar las características, regularidades, correlaciones o categorías que se puedan establecer entre los datos que se presentan en su entrada.

En algunos casos, la salida representa el grado de familiaridad o similitud entre la información que se le está presentando en la entrada y las informaciones que se le han mostrado hasta entonces (en el pasado). En otro caso podría realizar una clusterización o establecimiento de patrones o categorías, indicando la red a la salida a qué categoría pertenece la información presentada a la entrada.

2.3.2 Topología de las RNA

La topología o arquitectura de las redes neuronales consiste en la organización y disposición de las neuronas en la red formando capas o grupos de neuronas más o menos alejadas de la entrada y salida de la red. En este sentido, los parámetros fundamentales de la red son: *el número de capas, el número de neuronas por capa, el grado de conectividad y el tipo de conexiones entre neuronas.*

2.3.2.1 Perceptrón Multicapa (MLP)

El perceptrón fue propuesto por Rosenblatt en 1959 en su obra "Principles of Neurodynamics", Freeman y Skapura (1993). Los perceptrones son redes de propagación hacia adelante basados en unidades binarias que consta de una capa de entrada de n elementos; dichas entradas x se propagarán a una capa de m unidades actuadoras y de éstas a una sola unidad de salida. Para un perceptrón con dos entradas, cada entrada se multiplica por el peso W correspondiente, y los

resultados se suman, siendo evaluados contra el valor de umbral, si el resultado es mayor al mismo el perceptrón se activa, Freeman y Skapura (1993).

El entrenamiento de un perceptrón es por medio de la regla de aprendizaje delta :

$$\partial W = LR(T - Y)x, \quad (2.28)$$

donde LR representa la razón de aprendizaje, T el valor deseado a la salida, Y el valor obtenido, y x la señal de entrada aplicada al perceptrón. La figura 4 muestra la función de entrenamiento del perceptrón, donde P_1 y P_2 representan los vectores de entradas a la red, $W_{1,1}$ y $W_{1,2}$ los vectores de pesos, n es la función de umbral, b el vector de bias y a salida de la red.




Figura 2.3 Función de entrenamiento de Perceptrón.

2.3.2.2 Mapas auto organizados (SOM)

Existen evidencias que demuestran que en el cerebro hay neuronas que se organizan en muchas zonas, de forma que las informaciones captadas del entorno a través de los órganos sensoriales se representan internamente en forma de mapas bidimensionales.

Aunque en gran medida esta organización neuronal está predeterminada genéticamente, es probable que parte de ella se origine mediante el aprendizaje. Esto sugiere, por tanto, que el cerebro podría poseer capacidad inherente de formar mapas topológicos de las informaciones recibidas del exterior.

A partir de estas ideas, Teuvo Kohonen presentó en 1982 un sistema con un comportamiento semejante; se trata de un modelo de red neuronal con capacidad para formar mapas de características de manera similar a como ocurre en el cerebro. El objetivo de Kohonen era demostrar que un estímulo externo (información de entrada) por sí solo, suponiendo una estructura propia y una descripción funcional del comportamiento de la red, era suficiente para forzar la formación de

mapas. Este modelo llamado Self Organizing Maps (SOM) que se basa en el principio de formación de mapas topológicos para establecer características comunes entre las informaciones (vectores) de entrada a la red. Este modelo es uno de los más populares que se utilizan en redes neuronales artificiales y pertenece a la categoría de redes con aprendizaje competitivo y cuyo peso de la neurona ganadora es ajustada con la regla de aprendizaje de Kohonen.



Figura 2.4 a) SOM de estructura rectangular b) SOM de estructura Hexagonal

Algoritmo de la SOM.

- 1.- Inicializar pesos (w_{ij}) con valores aleatorios pequeños
- 2.- Fijar la zona inicial de vecindad entre las neuronas de salida.
- 3.- Introducir información que debe aprender

$$p = (p_1, p_n \dots p_n) \quad (2.29)$$

- 4.- Determina la neurona vencedora de la capa de salida.
- 5.- Se actualizan los pesos de las conexiones entre las neuronas de entrada y dicha neurona.

$$w_q = w_{q-1} + a_q(p_q - w_{q-1}) \quad (2.30)$$

- 6.- El coeficiente de aprendizaje o parámetro de ganancia a_g con un valor entre 0 y 1. Por lo general se toman 10000 iteraciones.

- 7.- El proceso debe repetirse, volviendo a presentar todo el juego de patrones de aprendizaje p_1, p_2, \dots, p_n hasta obtener la salida deseada.

Donde: C es la función de transferencia competitiva, N dist la función distancia, generalmente se utiliza la euclidiana o la Manhattan, B el Vector de Bias, IW el vector de pesos y P las entradas.




Figura 2.5 Diagrama que muestra la función de entrenamiento de la SOM

Donde: C es la función de transferencia competitiva, N dist la función distancia, generalmente se utiliza la euclidiana o la Manhattan, B el Vector de Bias, IW el vector de pesos y P las entradas.

Modificación propuesta para aceleramiento del proceso de aprendizaje de la SOM

Como se ha mencionado con anterioridad existen 2 tipos de entrenamientos principales, en supervisado y el no supervisado. La SOM que se conoce utiliza un aprendizaje no supervisado, sin embargo si se modifican los vectores de entrada a la red durante su entrenamiento agregando un patrón a cada tipo de señal de entrada, la red encontrará esa similitud y las clasificará de una manera más rápida y precisa.

Esa modificación sólo se aplicará durante la etapa de entrenamiento, ya que en la etapa de funcionamiento no sólo no es posible ni siquiera sería conveniente.

Para validar dicho punto se harán pruebas con la SOM de modelo tradicional y la SOM modificada sugerida.

Al aplicar esta metodología propuesta se atacará una de las consideradas desventajas de las RNAs, conservando las ventajas de la misma y compensando los errores del sistema de control tradicional debido a las suposiciones consideradas al momento de su formulación.

2.3. CAPÍTULO III

Con formato: Espacio Antes: 0 pto, Interlineado: Múltiple 1.15 lín., Esquema numerado + Nivel: 1 + Estilo de numeración: 1, 2, 3, ... + Iniciar en: 1 + Alineación: Izquierda + Alineación: 0.63 cm + Sangría: 1.27 cm

3 Metodología.

A lo largo de esta sección se abordará las diferentes etapas que conforman este proyecto (adquisición y acondicionamiento de señales, procesamiento y la toma de decisiones), las cuales se muestran en la figura 3.1.




Figura 3.1 Etapas del sistema de monitoreo propuesto.

Para el proceso de fresado se establecerán los parámetros de corte dentro de un rango en particular, con la finalidad de poder caracterizar de manera adecuada la señal proveniente del husillo; de la cual posteriormente se extraerán las fuerzas de corte.

El proceso de adquisición, consiste en la obtención de las señales de los servo controladores, lo cual deberá realizarse sin la utilización de sensores, o realizar modificaciones a la fresadora.

En la etapa de procesamiento se realizará el filtrado de las señales con la finalidad de eliminar el ruido; y es también en esta misma etapa en la que se aplicará el proceso de transformación utilizando diferentes Wavelet con la finalidad de reducir de manera considerable la cantidad de datos introducidos a la RNA, pero sin perder información característica de la misma.

Finalmente la etapa de clasificación consiste en el diseño de una RNA, la cual determinará la clase a la que pertenecen las señales presentadas. Existiendo 3 clases diferentes, Buen estado, desgastado y roto.

3.1 Proceso de fresado

De acuerdo a la literatura un punto importante para un proceso de fresado adecuado, que evite o disminuya los daños en las herramientas o en las maquinaria misma es el establecimiento adecuado de los parámetros de corte, los cuales son elegidos de acuerdo a la dureza del material, tipo de cortador y tipo de acabado principalmente.

Al mismo tiempo es necesario considerar la trayectoria en la cual el material se comenzará a desbastar. Si los parámetros son establecidos de manera correcta y los cortadores se encuentran en buen estado se obtendrá una pieza maquinada que cumpla con las especificaciones necesarias. La figura 3.2 muestra un diagrama a bloques de las etapas que conforman el proceso de fresado, así como los parámetros que se deben de considerar durante el proceso.

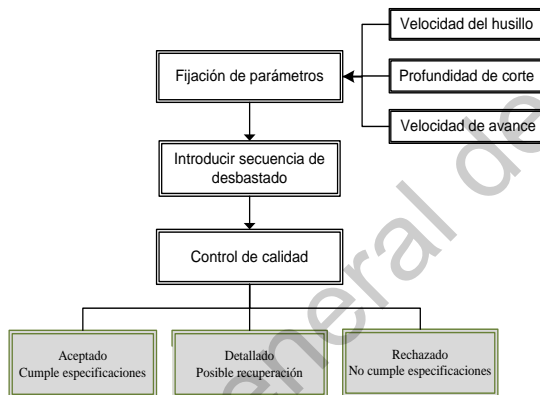


Figura 3.2 Etapas del proceso de fresado

En la tabla 3.1 se muestra los parámetros de corte establecido para el proceso de fresado utilizado en este proceso. El acero usado para el maquinado es acero ASTM – 4130, se utilizó un herramental para 2 insertos de carburo, los cuales presentaban diferentes niveles de desgaste o ruptura, así como insertos en buenas condiciones.

Tabla 3.1 Parámetros establecidos en el proceso de fresado para adquisición de señales

Parámetro	Valor	Unidad
Velocidad del husillo	300 – 450	rpm

Profundidad de corte	1 – 1.5	mm
Velocidad de avance	100 - 120	mm / min

Tabla 3.2 Parámetros de corte utilizados en este experimento

Profundidad De corte (mm)	Tasa de Alimentación (mm/min)	Velocidad Del husillo (rpm)	Combinaciones de insertos usadas
1	100	300	
1	100	450	2 insertos rotos
1	120	300	1 inserto roto y 1 en buen estado
1	120	450	1 inserto roto y 1 inserto gastado
1.5	100	300	2 insertos en buen estado
1.5	100	450	1 inserto en buen estado y 1 inserto gastado
1.5	120	300	2 insertos gastados
1.5	120	450	

Los parámetros de velocidad del husillo, profundidad de corte y velocidad de avance son variados entre los rangos mostrados. Las señales provenientes del husillo de la fresadora son adquiridas para determinar el estado de los cortadores, un osciloscopio Tektronik 4000b es el instrumento a través del cual se adquieren las señales para la realización de la base de datos.

3.2 Adquisición de señales

Como se mencionó anteriormente, en un proceso de maquinado existen diferentes medios para caracterizar, analizar y predecir el estado de las herramientas; clasificándolos principalmente en dos tipos: métodos directos e indirectos.

Una variable que se utilizan de manera frecuente para la caracterización del estado de los cortadores es el análisis de las fuerzas de corte (estáticas y dinámicas); debido a que se ha establecido que la variación en las fuerzas de corte está correlacionada con el desgaste de la herramienta. El análisis está basado en la variación de la fricción entre la herramienta de corte y la pieza de trabajo en proporción a las condiciones del desgaste (Shoba, 2015, Karabulut 2015, Razavykia 2015, Anandakrishnan 2011, Kumar 2014). Por lo expuesto anteriormente es que se optó por utilizar esta variable en el sistema de monitoreo propuesto.

De acuerdo a Romero et al 2003, las mediciones directas de las señales del husillo muestran que la señal principal son las fuerzas de corte, acompañadas de interferencias severas provenientes de del tornillo de bolas y el ruido de conmutación causado por los sistemas discretos del control. Tal como se muestra en la figura 3.3.

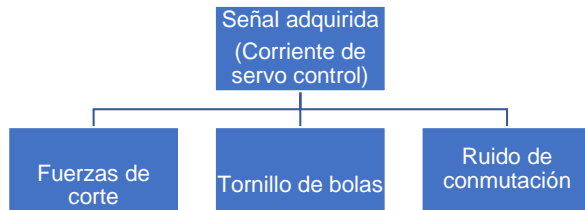


Figura 3.3 Señales presentes en las señales adquiridas

La componente principal de la corriente del controlador es la corriente de control del servo; esta señal es generada por el control de posición es en forma de un voltaje directo que es alimentado al servo amplificador

Troncoso et al 2003, determinaron a través de un análisis que las señales de corriente obtenidas del servo controle están formadas por una componente sinusoidal más un nivel de DC constante (Figura 3.4).




Figura 3.4 Corrientes de monitoreo que proporciona la fresadora

Para determinar las frecuencias en las que se encuentran las fuerzas de corte, debemos aplicar la siguiente fórmula.

$$f_F = \frac{HN}{2\pi} \quad (3.1.)$$

Siendo H la velocidad del husillo en rev/s y N el numero de cortadores utilizados. Por lo anterior es que podemos determinar que las fuerzas de corte se encuentran en las frecuencias bajas. Y también observó que el ruido presente en la señal se encuentra en las altas frecuencias, de tal manera que para la extracción de características de las señales adquiridas es necesario utilizar un filtro pasa bajas para eliminar la información no deseada.

La figura 3.5 muestra las salidas que provee la fresadora de donde podrán adquirirse las corrientes de los servomotores para su posterior análisis.

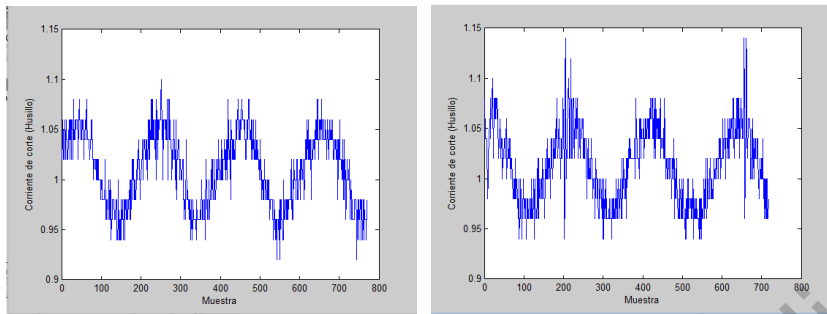


Figura 3.5 Señales adquiridas usando 2 insertos en buenas condiciones y posteriormente un inserto desgastado y 1 en buen estado

La adquisición de señales se realiza utilizando un osciloscopio Tektronik, las cuales son almacenadas en un archivo Excel, esto con la finalidad de facilitar el proceso de lectura de las mismas, ya que estas serán procesadas en Matlab. Lo anterior se muestra en la figura 3.5.

3.3 Acondicionamiento de las señales

La importancia de esta etapa radica en la necesidad de proporcionarle a la red señales con la calidad necesaria para que ésta pueda clasificar de manera correcta las señales que recibe, pero desafortunadamente como se mencionó, se debe considerar que la información obtenida directamente de la fresadora contiene ruido o no está en las condiciones adecuadas para poder analizarla y obtener información confiable, es por ello que es necesario realizar un acondicionamiento de las señales obtenidas que elimine el ruido y provea de las características adecuadas a la señal para su análisis, dicho acondicionamiento puede ser a través de:

- Filtrado
- Amplificación/Reducción de señales
- Sumas y restas de señales
- Cambio de dominio

La primera opción viable es por supuesto el uso de un filtro que elimine el ruido de las señales.

3.4 Proceso de Filtrado

La señal es filtrada por dos filtros FIR, un filtro pasa bandas para eliminar el efecto del tronillo de bolas (pasa altas) y el ruido (filtro pasa bajas). Se optó por un filtro FIR debido a su estabilidad y su respuesta de fase lineal.

A continuación se presentan las especificaciones de los filtros digitales utilizados, dichos filtros se realizaron en MatLab® que presenta una herramienta de diseño y análisis para la descripción de filtros. Con estas funciones se puede hacer una experimentación en cuanto al diseño y comportamiento de un sistema de filtrado.




Figura 3.6 Filtro FIR pasa banda

Matlab realiza todas las operaciones necesarias según las variables de entrada y nos permite ver el comportamiento del filtro para decidir si es factible su utilización. La figura 3.7 muestra la respuesta en magnitud y la 3.8 la respuesta en fase del filtro generado.

Tabla 3.2 Parámetros del filtro utilizado en el acondicionamiento de las señales.

Características del filtro	
Tipo de filtro:	Pasa banda
Método de diseño	FIR con Ventana de Kaiser
Frecuencia de muestreo,	6250 Hz
Orden de filtro,	20
Frecuencia de corte	fc1 20 Hz
	fc2 138 Hz




Figura 3.7 Respuesta en magnitud del filtro FIR pasa banda




Figura 3.8 Respuesta en fase del filtro FIR pasa banda

Una vez que la señal ha sido filtrada (Figuras 3.9 a,b y c), se realiza el proceso de transformación, el cual consiste en descomponer las señales en diferentes bandas de frecuencia en el dominio del tiempo, lo cual es posible con el uso de la transformada wavelet (TW), debido a que realiza un mapeo de la señal en el tiempo con una representación tiempo-escala, preservando el aspecto temporal.

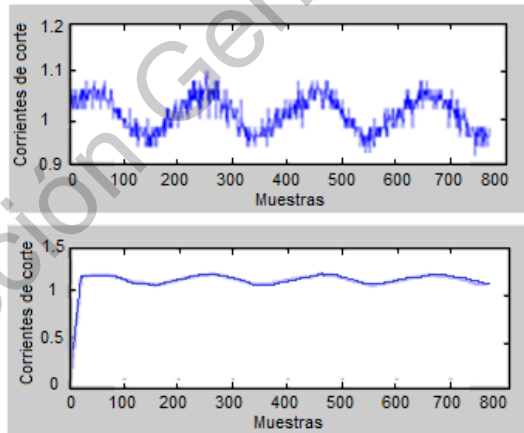


Figura 3.9 Señal de corriente obtenido del husillo con dos cortadores están en buenas condiciones sin filtrar y filtrada

3.5 Transformada Wavelet

La calidad de la información obtenida a partir de un análisis donde se aplica la WT depende en gran medida de la wavelet madre utilizada, de modo que se debe considerar como una etapa dentro del análisis por WT la selección de una wavelet madre adecuada para cada caso particular de estudio.

Según la teoría wavelet se obtendrán coeficientes de aproximaciones y detalles con mayores amplitudes, cuando haya una mayor similitud entre la wavelet madre y la señal analizada con la DWT. En la bibliografía revisada no se identificó un método o algoritmo claro que permita la selección adecuada de una wavelet basado en sus propiedades, sino que se encontró que básicamente se empleaban tres criterios:

- 1.- Determinar visualmente la semejanza que tiene la forma de la wavelet madre y la señal a analizar. Según la teoría wavelet se obtendrán coeficientes de aproximaciones y detalles con mayores amplitudes, cuando haya una mayor similitud entre la wavelet madre y la señal analizada con la DWT.
- 2.- Probar distintas wavelets o métodos para cada caso de estudio, y elegir la que menos distorsione la señal.

Tomando esto en cuenta los dos puntos anteriores, y que de acuerdo a la literatura las wavelets más usadas en los sistemas de monitoreo son las Daubechies principalmente. A continuación se muestran las principales familias de wavelets.

Tabla 3.3 Principales familias de wavelets

Familias de Wavelets			
Daubechies	db	Haar	haar
Coiflets	coif	Symlets	sym
ReverseBior	rbio	BiorSplines	bior
DMeyer	dmey	Meyer	meyr
Mexican_hat	mexh	Gaussian	gaus
Complex Gaussian	cgau	Morlet	morl
Frequency B-Spline	fbsp	Shannon	shan

Como se mencionó anteriormente, es de suma importancia la correcta elección de la wavelet madre utilizada, por lo tanto es necesario probar diferentes familias de

ellas para determinar la conveniencia de su uso. Las wavelet utilizadas de manera inicial son las de la familia Daubechies, Symlets, Haar y BiorSplines.




Figura 3.10 Familia de wavelets

Considerando el punto número uno, sobre las recomendaciones al momento de elegir la wavelet adecuada, se establece que cuando la wavelet es más parecida a la señal original se obtienen coeficientes altos, motivo por el cual se optó por obtener el valor promedio de los coeficientes con la finalidad de determinar el valor mayor.

En la figura 3.11 se observa la señal a transformar, y las dos señales que se obtienen de la transformación. Las cuales corresponde a las bajas frecuencias (Aproximaciones) y las altas frecuencias (Detalles). De las imágenes se puede apreciar que la señal que contiene la información importante para nosotros se encuentra en las bajas frecuencias.




Figura 3.11 Señal a transformar y las aproximaciones y detalles obtenidos de la transformación.

Para elegir la wavelet adecuada se siguieron los pasos sugeridos en la literatura, primeramente elegir la wavelet que visualmente se parezca más a las señal a transformar, aunado a esto la literatura sugiere que las wavelet más convenientes

para este tipo de señales son las de la familia Daubechies, por estas razones se probó esa familia de wavelets entre otras. (Figura 3.12)

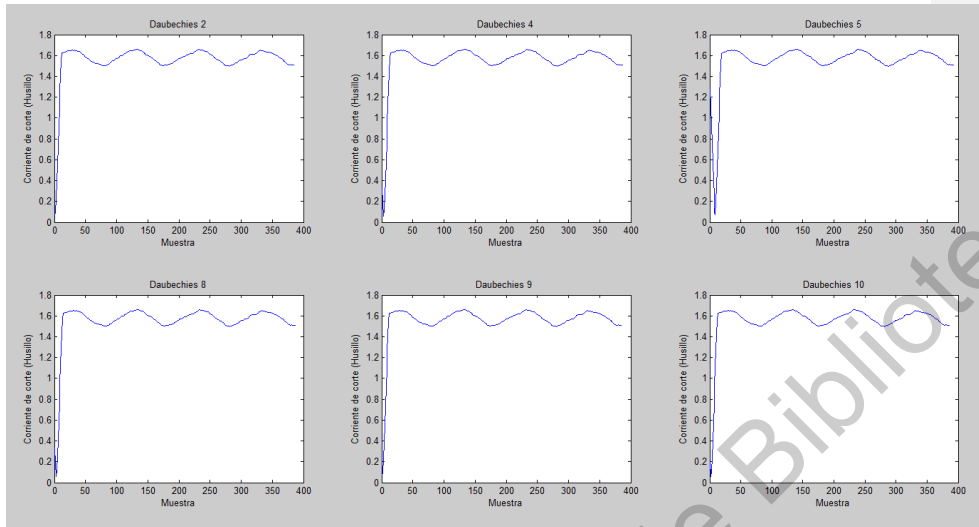


Figura 3.12 Señales transformadas utilizando la familia Daubechies

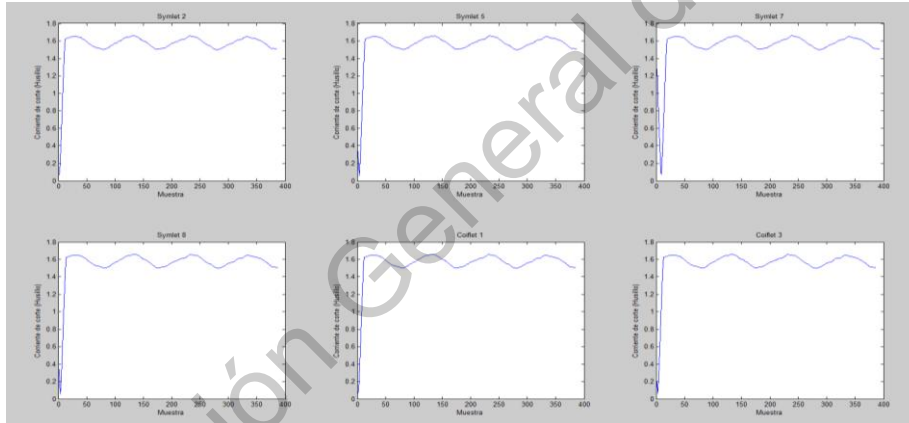


Figura 3.13 Señales transformadas utilizando las familias Symlet y Coiflet

Posteriormente, también la literatura señala que cuando una señal es muy similar a la wavelet los coeficientes obtenidos en la transformación tendrán un valor cercano a 1; Motivo por el cual se calcularon los coeficientes promedio de las wavelets usadas, mostrando en la tabla 3.4 algunos de los promedios obtenidos.

En la tabla 3.4 se muestran los promedios de las aproximaciones.

Transformada	Promedio de Aproximaciones
Db1	-0.6633
Db2	-0.4431
Db3	-0.2726
Db4	-0.1215
Db5	0.1727
Sym2	-0.4431
Sym3	-0.2726
Sym4	0.0798
Coif1	0.1031
Coif2	0.1227
Coif3	0.1686

De acuerdo a la tabla 3.4 la wavelet madre que ofrece el promedio más alto es la Daubechies 5, aunado a que de acuerdo a la literatura es la familia más recomendada para este tipo de señales es la razón por la cual será la wavelet utilizada en este proyecto.

Como se mencionó anteriormente, es en los coeficientes de aproximación es donde se encuentra la señal importante para nosotros de tal manera que podemos desechar la mitad de los datos y solo trabajaremos con las aproximaciones. Si se aplica un segundo nivel transformación la cantidad de datos disminuirá a la mitad, y al aplicar un tercer nivel de transformación el número los datos serán reducidos a una cuarta parte de la señal original.

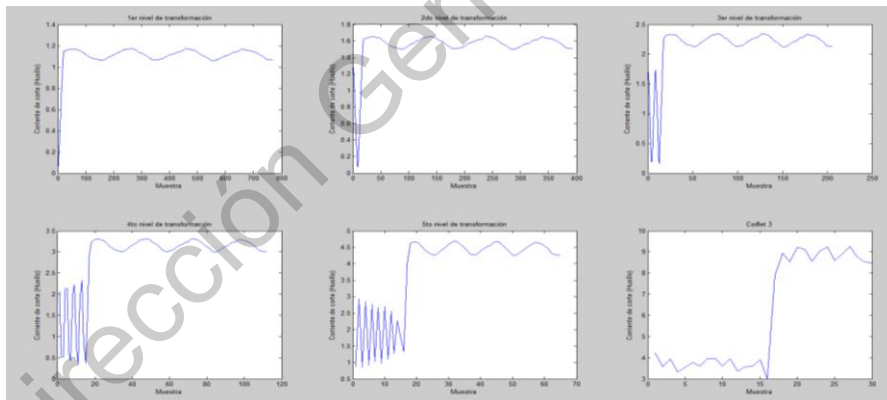


Figura 3.14 Señales resultantes de diversos niveles de transformación, utilizando una wavelet madre Daubechies 5

Con 5 niveles de transformación utilizada es posible reducir la señal a un tamaño de datos. Es muy importante mencionar que se verificó en todo momento que la señal podría ser recuperable, para lo cual se aplica la transformada wavelet inversa.

3.6 Red neuronal

Para seleccionar la RNA óptima para la correcta clasificación de los estados de los cortadores de la fresadora, se probaron diferentes tipos de RNA, principalmente del tipo perceptron multicapa (MLP), SOM con un entrenamiento no supervisado y una SOM modificada que utiliza un entrenamiento supervisado, se eligieron estos tipos de redes debido a que de acuerdo a la literatura son de las redes más utilizadas, y la red SOM porque es una red poco sensible al ruido y ha brindado buenos resultados en la clasificación de señales.

3.6.1 Parámetros del MLP

Las estructuras del MLP probadas fueron: [1, 10, 10, 3], [1, 8, 8, 3], [1, 8, 12, 3] and [1, 8, 10, 3], donde el primer número indica las neuronas en la capa de entrada, la segunda y tercera cantidad las neuronas en las capas ocultas y finalmente las neuronas en las capas de salida. En la tabla 3.5 se muestran las características principales con las que cuentan los MLP utilizados.

Tabla 3.5 Parámetros de la RNA tipo MLP con entrenamiento no supervisado

Parámetro	
Tamaño de las entradas	[16, 1]
Tasa de aprendizaje	0.25
Función de activación	Sigmoidal
Capas ocultas	2
Conexión	Completa

De acuerdo a la figura se observa que únicamente hay una neurona, pero al momento de establecer la estructura se mencionan 3, esto es debido a que en realidad las fuerzas de corte extraídas dependen de la velocidad del husillo y la profundidad de corte, ya que estas varían cuando los parámetros cambian. Es por eso que aunque no se introduzca de manera directa un calor va implícito en las fuerzas de corte.




Figura 3.15 Estructura del MLP utilizada. Es un MLP totalmente conectado

Dentro del entrenamiento de la red del tipo MLP, se utilizó la función de umbral del tipo sigmoide (Figura 3.16), la cual es de las más usadas en este tipo de redes. La tasa de aprendizaje fue de 0.1.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.1)$$




Figura 3.16 función sigmoide

Las condiciones de parada de la red son:

- 1.-Por número de iteraciones (1000)
- 2.- Error alcanzado (5%)

Otras estructuras diseñada para este proyecto fueron con la topología SOM, la cual no habían sido tan comúnmente utilizadas, sin embargo por si solas han ofrecido grandes ventajas en la clasificación y reconocimiento de patrones, y estos dos motivos fueron los que motivaron su uso.




Figura 3.17 Red neuronal tipo SOM de estructura [4,8], con vecindad de 1 y conexión vertical y horizontal.

3.6.2 Parámetros de la red SOM

En cuanto a las redes del tipo SOM entrenadas se encuentran estructuras [4, 4], [4, 8] y [8 8]. Las estructuras diseñadas fueron entrenadas usando dos modalidades, el entrenamiento tradicional (No supervisado) y un entrenamiento propuesto al que se le llama entrenamiento supervisado, porque aunque no calcula los pesos basados en un error o agente supervisor, si hace que haya una tendencia marcada para la red a cerca de la clase a la que pertenece la señal de entrada.

Como es sabido, las redes del tipo SOM son RNA que únicamente tienen capa de entrada y capa de salida, y los parámetros utilizados en la red se muestran en la siguiente tabla.

Tabla 3.6 Parámetros de la RNA tipo SOM con entrenamiento no supervisado

Parámetro	
Tamaño del vector de pesos	[16, 1]
Tasa de aprendizaje	0.1
Distancia	Manhattan
Vecindad	1
Conexión	cuadrada

Las condiciones de parada de la red son:

- 1.- Por número de iteraciones (1000)
- 2.- Distancia máxima (0,02)

En cuanto a la SOM con entrenamiento supervisado los parámetros fueron:

Tabla 3.7 Parámetros de la RNA tipo SOM con entrenamiento no supervisado

Parámetro	
Tamaño del vector de pesos	[19, 1]
Tasa de aprendizaje	0.1
Distancia	Manhattan
Vecindad	1
Conexión	Cuadrada

Como se puede observar en la tabla 3.6, el vector de pesos se incrementa de 16 a 19 valores. Los criterios de parada de la red SOM supervisada son los mismo que para la SOM no supervisada.

La siguiente tabla (tabla 3.8) muestra la relación de vecindades entre las neuronas de la red, indicando cuales modificaran sus pesos cuando alguna resulte ganadora. En dicha tabla se puede ver que cuando la neurona 1 resulta ganadora, modificará los pesos de las neuronas II, V, IV y XII en la red SOM de 4 x 4 mientras en una red de 4 x 8 el resultar como ganadora la neurona I, las neuronas que se modificaran son I, V, IV y XXIX. Posteriormente en la Tabla 3.10 se muestra la relación de las neuronas en la red SOM de 8x 8, que indica que cuando la neurona I resulta ganadora se modifican las neuronas II, VII, IX y LVII .

Tabla 3.8 Relación de vecindad entre neuronas de redes del tipo SOM de 4x4 y 4x8

MODIFICACIÓN DE NEURONAS VECINAS					
SOM 4 X 4			SOM 4 X 8		
Ganadora	Modifica	Ganadora	Modifica	Ganadora	Modifica
I	II, V, IV y XIII	I	II, V, IV y XXIX	XVII	XIII, XVIII, XX y XXI
II	I, III, VI y XIV	II	I, III, VI y XXX	XVIII	XIV, XVII, XIX y XXII
III	II, IV, VII y XV	III	II, IV, VII y XXXI	XIX	XV, XVIII, XXI y XXIII
IV	III, I, VII y XVI	IV	III, I, VII y XXXII	XX	XVI, XVII, XIX y XXIV
V	I, VI, VII y IX	V	I, VI, VII y IX	XXI	XVII, XXII, XXIV y XXV
VI	II, V, VII y X	VI	II, V, VII y X	XXII	XVIII, XXI, XXIII y XXVI
VII	III, VI, VII y XI	VII	III, VI, VII y XI	XXIII	XIX, XXII, XXIV y XXVII

VIII	IV, V, VII y XII	VIII	IV, V, VII y XII	XXIV	XX, XXI, XXIII y XXVIII
IX	V, X, XII y XIII	IX	V, X, XII y XIII	XXV	XXI, XXVI, XXVIII y XXIX
X	VI, IX, XI y XIV	X	VI, IX, XI y XIV	XXVI	XXII, XXV, XXVII y XXX
XI	VII, V, XII y XV	XI	VII, V, XII y XV	XXVII	XXIII, XXVI, XXVIII y XXXI
XII	VIII, IX, XI y XVI	XII	VIII, IX, XI y XVI	XXVIII	XXIV, XXV, XXVII y XXXII
XIII	I, IX, XIV y XVI	XIII	IX, XIV, XVI y XVII	XXIX	I, XXV, XXX y XXXII
XIV	II, X, XIII y XV	XIV	X, XIII, XV y XVIII	XXX	II, XXVI, XXIX y XXXI
XV	III, XI, XIV y XVI	XV	XI, XIV, XIX	XXXI	III, XXVII, XXX y XXXII
XVI	IV, XII, XIII y XV	XVI	IV, XII, XIII y XX	XXXII	IV, XXVII, XXX y XXXII

Tabla 3.9 Relación de vecindad entre neuronas de redes del tipo SOM de 8 x 8

MODIFICACIÓN DE NEURONAS VECINAS			
SOM 8 X 8			
Ganadora	Modifica	Ganadora	Modifica
I	II, VII, IX y LVII	XXXIII	XXV, XXXIV, XL y XLI
II	I, III, X y LVIII	XXXIV	XXVI, XXXIII, XXXV y XLII
III	II, IV, XI y LIX	XXXV	XXVII, XXXIV, XXXVI y XLIII
IV	III, V, XII y LX	XXXVI	XXVIII, XXXV, XXXVII y XLIV
V	IV, VI, XIII y LXI	XXXVII	XXIX, XXXVI, XXXVIII y XLV
VI	V, VII, XIV y LXII	XXXVIII	XXX, XXXVII, XXXIX y XLVI
VII	VI, VIII, XV y LXIII	XXXIX	XXXI, XXXVIII, XL y XLVII
VIII	I, VII, XVI y XLIV	XL	XXXII, XXXIII, XXXIX y XLVIII
IX	I, X, XVI y XVII	XLI	XXXIII, XLII, XLVIII y XLIX
X	II, IX, XI y XVIII	XLII	XXXIV, XLI, XLIII y L
XI	III, X, XII y XIX	XLIII	XXXV, XLII, XLIV y LI

XII	IV, XI, XIII y XX	XLIV	XXXVI, XLIII, XLV y LII
XIII	V, XII, XIV y XXI	XLV	XXXVII, XLIV, XLVI y LIII
XIV	VI, XIII, XV y XXII	XLVI	XXXVIII, XLV, XLVII y LIV
XV	VII, XIV, XVI y XXIII	XLVII	XXXIX, XLVI, XLVIII y LV
XVI	VIII, IX, XV, XXIV	XLVIII	XL, XLVII, XLIX y LVI
XVII	IX, XVIII, XXIV y XXV	XLIX	XLII, LVI y LVII
XVIII	X, XVII, XIX y XXVI	L	XLII, XLIX, LI y LVII
XIX	XI, XVIII, XX y XVII	LI	XLIII, L, LII y LIX
XX	XII, XIX, XXI y XXVIII	LII	XLIV, LI, LIII y LX
XXI	XIII, XX, XXII y XXIX	LIII	XLV, LII, XLIV y LXI
XXII	XIX, XXI, XXIII y XXX	LIV	XLVI, LIII, LV y XII
XXIII	XV, XXII, XXIV y XXXI	LV	XLVII, LIV, LVI y LXIII
XXIV	XVI, XVII, XXIII y XXXII	LVI	XLVIII, XLIX, LV y LXIV
XXV	XVII, XXVI, XXXII y XXXIII	LVII	I, XLIX, LVIII y LXIV
XXVI	XVIII, XXV, XXVII y XXXIV	LVIII	II, L, LVII y LIX
XXVII	XIX, XXVI, XVIII y XXXV	LVIX	III, LI, LVII y LX
XXVIII	XX, XXVII, XXIX y XXXVI	LX	IV, LII, LIX y LXI
XXIX	XXI, XXVIII, XXX y XXXVII	LXI	V, LIII, LX y LXII
XXX	XXII, XXIX, XXXI y XXXVIII	LXII	VI, LIV, LXI y LXIII
XXXI	XXIII, XXX, XXXII y XXIX	LXIII	VII, LV, LXII y LXIV
XXXII	XXIV, XXV, XXXI y XL	LXIV	VIII, LVI, LXVII y LXIII

4. CAPÍTULO IV

Con formato: Espacio Antes: 0 pto, Interlineado: Múltiple 1.15 lín., Esquema numerado + Nivel: 1 + Estilo de numeración: 1, 2, 3, ... + Iniciar en: 1 + Alineación: Izquierda + Alineación: 0.63 cm + Sangría: 1.27 cm

4 Resultados

En este apartado nos enfocaremos principalmente en los resultados obtenidos en el entrenamiento de las diferentes topologías, tamaños de redes y tipos de entrenamiento, debido a que en el capítulo anterior se mostraron los algunos de los resultados obtenidos.

4.1 Adquisición

Como se mencionó anteriormente, se puede observar que las señales obtenidas de los servo controles son señales senoidales sobre un nivel de DC, y que a medida que el cortador se daña, esta se va deformando. Tal como se muestra en la figura 4.1 donde se muestra una señal cuando los cortadores están en buen estado y otra cuando un cortador esta gastado y uno en buen estado.

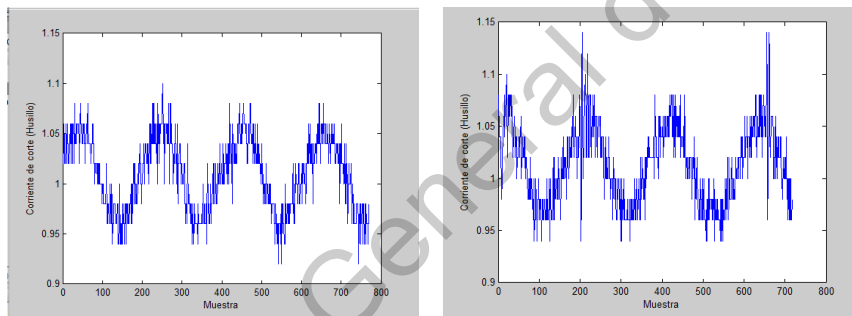


Figura 4.1 Adquisición de señales en el proceso de fresado, se muestra una señal con ambos insertos en buen estado y posteriormente con un inserto gastado y uno en buen estado.

Sin embargo también como era de esperarse, se observa que la señal esta acompañada de ruido no deseado. El cual tiene que ser eliminado con la finalidad de presentarle a la red una señal que no contenga información no deseada.

4.2 Filtrado

Como se puede observar en la figura 4.2 se muestra la señal antes del proceso de filtrado, y posteriormente en 4.2 se muestra la señal filtrada, donde se observa que el ruido se ha eliminado de manera considerable, permitiendo conservar únicamente la información deseada.




Figura 4.2 Señal resultante del proceso de filtrado, utilizando un filtro FIR pasa banda, la señal es producida por un cortador en buen estado

4.3 Transformada Wavelet

Para el proceso de selección de la wavelet ideal, se realizaron pruebas usando diferentes wavelets madre, observando como este proceso divide la señal en aproximaciones y detalles. En la figura 4.3 se muestra una señal a la cual se le aplicó la transformada Daubechies 5 y sus diferentes niveles de transformación.




Figura 4.3 muestra la señal filtrada y posteriormente con un nivel de transformación.

De las señales resultantes de la transformación, sólo se utilizaron las aproximaciones ya que ahí es donde se encuentra la información más importante de la señal, de tal manera que desechamos la mitad de los datos (Detalles).

4.4 Red Neuronal Artificial

El clasificador fue probado usando 2 topologías diferentes de RNAs, con tamaños diferentes. Las redes de tipo MLP y SOM.

Las topologías MLP que se probaron tenían las siguientes características.

Tabla 4.1 especificaciones de las RNA de topología MLP utilizadas

Característica	Valor
Conexión	Completa
Función de activación	Sigmoide
Tasa de aprendizaje	0.25
Iteraciones	1000
Error mínimo deseado	0.015
Condiciones de parada	Por error o número de iteraciones

La siguiente tabla muestra el error alcanzado por las redes, en cada una de las topologías usadas. La tabla 4.2 muestra el error alcanzado durante el entrenamiento de las diferentes configuraciones de RNA del tipo MLP, bajo las diferentes condiciones de fresado.

Tabla 4.2. Error en la red MLP

Profundidad De corte (mm)	Tasa de Alimentación (mm/min)	Velocidad Del husillo (rpm)	Neuronas en Capas ocultas	Error
1	100	300	[8,8]	0.01397
			[10,10]	0.01298
			[11,6]	0.0057
			[9,3]	0.00518
		450	[8,8]	0.01090
			[10,10]	0.01414
			[11,6]	0.00447
			[9,3]	0.0037
	120	300	[8,8]	0.01439
			[10,10]	0.01336
			[11,6]	0.005135
			[9,3]	0.005135
		450	[8,8]	0.01103
			[10,10]	0.01357
			[11,6]	0.00459
			[9,3]	0.003799
300	[8,8]	0.01453		
	[10,10]	0.01322		
	[11,6]	0.00705		
	[9,3]	0.00605		

1.5

100	450	[8,8]	0.01991
		[10,10]	0.01666
		[11,6]	0.004554
		[9,3]	0.00377
120	300	[8,8]	0.01933
		[10,10]	0.01875
		[11,6]	0.00534
		[9,3]	0.00534
	450	[8,8]	0.0201
		[10,10]	0.01766
		[11,6]	0.00473
		[9,3]	0.00393

Debido a que las redes que ofrecieron mejor resultados fueron las redes de tamaño [16, 9,3,3] y [16, 11, 6, 3] son las que ofrecieron mejores resultados, se muestra en la siguiente grafica como disminuye el error durante cada iteración.

De manera adicional debido a que la red de tamaño [16, 9, 3, 3] tiene una menor cantidad de neuronas es la red que se considera la mejor. En la figura 4.4 se muestra como durante el entrenamiento el error va disminuyendo.




Figura 4.4. Error en la red MLP

Red SOM modificada

Una vez hecho eso, se estructuraron las matrices de la siguiente forma, donde los valores escogidos para los pesos iniciales se generaron de manera aleatoria en Matlab:

$$\begin{pmatrix} I & II & III & IV \\ V & VI & VII & VIII \\ IX & X & XI & XII \\ XIII & XIV & XV & XVI \end{pmatrix}$$

I = [0.8147, 0.9058, 0.1270, 0.9134, 0.6324, 0.0975, 0.2485, 0.5469, 0.9575, 0.9649, 0.1576, 0.9706, 0.9542, 0.4854, 0.8003, 0.1419, 0, 1, 0]
 II = [0.4218, 0.9157, 0.7922, 0.9595, 0.6557, 0.0357, ...]

Figura 4.4 Numeración de las neuronas que forman la RNA del tipo SOM

Después de realizar todo y cada uno de los pasos del proceso anterior nos dispusimos a realizar la matriz de distancia empleando la fórmula de Distancia Manhattan, donde:

$$d_i = |\text{entrada} - \text{peso}_i| \quad 4.1$$

De tal manera que siendo vectores, la localidad de cada vector se restaba con su igual. Finalmente, se determinaban las distancias verdaderas entre cada peso y la entrada a partir de la sumatoria de cada una de las localidades de las matrices *dI, dII, dIII, etc.* Una de las entradas ejemplo que se usó fue la mostrada en la figura 4.5. Y es a partir de la distancia mínima que se determina la neurona ganadora.

Por lo que enseguida, se establecieron los casos para los cuales se modificaron los pesos a partir de la neurona ganadora, tomando en cuenta una vecindad de 1 y una conexión tipo horizontal y vertical. A partir de ese ajuste, se calcula si la distancia mínima debe ser menor a 0.05, de no ser así se vuelve a realizar el ajuste de pesos hasta alcanzar la distancia mínima deseada.

$$\begin{bmatrix} 1 \\ 0.5 \\ 0.7 \\ 0.8 \\ 0.7 \\ 0.1 \\ 0.2 \\ 0.9 \\ 1 \\ 0.6 \\ 0.3 \\ 0.4 \\ 0.8 \\ 0.2 \\ 1 \\ 0.7 \\ 1 \\ 0 \\ 0 \end{bmatrix} - \begin{bmatrix} I & II & III & IV \\ V & VI & VII & VIII \\ IX & X & XI & XII \\ XIII & XIV & XV & XVI \end{bmatrix} = \begin{bmatrix} [dI] & [dII] & [dIII] & [dIV] \\ [dV] & [dVI] & [dVII] & [dVIII] \\ [dIX] & [dX] & [dXI] & [dXII] \\ [dXIII] & [dXIV] & [dXV] & [dXVI] \end{bmatrix}$$

Figura 4.5 Obtención de distancias entre el vector de entrada y las diferentes neuronas que forman la red.

Una vez establecida la relación de vecindad (Tablas 3.9 y 3.10) se comienza a iterar, modificando los pesos de las neuronas. A continuación se muestran algunas iteraciones que demuestran la clasificación de la primera señal mostrada a la red. Esto solo para fines demostrativos, ya que en el apéndice A se muestra en entrenamiento completo de la red tipo SOM de 4 x 4, tanto con entrenamiento supervisado como no supervisado.

Una vez que se introducen todas las señales a la red, es posible obtener un gráfico que muestra como las diferencias entre las entradas y los vectores de pesos de cada neurona disminuyen, esto representa que se parecen un poco más a los vectores de entrada.

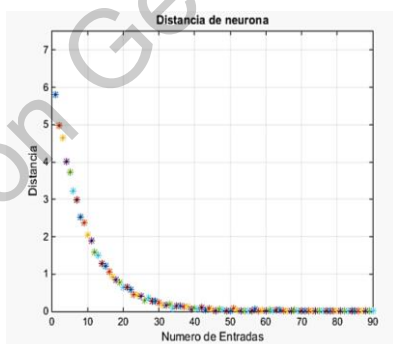


Figura 4.6 Modificación de la relación de distancia entre las entradas y los vectores de pesos

Ya que se finalizó el entrenamiento, la red arrojó los siguientes resultados a partir de cada columna de la base de datos ingresados, de tal manera que se clasificaron de la siguiente manera. Se puede observar que la señal C, correspondiente a una señal de la clase 3, no fue posible que la clasificara de manera correcta, esto se debe a que la señal presenta ciertas perturbaciones debido a una falla en el proceso de fresado.

Tabla 4.3 Clasificación de señales por neuronas de una red SOM 4x4 supervisada

Neuronas activas para las entradas															
I	II	III	IV	V	VI	VII	VIII	IX	X	XI	XII	XIII	XIV	XV	XVI
D	CJ		H	AC			E	B	F	F	B	A	V	BH	
G			N	AI			H	C	I	L	E	D	AE	BN	
M			Q				K		L	U	C	J		CL	
CJ			W				N		O	X		M			
			Z				Q		R	AA		P			
			AF				T		AJ	AD		S			
			AL				W		BB	AJ		V			
			AR				Z		BZ	AM		Y			
			BM				AC		CF	AP		AB			
							AF			AS		AE			
							AI			AV		AH			
							AL			AY		AK			
							AR			BE		AN			
							AU			BH		BI			
							BA			BK		BL			
							BD			BQ		BO			
							BG			BT		BR			
							BJ			CC		BX			
							BS			CI		CA			
							BV			CL		CD			
							BY					CG			
							CB					CJ			
							CH								
							CK								

Clase 1 Al menos 1 inserto roto

Clase 2 Al menos un inserto gastado

Clase 3 2 insertos en buen estado

Co los resultados mostrados en la tabla anterior podemos decir que la red clasifica de manera correcta con un error menor al 98%. Identificando que las neuronas que identifican cada clase quedan de la siguiente manera.

Tabla 4.4 Neuronas que identifican cada clase.

Clase	Neuronas que la clasifican
Clase 1 (Roto)	I, II, XIII y XIV
Clase 2 (Gastado)	IV, V, VIII, IX y XII
Clase 3 (Buen estado)	X, XI y XV

Una vez que se realizó el entrenamiento de la red SOM supervisada se quitaron los tres últimos valores del vector de entrada, que son los que se utilizaron para diferenciar entre las señales pertenecientes a cada una de las clases ([1, 0, 0] para clase 1, [0, 1, 0,] para la clase 2 y [0, 0, 1] para la clase 3). Se puede observar que la red no fue capaz de identificar de manera adecuada las señales correspondientes a las diferentes clases.

Tabla 4.5 Clasificación de señales por neuronas de una red SOM 4x4 No supervisada

Neuronas activas para las entradas																
I	II	III	IV	V	VI	VII	VIII	IX	X	XI	XII	XIII	XIV	XV	XVI	
H				AZ				A	M		P	BC	AB		V	
W				CG				D	Y		S	E	AK		AH	
AO				CJ				G	O		AE	AX	AW		AN	
BH				N				J	AL		AQ	BP	BF		BO	
CL				Z				BL	BS		AT	BV	BR		AI	
				AF				CA	AY		BI	CH	BU		AU	
				AR				CD	BK		BX	C	T		BJ	
				BA				K			B	F	L		CE	
				BD				AG			AC	I	X		CN	
				BG							BY	O	AP		U	
				MB							AA	AM	AS		AJ	
				CV							AD	BT	BN		BE	
				R							AV		BW		CC	
											BB					
											BQ					
											BZ					
											CF					
											CI					

Cuando se encuentra un inserto roto y uno gastado lo clasifica por el inserto roto, se puede observar que la señal C que pertenece a insertos en buen estado lo identifico como insertos en buen estado, y eso es porque corresponde a un inserto con nivel de desgaste menor a 1 mm.

Table 4.6. Error alcanzado por la red del tipo SOM supervisada y no supervisada durante el entrenamiento

Profundidad De corte (mm)	Tasa de Alimentación (mm/min)	Velocidad Del husillo (rpm)	Neuronas en Capas ocultas	Error SOM no supervisada	Error supervisada	
1	100	300	[4,4]	0.03059	0.04436	
			[4,8]	0.04633	0.04175	
			[8,8]	0.06327	0.0464	
			[10,10]	0.07139	0.06272	
		450	[4,4]	0.03544	0.0406	
			[4,8]	0.06736	0.05242	
			[8,8]	0.07321	0.06449	
			[10,10]	0.05227	0.0613	
	120	300	[4,4]	0.0408	0.03778	
			[4,8]	0.0484094	0.04465	
			[8,8]	0.0573909	0.05279	
			[10,10]	0.06549862	0.06073	
		450	[4,4]	0.03869862	0.03273	
			[4,8]	0.06668134	0.06183	
			[8,8]	0.06745893	0.06222	
			[10,10]	0.04944332	0.04785	
	1.5	100	300	[4,4]	0.03059471	0.02482
				[4,8]	0.04632193	0.03632
				[8,8]	0.06325327	0.04998
				[10,10]	0.07139544	0.05624
450			[4,4]	0.03659544	0.0284	
			[4,8]	0.06305736	0.04931	
			[8,8]	0.07324921	0.05788	
			[10,10]	0.0562127	0.04403	
120		300	[4,4]	0.0408128	0.03211	
			[4,8]	0.0484094	0.03843	
			[8,8]	0.0573909	0.04581	
			[10,10]	0.06549862	0.05191	
450	[4,4]	0.03869862	0.03091			
	[4,8]	0.06668134	0.05226			
	[8,8]	0.06745893	0.05355			
	[10,10]	0.04944332	0.03922			

Cabe mencionar que en este capítulo nos enfocamos principalmente en las redes que mostraron los mejores resultados y utilizan una menor cantidad de recursos.

4.2 Discusión de los resultados

Una vez analizados los resultados es posible concluir que el método usado nos permite determinar niveles de desgaste en un cortador mayores a 0.25 mm, y se clasifica como ruptura a partir de los 0.6 mm.

Una red Neuronal del tipo MLP o SOM pueden ser utilizadas en los sistemas de monitoreo para determinar condiciones del cortador, sin embargo en este caso se obtuvieron mejores resultados usando una red del tipo MLP.

Al realizar algunas modificaciones en el proceso de entrenamiento de la red SOM es posible reducir los tiempos de entrenamiento, comparado con los tiempos de entrenamiento de la red SOM tradicional, sin embargo en términos generales no podemos garantizar que el proceso de clasificación también se mejora.

Por otra parte podemos concluir que entre mayor sea el nivel de desgaste o de rotura de inserto se obtiene un mayor porcentaje de clasificación, y con niveles de ruptura o desgaste cercanos a los 0.25 mm, es donde se tiene un mayor porcentaje de error en la clasificación, ya que puede ser clasificada como si el cortador estuviera en buenas condiciones.

- [1] Abbas J., Al-Habaibeh A. y D. Su. 2011, Sensor fusion for condition monitoring system of end milling operations. *Key Eng. Mater.* 450: 267-270.
- [2] Aggarwal S. Aggarwal, N. Nešić, P. Xirouchakis, 2012, Cutting torque and tangential cutting force coefficient identification from spindle motor current, *Int. J. Adv. Manuf. Technol.* 65 (1–4) pp 81–95.
- [3] Ai, C.S., Sun Y. J., He G.W., Ze X.B., Li W y Mao K., 2012. The milling tool wear monitoring using the acoustic spectrum. *Int. J. Adv. Manuf. Tech.*, 61(5-8): 457-463.
- [4] Anandakrishnan V., Mahamani A., 2011, Investigations of flank wear, cutting force, and surface roughness in the machining of Al-6061–TiB₂ in situ metal matrix composites produced by flux-assisted synthesis, *Int. J. Adv. Manuf. Technol.* Pp 55 65.
- [5] Andersson, C., Andersson M., y Stahl J.E., 2011. Experimental studies of cutting force variation in face milling. *Int. J. Mach. Tool. Manu.*, 51: 67-76.
- [6] Baccar, D y .Söffker D., 2015, Wear detection by mean soft wavelet-based acoustic emission analysis, *Mechanical Systems and Signal Processing* 60-61 pp 198–207
- [7] Beruvides Surface roughness modeling and optimization of tungsten–copper alloys in micro-milling processes Gerardo Beruvides, Fernando Castaño, Ramón Quiza, Rodolfo E. Haber, *Measurement* 86 (2016) 246–252
- [8] Biswajit 2015 Biswajit Das, S. Roy, R.N. Rai, S.C. Saha, Application of grey fuzzy logic for the optimization of CNC milling parameters for Al–4.5%Cu–TiC MMCs with multi-performance characteristics, *Engineering Science and Technology, an International Journal* (2015), doi: 10.1016/j.jestch.2015.12.002
- [9] Coz, G.L., Marinescu M., Devillez A., Dudzinski D. y Velnom L., 2012. Measuring temperature of rotating cutting tools: Application to MQL drilling and dry milling of aerospace alloys. *Appl. Therm. Eng.*, 36: 434-441.
- [10] Ghani, J.A., Rizal M., Nuawi M.Z., Ghazali M.J. y Haron C.H.C., 2011. Monitoring online cutting tool wear using low-cost technique and user-friendly GUI. *Wear*, 271: 2619- 2624.
- [11] Gok A., Gologlu C., Demirci H.I., 2013, Cutting parameter and tool path style effects on cutting force and tool deflection in machining of convex and concave inclined surfaces, *Int. J. Adv. Manuf. Technol.* 3
- [12] Hase A., Mishina H., Wada M., 2012, Correlation between features of acoustic emission signals and mechanical wear mechanisms. *Volumes 292–293*, pp 144–150
- [13] Huang L. Huang, Q. Kemao, B. Pan, A.K. Asundi, 2010, Comparison of Fourier transform, windowed Fourier transform, and wavelet transform methods for

- phase extraction from a single fringe pattern in fringe projection profilometry, *Opt. Lasers Eng.* 48 (2) pp 141–148
- [14] Hui L. Hui, T. Chaonan, P. Kaixiang, 2011, Data-driven modeling and online algorithm for hot rolling process, in: *Proceedings of the 30th Chinese Control Conference*, Yantai, China, pp. 1560–1564.
- [15] Jesudoss, R., Kumar R., J. A. J Sujana, 2016, Modeling of process parameters of friction stud welding Using Fuzzy logic system N, *Int J Adv Engg Tech/Vol. VII/ Issue I* pp /413-417
- [16] Kalvoda, T. and Y.R. Hwang, 2010b. Analysis of signals for monitoring of nonlinear and non-stationary machining processes. *Sensor Actuat. A-Phys.*, 161(1-2): pp 39-45.
- [17] Kalvoda, T. and Y.R. Hwang, 2010a, A cutter tool monitoring in machining process using Hilbert-Huang transform. *Int. J. Mach. Tool. Manu.*, 50: pp 495-501.
- [18] Karabulut S., 2015, Optimization of surface roughness and cutting force during AA7039/Al₂O₃ metal matrix composites milling using neural networks and Taguchi method *Measurement*, 66, pp. 139–149
- [19] Kaya, B., Oysu C., y Ertunc H.M., 2011. Force-torque based on-line tool wear estimation system for CNC milling of Inconel 718 using neural networks. *Adv. Eng. Software*, 42: pp 76-84.
- [20] Kistler, 2016. <https://www.kistler.com/es/es/aplicaciones/tecnologia-de-sensores/medicion-de-fuerza-de-corte/fresado/dinamometro-estacionario-con-compensacion-de-temperatura-tipo-9139aa-de-kistler/>
- [21] Kovac. P, Rodic. D, Pucovsky. V, Savkovic. B, Gostimirovic. M. 2013, Application of fuzzy logic and regression analysis for modeling surface roughness in face milling. *Journal of intelligent manufacturing*. 24, pp. 755-762.
- [22] Krishnamoorthy A., Boopathy S.R., Palanikumar K., Davim J.P., 2012, Application of grey fuzzy logic for the optimization of drilling parameters for CFRP composites with multiple performance characteristics *J. Int. Meas. Confeder.* 45 (5), pp. 1286–1296
- [23] Kuljanic, E., Totis G., y Sortino M., 2009. Development of an intelligent multisensor chatter detection system in milling. *Mech. Syst. Sig. Process.*, 23: pp 1704-1718.
- [24] Kumar A., Mahapatra M.M., Jha P.K., 2014, Effect of machining parameters on cutting force and surface roughness of in situ Al–4.5%Cu/TiC metal matrix composites *Measurement*, 48, pp. 325–332
- [25] Lamraoui, M. Thomas, M. El-Badaoui, 2014, Cyclostationarity approach for monitoring chatter and tool wear in high speed milling, *Mech. Syst. Signal Process.* 44, pp 177–198.

- [26] Lee J.Y., 2013, Variable short-time Fourier transform for vibration signals with transients, *J. Vib. Control*.
- [27] Lu C., Wan B.-S., 2012, Study of high-frequency sound signals for tool wear monitoring in micromilling, *Int. J. Adv. Manuf. Technol.* 66 (9–12) pp 1785–1792.
- [28] Modi. B. S, George. P. M y Sheth. S, 2013. Study and investigate effect of cutting parameters on flatness for dual plate check valve. *Proceeding of 7th International Conference on Advanced Computing and Communication Technologies (ICACCT™-2013)*. DOI: 10.13140/2.1.3867.7286
- [29] Muhammad R., Ghani J. A., Nuawi M. Z., Hassan C., y Haron C., 2015, Development and testing of an integrated rotating dynamometer on tool holder for milling process, *Mechanical Systems and Signal Processing* 52-53, pp 559–576
- [30] Nouri a, Barry K., .Fussell N, Beth Ziniti L., Linder E., 2015, Real-time tool wear monitoring in milling using acutting condition independent method Mehdi, *International Journal of Machine Tools&Manufacture* 89 pp 1–13
- [31] Pandey R.K., Panda S.S., 2014, Optimization of bone drilling parameters using greybased fuzzy algorithm *Measurement*, 47, pp. 386–392
- [32] Rafezi H. Rafezi, J. Akbari, M. Behzad, 2012, Tool condition monitoring based on sound and vibration analysis and wavelet packet decomposition, in: 2012 8th International Symposium on Mechatronics and its Applications, pp. 1–4.
- [33] Rajmohan T., Palanikumar K., Prakash S., 2013, Grey-fuzzy algorithm to optimise machining parameters in drilling of hybrid metal matrix composites *Compos. Part B Eng*, 50, pp. 297–308
- [34] Ramanujam R., Venkatesan K., Saxena V., Chawdhury N., Choudhary V., 2014, Influence of cutting parameters on machinability on Inconel 718 alloy with coated carbide insert-a Taguchi based fuzzy logic approach, *ARPN J. Eng. Appl. Sci.* 5, 630–637.
- [35] Razavykia A., Farahany S., Mohd-Yusof N., 2015, Evaluation of cutting force and surface roughness in the dry turning of Al–Mg₂Si in-situ metal matrix composite inoculated with bismuth using DOE approach *Measurement*, 76, pp. 170–182 3rd International Conference on Innovations in Automation and Mechatronics Engineering, ICIAME 2016
- [36] Rehorn, A.G., Jiang, J. y Orban, P.E., 2005, State-of-the-art methods and results in tool condition monitoring: A review. *International Journal of Manufacturing Technology*, 26 (7-8), 693-710.
- [37] Sarhan,A., 2015, Investigation about the characterization of machine tool spindle stiffness for intelligent CNC end milling, *Matsubara/Robotics and Computer integrated Manufacturing* 34, pp 133–139
- [38] Sato, M., Tamura N., y Tanaka H., 2011. Temperature variation in the cutting tool in end milling. *J. Manuf. Sci. Eng.*, 133: 021005-1-021005-7.

- [39] Sevilla-Camacho, P.Y., G. Herrera-Ruiz, J.B. Robles-Ocampo and J.C. Jáuregui-Correa, 2011. Tool breakage detection in CNC high-speed milling based in feed-motor current signals. *Int. J. Adv. Manuf. Technol.*, 53, pp 1141-1148.
- [40] Sheth. S, Modi. B. S, George. P. M y Patel. P, 2014. A Fuzzy Logic based Model to Predict MRR in Flashing Operation of Precision Steel Ball Manufacturing Process. *Procedia Materials Science*. 5, pp. 1837-1845.
- [41] Sheth. S, Modi. B. S, Patel. D and Chaudhari. A. B, 2015. Modeling and prediction using regression, ANN and Fuzzy logic of real time vibration monitoring on lathe machine in context of machining parameters. *Bonfring International Journal of man machine Interface*, 3 (3), pp. 30-35.
- [42] Shoba C., Ramanaiah N., Nageswara Rao D., 2015, Effect of reinforcement on the cutting forces while machining metal matrix composites – an experimental approach *Eng. Sci. Technol*, 18, pp. 658–663
- [43] Soepangkat B.O.P., Pramujati B., 2013, Optimization of surface roughness and recast thickness in the wire-EDM process of AISI D2 tool steel using Taguchi-greyfuzzy Appl. Mech. Mater, 393, pp. 21–28
- [44] Suprock, C.A. y J.S. Nichols, 2009. A low cost wireless high bandwidth transmitter for sensor-integrated metal cutting tools and process monitoring. *Int. J. Mechatr. Manuf. Syst.*, 2(4): pp 441-454.
- [45] Rajasekaran T., Palanikumar K., Vinayagam B.K., 2011, Application of fuzzy logic for modelling surface roughness in turning CFRP composites using CBN tool, *Prod. Eng. Res. Develop.* 5, pp 191–199.
- [46] Tamiloli N., Venkatesan J., Vijaya Ramnath B., 2016, A grey-fuzzy modeling for evaluating surface roughness and material removal rate of coated end milling insert, *Measurement* 84, pp 68–82
- [47] Tansel, I.N., Demetgul M., Bickraj K., Kaya B., y Ozcelik B., 2011. Basic computational tools and mechanical hardware for torque-based diagnostic of machining operations. *J. Intell. Manuf.*, 24(1), pp 141-161.
- [48] Tansel, I.N., Li M., Demetgul M., Bickraj K., Kaya B., y Ozcelik B., 2012. Detecting chatter and estimating wear from the torque using Index Based Reasoner (IBR). *Int. J. Adv. Manuf. Tech.*, 58: 109-118.
- [49] Teti R, Jemielniak K, O'Donnell G, Dornfeld D., 2010, Advanced monitoring of machining operations. *CIRP Annals - Manufacturing Technology*, 79, pp 717-739.
- [50] Totis, G., Wirtz G., Sortino M., Veselovac D., Kuljanic E., y Klocke F., 2010, Development of a dynamometer for measuring individual cutting edge forces in face milling. *Mech. Syst. Sig. Process.*, 24, pp 1844-1857.
- [51] Turchetta S., 2011, Cutting force and diamond toolwear in stonemachining, *Int. J. Adv. Manuf. Technol.* 61 (5–8), pp 441–448.

- [52] Vladimir P., Borislav S., Marin G., 2014, Multi-output fuzzy inference system for modelling cutting temperature and tool life in face milling, J. Mech. Sci. Technol. 28 pp 4247–4256.
- [53] Wang G., Yang Y., Xie Q., Zhang Y., 2014 Force based tool wear monitoring system for milling process based on relevance vector machine, Advances in Engineering Software 71, pp 46–51
- [54] Xiqing, M. y Chuangwen X, 2009. Tool wear monitoring of acoustic emission signals from milling processes. Proceeding of the 1st International Workshop on Education Technology and Computer Science.
- [55] Yaldiz, S., Unsacar F., Saglam H., y Isik H., 2007. Design, development and testing of a four-component milling dynamometer cutting force and torque. Mech. Syst. Sig. Process., 21, pp 1499-1511.
- [56] Zhanwei Yuan Zhanwei, Li Fuguo *, Zhang Peng, Chen Bo Chinese Journal of Aeronautics, (2014),27(1): 160–168