



# Universidad Autónoma de Querétaro

## Facultad de Ingeniería

Detección y evaluación del desgaste gradual de herramientas en torno CNC mediante flujo magnético y métodos estadísticos.

Tesis

Que como parte de los requisitos para obtener el Grado de  
Maestro en Ciencias Mecatrónica

Presenta:

Ing. Giovanni Díaz Saldaña

Dirigido por:

Dr. Roque Alfredo Osornio Ríos

San Juan del Río, Querétaro. Junio 2022.



Universidad Autónoma de Querétaro  
Facultad de Ingeniería  
Maestría en Ciencias Mecatrónica

Detección y evaluación del desgaste gradual de herramientas en torno CNC mediante flujo magnético y métodos estadísticos.

### TESIS

Que como parte de los requisitos para obtener el grado de

Maestro en Ciencias Mecatrónica

#### Presenta:

Ing. Giovanni Díaz Saldaña

#### Dirigido por:

Dr. Roque Alfredo Osornio Ríos

### SINODALES

Dr. Roque Alfredo Osornio Ríos  
Presidente

\_\_\_\_\_  
Firma

M. en C. Israel Zamudio Ramírez  
Secretario

\_\_\_\_\_  
Firma

Dr. Miguel Trejo Hernández  
Vocal

\_\_\_\_\_  
Firma

Dr. Arturo Yosimar Jaen Cuellar  
Suplente

\_\_\_\_\_  
Firma

Dr. Martín Valtierra Rodríguez  
Suplente

\_\_\_\_\_  
Firma

San Juan del Río, Qro.  
Junio 2022  
México

# Resumen.

Dentro de la industria manufacturera, la condición de las herramientas de corte utilizadas en los procesos de producción es de gran importancia, ya que tiene un impacto directo en la calidad de las piezas producidas, los costos y tiempos de producción. Debido a esto, por décadas se han desarrollado diversas metodologías que emplean diversas clases de sensores para medir magnitudes físicas presentes en los procesos de mecanizado con la finalidad de obtener información que permita identificar las fallas de las herramientas para reducir su impacto en la producción. En tiempos recientes, ha crecido la tendencia a la fusión de datos de múltiples sensores para generar metodologías más robustas y complejas para análisis más complejos y completos. Sin embargo, en ocasiones los sensores son costosos, requieren una colocación invasiva para el proceso o se ven afectados por elementos dentro del proceso de maquinado.

Por otra parte, el análisis de flujo magnético disperso ha crecido como una técnica que permite la detección de fallas en máquinas de inducción y las cadenas cinemáticas de la que forman parte, presentando resultados comparables al uso de metodologías tradicionales como el análisis de corriente, así como la ventaja de utilizar sensores de bajo costo y no invasivos para la máquina. Además, ha mostrado resultados positivos en la detección del desgaste en herramientas de corte en maquinaria CNC.

La presente investigación plantea el uso del flujo magnético de dispersión del motor del husillo de un torno CNC, en fusión con la corriente consumida por la máquina, para detectar y evaluar el desgaste gradual en las herramientas de corte ante la variación individual de la velocidad de corte y el avance de la herramienta, haciendo uso de indicadores estadísticos y no estadísticos, así como redes neuronales, consiguiendo resultados satisfactorios en la detección de los distintos niveles de desgaste presentes en las herramientas de corte.

**(Palabras clave:** Desgaste en herramientas, flujo magnético de dispersión, fusión de datos, motor de inducción, torno CNC).

# Summary.

Within the manufacturing industry, the condition of the cutting tools used in production processes is of great importance, as it has a direct impact on the quality of the parts produced, costs and production times. Due to this, several methodologies have been developed for decades that use various kinds of sensors to measure physical quantities present in production processes in order to obtain information that allows the identification of tool failures to reduce their impact on production. In recent years, there has been a growing trend to merge data from multiple sensors to generate more robust and complex methodologies for more complex and complete analysis. However, sometimes sensors are expensive, require process-invasive placement, or are affected by elements within the machining process.

On the other hand, the analysis of stray magnetic flux has grown as a technique that allows the detection of faults in induction machines and the kinematic chains of which they are part, presenting results comparable to the use of traditional methodologies such as current analysis, as well as the advantage of using low-cost and non-invasive sensors for the machine. In addition, it has shown positive results in the detection of wear on cutting tools in CNC machinery.

The present research proposes the use of the stray magnetic flux of the spindle motor of a CNC lathe, in fusion with the current consumed by the machine, to detect and evaluate the gradual wear in the cutting tools with the individual variation of the cutting speed and the feed rate of the tool, using statistical and non-statistical indicators, as well as neural networks, achieving satisfactory results in the detection of the different levels of wear present in the cutting tools.

**(Key words:** Tool wear, stray magnetic flux, data fusion, induction motor, CNC lathe).

# Dedicatoria.

A mis padres y hermano.

# Agradecimientos.

Agradezco a mi familia el amor y apoyo que me han brindado a lo largo de mi preparación académica, por alentarme a seguir creciendo y preparándome profesionalmente. Agradezco también a mis profesores, por sus enseñanzas, dedicación y guía durante estos años de formación; a mi asesor y sinodales, por la confianza, paciencia, guía, apoyo y conocimiento brindado durante la realización de este trabajo. A mis compañeros del posgrado y todos aquellos que de alguna manera contribuyeron a la culminación de este trabajo con su experiencia, presencia y apoyo.

Igualmente, agradezco a la Universidad Autónoma de Querétaro y al Consejo Nacional de Ciencia y Tecnología (CONACYT) por la beca otorgada (No. 778042) para la realización de este posgrado.

# Índice

Resumen.....	i
Summary.....	ii
Dedicatoria.....	iii
Agradecimientos.....	iv
Índice de figuras.....	viii
Índice de tablas.....	x
1 Introducción.....	1
1.1 Antecedentes.....	2
1.1.1 Evolución de las máquinas herramienta y las herramientas de corte..	2
1.1.2 Detección de fallos en herramientas en torno.....	4
1.1.3 Metodologías y técnicas para la identificación del desgaste en herramientas de corte en otros procesos.....	8
1.1.4 Detección de fallas en cadenas cinemáticas mediante la medición de flujo magnético.....	10
1.1.5 Métodos estadísticos en la detección de fallos en herramientas de corte en procesos de maquinado.....	12
1.1.6 Investigación sobre desgaste de herramientas dentro de la Universidad Autónoma de Querétaro.....	13
1.2 Objetivos e hipótesis.....	15
1.2.1 Objetivo general.....	15
1.2.2 Objetivos específicos.....	16
1.2.3 Hipótesis.....	16
1.3 Justificación.....	17
1.4 Descripción del problema.....	17
2 Revisión de la literatura.....	20

2.1	Desgaste en herramientas de corte. ....	20
2.2	Variables de maquinado.....	22
2.2.1	Torneado. ....	22
2.2.2	Fresado. ....	24
2.3	Flujo magnético de dispersión.....	26
2.3.1	Identificación de fallos en máquinas de inducción. ....	27
2.4	Transformada de Fourier.....	27
2.5	Transformada Wavelet. ....	29
2.6	Parámetros estadísticos y no estadísticos. ....	31
2.6.1	Estadísticos. ....	31
2.6.2	No estadísticos. ....	34
2.7	Análisis Discriminante Lineal (LDA). ....	37
2.8	Validación cruzada.....	38
3	Metodología.....	40
3.1	Configuración experimental.....	41
3.1.1	Parámetros de maquinado. ....	41
3.1.2	Herramientas de corte. ....	42
3.1.3	Diseño de las pruebas. ....	42
3.2	Sistema de Adquisición de Datos.....	45
3.2.1	Sensores de efecto Hall.....	45
3.2.2	Sensor de corriente. ....	47
3.2.3	Tarjeta de adquisición.....	47
3.3	Procesamiento de la información. ....	48
3.3.1	Acondicionamiento de las señales.....	48
3.3.2	Procesamiento con FFT y DWT.....	49

3.3.3	Cálculo de parámetros estadísticos y no estadísticos. ....	50
3.3.4	Reducción de la dimensionalidad mediante LDA.....	50
3.3.5	Generación de Redes Neuronales para la clasificación del nivel de desgaste. ....	51
3.3.6	Desarrollo de software en C y comparación de los resultados. ....	52
4	Resultados.....	53
4.1	Herramientas de corte.....	53
4.2	Pruebas en torno CNC. ....	56
4.2.1	Programación de las rutinas de corte. ....	57
4.2.2	Barras maquinadas.....	58
4.3	Análisis de las señales capturadas. ....	60
4.4	Análisis de los parámetros contra desgaste.....	75
4.4.1	Velocidad de corte. ....	75
4.4.2	Avance de la herramienta.....	75
4.5	Comparación de resultados con el software desarrollado.....	75
4.6	Conclusiones.....	76
4.7	Prospectivas.....	77
	Bibliografía. ....	78
	Apéndice I. Artículos publicados. ....	87
	Apéndice II. Software desarrollado.....	94

# Índice de figuras.

Figura 2.1. Diferentes desgastes en herramientas usadas en torno: (a) desgaste del flanco; (b) craterización; (c) astillado; (d) agrietamiento térmico en la cara de ataque; (e) acumulación de material en el borde (BUE); (f) falla catastrófica (Kalpakjian, 2008). .....	22
Figura 2.2. Componentes del flujo de dispersión y colocaciones de sensores tipo bobina (Romary et al., 2013). .....	27
Figura 2.3. Distribución del plano tiempo-frecuencia al utilizar la DWT (Polikar, 1996). .....	30
Figura 2.4. Ilustración del algoritmo de codificación sub-banda o algoritmo de Mallat (Polikar, 1996). .....	31
Figura 2.5. Ilustración del proceso de validación cruzada con $k=3$ . .....	39
Figura 3.1. Diagrama de la metodología propuesta. ....	41
Figura 3.2. Ejemplo de herramienta de corte utilizada en el estudio. ....	42
Figura 3.3. Torno CNC empleado en experimentación. ....	44
Figura 3.4. Colocación de los equipos para adquisición de datos. ....	44
Figura 3.5. Barras de aluminio 6061 preparadas para las pruebas. ....	45
Figura 3.6. Sensores A1325 empleados (Allegro MicroSystems, 2020). ....	45
Figura 3.7. (a) Sistema de flujo triaxial y (b) colocación de los sensores en el motor del husillo. ....	46
Figura 3.8. Sensor de corriente utilizado (Fluke, 2022). .....	47
Figura 3.9. Tarjeta MSP-EXP432P401R empleada (Texas Instruments, 2020). ....	48
Figura 3.10. Respuesta del filtro Butterworth utilizado. ....	49
Figura 3.11. Ilustración del proceso de generación de la matriz de indicadores para cada parámetro de maquinado. ....	50
Figura 4.1. Trayectoria de corte seguida durante las operaciones de maquinado. ....	56
Figura 4.2. Ejemplo de código G empleado como base para la realización de las pruebas. ....	57
Figura 4.3. Comparación entre las señales (a) sin acondicionamiento y (b) acondicionadas. ....	62

Figura 4.4. Gráficas generadas a partir del análisis con FFT para las señales anteriores: (a) señal de corriente, (b) flujo axial, (c) flujo combinado y (d) flujo radial. ....	64
Figura 4.5. Gráficas de la reconstrucción de las señales anteriores en las bandas consideradas para el análisis: (a) corriente, (b) flujo axial, (c) flujo combinado y (d) flujo radial.....	66
Figura 4.6. Resultados del uso de LDA sobre señales de flujo para (a) velocidad de corte y (b) avance de la herramienta.....	67
Figura 4.7. Resultados del uso de LDA sobre las señales de corriente para (a) velocidad de corte y (b) avance de la herramienta.....	68
Figura 4.8. Resultados del uso de LDA con la fusión de datos para (a) velocidad de corte y (b) avance de la herramienta.....	69
Figura 4.9. Matrices de confusión obtenidas para el análisis de las pruebas de velocidad utilizando (a) flujo magnético, (b) corriente y (c) fusión de datos. ....	71
Figura 4.10. Matrices de confusión obtenidas para el análisis de las pruebas de avance utilizando (a) flujo magnético, (b) corriente y (c) fusión de datos. ....	73

# Índice de tablas.

Tabla 2.1. Parámetros y fórmulas utilizadas en operaciones de torneado (Kalpakjian, 2008).....	24
Tabla 2.2. Parámetros y fórmulas empleadas en fresado periférico (Kalpakjian, 2008).....	26
Tabla 2.3. Parámetros estadísticos (Saucedo, 2017).....	33
Tabla 3.1. Parámetros de maquinado para las pruebas de velocidad de corte.....	43
Tabla 3.2. Parámetros de maquinado para las pruebas de avance de la herramienta. .....	43
Tabla 4.1. Herramientas utilizadas para las pruebas de velocidad y sus áreas de desgaste.....	53
Tabla 4.2. Herramientas utilizadas para las pruebas de avance y sus áreas de desgaste.....	55
Tabla 4.3. Fotografías tomadas de las barras maquinadas en las pruebas de avance de la herramienta. ....	58
Tabla 4.4. Fotografías tomadas de las barras maquinadas en las pruebas de velocidad de corte. ....	59
Tabla 4.5. Resultados obtenidos con la validación cruzada.....	74
Tabla 4.6. Resultados obtenidos con la implementación de las funciones convertidas a C.....	74

# 1 Introducción.

Una rama muy importante para el crecimiento económico de las naciones en desarrollo es la industria de la manufactura (Haraguchi *et al.*, 2017). En ella, la condición de las herramientas de corte empleadas para la producción de partes es de gran importancia, ya que su desgaste afecta directamente a la calidad de las piezas maquinadas, así como implica un impacto económico al destinarse cerca del 25% del costo a las herramientas, mientras que sus fallas consumen hasta un 20% del tiempo de paro dentro de los procesos (Ghosh *et al.*, 2018).

En este sentido, el monitoreo y la detección del grado de desgaste en herramientas de corte son de gran importancia dentro de la industria manufacturera. Es por ello, que se han desarrollado diversas metodologías que buscan analizar distintas magnitudes físicas, como lo son la corriente eléctrica, vibraciones, fuerza, emisiones acústicas y la fusión de estas, con la finalidad de detectar y monitorear la condición en que se encuentran las herramientas de corte en los distintos procesos productivos, sirviéndose de diversas técnicas de análisis, como el uso de indicadores estadísticos, técnicas de análisis en frecuencia y tiempo-frecuencia, o el uso de métodos inteligentes como redes neuronales.

Por otro lado, en años recientes, monitoreo del estado de las máquinas eléctricas ha recibido gran interés debido a su relevancia en el sector industrial. Por ello, se han desarrollados diversas metodologías para su análisis, algunas bien establecidas como el análisis de corriente; adicionalmente, se siguen investigando metodologías como alternativa o complemento, siendo el análisis de flujo magnético de dispersión una opción que ha crecido en interés debido a las ventajas que ofrece, como el uso de sensores de menor costo y colocación no invasiva y simple, así como la obtención de resultados eficientes y confiables (Zamudio *et al.*, 2021).

Considerando lo expuesto, el presente proyecto emplea el flujo magnético de dispersión, en conjunto con la corriente consumida, como variables físicas que permiten detectar y evaluar el nivel de daño, de manera gradual, en herramientas

de corte dentro del proceso de torneado en una máquina de Control Numérico por Computadora (CNC), haciendo uso de indicadores estadísticos y no estadísticos.

## 1.1 Antecedentes.

### 1.1.1 Evolución de las máquinas herramienta y las herramientas de corte.

Kamperidou y Barboutis (2013) realizaron un trabajo sobre la historia del torno. En él, se menciona cómo su origen se centraba en el corte sobre madera mediante el movimiento rotatorio de ésta sobre un eje y el uso de herramientas para cortar, raspar o alisar la madera con la finalidad de darle un acabado final. Los autores mencionan que se han encontrado evidencias pictóricas del uso de este tipo de herramientas en el antiguo Egipto, alrededor del 1300 AC, y siendo usados posteriormente por otras civilizaciones, como los sirios, griegos y romanos, llegando a ser usados para trabajar metales. Durante los primeros siglos de esta era, su uso comenzó a expandirse por Europa, existiendo evidencia de su empleo en Inglaterra entre los siglos IV y VII, y en Alemania alrededor del año 1180. Durante la edad media, se popularizó el uso del torno de “resorte”, el cual utilizaba una cuerda atada a un marco, la cual rodeaba la pieza de trabajo y estaba unida a un pedal que el artesano movía para generar el movimiento de forma continua. A finales del siglo XV y principios del siglo XVI, se empleó por primera vez una superficie para la colocación de las herramientas, siendo esta de gran utilidad para obtener una mejor calidad. Estas máquinas continuaron cambiando, buscando mejores medios para realizar el movimiento, como el uso de molinos ubicados a la orilla de ríos, lo que permitió emplear la energía cinética generada por el flujo de agua para producir movimiento rotativo continuo en los tornos. Hasta finales del siglo XVIII, los tornos de resorte fueron los más empleados.

Con la revolución industrial, la necesidad de mejor precisión en las piezas realizadas y de trabajar metales con mayor facilidad se volvió un reto importante. A principios del siglo XIX, Henry Maudslay implementó el uso de rieles para deslizar las herramientas durante el trabajo con metales en torno y así conseguir maquinados de mejor calidad. Su invención fue empleada por él para estandarizar las cuerdas de los tornillos y permitir su producción en masa. Posteriormente, se

comenzó a acoplar este tipo de tornos con motores a vapor para mejorar su eficiencia y capacidad (Summit, 2020).

Con el desarrollo tecnológico, se siguió mejorando la forma de generar movimiento hasta llegar al uso de motores eléctricos. En la década de 1940, surgió la necesidad de piezas de mayor precisión; en 1947, John T. Parsons comenzó a utilizar trayectorias de corte computarizadas y posteriormente desarrolló junto al Instituto Tecnológico de Massachussets (MIT, por sus siglas en inglés) la primera máquina de control numérico (Numerical Control, NC), una fresadora; en 1958, junto a Kearney y Trecker desarrollaron el primer centro de maquinado automatizado. Entre los años 1960 y 2000, se extendió el uso del control numérico a diversas máquinas, y con el desarrollo de los microprocesadores se logró un mayor control, automatización y funcionalidad, creando el control numérico por computadora (CNC). Estos sistemas permiten una mayor precisión, velocidad de trabajo, control y automatización de los procesos de maquinado, así como el trabajo con distintos ejes para generar piezas de mayor complejidad y calidad a partir del uso de una serie de instrucciones denominadas código G (UNISON, 2019).

En cuanto a las herramientas de corte, hace aproximadamente 2.6 millones de años, el *homo habilis* comenzó a utilizar herramientas hechas de piedra para cortar carne y fabricar herramientas más avanzadas, marcando el inicio del uso de herramientas con esta finalidad, partiendo del principio de que la herramienta debía tener una dureza y resistencia mayor a la del material a cortar. Posteriormente, la Edad de Bronce marcó otro punto importante con el tratamiento del cobre para fabricar herramientas afiladas gracias a sus propiedades. Durante esta época se inició la metalurgia y se realizaron las primeras aleaciones de metales, abriendo el campo para la comprensión de la composición estructural de los metales y el desarrollo de nuevos materiales con mejores características. Durante los años siguientes, el hierro tomó gran importancia, aunque su fragilidad era una de sus mayores desventajas. Posteriormente, la creación de aceros impulsó más el desarrollo metalúrgico, ya que estos presentaban mejores características que el

hierro gracias al contenido de carbono, y su aleación con otros elementos permitió la obtención de distintas características para el acero (Seland, 2021).

El desarrollo del torno por parte de Maudslay permitió un gran salto para el trabajo con metales y el uso de herramientas de corte, así como el comienzo de la producción en masa de partes. A fines del siglo XIX, se habían desarrollado las máquinas herramientas más importantes para los procesos de manufactura: torno, fresadora, amoladora y sierra; igualmente, se desarrollaron abrasivos artificiales que permitieron mejorar los procesos de maquinado. El siguiente paso importante fue el surgimiento del control numérico y el control numérico computarizado, los cuales permitieron mejorar la calidad de los maquinados e impulsaron el desarrollo de las herramientas de corte, buscando mejorar sus características, como dureza y resistencia al desgaste. En los últimos años, han surgido nuevos métodos de maquinado, como el uso de corte por láser, plasma y maquinado por descarga eléctrica, así como el desarrollo de procesos de producción por adición de material, como la impresión 3D. Sin embargo, estos métodos no presentan la misma flexibilidad que las otras técnicas de maquinado permiten al momento de trabajar (Coşkun, 2020).

#### 1.1.2 Detección de fallos en herramientas en torno.

Rehorn *et al.* (2004) y Kuntoğlu *et al.* (2020) han realizado revisiones sobre el monitoreo de la condición de las herramientas de corte. En el trabajo de Rehorn *et al.*, los autores presentaron una investigación sobre el monitoreo de la condición de herramientas, generando un estado del arte organizado por el tipo de operación realizada y presentando recomendaciones dentro de este campo. Los investigadores reportan, en el caso del torneado, el uso importante de dinamómetros para medición de fuerzas de corte, seguido de mediciones de corriente, voltaje y la velocidad en el husillo de la máquina. Otra variable ampliamente usada es la emisión acústica, normalmente capturada con el uso de micrófonos; igualmente, la medición de vibraciones y emisiones ultrasónicas, estas variables son utilizadas mayormente para la determinación de los efectos sobre el acabado debido al desgaste. Dentro de las técnicas de procesamiento más

utilizadas, las redes neuronales presentan una mayor preferencia para el tratamiento y clasificación de la información obtenida, el uso de *wavelets* para el análisis también muestra buenos resultados para la detección del quiebre de la herramienta, mientras que el análisis mediante la raíz cuadrática media (*Root-Mean Square*, RMS) de señales acústicas permite una mejor detección de la ruptura en las herramientas. Igual existe una tendencia al uso combinado de sensores para mejorar la confiabilidad de los resultados al compararlos con la medición de un solo sensor. Por su parte, en el trabajo de Kuntoğlu *et al.*(2020), los autores realizaron una revisión de los sistemas de monitoreo indirecto del estado de las herramientas de corte en torneado, así como los métodos de toma de decisiones empleados en los mismos. En este trabajo se menciona el uso de múltiples sensores al mismo tiempo para recabar más información sobre los fenómenos de interés, así como el desgaste en el flanco de la herramienta como falla principal. Entre las variables medidas se encuentran la rugosidad de la superficie, fuerzas de corte, corriente de los motores, vibraciones, temperatura, emisión acústica/sonido y la medición directa del desgaste, mientras los métodos de análisis de la información se centran en el uso de redes neuronales artificiales (ANN, por sus siglas en inglés), sistemas de inferencias difusos, máquinas de soporte vectorial (*Support Vector Machines*, SVM) y la combinación de ellos.

Mikolajczyk *et al.* (2018) y Li *et al.* (2021) han realizado investigaciones basadas en el análisis de imágenes. En el primer caso, los autores presentan un método para la predicción de la vida útil de herramientas en proceso de torneado en dos etapas: la recolección de datos sobre tres filos de corte de la herramienta a través de métodos tradicionales (uso de cámara de video) y un software basado en ANN para reconocimiento de desgaste de cara, y la predicción de la vida útil gracias a un modelo de ANN. En este trabajo, los autores reportan resultados que cumplen con estándares industriales, aunque se obtiene un error mayor con el uso de sus sistemas en comparación de la medición directa. En el segundo caso, los investigadores proponen una metodología automatizada para la inspección del desgaste en herramientas mediante el uso de un algoritmo de probabilidad de imagen en escala de grises basado en inferencia Bayesiana que permite una mejor

medición del área desgastada al reconstruir los bordes digitalmente. Los autores reportan un error menor al 5% comparado con medición directa del área de desgaste, superando otras propuestas basadas en imagen, resaltando también que la precisión de la inspección depende de la calidad de las imágenes utilizadas.

Por su parte, Li *et al.* (2020) propusieron un sistema de monitoreo del desgaste en herramientas de corte en el proceso de torneado mediante el uso de un termopar de láminas delgadas. Para la medición del desgaste realizaron 130 mediciones en el flanco del inserto, relacionándolo con tres niveles de desgaste (inicial, intermedio y severo). Estas mediciones fueron relacionadas con las mediciones de la temperatura máxima de corte medida con el termopar, con lo que concluyeron la relación entre estas variables. Sin embargo, la colocación del sensor y la necesidad de preparar los insertos para montar el termopar hace complicada su utilización. Otro trabajo es el de Neslušán *et al.* (2015), quienes desarrollaron un método para la detección y predicción de fallas catastróficas en insertos cerámicos en torneado de acero 100Cr6 a través del análisis de señales acústicas con el uso de varios micrófonos con rangos de frecuencia distintos. Los autores lograron resultados favorables que permiten la detección y predicción de daños catastróficos para las herramientas mencionadas, sin embargo, la metodología planteada presenta poca sensibilidad a distintos niveles de desgaste.

Como se mencionó en los trabajos de Rehorn *et al.* (2004) y Kuntoğlu *et al.* (2020), la tendencia en el campo de detección de fallas en herramientas es el uso de múltiples sensores para obtener una mayor cantidad de información útil. En este sentido, Salgado y Alonso (2007) presentaron un sistema de monitoreo del desgaste de herramientas en línea para el torneado de acero AISI 1040 a partir del análisis de señales de corriente del motor de avance de la herramienta y sonido. Dicho sistema emplea SVM's para analizar los datos de corriente y estimar la fuerza de corte, así como análisis de espectro singular (*Singular Spectrum Analysis, SSA*) para obtener información del desgaste con las señales de sonido. Los autores concluyeron que este sistema demostraba las posibilidades del uso de las señales y técnicas presentadas para el correcto análisis del desgaste con un costo aceptable,

pese a que las estimaciones de fuerzas de corte presentaban, en algunos casos, errores de hasta 27%, siendo la fuerza de corte de avance la única señal útil para análisis.

Igualmente, Kuntoğlu y Sağlam (2019) realizaron una investigación considerando el desgaste progresivo en herramientas durante el proceso de torneado con el fin de determinar los parámetros más adecuados para el torneado de acero AISI 1050. En este estudio se analizaron señales acústicas, fuerza de corte y desgaste de flanco mediante el análisis de la varianza (*Analysis of Variance*, ANOVA) para estimar el impacto de los parámetros de maquinado (velocidad de corte, velocidad de avance y la punta de la herramienta) en las variables analizadas. Los autores concluyeron con la obtención de parámetros óptimos para este tipo de maquinados, al igual que la detección del quiebre de la herramienta durante el proceso. De igual forma, los mismos autores, Kuntoğlu y Sağlam (2020) realizaron una investigación experimental empleando cinco sensores (fuerza de corte, vibraciones, emisión acústica, temperatura y corriente) durante el maquinado de acero AISI 5140 para detectar el desgaste progresivo en el flanco de las herramientas, así como su fractura. Los investigadores reportan buenos resultados, alrededor de 74% de efectividad, para el uso de señales de temperatura y emisión acústica para detectar el desgaste. De igual manera, mediante el empleo de lógica difusa se generó un sistema de predicción del desgaste con una precisión cercana al 99%. Los autores concluyeron con los buenos resultados del sistema desarrollado, la importancia del uso de múltiples sensores para contar con una mayor cantidad de información y señalaron la complejidad que ello implica, tanto en procesamiento como económicamente.

Por su parte, Kene y Choudhury (2019) emplearon señales de fuerza, vibraciones y rugosidad superficial para desarrollar un sistema en línea para determinar la salud del inserto durante un proceso de torneado CNC de acero endurecido EN24 mediante la fusión de los datos de los sensores mediante una función matemática considerando los parámetros del maquinado. Reportan un error

cercano al 8% y consideran que el empleo de múltiples sensores brinda mejores resultados y concluyen que a futuro podrían implementarse más variables físicas.

### 1.1.3 Metodologías y técnicas para la identificación del desgaste en herramientas de corte en otros procesos.

Igualmente, además del torno, en el trabajo presentado por Rehorn, se enfocaron también en operaciones de fresado y taladrado. Para las operaciones de fresado, las señales analizadas corresponden principalmente a la potencia o corriente del husillo, vibraciones, emisión acústica y fuerzas de corte. En cuanto a los sensores empleados, acelerómetros, sensores de corriente, dinamómetros y micrófonos son los más empleados para la recolección de información, la cuál es analizada principalmente mediante métodos de tiempo y tiempo-frecuencia (como el uso de *wavelets*, Fourier, etc.), redes neuronales y lógica difusa, así como métodos estadísticos. Por su parte, durante el taladrado las señales más empleadas son aquellas de torque, fuerza de corte y vibración, medidas con la ayuda de dinamómetros, acelerómetros y sensores de velocidad de corte. Para el análisis utilizaron principalmente el análisis en el dominio del tiempo y tiempo-frecuencia, así como métodos estadísticos.

En el caso del fresado, se revisaron los trabajos de Pai y Rao (2002), Susanto y Chen (2003), Jun *et al.* (2001) y Fu *et al.* (2001). Pai y Rao (2002) presentaron un sistema de monitoreo con el uso de emisión acústica en fresado frontal de acero En-8 usando insertos de carburo. Los investigadores realizaron experimentos con uno, dos y tres insertos, para los cuales analizaron el voltaje RMS medido y un indicador para contar el número de veces que la señal cruzaba un umbral preestablecido por ellos. Estas técnicas dieron resultados favorables para uno y dos insertos, siendo el valor RMS un buen indicador del desgaste de flanco en las herramientas, mientras el contador presenta una buena correlación con el desgaste progresivo. Sin embargo, los resultados más claros fueron obtenidos solamente para uno y dos insertos, ya que al incrementar el número el análisis presentaba dificultades. Por su parte, Chen y Susanto (2003) desarrollaron un sistema para monitoreo del desgaste durante el proceso de fresado frontal basado

en lógica difusa. Para el análisis consideraron la fuerza durante el corte y los parámetros de la operación (avance y profundidad de corte) de 25 experimentos. Los autores concluyeron que su sistema tenía un 91.3% de precisión para la detección del desgaste, reconociendo también que su proceso de maquinado no estaba optimizado y recomendando la adición de más factores para mejorar la precisión del sistema y su capacidad de detección. Igualmente, Jun *et al.* (2001) presentaron el uso de un sensor de fuerza tipo anillo para el husillo durante operaciones de fresado y analizan sus resultados contra los obtenidos con el uso de un dinamómetro para monitoreo y detección de fallos durante el maquinado. Los resultados del estudio mostraron una respuesta similar para este tipo de sensores respecto a los dinamómetros, teniendo una diferencia entre 2.3% y 4,7% entre las predicciones y los valores experimentales; sin embargo, también mencionan el impacto de la temperatura durante el maquinado sobre el sensor, lo cual requiere uso constante de refrigerante para mantener un rango adecuado para su empleo. Finalmente, Fu *et al.* (2001) presentaron un sistema para monitoreo basado en un algoritmo de reconocimiento de patrones basado en redes neuronales impulsadas por lógica difusa, en el cual se emplean señales de distintos sensores (corriente, fuerza, emisión acústica y vibraciones) dentro de un proceso de fresado. El sistema inteligente presentado mostró una buena capacidad para clasificar el desgaste según las señales medidas (superior al 80%), con lo que los autores consideran que el sistema es capaz de utilizarse bajo distintas condiciones de maquinado y presentar resultados precisos.

Sobre el proceso de taladrado, Singhal *et al.* (2020) implementaron un sistema de monitoreo de la condición de las herramientas de corte con el uso de modelos estadísticos SARIMA (*Seasonal AutoRegressive Integrated Moving Average*, Media móvil integrada autorregresiva estacional) y ETS (*Error Trend and Seasonality, or exponential smoothing*; Tendencia de error y estacionalidad, o suavizado exponencial). Para ello emplearon microcontroladores y acelerómetros de código abierto, y consideraron el tiempo para las operaciones, el trabajo pico, la aceleración tangencial y la vibración de aceleración. Los resultados reportaron muestran un mejor resultado utilizando el modelo SARIMA para predecir las

variables mencionadas y su relación con el desgaste, sugiriendo el uso de modelos estadísticos en sistemas de monitoreo. Con un enfoque distinto, Li *et al.* (2000) presentaron un sistema de monitoreo del quiebre y la condición del desgaste de las herramientas en el proceso de taladrado a partir de la medición de corriente en los motores del husillo y del avance, para esto utilizaron la transformada *wavelet* y lógica difusa para extraer y clasificar la información correspondiente a las operaciones para monitorear las herramientas de forma inteligente. Los autores concluyen que el sistema desarrollado detecta el quiebre con 95% de precisión y clasifica el desgaste con 15% de error, por lo que da resultados positivos. Por otro lado, Atli *et al.* (2006) propusieron un sistema de monitoreo del estado de las herramientas basado en visión por computadora, para ello utilizan una cámara de alta velocidad y se extraen las características necesarias con un detector de borde para ser analizadas mediante una métrica de desviación de la linealidad de la información obtenida. Los autores reportan resultados favorables para la detección del desgaste de las pruebas realizadas, sin embargo, mencionan que debe considerarse la forma de las herramientas y realizar modificaciones para la utilización de distintos tipos de herramientas, los cuales no fueron analizados.

#### 1.1.4 Detección de fallas en cadenas cinemáticas mediante la medición de flujo magnético.

El flujo magnético de dispersión es la parte del flujo magnético al interior de las máquinas de inducción que logra escapar del cuerpo de la máquina, y el cual ha sido investigado como variable que permita obtener información sobre el estado de la máquina. Pese a ser utilizado principalmente para la detección de fallas eléctricas al interior de los motores eléctricos, también se ha utilizado para estudiar fallas relacionadas con la parte mecánica de la máquina y la cadena cinemática de la que son parte. Jiang *et al.* (2017) realizaron una revisión de los trabajos acerca de la monitorización del estado de los motores de inducción basada en el flujo, haciendo una comparación con la detección mediante corriente del estator para distintas fallas, las cuales reportan ser relacionadas con rodamientos (40% de casos), estator (38%), rotor (10%) y otras causas (10%). Dentro de la discusión que realizaron, se muestra la eficacia de la medición del flujo para la detección de las distintas fallas, esto

mediante el uso de distintos tipos de sensores y diversas técnicas de procesamiento. Los autores concluyeron que es un método con grandes ventajas como el ser no invasivo, tener mejor sensibilidad, robustez y confiabilidad que el análisis de corriente, al igual que proporciona una mayor cantidad de información. Sin embargo, consideraron ciertos inconvenientes al medir esta variable, como puede ser la colocación del sensor para la medición y las variaciones para la medición en motores distintos.

Salem *et al.* (2017) realizaron un estudio experimental para detectar excentricidades en máquinas de inducción mediante el análisis del espectro frecuencial de señales de corriente y flujo magnético. Los investigadores reportaron la poca efectividad del análisis de corriente debido a los efectos que la carga que mueve el motor tiene en las señales de corriente, produciendo efectos similares por lo que es difícil de detectar; igualmente, mencionaron la efectividad del uso de flujo, principalmente la componente transversal, para la detección de esta falla, así como las ventajas que presenta (no invasivo, bajo costo, no requiere conocimiento previo de las características de la máquina, etc.). Por otro lado, Fatemi *et al.* (2008) realizaron un análisis experimental para la influencia del uso de una caja de engranes en las señales de flujo de un par de motores trifásicos. Los resultados obtenidos corresponden, en la mayoría de los casos, con las componentes frecuenciales esperadas para las vibraciones generadas por la caja de engranes, las cuales influyen la corriente del estator y no son fácilmente detectadas al analizar dicha variable. Por otro lado, los investigadores mencionaron que algunas frecuencias asociadas a las frecuencias de entrada y salida del sistema no son detectables según el tipo de máquina (jaula de ardilla y bobinado), al igual que la necesidad de mayor análisis y uso de técnicas de procesamiento más avanzadas para reducir el ruido de las señales. De forma similar, Frosini *et al.* (2015) realizaron una detección de fallos en rodamientos en máquinas de inducción a partir del análisis de flujo con el uso métodos estadísticos. Para esto se utilizó un sensor comercial y uno propietario, con el cual se midieron las señales del motor para un análisis de componentes armónicas que, según los autores, puede ser aplicado en condiciones industriales debido a su precisión. Los autores reportaron resultados

favorables para detectar diversas fallas en los baleros, resaltando los beneficios del uso de esta variable, al igual que mencionando la necesidad de una medición del estado sano de la máquina para resultados confiables. Finalmente, Zamudio *et al.* (2020) desarrollaron un sistema automático para detección de fallas electromecánicas (desalineamiento y barras rotas) mediante el análisis de flujo utilizando técnicas como MUSIC (*MUltiple Signal Classification*, clasificación de múltiples señales), redes neuronales y distintos parámetros estadísticos y no estadísticos. Los investigadores reportaron la correcta identificación de los fallos con el sistema desarrollado y confirman el potencial del uso del flujo para detectar fallos en máquinas eléctricas.

#### 1.1.5 Métodos estadísticos en la detección de fallos en herramientas de corte en procesos de maquinado.

Los indicadores estadísticos permiten la obtención de información de señales y su caracterización para identificar los fenómenos de interés. En subsecciones anteriores se mencionó la utilización de algunos indicadores y métodos estadísticos identificar fallas en herramientas y máquinas eléctricas. Igualmente, los trabajos de Rehorn y Kuntoğlu mencionaron el uso de diversas técnicas de procesamiento, entre ellas los estadísticos, que son usados más ampliamente en el monitoreo dentro del fresado y taladrado, así como para analizar señales de emisión acústica.

Otros trabajos que muestran la utilización de los métodos estadísticos son los presentados por Wang *et al.* (2016), Liu *et al.* (2019) y Wang y Grosu (2017). Wang *et al.* (2016) desarrollaron un método de monitoreo del desgaste durante el proceso de fresado a partir de señales de fuerza y vibración mediante el uso de la transformada wavelet, el uso de indicadores estadísticos (RMS y curtosis) y el empleo de análisis de la componente principal (PCA) y análisis multiescala de la componente principal (MSPCA). Los autores realizaron distintas pruebas para el entrenamiento y validación del sistema, reportaron resultados favorables en ambos casos, siendo la MSPCA la técnica más eficaz para la detección (99.1% contra 93.8%). Por su parte, Liu *et al.* (2019) desarrollaron un sistema para monitoreo y

predicción del desgaste en herramientas de fresado al analizar señales de emisión acústica. Para esto, los investigadores hicieron uso de *wavelets* e índices estadísticos (RMS, promedio, desviación estándar, máximo, curtosis y *skewness*) para extraer características de las señales, las cuales posteriormente pasaban por un modelo de regresión y una red neuronal para su clasificación y predicción. Los autores mostraron resultados favorables con el proceso desarrollado, los cuales presentan un error entre 7.2 y 8.59%, bajo las condiciones específicas del maquinado, siendo posible su posterior expansión a otros procesos. Igualmente, Wang y Grosu (2017) presentaron un sistema de predicción del desgaste en fresado a partir de señales de emisión acústica, vibración y corriente, de las cuales se obtienen 8 parámetros estadísticos (promedio, RMS, varianza, máximo, factor de cresta, curtosis, relación pico a promedio y *skewness*), los cuales son procesados utilizando el coeficiente de correlación de Pearson y posteriormente parte de la información es introducida a una red de eco-estados, la cual después del entrenamiento permitió obtener una predicción del nivel de desgaste capaz de ser utilizada para procesos de mantenimiento preventivo.

#### 1.1.6 Investigación sobre desgaste de herramientas dentro de la Universidad Autónoma de Querétaro.

Dentro de la Universidad Autónoma de Querétaro (UAQ) se han desarrollado algunos trabajos relacionados con la detección del desgaste en herramientas de corte. Como ejemplo de ello, Romero (2004) presentó un algoritmo de procesamiento de señales para detectar la ruptura de herramientas en el proceso de fresado con maquinaria CNC, al igual que una propuesta de sistema de monitoreo de la condición de las herramientas. Adicionalmente, parte de sus resultados se presentaron en los siguientes trabajos: de Jesus *et al.* (2003) donde emplearon señales de corriente para obtener información sobre la fuerza de corte, logrando detectar la ruptura de la herramienta con el uso de *wavelets* y un modelo de autocorrelación; de Jesus *et al.* (2004) donde implementaron el sistema desarrollado en FPGA (del inglés *Field-Programmable Gate Array*, matriz de puertas lógicas programable en campo) para generar un sistema de detección de ruptura de las herramientas en línea a partir de las técnicas mencionadas.

Por otro lado, el trabajo de Trejo (2010) se enfoca en el monitoreo, análisis y modelado del desgaste de las herramientas de corte en torno CNC. En este trabajo, se emplearon señales de corriente y vibración, considerando el efecto de parámetros del proceso, como el avance y la profundidad de corte, para implementar el sistema como un sensor inteligente desarrollado en FPGA. Dentro de este trabajo, se consideró el variar la profundidad de corte y el avance de la herramienta, independientemente, mientras los demás parámetros permanecían constantes para un maquinado cónico. Los resultados reportados muestran una estimación del desgaste con un error relativo menor al 4% comparado con el análisis de una sola variable.

De forma similar, Sevilla (2012) desarrolló un sistema para la detección de fallas en herramientas de corte en fresado CNC de alta velocidad, basado en el análisis de señales de vibración utilizando un filtro digital pasa-banda reprogramable y la Transformada Wavelet Continua (CWT), implementado en FPGA para operar en línea. El sistema desarrollado consideraba el uso de tres herramientas en el cortador y consiguió detectar las fallas de las herramientas, haciendo distinción entre el uso de herramientas sanas, el uso de un inserto con desgaste parcial, el uso de un inserto con desgaste severo y la falta de un inserto como simulación de falla crítica, esto mediante la comparación de la información obtenida de las señales de vibraciones contra un valor de referencia. Complementariamente, en el artículo de Sevilla *et al.* (2010) se desarrolla una metodología similar, usando el valor RMS de la corriente de uno de los servomotores de la fresadora CNC, tomando un valor de referencia para la corriente cuando los dos cortadores empleados se encuentran en buenas condiciones para aplicar el método de asimetría entre la referencia y las señales obtenidas para la posterior detección de la fractura de alguno de los insertos.

Mota (2019) desarrolló un sistema inteligente basado en ANN y Mapas Autoorganizados para monitorear fallas en herramientas utilizadas en fresado CNC. Para ello, se emplearon las señales de corriente de los servo-controladores de la máquina para determinar las fuerzas de corte; posteriormente se hizo uso de la Transformada Wavelet Discreta (DWT) para obtener información que sirviera para el

entrenamiento de las redes y mapas empleados, teniendo resultados favorables para la clasificación de desgastes mayores a 0.25mm.

Finalmente, Díaz (2021) realizó un análisis de flujo magnético de dispersión para evaluar el estado de desgaste de las herramientas de corte en un torno CNC empleando análisis en el dominio tiempo-frecuencia y considerando la variación de la profundidad de corte. Los resultados reportados muestran la capacidad de la metodología al relacionar el flujo magnético disperso con el desgaste de las herramientas y la variación de la profundidad de corte, generando una nueva línea de análisis para el estudio del desgaste en herramientas.

Con base en los antecedentes presentados, es posible señalar el uso de sensores, principalmente invasivos, para la toma de señales que permiten detectar el nivel de desgaste en las herramientas (corriente eléctrica, vibraciones emisión acústica, etc.), así como la preferencia de sistemas inteligentes (Redes Neuronales, Aprendizaje Profundo, etc.) para clasificar y detectar fallas en las herramientas. Igualmente, es apreciable el uso del flujo magnético disperso para detectar fallas en motores de inducción, donde se han tenido resultados favorables y comparables a otras variables, como corriente eléctrica y vibraciones. Con esto en mente, se pretende emplear el flujo magnético, en fusión con señales de corriente, para analizar la relación existente entre dichas variables y el nivel de desgaste en herramientas de corte; para esto, se utilizarán parámetros estadísticos y no estadísticos como herramienta de análisis de la información obtenida, buscando obtener resultados favorables que permitan la detección y monitoreo del nivel de desgaste en herramientas de corte.

## 1.2 Objetivos e hipótesis.

### 1.2.1 Objetivo general.

Detectar y evaluar el desgaste gradual en herramientas de corte de un torno CNC mediante el procesamiento de las señales de flujo magnético de dispersión en el motor del husillo y corriente, así como la utilización de herramientas estadísticas y no estadísticas y Redes Neuronales, ante la variación individual de los parámetros de maquinado: velocidad de corte y avance de la herramienta.

### 1.2.2 Objetivos específicos.

- Fabricar las muestras del desgaste en la herramienta del torno CNC en base a la gradualidad reportada en otros trabajos para realizar una comparativa directa.
- Determinar los parámetros de maquinado que se utilizarán para las pruebas de detección del desgaste gradual en las muestras en función de lo que recomienda la literatura (velocidad de corte y avance de la herramienta), para realizar una comparativa de los parámetros variables con la detección del desgaste gradual.
- Realizar las adecuaciones al sistema propietario de adquisición de flujo mediante su instalación y puesta a punto en el motor del husillo de un torno CNC con control marca Fanuc, para la obtención de los datos.
- Realizar el procesamiento de los datos de flujo obtenidos de la matriz de prueba, mediante el filtrado y procesamiento de estos para detectar los fallos utilizando el lenguaje de programación C.
- Encontrar correlación entre la cuantificación del desgaste y los parámetros del maquinado mediante los índices estadísticos más adecuados y la reducción de la dimensionalidad de los datos mediante Análisis Discriminante Lineal (LDA) para proyectar la incidencia entre ellos.
- Realizar una comparativa para demostrar, mediante los resultados y trabajos reportados del desgaste gradual, que el método propuesto tiene un comportamiento de detección y evaluación adecuados para diferentes condiciones de maquinado.

### 1.2.3 Hipótesis.

Mediante la fusión de las señales del flujo magnético de dispersión del motor de inducción y la corriente de una máquina CNC y aplicando procesamiento de señales y herramientas estadísticas y no estadísticas, se puede detectar y evaluar el desgaste gradual de las herramientas de corte, además de encontrar

correlaciones con los parámetros del maquinado (velocidad de corte y avance de la herramienta).

### 1.3 Justificación.

Esta investigación se enfoca en el estudio del flujo magnético de dispersión y la corriente consumida para la detección y evaluación del desgaste en herramientas de corte de un torno CNC, mediante el análisis con parámetros estadísticos y no estadísticos de la información obtenida, así como LDA y Redes Neuronales. La detección oportuna del desgaste en las herramientas es de gran importancia en la industria manufacturera, ya que el mal estado de éstas afecta directamente a las piezas producidas, obteniendo acabados irregulares y dimensiones incorrectas, lo cual afecta directamente a los costos de producción y el tiempo de paro de producción.

Para la obtención de las señales se emplearán sensores no invasivos colocados en el motor del husillo de la máquina herramienta, esto con la finalidad de no afectar al proceso de maquinado ni el espacio de trabajo.

Las pruebas que se realizarán considerando dos parámetros importantes, la velocidad de corte y el avance de la herramienta, manteniendo cada uno de los parámetros constantes mientras el otro varía. Esto con la finalidad de observar los efectos que estos parámetros tienen sobre las señales obtenidas y sobre el desgaste de las herramientas, buscando relacionarlos a través del uso de indicadores estadísticos y no estadísticos que proporcionen información del desgaste gradual que presenten las herramientas.

### 1.4 Descripción del problema.

Un sector muy importante para el crecimiento económico de los países en desarrollo es la industria manufacturera, la cual cumple las condiciones para ser descrita como un motor de desarrollo económico al lograr un alto crecimiento sostenido (Haraguchi *et al.*, 2017). En esta industria, el estado de las herramientas empleadas en los diferentes procesos de maquinado es fundamental para la correcta producción de las piezas debido a que tiene efectos directos sobre la

calidad de los insumos producidos, así como un impacto económico considerable ya que aproximadamente el 25% del costo de los maquinados se destina a las herramientas y sus fallas son responsables de cerca del 20% del tiempo de paro durante la producción (Ghosh *et al.*, 2018).

En los sistemas para la detección y monitoreo del desgaste en herramientas de corte se han utilizados diferentes variables físicas (como corriente, emisiones acústicas, fuerza, vibraciones, entre otras), de forma individual y en conjunto, con la finalidad de conocer el estado de la herramienta, algunas de estas emplean sensores que requieren una colocación invasiva para el proceso de maquinado o condiciones muy controladas ya que su eficiencia puede ser diezmada por aspectos del mismo proceso, como al utilizar fluidos de corte y sistemas de visión artificial.

Si bien, cada vez es más frecuente el estudio y desarrollo de sistemas de monitoreo que permitan evaluar o predecir el nivel de desgaste debido al impacto que tiene sobre los insumos fabricados y los costos de producción, una gran parte de las investigaciones se centra en detectar y predecir la falla catastrófica de la herramienta, mas no el diagnóstico del desgaste gradual de las herramientas. Igualmente, las tendencias dentro de este campo de investigación buscan la optimización de la vida útil de la herramienta mediante la selección de parámetros óptimos sin enfocarse al efecto individual de los parámetros sobre el desgaste ni buscando que los métodos desarrollados sean insensibles a los cambios en los parámetros. Así mismo, se han realizado pocos estudios que relacionan los parámetros de maquinado con el nivel de desgaste que presentan las herramientas de corte analizando señales de flujo magnético.

De igual manera, pese a que la utilización de parámetros estadísticos para el análisis e identificación de fallas en herramientas de corte es frecuente en procesos de maquinado como el fresado y taladrado, donde proporcionan información útil que permite la correcta detección de fallas, su uso es menor en el proceso de torneado, siendo favorecidos los sistemas que analizan la información

obtenida por los sensores mediante Análisis de Tiempo-Frecuencia y sistemas inteligentes como Redes Neuronales y Lógica difusa.

## 2 Revisión de la literatura.

Con el propósito de desarrollar una metodología que permita estudiar los fenómenos del desgaste en herramientas de corte, las variables de maquinado dentro de los procesos de torneado y fresado, el flujo magnético de dispersión, y herramientas de análisis de señales, como la Transformada de Fourier, la Transformada Wavelet y los parámetros estadísticos y no estadísticos, se realizó una revisión del conocimiento teórico relacionado con estas temáticas para el diseño y futura implementación de una metodología adecuada para la realización del presente proyecto.

### 2.1 Desgaste en herramientas de corte.

Las herramientas de corte son sometidas a distintos esfuerzos al ser usadas: distintos esfuerzos en la punta, temperaturas elevadas y desplazamiento de viruta sobre la cara de ataque y rozamiento al desplazarse a lo largo de la superficie de la pieza de trabajo. Estos esfuerzos provocan el desgaste de la herramienta, afectando su vida útil y la calidad de las piezas maquinadas al modificar los acabados superficiales y la precisión dimensional (Kalpakjian, 2008).

En la década de 1890, F.W. Taylor condujo un estudio sobre el maquinado de aceros, a partir del cual estableció la relación de parámetros mostrada en la ecuación 2.1 (Kalpakjian, 2008):

$$VT^n = C \quad 2.1$$

Donde  $V$  es la velocidad de corte,  $T$  es el tiempo necesario para generar una profundidad específica de desgaste en el flanco de la herramienta,  $n$  es un exponente dado por el material de la herramienta, el material trabajado y las condiciones del proceso; y  $C$  es una constante dependiente del material de la pieza.

Posteriormente, se modificó la ecuación 2.1 para considerar otros parámetros como la profundidad del corte y el avance de la herramienta, obteniendo la ecuación 2.2, mientras la ecuación 2.3 muestra el despeje necesario para calcular el tiempo de vida de la herramienta:

$$VT^n d^x f^y = C \quad 2.2$$

$$T = C^{1/n} V^{-1/n} d^{-x/n} f^{-y/n} \quad 2.3$$

Siendo  $d$  la profundidad de corte,  $f$  es el avance de la herramienta y los exponentes  $x$  y  $y$  son definidos experimentalmente. La ecuación 2.3 establece que un incremento en el avance de la herramienta o la profundidad de corte supone una disminución en la velocidad de corte para conservar la vida útil de la herramienta, y viceversa, así como una variación en el volumen de material removido según los exponentes.

El desgaste se puede clasificar de la siguiente forma, y se ejemplifican en la figura 2.1 (Kalpakjian, 2008):

- Desgaste de flanco: Aparece en la cara de alivio o flanco de la herramienta y es causado por la abrasión y el incremento de temperatura entre la herramienta y la superficie de la pieza.
- Craterización. Ocurre en la cara de ataque de la herramienta, modificando el contacto de la herramienta con la viruta y es ocasionado por la temperatura y la composición química de la herramienta y el material trabajado.
- Desgaste de punta. Corresponde a la pérdida de filo de la herramienta debido a los esfuerzos térmicos y mecánicos del maquinado.
- Muescado. Es la generación de muescas en la región donde la viruta deja de hacer contacto con la herramienta, se genera por el contacto con la capa endurecida del material debido al trabajo realizado, óxido o escoria.
- Deformación plástica de la punta de la herramienta. Ocurre por un incremento considerable de la temperatura durante las operaciones de maquinado.
- Astillado. Corresponde a una fractura del filo de la herramienta, perdiendo parte del material de la misma y modificando su forma.

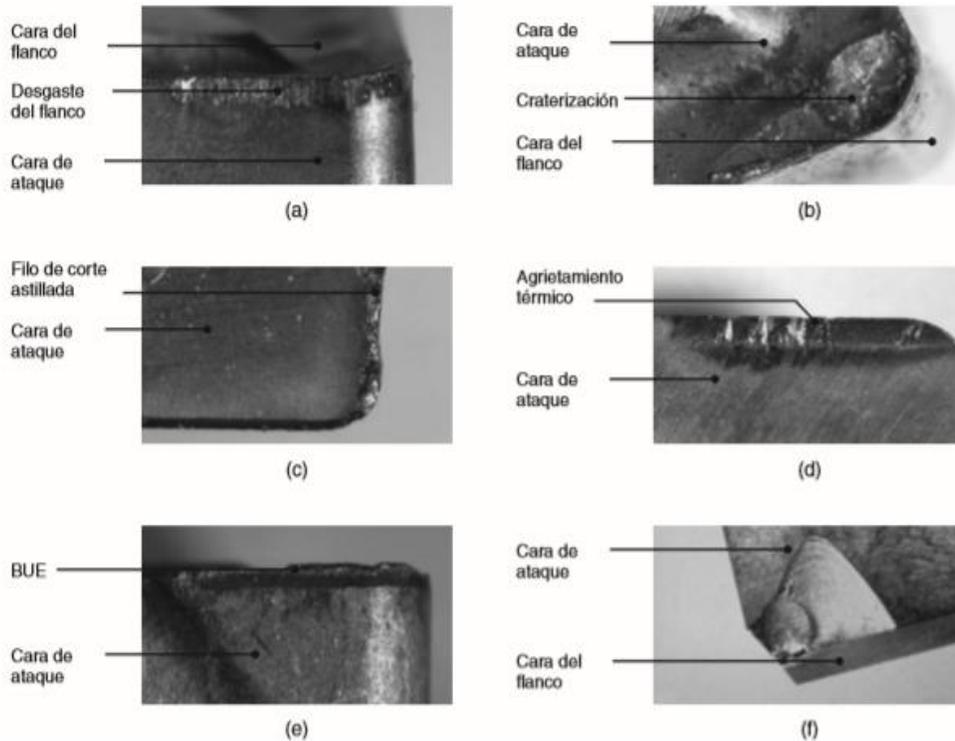


Figura 2.1. Diferentes desgastes en herramientas usadas en torno: (a) desgaste del flanco; (b) craterización; (c) astillado; (d) agrietamiento térmico en la cara de ataque; (e) acumulación de material en el borde (BUE); (f) falla catastrófica (Kalpakjian, 2008).

## 2.2 Variables de maquinado.

Dentro de los procesos de maquinado se consideran distintas variables que permiten el correcto trabajo de los materiales, afectando directamente a la calidad de los maquinados y la vida útil de las herramientas utilizadas. A continuación, se presentan los parámetros que impactan en dos de los procesos de maquinado por arranque de viruta más empleados: el torneado y el fresado.

### 2.2.1 Torneado.

En el proceso de torneado existen diversos parámetros que definen la realización del maquinado (Deingenierias.com, 2020; Kalpakjian, 2008) y se presentan resumidos en la tabla 2.1:

- Velocidad de corte ( $V$ ): Es la velocidad con que la herramienta recorre el material a trabajar, siendo una velocidad lineal, tangencial a la pieza, dependiente de la velocidad del husillo. La ecuación 2.4

es la ecuación para la velocidad de corte en operaciones de cilindrado, siendo  $V$  la velocidad de corte (m/min),  $D_o$  es el diámetro original del material (mm) y  $N$  es la velocidad de rotación del husillo en revoluciones por minuto (rpm).

$$V = \frac{\pi D_o N}{1000} \quad 2.4$$

- Velocidad de avance ( $v$ ): Es la velocidad de desplazamiento de la herramienta por cada revolución de la pieza, medida en mm/min. La ecuación 2.5 muestra cómo calcular este parámetro a partir del avance de la herramienta,  $f$ , y la velocidad angular,  $N$ .

$$v = fN \quad 2.5$$

- Velocidad de rotación de la pieza ( $N$ ): Es la velocidad del husillo de la máquina, a la cual rota la pieza a trabajar, medida en rpm.
- Profundidad de corte ( $d$ ): Es la diferencia entre el diámetro original del material y el diámetro después de una operación de corte.
- Velocidad de remoción de material ( $MRR$ ): Es el volumen del material que la herramienta remueve de la pieza con respecto del tiempo, medido en mm<sup>3</sup>/min. Se puede calcular con la ecuación 2.6, donde  $D_{prom}$  es el diámetro promedio del material removido,  $f$  es el avance,  $d$  es la profundidad de corte y  $V$  es la velocidad de corte:

$$MRR = \pi D_{prom} d f N = d f V \quad 2.6$$

- Tiempo de corte ( $t$ ): Es el tiempo que toma la realización de un cilindrado sin contar el movimiento de colocación y retracción de los cortadores. Se define conforme a la ecuación 2.7, donde  $l$  es la longitud por cortar de la pieza:

$$t = \frac{l}{fN} \quad 2.7$$

- Fuerza de corte: Es la aportación de energía necesaria para la realización del corte, permite conocer el torque sobre el husillo de la máquina al multiplicarse con el radio al centro de la pieza.

- **Potencia de corte:** Es la potencia necesaria para hacer una operación de cilindrado, obtenida al multiplicar el torque y la velocidad del husillo; se mide en kilovatios (kW).

Tabla 2.1. Parámetros y fórmulas utilizadas en operaciones de torneado (Kalpakjian, 2008).

Resumen de parámetros y fórmulas de torneado		
Parámetro	Fórmula (unidades)	Descripción
$N$	(rpm)	Velocidad de giro de la pieza de trabajo
$f$	(mm/rev o in/rev)	Avance
$v$	$v = fN$ (mm/min o in/min)	Velocidad de avance o velocidad lineal de la herramienta a lo largo de la pieza de trabajo
$V$	$V = \pi D_o N$ para velocidad máxima $V = \pi D_{prom} N$ para velocidad promedio (m/min o ft/min)	Velocidad superficial de la pieza de trabajo
$l$	(mm o in)	Longitud de corte
$D_o$	(mm o in)	Diámetro original de la pieza de trabajo
$D_f$	(mm o in)	Diámetro final de la pieza de trabajo
$D_{prom}$	$D_{prom} = \frac{D_o + D_f}{2}$ (mm o in)	Diámetro promedio de la pieza de trabajo
$d$	$D_{prom} = \frac{D_o + D_f}{2}$ (mm o in)	Profundidad de corte
$t$	$t = \frac{l}{fN}$ (s o min)	Tiempo de corte
$MRR$	$MRR = \pi D_{prom} d f N$ (mm <sup>3</sup> /min o in <sup>3</sup> /min)	Velocidad de remoción de material
<b>Torque</b>	$T = \frac{F_c D_{prom}}{2}$ ( $F_c$ es la fuerza de corte; N*m o lb*ft)	
<b>Potencia</b>	$P = T \left( \frac{2\pi N rad}{min} \right)$ (kW o hp)	

## 2.2.2 Fresado.

Dentro del proceso de fresado existen diversos parámetros a considerar (Kalpakjian, 2008), los cuales se enlistan a continuación y se resumen en la tabla 2.2:

- Velocidad de corte ( $V$ ): Es la velocidad superficial del cortador, definida por la ecuación 2.8, siendo  $D$  el diámetro del cortador (mm) y  $N$  su velocidad de rotación (rpm):

$$V = \pi DN \quad 2.8$$

- Velocidad de avance ( $v$ ): Es la velocidad a la cual la pieza se desplaza de forma lineal y sus unidades son mm/min.
- Avance por diente del cortador ( $f$ ): Es la distancia que se desplaza el material maquinado por cada diente de la herramienta, definida conforme a la ecuación 2.9, considerando la velocidad de avance, la velocidad de rotación y el número de dientes del cortador ( $n$ ); dada en mm/diente:

$$f = \frac{v}{Nn} \quad 2.9$$

- Tiempo de corte ( $t$ ): se calcula según la ecuación 2.10, siendo  $l$  el largo de la pieza y  $l_c$  la distancia horizontal de la primera interacción del cortador con la pieza.

$$t = \frac{l + l_c}{v} \quad 2.10$$

- Velocidad de remoción de material ( $MRR$ ): Está definida por la ecuación 2.11, donde  $w$  es el ancho del corte y  $d$  es la profundidad del corte:

$$MRR = \frac{lwd}{t} = wdv \quad 2.11$$

Tabla 2.2. Parámetros y fórmulas empleadas en fresado periférico (Kalpakjian, 2008).

Resumen de parámetros y fórmulas de torneado		
Parámetro	Fórmula (unidades)	Descripción
$N$	(rpm)	Velocidad rotacional del cortador de fresado
$F$	(mm/diente o in/diente)	Avance
$D$	(mm o in)	Diámetro del cortador
$n$		Número de dientes del cortador
$v$	(mm/min o in/min)	Velocidad lineal de la pieza de trabajo o velocidad de avance
$V$	$V = DN$ (m/min o ft/min)	Velocidad superficial del cortador
$f$	$f = \frac{v}{Nn}$ (mm/diente o in/diente)	Avance por diente
$l$	(mm o in)	Longitud de corte
$t$	$t = \frac{l+l_c}{v}$ ( $l_c$ es la medida del primer contacto del cortador con la pieza de trabajo; s o min)	Tiempo de corte
$MRR$	$MRR = wdv$ ( $w$ es el ancho de corte; mm <sup>3</sup> /min o in <sup>3</sup> /min)	Velocidad de remoción de material
<b>Torque</b>	$T = \frac{F_c D}{2}$ ( $F_c$ es la fuerza de corte; N*m o lb*ft)	
<b>Potencia</b>	$P = T \left( \frac{2\pi N \text{rad}}{\text{min}} \right)$ (kW o hp)	

### 2.3 Flujo magnético de dispersión.

En el último siglo, los motores eléctricos se han vuelto elementos esenciales en el entorno industrial, por lo cual su mantenimiento y la detección temprana de fallas son tareas de gran importancia, por lo que durante décadas se han desarrollado diversas técnicas de análisis, basadas principalmente en el estudio de señales de corriente y vibraciones de la máquina por su relación con las condiciones eléctricas y mecánicas del motor. Durante la década de 1970, Penman desarrolló técnicas de análisis basadas en el estudio del campo magnético generado al exterior de la máquina eléctrica; estas técnicas presentaban las ventajas de ser simples de implementar y no ser invasivas para el motor, con la principal desventaja de la complejidad para el modelado de dicho campo debido al blindaje generado por el yugo del estator y la carcasa de la máquina.

### 2.3.1 Identificación de fallos en máquinas de inducción.

La identificación de fallos en motores eléctricos con análisis del flujo magnético disperso está basada en la propiedad de que la aparición de cualquier falla se ve reflejada en el campo magnético al exterior de la máquina, y debido a la dificultad para modelar e interpretar dicho campo, su aplicación se centra en el análisis de ciertas propiedades cualitativas, como la búsqueda de componentes frecuenciales específicas (Romary *et al.*, 2013).

Diversos estudios han logrado definir ecuaciones que permiten identificar frecuencias que guardan relación con diversas fallas que ocurren en el rotor y el estator del motor, al igual que fallos mecánicos (Capolino *et al.*, 2019). Para el estudio del flujo disperso se consideran las direcciones axial y radial del flujo, como se observa en la figura 2.2, la cual se muestra las posiciones más comunes para la colocación de sensores tipo bobina: la Pos.2 facilita la captura de la componente axial, la Pos.3 de la componente radial y la Pos.1 de la componente radial y una parte de la axial (Romary *et al.*, 2013).

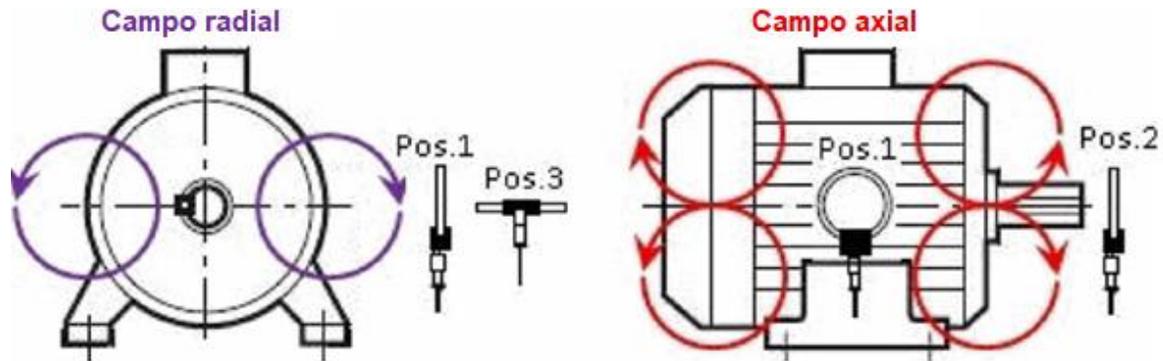


Figura 2.2. Componentes del flujo de dispersión y colocaciones de sensores tipo bobina (Romary *et al.*, 2013).

### 2.4 Transformada de Fourier.

Durante el siglo XIX, Joseph Fourier logró demostrar la representación de funciones periódicas como la suma de infinitas funciones exponenciales complejas periódicas, creando así la Transformada de Fourier (Fourier Transform, FT). Con el paso del tiempo, se crearon variaciones de la FT para análisis más específicos, como señales no periódicas y discretizadas.

La FT realiza una descomposición compleja de una señal en funciones sinusoidales complejas que componen la señal original, permitiendo conocer las frecuencias que la componen, siguiendo la definición de la ecuación 2.12, mientras la ecuación 2.13 es la Transformada inversa de Fourier. En ambas ecuaciones  $t$  corresponde al tiempo,  $f$  a la frecuencia,  $x$  a la señal representada en el dominio del tiempo y  $X$  a la señal representada en el dominio de la frecuencia.

$$X(f) = \int_{-\infty}^{+\infty} x(t) * e^{-2\pi jft} dt \quad 2.12$$

$$x(t) = \int_{-\infty}^{+\infty} X(f) * e^{2\pi jft} df \quad 2.13$$

La transformada entrega información correspondiente a todos los instantes de tiempo, por lo que muestra las componentes frecuenciales presentes a lo largo de toda la señal analizada. Debido a esto no se considera adecuada para analizar señales en las que las frecuencias que la componen varían con el tiempo, si se busca conocer el instante de tiempo en que se presentan dichas frecuencias (Polikar, 1996).

Para solucionar este inconveniente, se formularon la Transformada Rápida de Fourier (FFT) y la Transformada Discreta de Fourier (DFT). Ésta última transforma una señal discretizada en el dominio del tiempo en una señal discreta en el dominio de la frecuencia, y se define conforme a la ecuación 2.14, donde  $k=0, \dots, N-1$  y  $e^{-j2\pi kn/N}$  es una raíz de 1.

$$X_k = \sum_{n=0}^{N-1} x_n e^{-j2\pi kn/N} \quad 2.14$$

De forma similar, se creó la Transformada de Fourier de Tiempo Corto (STFT) como alternativa para una mejor representación tiempo-frecuencia, analizando una señal cambiante en el tiempo utilizando ventanas de pequeña en el tiempo de forma que la señal dentro de la ventana pueda ser considerada estacionaria para la aplicación de la FT. La ecuación 2.15 muestra la formulación de la STFT, donde  $x(t)$  es la señal en tiempo,  $w(t)$  es la función de la ventana a

utilizar, el \* indica el conjugado complejo y  $t'$  es el centro de la ventana (Polikar, 1996).

$$STFT_x^{(\omega)}(t', f) = \int_t [x(t) * \omega^*(t - t')] * e^{-j2\pi ft} dt \quad 2.15$$

## 2.5 Transformada Wavelet.

Durante la década de 1970, J. Morlet descubrió un inconveniente de la STFT: la transformada realiza el análisis de componentes de alta frecuencia implementando ventanas pequeñas o componentes de baja frecuencia implementando ventanas grandes, sin embargo, no era posible realizar ambas tareas de forma simultánea. Con esto en mente, Morlet empleó funciones de ventana diferentes para analizar distintas bandas frecuenciales, dichas ventanas se generaban al dilatar o comprimir una función Gaussiana y las llamó ondículas u ondoletas (*wavelets*) de forma constante. En años posteriores, varios matemáticos diseñaron o redescubrieron distintas *wavelets* para analizar señales en tiempo-frecuencia, lo que sentó las bases de la Transformada Wavelet Continua (Continuous Wavelet Transform, CWT).

Años después, Ingrid Daubechies generó las técnicas para discretizar el tiempo y los parámetros de escala utilizados en la CWT; igualmente, Stephane Mallat creó Algoritmo de Mallat, también conocido como Análisis Multi-Resolución (MRA, por sus siglas en inglés), que permite el análisis de una señal con diferentes frecuencias utilizando resoluciones distintas. Ambos son acreditados por la transición de la CWT a la Transformada Wavelet Discreta (DWT). La figura 2.3 ilustra la manera en que se distribuye el plano tiempo-frecuencia con el uso de la DWT: con una mayor resolución en tiempo (ventanas más cortas en tiempo) se tiene una menor resolución en frecuencia (ventanas más amplias en frecuencia) y con una menor resolución temporal (ventanas más amplias en tiempo) se tiene una mejor resolución frecuencial (ventanas más cortas en frecuencia, siempre manteniendo un área igual en el plano tiempo-frecuencia (Polikar, 1996).

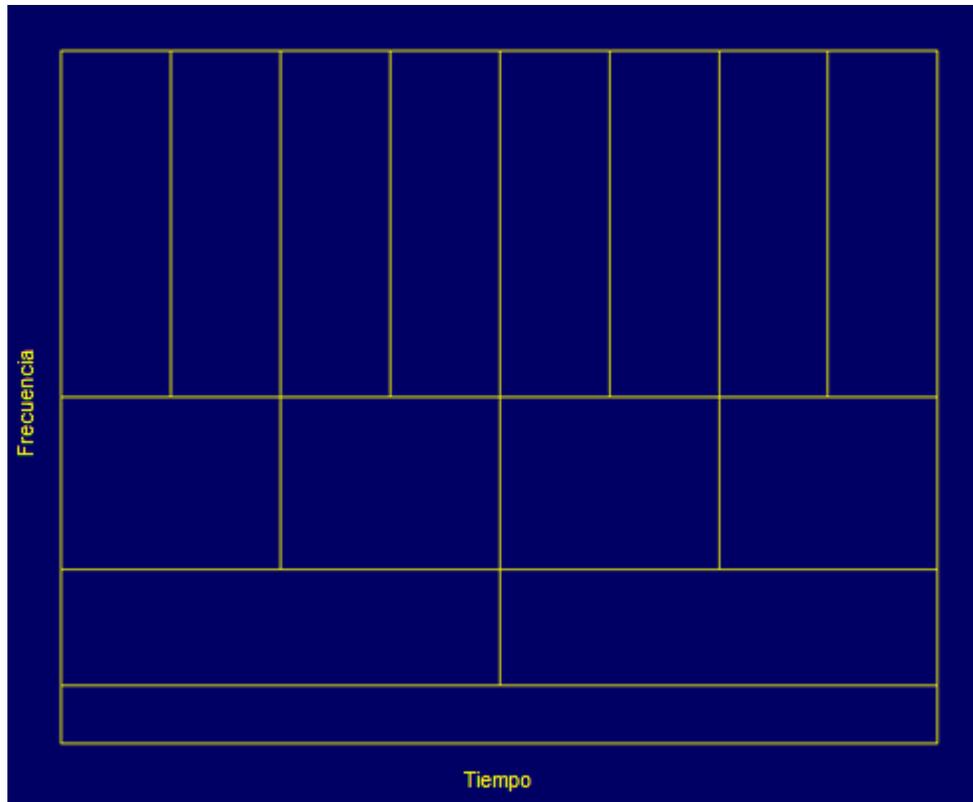


Figura 2.3. Distribución del plano tiempo-frecuencia al utilizar la DWT (Polikar, 1996).

La ecuación 2.16 es la formulación de la CWT, la cual depende de dos variables: la traslación,  $\tau$ , y la escala,  $s$ ; igualmente,  $\Psi$  corresponde a la función *wavelet* utilizada para la generación de las ventanas.

$$CWT_x^\Psi(\tau, s) = \Psi_x^\Psi(\tau, s) = \frac{1}{\sqrt{|s|}} \int x(t) \psi^* \left( \frac{t - \tau}{s} \right) dt \quad 2.16$$

La aplicación de DWT emplea la codificación sub-banda y el MRA, realizando una filtración sucesiva de la señal con filtros paso-alto y paso-bajo con frecuencia de corte diferente para la descomposición de las señales en diversas bandas frecuenciales. Con esto, la resolución de la señal se modifica durante el filtrado, reduciéndose a la mitad de su resolución en tiempo y duplicando su resolución en frecuencia al reducirse el ancho de banda con cada filtrado. Igualmente, la escala de la señal, definida como el inverso de la frecuencia, se modifica debido al sobremuestreo y submuestreo durante la implementación del algoritmo. Las ecuaciones 2.17 y 2.18 muestran el nivel de descomposición realizado por el filtrado de la señal original,  $x[n]$ , con filtros de media banda paso-

alto  $g[n]$  y paso-bajo  $h[n]$ , siendo  $y_{high}$  la salida del filtro pasa-altas y  $y_{low}$  la salida del filtro pasa-bajas después del submuestreo con un factor de dos, y  $n$  y  $k$  son enteros.

$$y_{high}[k] = \sum_n x[n] * g[2k - n] \quad 2.17$$

$$y_{low}[k] = \sum_n x[n] * h[2k - n] \quad 2.18$$

En la figura 2.4 se ilustra el algoritmo de codificación sub-banda, mostrando el filtrado sucesivo y la obtención de los coeficientes de la descomposición realizada por la DWT.

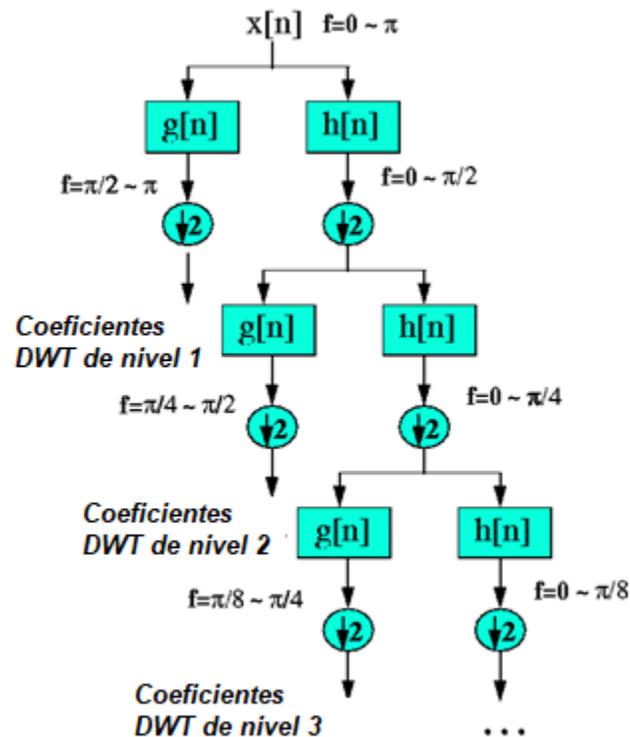


Figura 2.4. Ilustración del algoritmo de codificación sub-banda o algoritmo de Mallat (Polikar, 1996).

## 2.6 Parámetros estadísticos y no estadísticos.

### 2.6.1 Estadísticos.

Un parámetro estadístico es una cantidad que abstrae la información que se deriva del análisis de una característica, o variable estadística, la cual puede adoptar distintos valores. El cálculo de esta magnitud está definido aritméticamente

a partir de la información obtenida de una población. Estos parámetros sirven para permitir generar un modelado de la información en nuestro entorno (Ross, 2007; Moreno-Gil, 1998).

Los parámetros se pueden agrupar según su forma de analizar los datos de interés, como se muestra a continuación:

- Medidas de posición: Son indicadores basados en la ubicación de los datos en el conjunto de valores posibles. Se subdividen en:
  - Medidas de tendencia central: Algunos ejemplos son la media, la mediana, la moda, la media cuadrática, entre otros.
  - Medidas de tendencia no central: El principal ejemplo son los cuantiles (cuartiles, deciles, percentiles).
- Medidas de dispersión: Indican la dispersión en el conjunto de los datos. Se subdividen en:
  - Medidas absolutas: Se expresan en la misma unidad de los datos, siendo las principales la desviación media, la desviación estándar y la varianza.
  - Medidas relativas: Muestran la separación de los datos como un porcentaje, como el coeficiente de variación y de apertura.
- Medidas de forma: Proporcionan información sobre la distribución gráfica de los datos. Los principales son:
  - Asimetría (*skewness* en inglés): Indica el nivel de simetría o asimetría de la distribución probabilística de una característica.
  - Curtosis: Es un indicador de la altura de la curva relacionando la distribución de las frecuencias y probabilidades de una variable.
- Medidas de propósito específico: Son indicadores utilizados para analizar características o relaciones específicas del conjunto de datos. Algunos de estos parámetros se utilizan para medir relaciones entre características de la señal, relaciones en la forma, etc.

La tabla 2.3 enlista algunos de los parámetros más utilizados para monitorear y diagnosticar fallas en cadenas cinemáticas conectadas a máquinas de inducción, descritos en las ecuaciones 2.19 a 2.33 (Prieto *et al.*, 2013).

Tabla 2.3. Parámetros estadísticos (Saucedo, 2017).

Parámetro	Ecuación	
<b>Media</b>	$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$	2.19
<b>Valor máximo</b>	$\hat{x} = \max(x)$	2.20
<b>Root Mean Square</b>	$x_{RMS} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i)^2}$	2.21
<b>Square Root Mean</b>	$x_{SRM} = \left( \frac{1}{n} \sum_{i=1}^n \sqrt{ x_i } \right)^2$	2.22
<b>Desviación estándar</b>	$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$	2.23
<b>Varianza</b>	$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$	2.24
<b>Factor de forma (RMS)</b>	$SF_{RMS} = \frac{x_{RMS}}{\frac{1}{n} \sum_{i=1}^n  x_i }$	2.25
<b>Factor de forma (SRM)</b>	$SF_{SRM} = \frac{x_{SRM}}{\frac{1}{n} \sum_{i=1}^n  x_i }$	2.26
<b>Factor de cresta</b>	$CF = \frac{\hat{x}}{x_{RMS}}$	2.27
<b>Factor de latitud</b>	$LF = \frac{\hat{x}}{x_{SRM}}$	2.28
<b>Factor de impulso</b>	$IF = \frac{\hat{x}}{\frac{1}{n} \sum_{i=1}^n  x_i }$	2.29
<b>Skewness</b>	$S_k = \frac{E[(x - \mu)^3]}{\sigma^3}$	2.30
<b>Curtosis</b>	$k = \frac{E[(x - \mu)^4]}{\sigma^4}$	2.31
<b>5° momento</b>	$5thM = \frac{E[(x - \mu)^5]}{\sigma^5}$	2.32
<b>6° momento</b>	$6thM = \frac{E[(x - \mu)^6]}{\sigma^6}$	2.33

### 2.6.2 No estadísticos.

De forma similar, existen indicadores basados en características no estadísticas que son utilizados para obtener información que describa el comportamiento de señales dadas las características que estas presenten, algunos de ellos son empleados en el presente trabajo y se enlistan a continuación.

- Dimensión fractal.

Un fractal es una forma geométrica que puede ser subdividida en partes de tal forma que cada una de ellas sea una copia aproximada, en tamaño reducido, de la totalidad de la forma. En la geometría fractal, la dimensión fractal es una cantidad estadística que indica qué tanto un fractal parece llenar un espacio al aproximarse a escalas cada vez más pequeñas (Deng, 2016). Adicionalmente, es utilizado como una medida de la autosimilitud o aparición de patrones repetidos presentes en una señal de tiempo (Amezquita-Sanchez *et al.*, 2017). Existen varios algoritmos para el cálculo de la dimensión fractal, que va de 1.0 para líneas rectas a 2.0 para un plano, siendo los índices de Katz y Higuchi los seleccionados para el análisis en este trabajo.

- Dimensión fractal de Katz:

Katz presenta el siguiente algoritmo para el cálculo de la distancia fractal,  $KFD$ , con los siguientes pasos (Katz, 1988):

1. Encontrar la máxima distancia Euclidiana entre la primera muestra,  $x_1$ , y la muestra  $x_k$  (donde  $k = 1, \dots, N$ ,  $N$  es el número de puntos o muestras en la señal). Esto da la máxima distancia,  $d$ .
2. Calcular  $L$ , la suma aritmética de las distancias Euclidianas entre muestras consecutivas de la señal  $x$ , como lo ilustra la ecuación 2.34. Obtener el promedio de  $L$ ,  $a$ , como lo muestra la ecuación 2.35.

$$L = \sum_{k=2}^N \text{dist}(x_k - x_{k-1}) \quad 2.34$$

$$a = \frac{L}{N-1} \quad 2.35$$

3. Calcular *KFD* como lo muestra la ecuación 2.36.

$$KFD = \frac{\log(L/a)}{\log(d/a)} \quad 2.36$$

o Dimensión fractal de Higuchi:

El algoritmo para la estimación de la distancia fractal de Higuchi, *HFD*, se compone de los siguientes pasos (Higuchi, 1988):

1. Descomponer la señal original,  $x$ , con  $N$  muestras, en nuevas señales o secuencias en el dominio del tiempo,  $x_k^m$ , como se muestra en la ecuación 2.37, donde  $m$  y  $k$  son enteros que corresponden al tiempo inicial y el intervalo de tiempo, respectivamente, y el término entre corchetes denota el redondeo a la parte integral del valor calculado.

$$x_k^m = x_m, x_{m+k}, x_{m+2k}, \dots, x_{m+\left[\frac{N-m}{k}\right]k} \quad (m = 1, 2, \dots, k) \quad 2.37$$

2. Calcular la longitud normalizada promedio,  $L_m$ , para cada secuencia de  $x_k^m$ , como se presenta en la ecuación 2.38, teniendo al término  $\left[\frac{N-m}{k}\right]$  como factor de normalización de cada secuencia.

$$L_m(k) = \frac{(N-1)}{k \left[\frac{N-m}{k}\right]} \sum_i^{\left[\frac{N-m}{k}\right]} |x_{m+ik} - x_{m+(i-1)k}| \quad 2.38$$

3. Calcular la longitud total,  $L(k)$ , mediante el promedio del largo de todas las secuencias,  $L_m(k)$ , para un valor dado de  $k$ , como en la ecuación 2.39.

$$L(k) = \sum_{m=1}^k L_m(k) \quad 2.39$$

4. Modificar  $k = k+1$ . Si  $k < k_{max}$ , repetir los pasos 1 a 3. El valor  $k_{max}$  es seleccionado para que sea el número para el que la pendiente de la mejor línea ajustada al diagrama trazado en el plano ( $\ln[L(k)]$  contra  $\ln[1/k]$ ) permanece constante. La pendiente obtenida de esta línea,  $L$ , representa el valor de fractalidad,  $HFD$ , de la señal analizada.

- Energía DWT.

El parámetro de energía DWT,  $\gamma_{DWT}$ , es un indicador normalizado, definido como la relación inversa entre la energía de la señal *wavelet* seleccionada y la energía de la señal original en una ventana de tiempo. Este indicador da un resultado en decibeles, teniendo a mayor valor obtenido, menor nivel de energía en la *wavelet*.

La ecuación 2.40 presenta la expresión para su cálculo, siendo  $emf_j$  el valor de la  $j$ -ésima muestra de la señal original,  $emf_j$ ;  $d_i(j)$  es el punto  $j$  de la señal *wavelet* seleccionada;  $N_s$  es la muestra que marca el fin del intervalo y  $N_b$  es la muestra que inicia el intervalo de interés (Antonino-Daviu *et al.*, 2017).

$$\gamma_{DWT}(dB) = 10 * \log \left[ \frac{\sum_{j=N_b}^{N_s} emf_j^2}{\sum_{j=N_b}^{N_s} [d_i(j)]^2} \right] \quad 2.40$$

- Entropía *wavelet*.

La entropía *wavelet* es una medida del grado de orden/desorden de una señal, entregando información útil sobre los procesos dinámicos asociados con la señal (Rizal *et al.*, 2017). La entropía *wavelet*,  $S_{WT}$ , está dada por la ecuación 2.41.

$$S_{WT} \equiv S_{WT}(p) = - \sum_{j=m}^n \ln (p_j) \quad 2.41$$

Donde  $m$  y  $n$  son el primer y último nivel de descomposición, respectivamente, y  $p_j$  representa la energía *wavelet* normalizada, como se muestra en la ecuación 2.42.

$$p_i = \frac{E_i}{E_{tot}} \quad 2.42$$

Donde  $E_i$  y  $E_{tot}$  son la energía de los niveles de descomposición *wavelet*,  $i$ , y la energía total de todos los niveles de descomposición, respectivamente, como se define en las ecuaciones 2.43 y 2.44.

$$E_i = \sum_k |C_i(k)|^2 \quad 2.43$$

$$E_{tot} = \sum_i E_i \quad 2.44$$

## 2.7 Análisis Discriminante Lineal (LDA).

El Análisis Discriminante Lineal es una técnica de reducción de la dimensionalidad supervisada, es decir, en la que se conocen la información referente a las clases involucradas. El objetivo de los métodos de reducción de la dimensionalidad es encontrar combinaciones de distintas variables que permita satisfacer ciertos criterios de separación de datos para su agrupación y clasificación, siendo la LDA una técnica basada en la búsqueda de combinaciones lineales entre las variables del análisis, separando las diferentes clases lo más posible al maximizar la matriz de dispersión entre clases y condensando cada clase lo más posible al minimizar la matriz de dispersión dentro de las clases (Ding, 2016).

Para la aplicación de esta técnica, se requiere el cálculo de las matrices de dispersión entre clases ( $S_b$ ) y dentro de las clases ( $S_w$ ), las cuales se calculan como se muestra en las ecuaciones 2.45 y 2.46, donde la dimensión  $k$  del subespacio está definida como  $k=C-1$ , siendo  $C$  el número de clases,  $m_k$  es la media de la clase  $C_k$ ,  $m$  es la media global y  $n_k$  es el número de muestras,  $x_i$  es la  $i$ -ésima muestra de la clase  $C_k$ .

$$S_b = \sum_k n_k (m_k - m)(m_k - m)^T \quad 2.45$$

$$S_w = \sum_k \sum_{i \in C_k} (x_i - m_k)(x_i - m_k)^T \quad 2.46$$

El subespacio óptimo,  $G_{LDA}$ , se obtiene mediante la ecuación 2.47, donde la solución está dada por los  $k$  eigenvectores de  $S_w^{-1}S_b$  asociados con los eigenvalores más altos.

$$G_{LDA} = \max Tr \frac{G^T S_b G}{G^T S_w G} = (g_1, \dots, g_k) \quad 2.47$$

Finalmente, la información transformada al nuevo espacio se obtiene con la ecuación 2.48, siendo esta la proyección del grupo original de datos,  $X$ , en el subespacio resultante.

$$Y = G^T X \quad 2.48$$

## 2.8 Validación cruzada.

La validación cruzada es una metodología estadística para la evaluación y comparación de algoritmos de aprendizaje y clasificación mediante la división de los datos en dos conjuntos, uno para el entrenamiento del algoritmo y uno para su validación. En este método, los grupos de entrenamiento y validación deben cruzarse de forma sucesiva de forma que todos los datos tienen la oportunidad de ser validados. Es una técnica ampliamente aceptada como procedimiento estándar para la estimación del desempeño de un algoritmo/modelo particular o para la selección de un modelo dentro de un conjunto de alternativas, así como para la selección de parámetros adecuados dentro de un modelo específico.

La forma básica de este método es conocida como validación cruzada de  $k$ -iteraciones, en la cual la información es dividida en  $k$  partes de similar dimensión (idealmente de la misma dimensión). Posteriormente, se realizan  $k$  iteraciones de entrenamiento y validación de forma que en cada una se utilice un conjunto de datos distinto para la validación del algoritmo mientras los  $k-1$  conjuntos restantes son

utilizados para el entrenamiento. La figura 2.5 ilustra el procedimiento para la implementación de una validación cruzada con  $k = 3$  iteraciones.

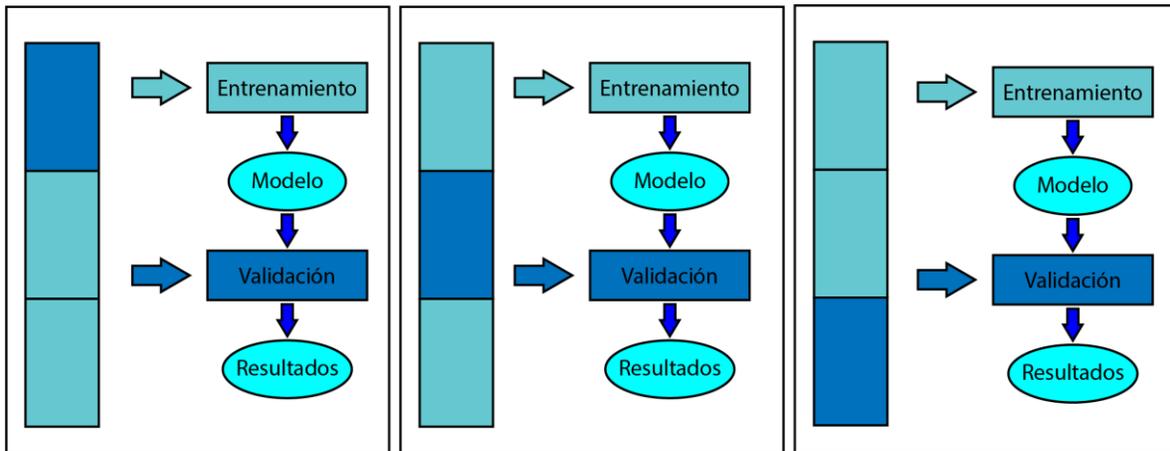


Figura 2.5. Ilustración del proceso de validación cruzada con  $k=3$ .

Dentro de este tipo de análisis, el uso de diez iteraciones es ampliamente aceptado como una buena alternativa ya que emplea el 90% de los datos disponibles para el entrenamiento de los modelos, permitiendo una mejor generalización de los fenómenos a estudiar; sin embargo, no hay una cantidad específica de iteraciones que aseguren un mejor análisis (Refaeilzadeh *et al.*, 2016).

### 3 Metodología.

La figura 3.1 muestra un diagrama que ilustra la metodología seguida durante el desarrollo de este trabajo. El diagrama consta de tres bloques principales:

1. Configuración experimental: En este bloque se engloba, como su nombre lo sugiere, la parte experimental. Se consideró la variación de dos parámetros de maquinado de forma independiente, la velocidad de corte y el avance de la herramienta, con lo cual se realizaron dos conjuntos de pruebas. En cada prueba se empleó un conjunto de tres herramientas de corte (o insertos), las cuales presentaban distinto nivel de desgaste. Finalmente, se diseñó una matriz de pruebas para la variación de cada parámetro, considerando cinco variaciones de cada parámetro para evaluar su efecto en la detección del desgaste.
2. Sistema de Adquisición de Datos: El segundo bloque consta de los elementos utilizado para la captura y almacenamiento de la información, para esto se utilizó un sistema propietario de detección de flujo triaxial y un sensor de corriente comercial, posteriormente, las señales son adquiridas y almacenadas con el uso de un microprocesador comercial.
3. Procesamiento de la información: El último bloque consiste en el procesamiento y análisis de la información obtenida de las pruebas experimentales, el cual se realizó inicialmente con software comercial (Matlab) y posteriormente se recreó con código en C con el desarrollo de un software propio. Para ello, se realizó un filtrado digital de las señales para eliminación de ruido, seguido de un análisis frecuencial empleando FFT y DWT; posteriormente, se calcularon diversos parámetros estadísticos y no estadísticos para caracterizar los datos. Una vez realizado esto, se utilizó el LDA para reducir la dimensionalidad de los datos y posteriormente entrenar

redes neuronales para la detección y clasificación del desgaste para cada uno de los parámetros analizados.

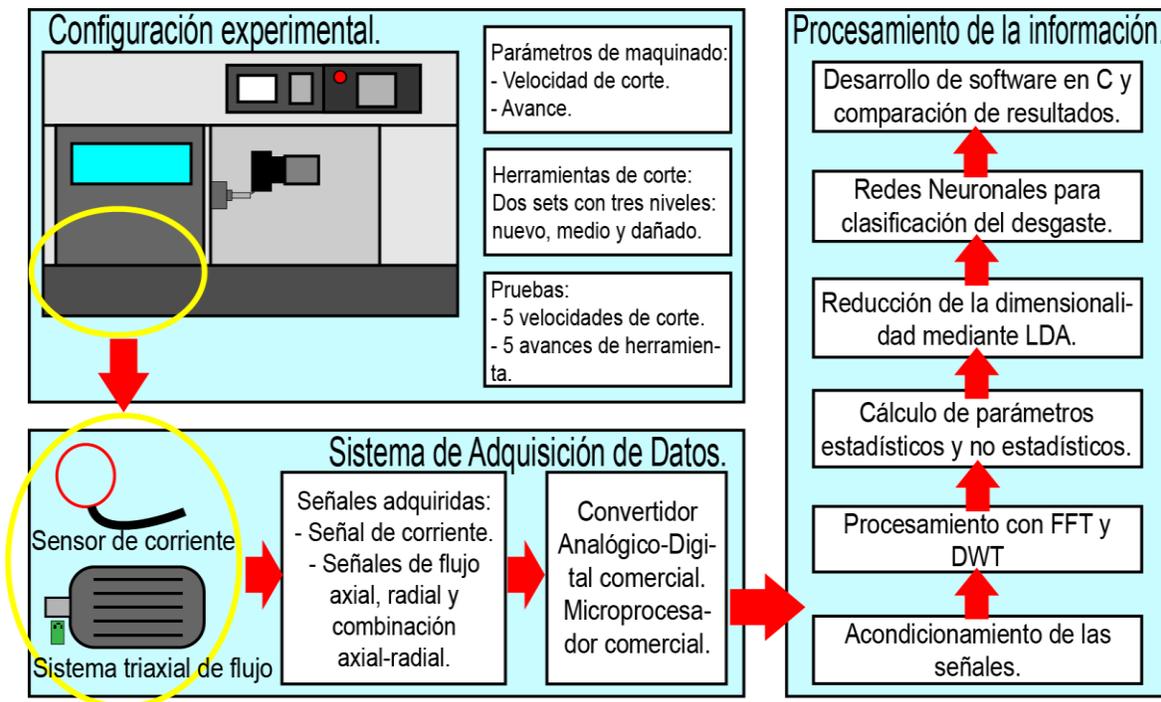


Figura 3.1. Diagrama de la metodología propuesta.

### 3.1 Configuración experimental.

Dentro de la configuración experimental se consideraron tres bloques principales: los parámetros de maquinado en los que se enfocaría el análisis, las herramientas de corte a utilizar y el diseño de las pruebas a realizar.

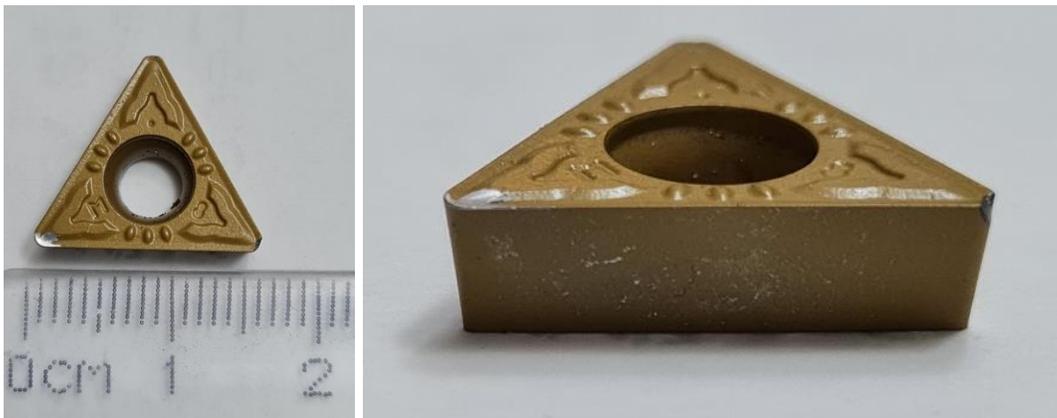
#### 3.1.1 Parámetros de maquinado.

Para el desarrollo de la investigación se seleccionaron dos parámetros de maquinado de gran importancia: la velocidad de corte y el avance de la herramienta. Esto con la finalidad de ver los efectos que su variación, de forma independiente, tiene sobre las señales obtenidas, debido a que afectan directamente la vida útil de las herramientas de corte. Igualmente, se busca que los modelos generados sean capaces de identificar el desgaste presente en las herramientas ante la variación de dichos parámetros, haciendo el sistema insensible a ellos.

### 3.1.2 Herramientas de corte.

Con el fin de realizar la experimentación propuesta, se consideraron dos grupos de herramientas, uno por parámetro de maquinado, los cuales cuentan con tres niveles de desgaste: herramienta nueva, herramienta con desgaste medio y herramienta con desgaste mayor o dañada. Dichos desgastes fueron causados de forma artificial para preparar las herramientas a los requerimientos de la investigación.

Las herramientas de corte utilizadas fueron insertos BOEHLERIT TCMT-16T308-MP LCP-25T, los cuales son de uso general con alta resistencia al desgaste y excelentes características en una amplia gama de aplicaciones (Boehlerit, 2022). La figura 3.2 muestra uno de los insertos utilizados.



*Figura 3.2. Ejemplo de herramienta de corte utilizada en el estudio.*

### 3.1.3 Diseño de las pruebas.

Para la realización de los experimentos, se realizaron dos matrices de prueba, cada una variando uno de los parámetros de interés mientras que el resto de ellos permanecieron constantes. Para cada prueba se realizaron tres cortes o desbastes a lo largo de la pieza, tomando un tiempo de maquinado de 30 segundos por pieza.

En las tablas siguientes, se consideran los parámetros que se enlistan a continuación:

- $a_p$ : profundidad de corte.

- $f$ : avance de la herramienta.
- $V_c$ : velocidad superficial de la pieza de trabajo.
- $N$ : número de revoluciones por minuto.
- $V_f$ : velocidad de avance lineal de la herramienta.

La tabla 3.1 enlista los parámetros empleados para la realización de las pruebas de variación de la velocidad de corte.

Tabla 3.1. Parámetros de maquinado para las pruebas de velocidad de corte.

No.	$a_p$ (mm)	$f$ (mm/rev)	$V_c$ (m/rev)	$N$ (rpm)	$V_f$ (mm/min)
1	1.25	0.16	60	779.53	124.72
2	1.25	0.16	70	909.45	145.51
3	1.25	0.16	80	1039.37	166.30
4	1.25	0.16	90	1169.26	187.08
5	1.25	0.16	100	1299.22	207.87

La tabla 3.2 muestra los parámetros empleados para la realización de las pruebas de variación del avance de la herramienta.

Tabla 3.2. Parámetros de maquinado para las pruebas de avance de la herramienta.

No.	$a_p$ (mm)	$f$ (mm/rev)	$V_c$ (m/rev)	$N$ (rpm)	$V_f$ (mm/min)
1	1.25	0.08	100	1299.22	103.938
2	1.25	0.12	100	1299.22	155.907
3	1.25	0.16	100	1299.22	207.875
4	1.25	0.20	100	1299.22	259.844
5	1.25	0.24	100	1299.22	311.813

La experimentación se realizó en los laboratorios de la Facultad de Ingeniería de la UAQ, campus San Juan, empleando un torno CNC marca DYNAMACH con control Fanuc Oi Mate-TC (cncmanual.com, 2021), mostrado en la figura 3.3. Este torno cuenta con un motor de inducción trifásico Realland Smart Motors, modelo P96AR06D4152704 con 4 polos y potencia nominal de 3.7 KW, el cual es alimentado con un variador de velocidad a 220 Vac.



Figura 3.3. Torno CNC empleado en experimentación.

En la figura 3.4 se observa la colocación de los equipos previo a las pruebas de maquinado y la adquisición de los datos: la PC utilizada para el almacenamiento de las señales, el sistema de adquisición de datos propietario, la ubicación del motor del husillo de la máquina CNC donde se colocaron los sensores de flujo magnético y el área de trabajo del torno CNC.

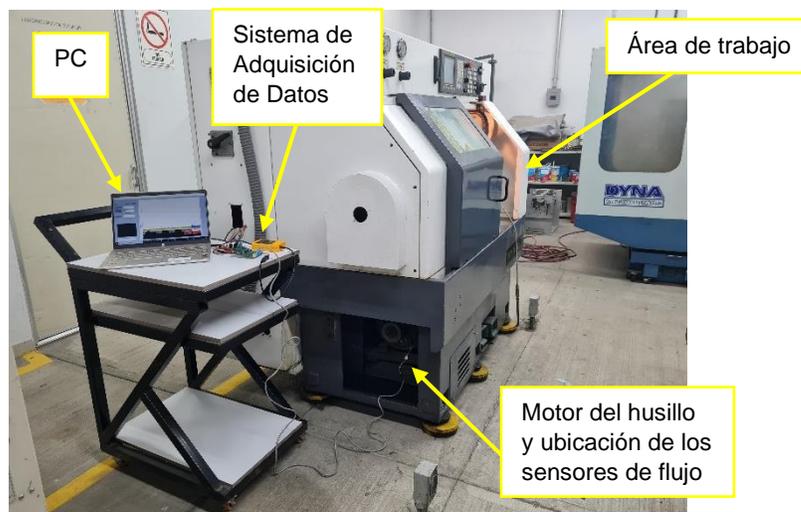


Figura 3.4. Colocación de los equipos para adquisición de datos.

El material utilizado para la experimentación fue barras de 1.5 pulgadas de diámetro de Aluminio 6061. Este material es una aleación de uso general, endurecida por precipitación, con buenas propiedades mecánicas. En la figura 3.5 se muestran algunas barras utilizadas previo al maquinado.



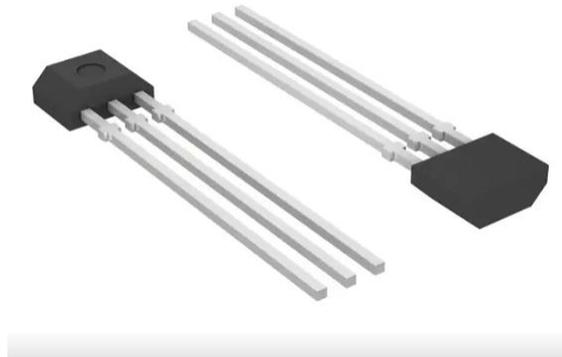
*Figura 3.5. Barras de aluminio 6061 preparadas para las pruebas.*

## 3.2 Sistema de Adquisición de Datos.

Para la adquisición de datos se realizaron mediciones de corriente y flujo magnético disperso en el motor, para esto se utilizaron sensores primarios comerciales implementados en un sistema propietario. Para la obtención de los datos, se utilizó una tarjeta de adquisición comercial.

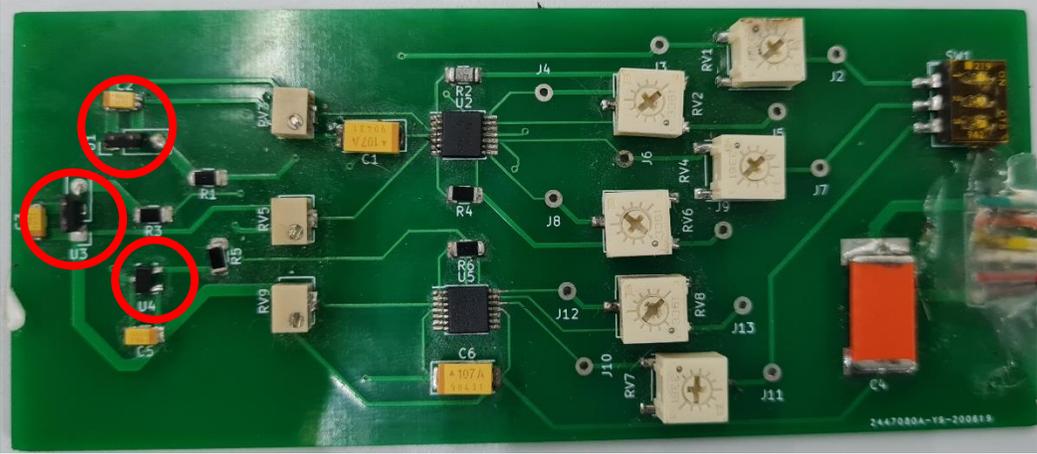
### 3.2.1 Sensores de efecto Hall.

Para medir las señales de flujo magnético se utilizaron sensores primarios de efecto Hall, modelo A1325 de Allegro Microsystems (Allegro Microsystems, 2020), como los mostrados en la figura 3.6.

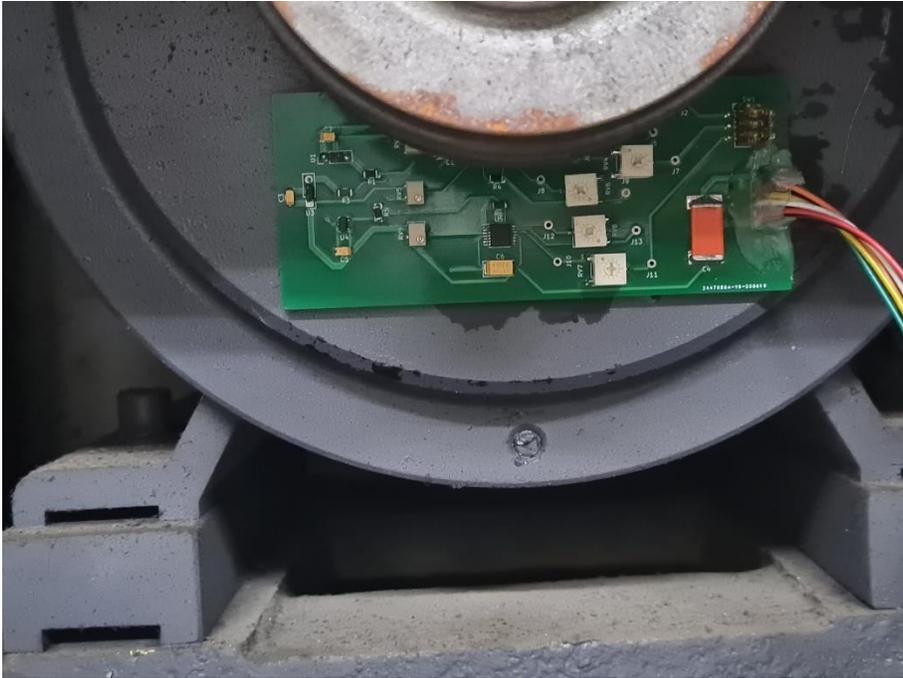


*Figura 3.6. Sensores A1325 empleados (Allegro MicroSystems, 2020).*

Con estos sensores, se diseñó un sistema de captura triaxial que permite capturar las componentes de flujo axial, radial y la combinación de estas, como se muestra en la figura 3.7a (señalados con círculos), donde el sensor de la parte superior captura el flujo combinado, el central la componente radial y el inferior la componente axial. La figura 3.7b muestra la colocación de los sensores en el motor del husillo.



(a)



(b)

Figura 3.7. (a) Sistema de flujo triaxial y (b) colocación de los sensores en el motor del husillo.

### 3.2.2 Sensor de corriente.

Para la medición de las señales de corriente de alimentación del motor del torno, se utilizó una pinza de corriente de CA Fluke, modelo i3000s Flex-24, 610mm (24in) (Fluke, 2022). Esta es una sonda de corriente alterna tipo Rogowski con un rango de frecuencia de 10Hz a 50kHz con rangos de corriente de 30, 300 y 3000A, como la que se muestra en la figura 3.8.



*Figura 3.8. Sensor de corriente utilizado (Fluke, 2022).*

### 3.2.3 Tarjeta de adquisición.

La tarjeta empleada es una tarjeta Texas Instruments MSP-EXP432P401R (Texas Instruments, 2020), mostrada en la figura 3.9. Este equipo fue seleccionado debido a sus capacidades de conversión ya que cuenta con un convertidor analógico digital de 16 bits y capacidad de 1Msps. Para la realización de las pruebas se utilizó una frecuencia de muestreo de 5kHz, obteniendo 150 mil muestras por cada sensor en cada una de las pruebas realizadas.

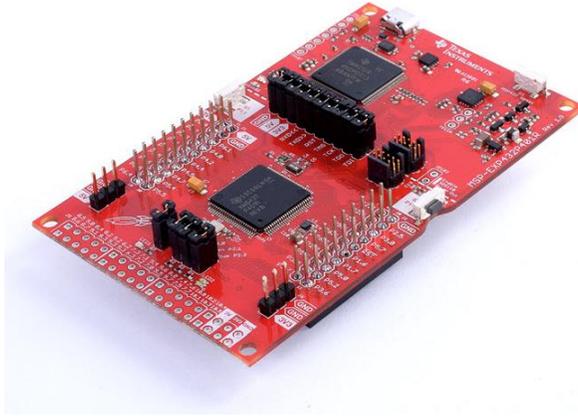


Figura 3.9. Tarjeta MSP-EXP432P401R empleada (Texas Instruments, 2020).

### 3.3 Procesamiento de la información.

El procesamiento de las señales obtenidas para la generación de los sistemas de identificación del desgaste se realizó en dos etapas: la primera de ellas haciendo uso de software comercial, Matlab, debido a sus características y la facilidad para realizar análisis complejos; la segunda etapa fue la recreación del análisis mediante el desarrollo de un software propietario en C que permitiera recrear el análisis con software comercial.

#### 3.3.1 Acondicionamiento de las señales.

Las señales capturadas presentaban ruido, lo cual es indeseable para el análisis, por lo que se realizó un proceso de filtrado digital utilizando un filtro paso-bajo tipo Butterworth de orden 10 con una frecuencia de corte ( $W_n$ ) de 0.1 radianes por segundo. El comportamiento del filtro se muestra en la figura 3.10.

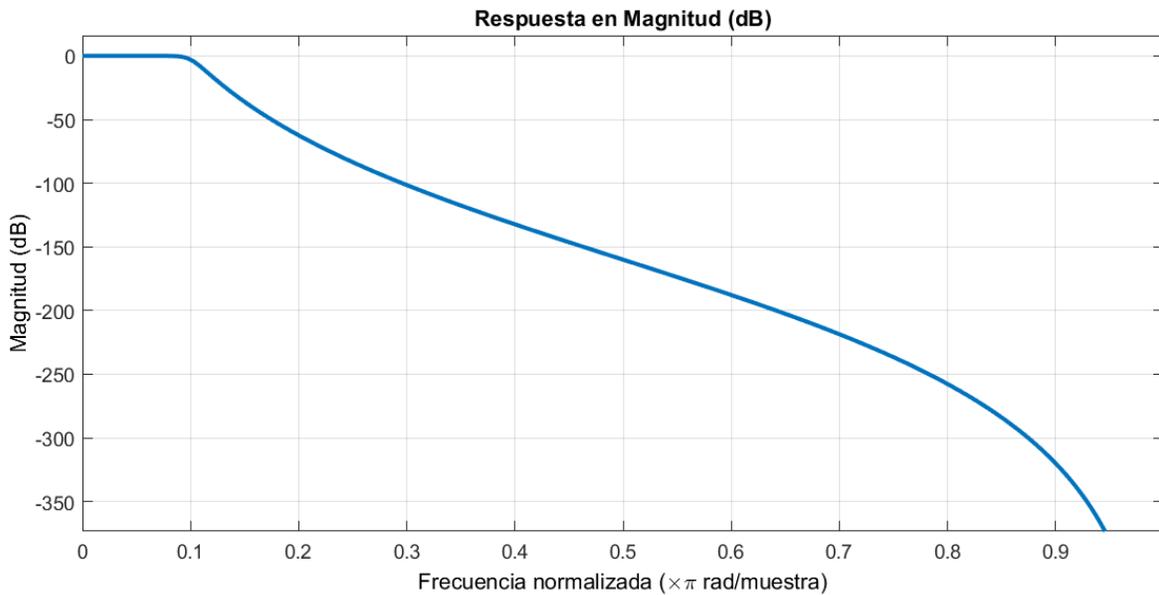


Figura 3.10. Respuesta del filtro Butterworth utilizado.

Posteriormente, se eliminó la componente de corriente continua presente en las señales, la cual fue inducida por el comportamiento de los sensores. Para ello, se restó digitalmente el promedio de la amplitud de cada señal a la misma, obteniendo así señales con media cero, siguiendo lo mostrado en la ecuación 3.1.

$$x_{filtrada} = x - \bar{x} \quad 3.1$$

Realizado este proceso, se identificaron los tres cortes realizados por la herramienta en cada una de las señales para su posterior división en ventanas de 1024 valores.

### 3.3.2 Procesamiento con FFT y DWT.

Una vez acondicionadas las señales, se utilizó la FFT para la obtención de la componente frecuencial fundamental de cada señal debido a que el motor del husillo del torno CNC es alimentado con un variador de frecuencia. Con la componente frecuencial identificada, se seleccionó el nivel de reconstrucción pertinente para el análisis con la DWT.

La implementación de la DWT se realizó descomponiendo la señal en diez niveles, utilizando la *wavelet* madre “Daubechies 44”, la cual se seleccionó ya que en la literatura se ha demostrado que este tipo de filtros de orden superior permiten

extraer información de mejor forma y tienen un comportamiento casi ideal, reduciendo la superposición de bandas consecutivas (Zamudio *et al.*, 2019).

### 3.3.3 Cálculo de parámetros estadísticos y no estadísticos.

Con las señales reconstruidas en las bandas más adecuadas, se calcularon los 15 indicadores estadísticos y los cuatro no estadísticos mencionados en la sección 2.6. Para esto, como se mencionó anteriormente, las señales de los cortes se dividieron en ventanas de 1024 datos, con lo que se obtuvieron 80 ventanas para cada una de las señales adquiridas, calculando los 19 indicadores para cada sensor, obteniendo una matriz de 19 indicadores para las 80 ventanas de cada sensor. Las matrices de cada prueba se concatenaron horizontalmente, resultando en una matriz de 76 indicadores y 80 ventanas por prueba. Debido a que se realizaron cinco variaciones de cada prueba, teniendo tres herramientas distintas por parámetro, se concatenaron verticalmente las matrices de indicadores de cada herramienta utilizada, generando una matriz de 76 indicadores y 400 ventanas por herramienta. Posteriormente, se concatenaron las matrices de los tres insertos empleados por cada parámetro de maquinado, obteniendo una matriz final de 76 indicadores y 1200 ventanas. La figura 3.11 ilustra la obtención de la matriz de indicadores.

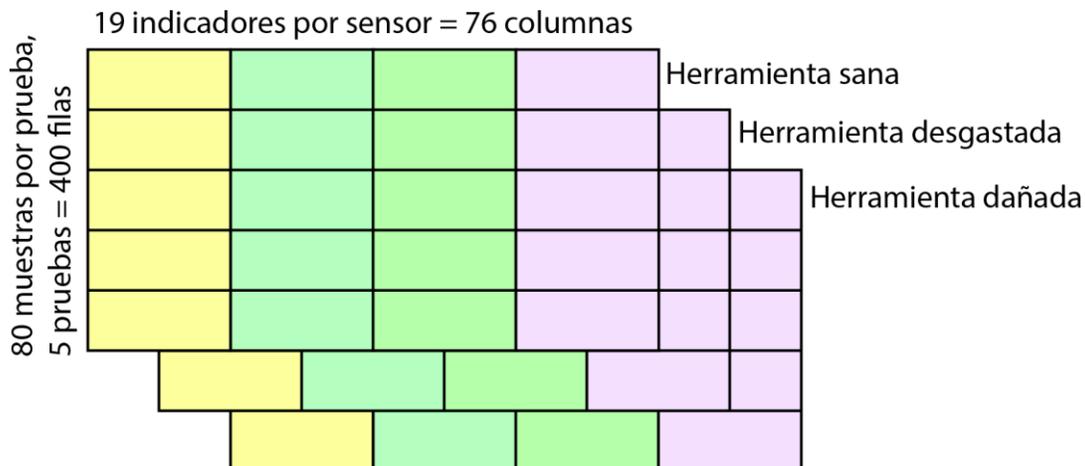


Figura 3.11. Ilustración del proceso de generación de la matriz de indicadores para cada parámetro de maquinado.

### 3.3.4 Reducción de la dimensionalidad mediante LDA.

Con la matriz de indicadores de cada parámetro obtenida en la etapa anterior, se implementó un proceso de reducción de la dimensionalidad utilizando

LDA para conseguir reducir la matriz de 76 características a dos características que permitieran la distinción entre las tres clases o condiciones de desgaste de interés.

### 3.3.5 Generación de Redes Neuronales para la clasificación del nivel de desgaste.

Con la información reducida a dos dimensiones, se procedió a la creación de Redes Neuronales para la identificación y clasificación del desgaste. Para su entrenamiento se utilizó el 90% de los 400 datos disponibles por cada condición de desgaste, usando el 10% restante para su validación.

Se probaron distintas combinaciones de número de capas y neuronas de forma experimental, seleccionando el modelo con dos entradas, dos capas ocultas de dos y ocho neuronas, respectivamente, y tres salidas como la más adecuada para la tarea. Las redes utilizaron como funciones de transferencia la función tangente hiperbólica (ecuación 3.2) para las capas ocultas y la función lineal (ecuación 3.3) para la capa de salida (donde  $h$  es el valor de salida de la neurona y  $S$  es la suma de los valores por los pesos de entrada más el valor del bias). Con este modelo de red, se realizaron los entrenamientos necesarios, comparando los resultados del uso de las variables físicas (corriente y flujo magnético) por separado contra la fusión de los datos.

$$h = \tanh(S) = \frac{e^S - e^{-S}}{e^S + e^{-S}} = \frac{2}{1 + e^{-2S}} - 1 \quad 3.2$$

$$h = S \quad 3.3$$

Con los resultados obtenidos, se procedió a la realización de un proceso de validación cruzada para mejorar los resultados del modelo. Para esto, se optó por un proceso de diez iteraciones, utilizando 90% de la información para entrenamiento y 10% para validación, entrenando 10 redes por cada parámetro de maquinado, con las mismas características mencionadas en el párrafo anterior. Este proceso de validación cruzada permite el uso de todos los datos para el entrenamiento de los modelos, lo que permite obtener mejores resultados con un modelo global.

### 3.3.6 Desarrollo de software en C y comparación de los resultados.

Una vez realizado el procesamiento anterior de acondicionamiento, análisis en tiempo-frecuencia y reducción de la dimensionalidad en Matlab, se dividió el procesamiento en funciones, las cuales se adecuaron para la conversión a código en C mediante el *toolbox* MATLAB Coder. Por otro lado, las Redes Neuronales entrenadas fueron almacenadas, lo que permitió la obtención de los pesos y bias de las mismas; con esto, se recrearon las redes mediante funciones, utilizando las mismas características de arquitectura y procesamiento. Igualmente, se generó una función que permitiera la evaluación de las redes y la obtención de los porcentajes de efectividad al clasificar las señales analizadas; estas funciones fueron convertidas a C utilizando el *toolbox* mencionado anteriormente.

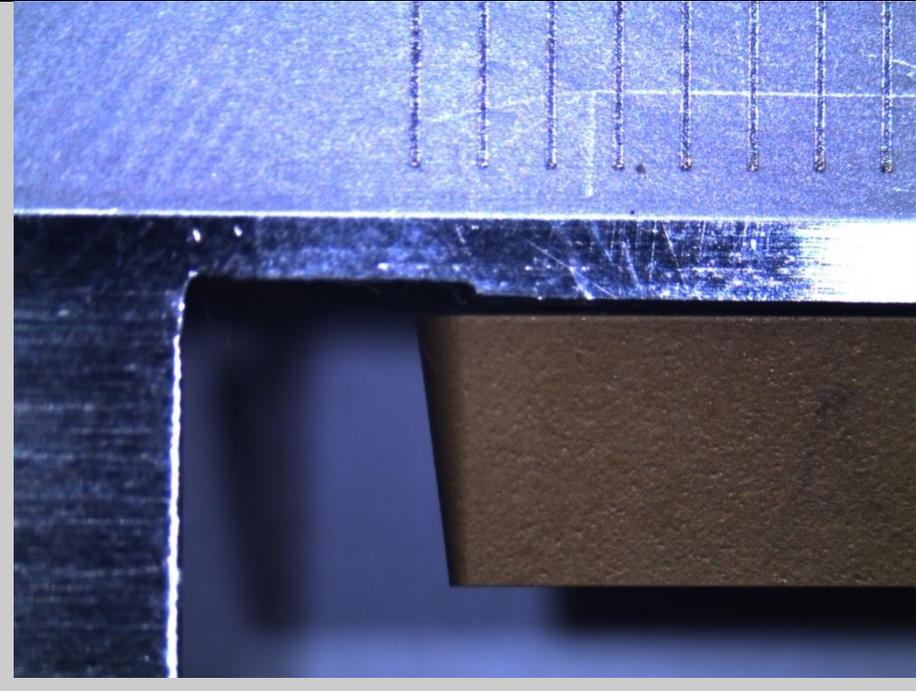
Las funciones generadas se verificaron en el entorno de Matlab, con la finalidad de comparar los resultados contra el procesamiento original.

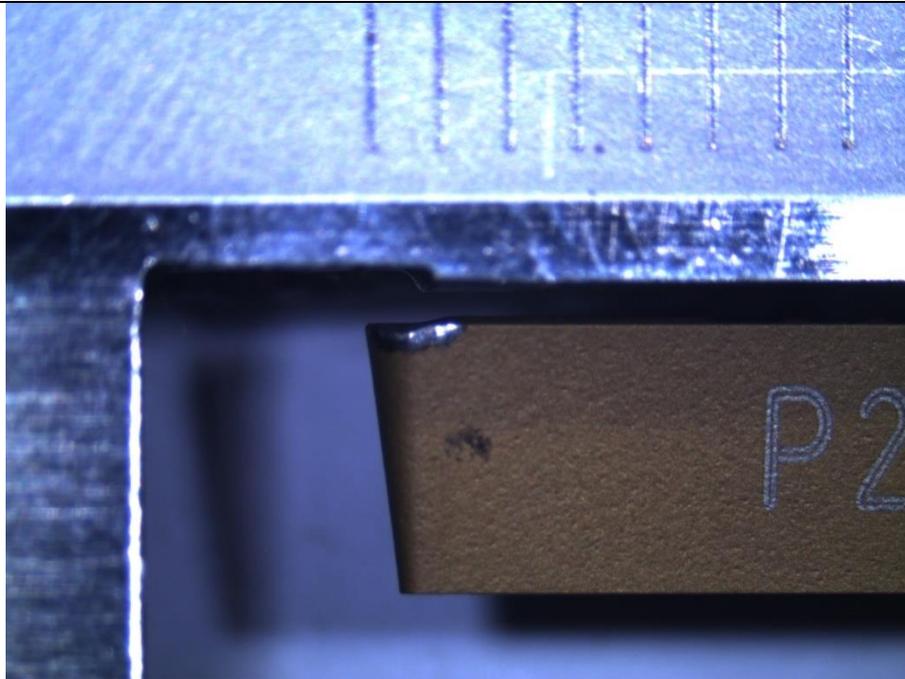
# 4 Resultados.

## 4.1 Herramientas de corte.

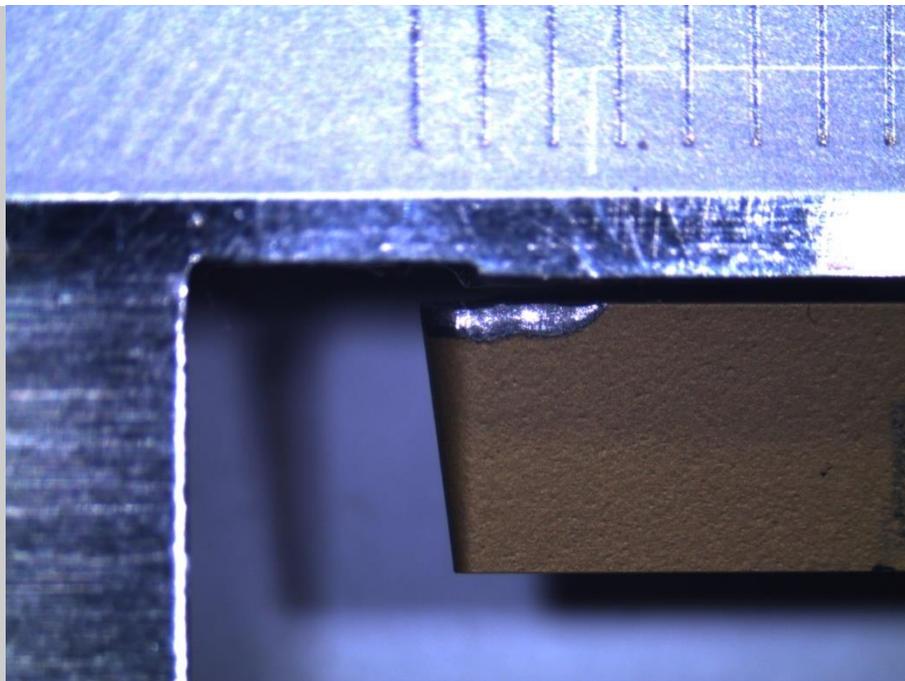
Como se mencionó en el capítulo anterior, se emplearon seis herramientas diferentes, divididas en dos grupos, presentando tres niveles de desgaste: nuevo, desgaste medio, dañado. Para la medición del desgaste, se tomaron fotografías haciendo uso de un microscopio Leica LAS EZ, las cuales fueron procesadas para medir el área desgastada en cada una. En las tablas 4.1 y 4.2 se muestran las herramientas empleadas para la realización de las pruebas, de menor a mayor desgaste, así como área medida para cada uno. Es posible observar las diferencias entre los distintos niveles de desgaste presente en los insertos utilizados.

*Tabla 4.1. Herramientas utilizadas para las pruebas de velocidad y sus áreas de desgaste.*

Herramienta	Área (mm <sup>2</sup> )
	0.0

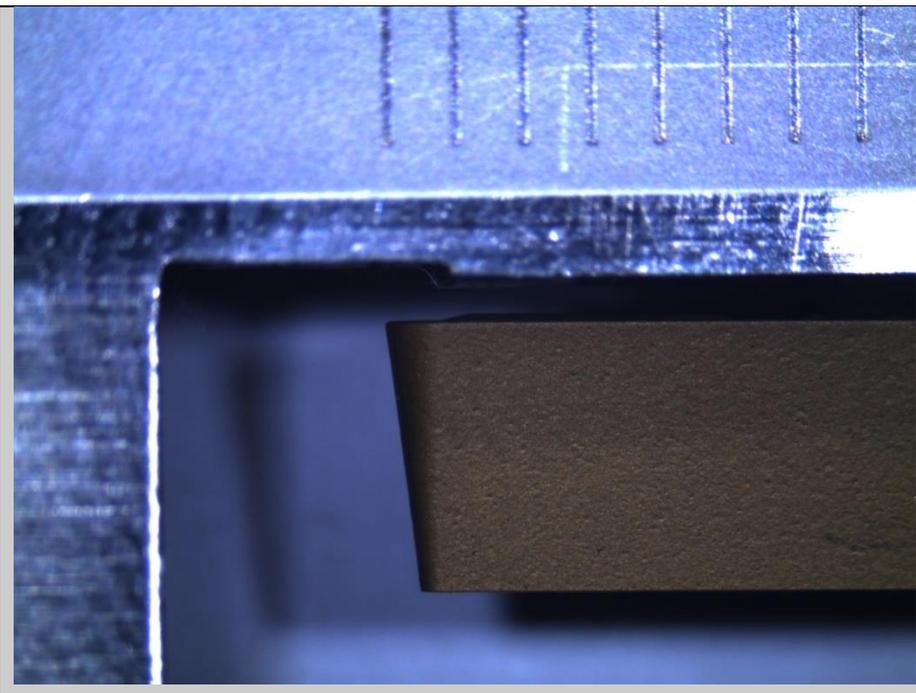
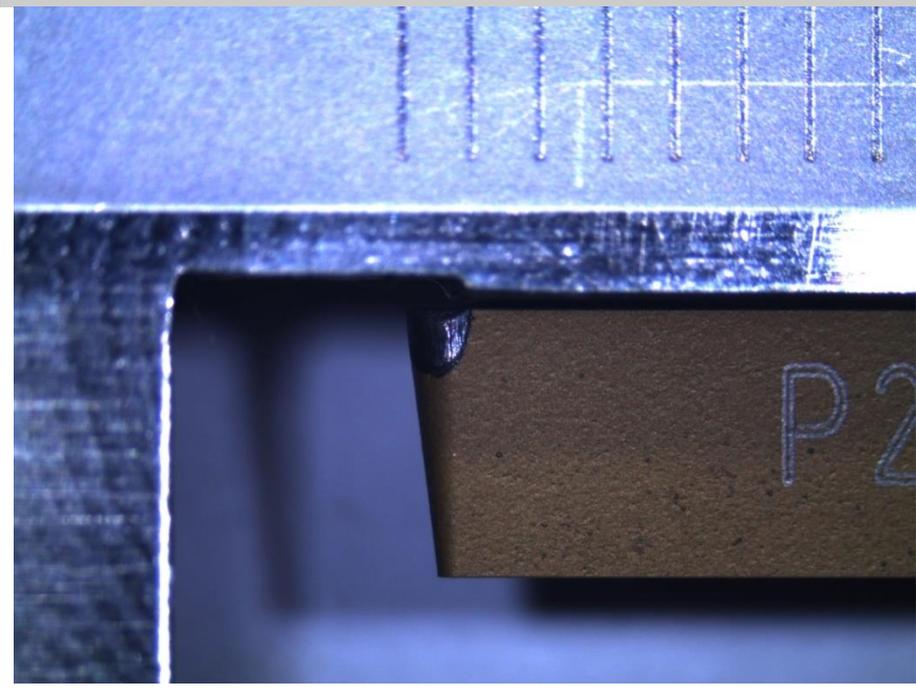


0.5858



1.739

Tabla 4.2. Herramientas utilizadas para las pruebas de avance y sus áreas de desgaste.

Herramienta	Área (mm <sup>2</sup> )
	0.0
	1.2645



#### 4.2.1 Programación de las rutinas de corte.

Dentro del código G, utilizado para la programación de trayectorias en el torno CNC, existen diferentes comandos que definen los parámetros a emplear:

- O: Indica el nombre con el cual se almacena el programa.
- N: Indica el número de línea del programa.
- S: Indica las revoluciones por minuto a las que girará el husillo durante el maquinado.
- F: Indica el avance que tendrá la herramienta.
- G00: Realiza un movimiento para posicionar la herramienta en una coordenada indicada.
- G01: Realiza un movimiento lineal con la herramienta con un avance indicado.

La figura 4.2 muestra la estructura básica de un código G, a partir de la cual se modificaron los parámetros de interés en este estudio, definidos en las tablas 3.1 y 3.2.

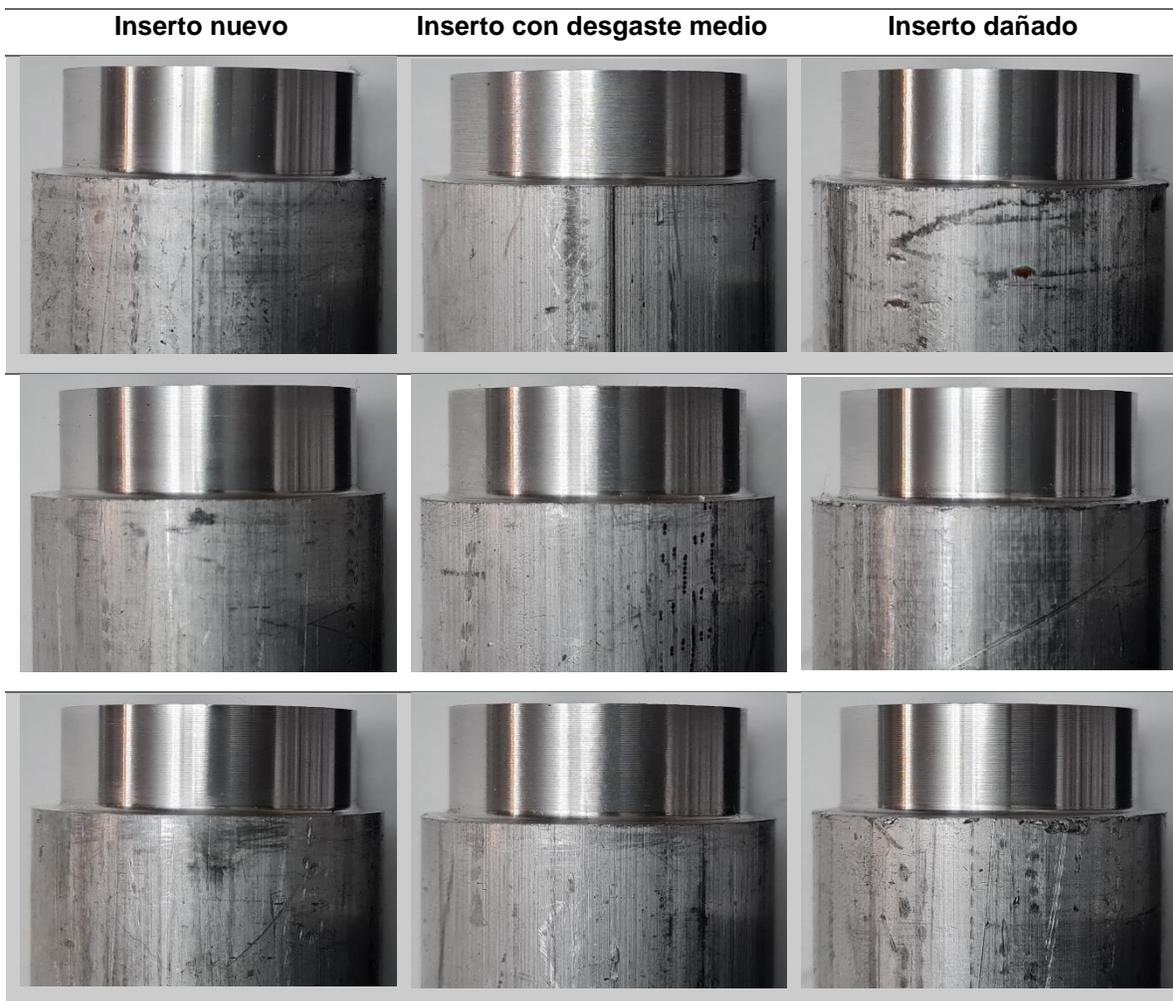
```
00077
N10    M04    S1000
N20    G00    X43.00 Z81.50
N30    G01    X37.39 Z81.50 F0.08
N40    G01    X37.39 Z71.50 F0.08
N50    G00    X43.00 Z71.50
N60    G00    X43.00 Z81.50
N70    G01    X34.89 Z81.50 F0.08
N80    G01    X34.89 Z71.50 F0.08
N90    G00    X43.00 Z71.50
N100   G00    X43.00 Z81.50
N110   G01    X32.39 Z81.50 F0.08
N120   G01    X32.39 Z71.50 F0.08
N130   G00    X43.00 Z71.50
N140   G00    X43.00 Z81.50
N150   M05
N160   M30
```

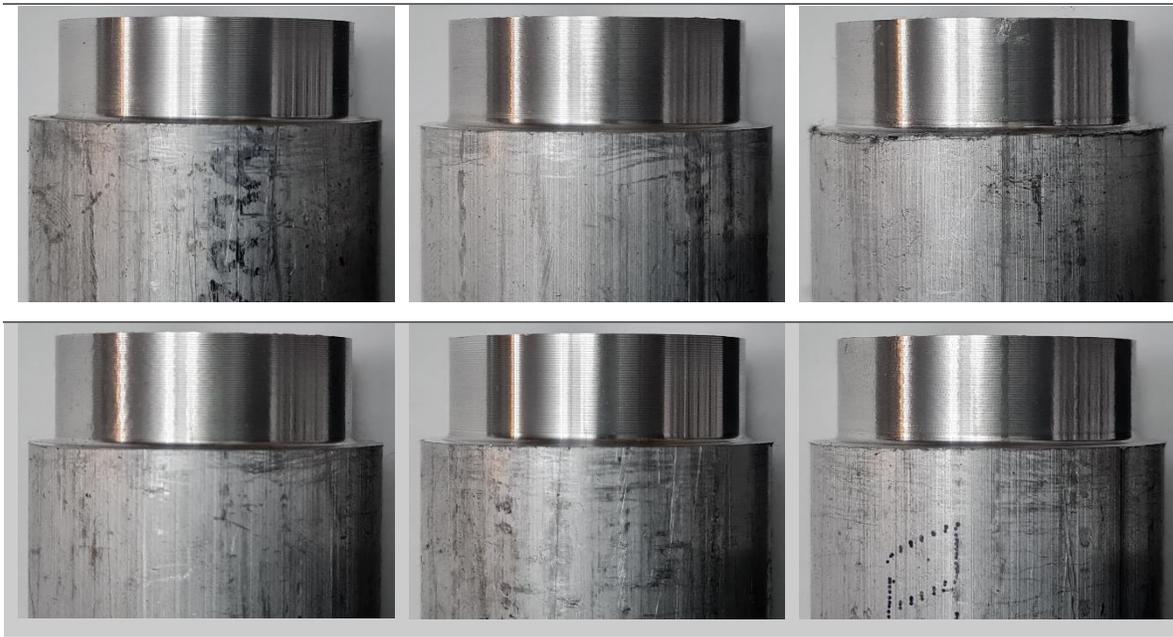
Figura 4.2. Ejemplo de código G empleado como base para la realización de las pruebas.

#### 4.2.2 Barras maquinadas.

Una vez realizados los maquinados, se analizaron las piezas para observar el efecto del desgaste sobre los acabados. En la tabla 4.3 se muestran los maquinados de la prueba de avance de la herramienta, siendo cada columna los resultados de un inserto distinto, mientras que el incremento en avance se ve reflejado al recorrer la tabla verticalmente, correspondiendo a los valores descritos en la tabla 3.2. Es posible apreciar que, con el incremento en el avance de la herramienta, se pueden notar líneas transversales sobre la cara maquinada, las cuales incrementan en número al incrementar el avance. En cuanto al acabado, las diferencias más notorias se encuentran en los bordes de las piezas, aumentando los defectos y material acumulado conforme aumenta el desgaste de la herramienta.

*Tabla 4.3. Fotografías tomadas de las barras maquinadas en las pruebas de avance de la herramienta.*





En la tabla 4.4 se muestran los resultados de los maquinados de las pruebas de velocidad de corte, siendo cada columna los resultados de cada inserto y las filas los distintos niveles de velocidad considerados en la tabla 3.1. De manera similar a la tabla anterior, el incremento de la velocidad de corte aumenta la presencia de líneas transversales sobre la superficie maquinada. Igualmente, los maquinados con la herramienta dañada presentan mayores imperfecciones superficiales y material acumulado en los bordes a comparación de las maquinadas con una herramienta nueva.

*Tabla 4.4. Fotografías tomadas de las barras maquinadas en las pruebas de velocidad de corte.*

Inserto sano	Inserto con desgaste medio	Inserto dañado

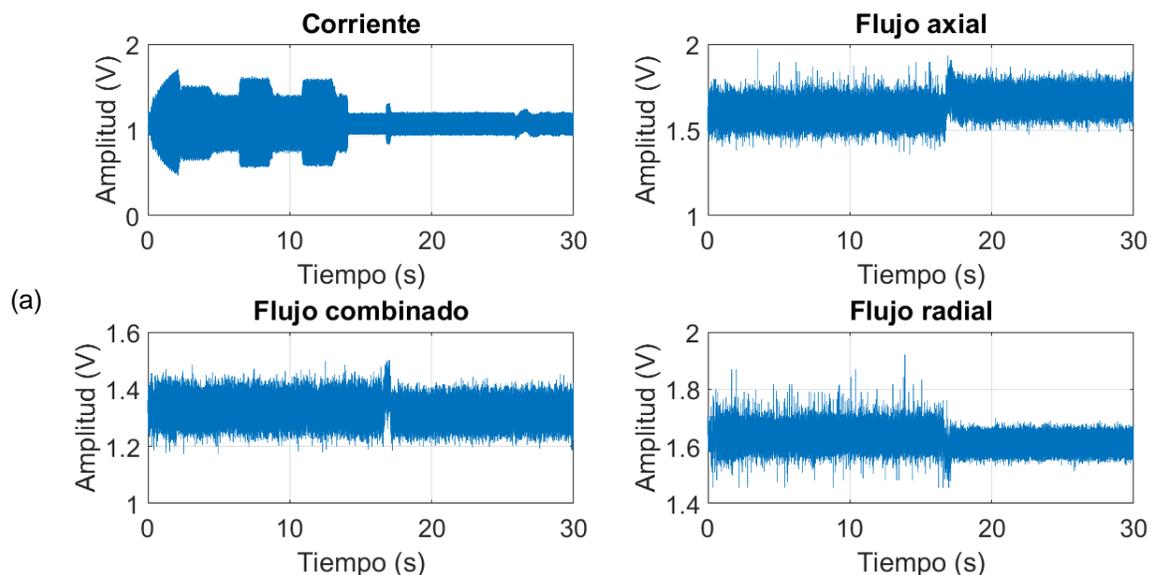


### 4.3 Análisis de las señales capturadas.

Los antecedentes expuestos muestran que la fusión de información de distintos sensores es una tendencia en el monitoreo del desgaste de herramientas, esto debido a que el uso de distintos sensores permite la obtención de señales relacionadas a distintas magnitudes físicas presentes en el proceso de maquinado. Con esto, es posible realizar un análisis más complejo y completo debido a la cantidad de información obtenida del fenómeno, lo cual permite mejorar los

resultados al fusionar la información de los distintos sensores en comparación al análisis de las magnitudes por separado. A partir de lo anterior, se realizó una fusión de las señales de corriente y flujo magnético para analizar la información obtenida, logrando así complementar las características que cada una de las señales aportaba de forma individual para lograr la identificación del desgaste ante la variación individual de los parámetros de maquinado.

En la figura 4.3 se muestran las señales obtenidas durante la prueba de avance de la herramienta, con un avance de 0.24, utilizando la herramienta dañada. En (a) se muestran las señales obtenidas por el sistema de adquisición y en (b) se muestran las mismas señales tras el proceso de acondicionamiento y filtrado digital. Es posible observar la diferencia en amplitudes y en definición tras el proceso, sin embargo, es evidente que los cortes realizados no son claramente apreciables en las señales de flujo, a diferencia de la señal de corriente. Esto demuestra la importancia de la fusión de datos, ya que permite obtener información necesaria para el análisis que complementa la obtenida por otros sensores. Este proceso se aplicó a todas las señales para mejorar la calidad de la información previo a la obtención de los parámetros.



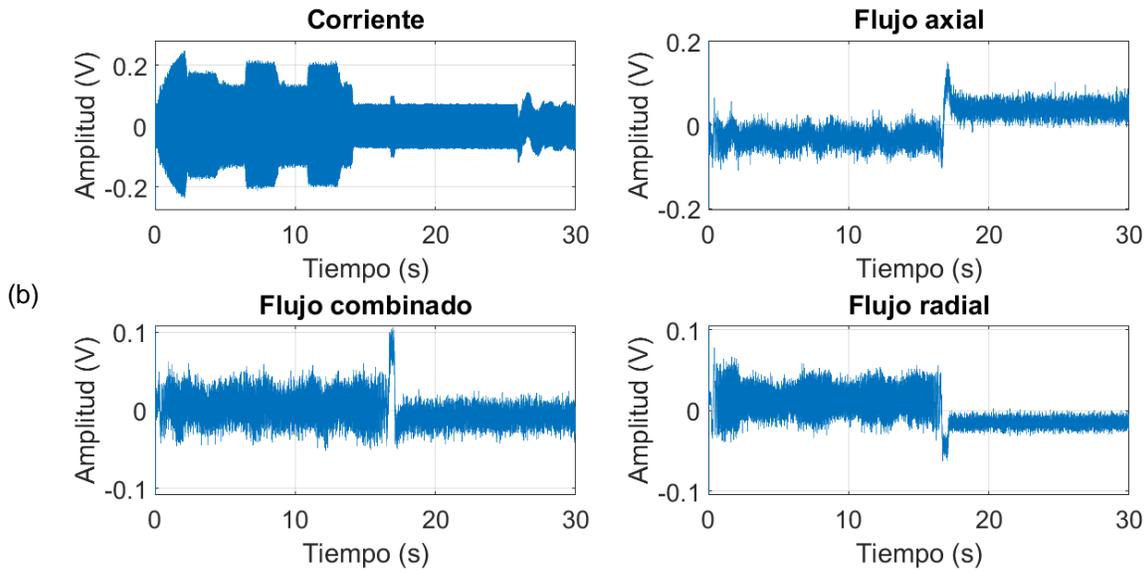
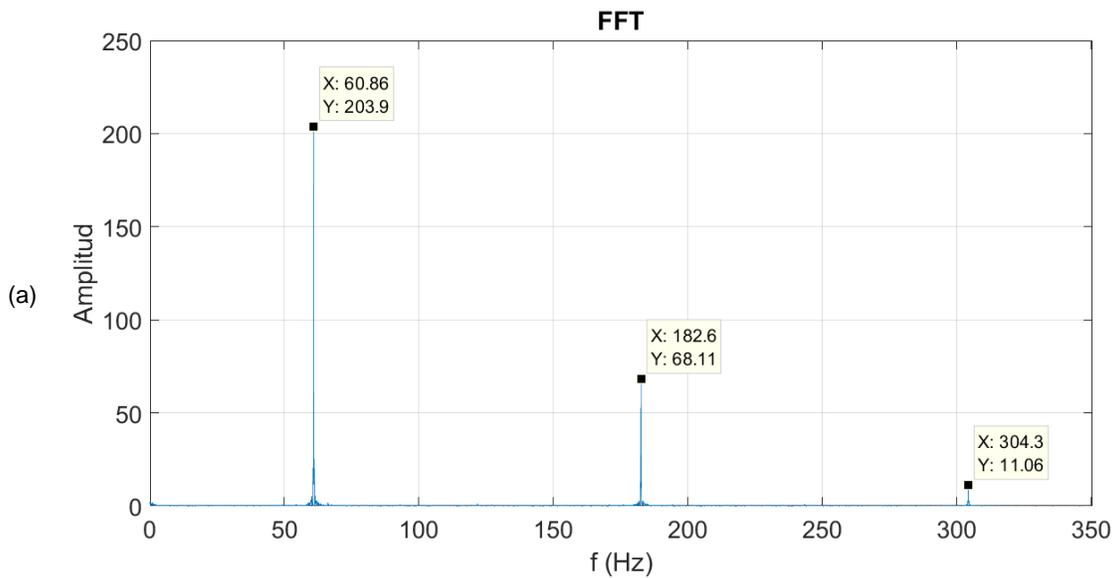
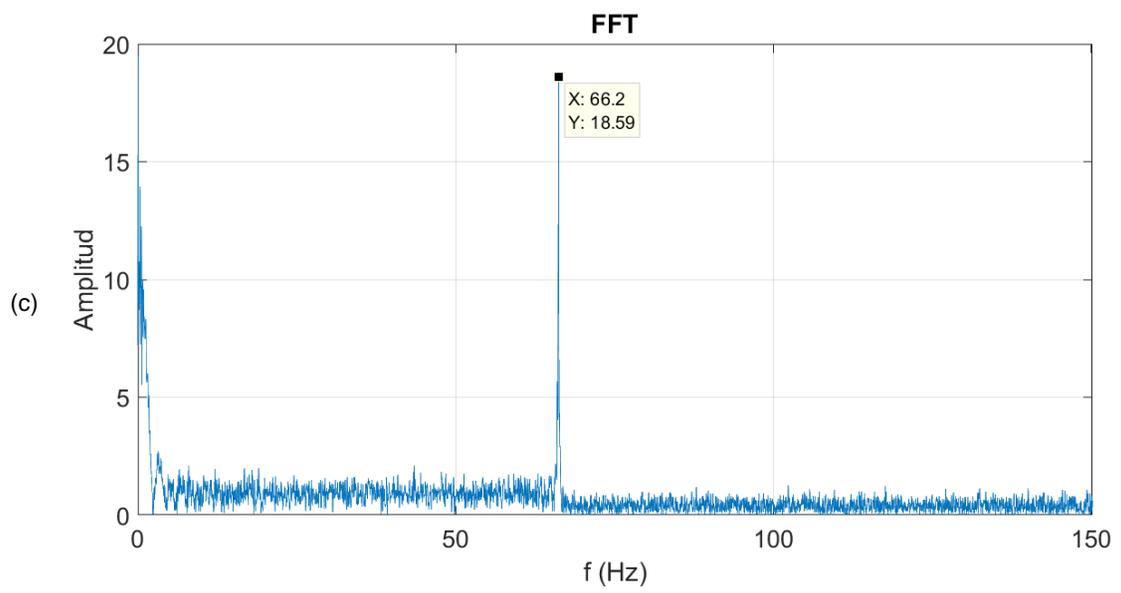
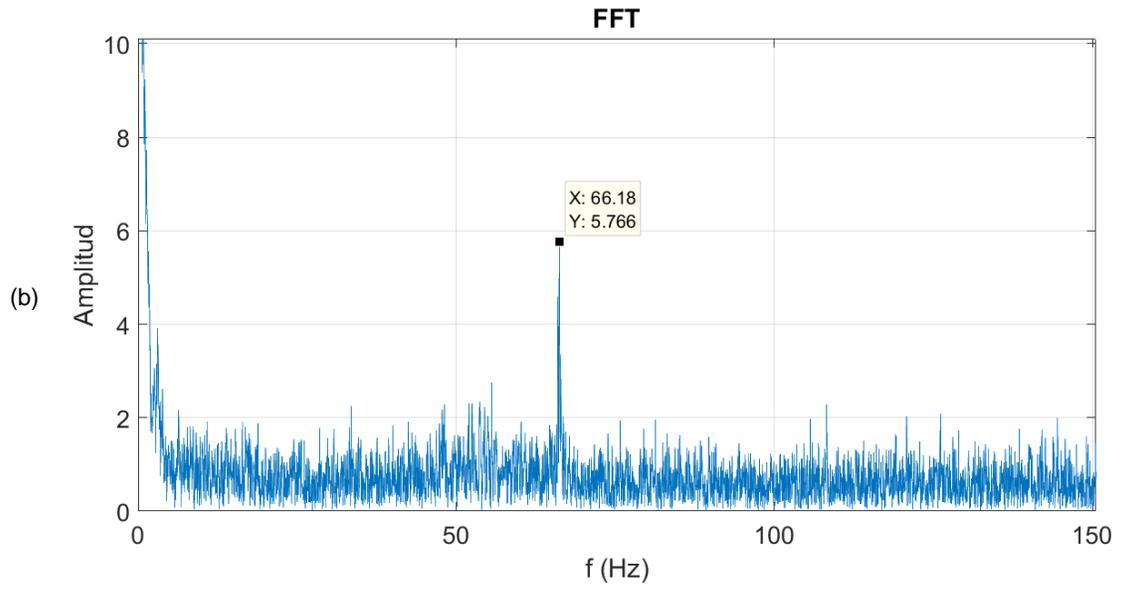


Figura 4.3. Comparación entre las señales (a) sin acondicionamiento y (b) acondicionadas.

Posteriormente, se realizó el análisis con FFT para la obtención de la componente fundamental y la posterior selección de la banda más apropiada para la reconstrucción. En la figura 4.4 se muestran los resultados del procesamiento con FFT para las señales de la figura 4.3. Es posible apreciar resultados más claros en la señal de corriente (a), teniendo una frecuencia cercana a los 60Hz, así como la presencia de armónicos. Por otro lado, la magnitud de la fundamental en la señal de flujo axial (b) es evidentemente menor que en los casos de flujo combinado (c) y flujo radial (d), teniendo una frecuencia cercana a los 66Hz en todos los casos.





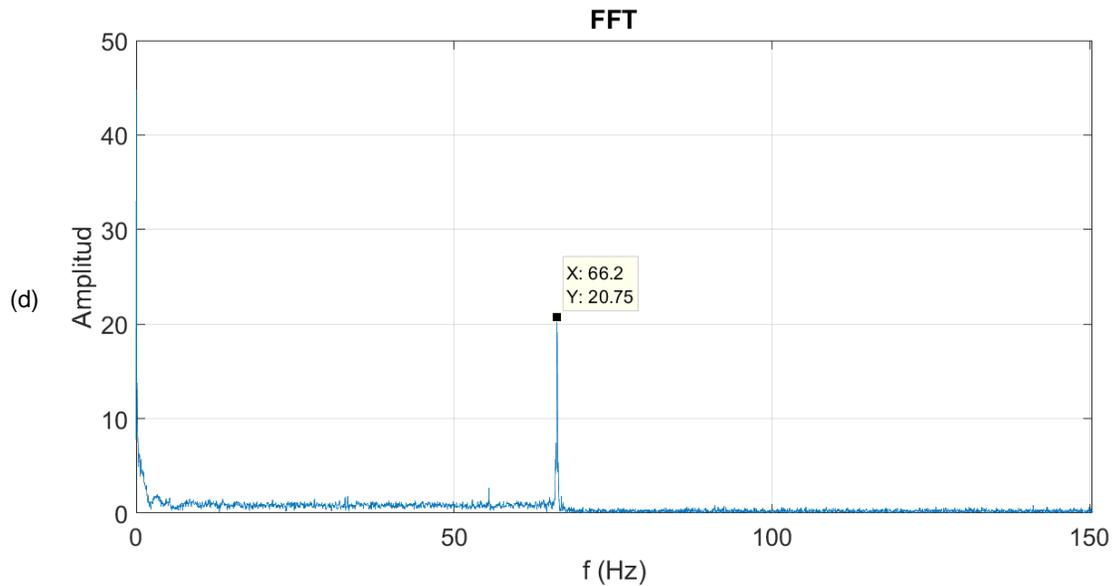
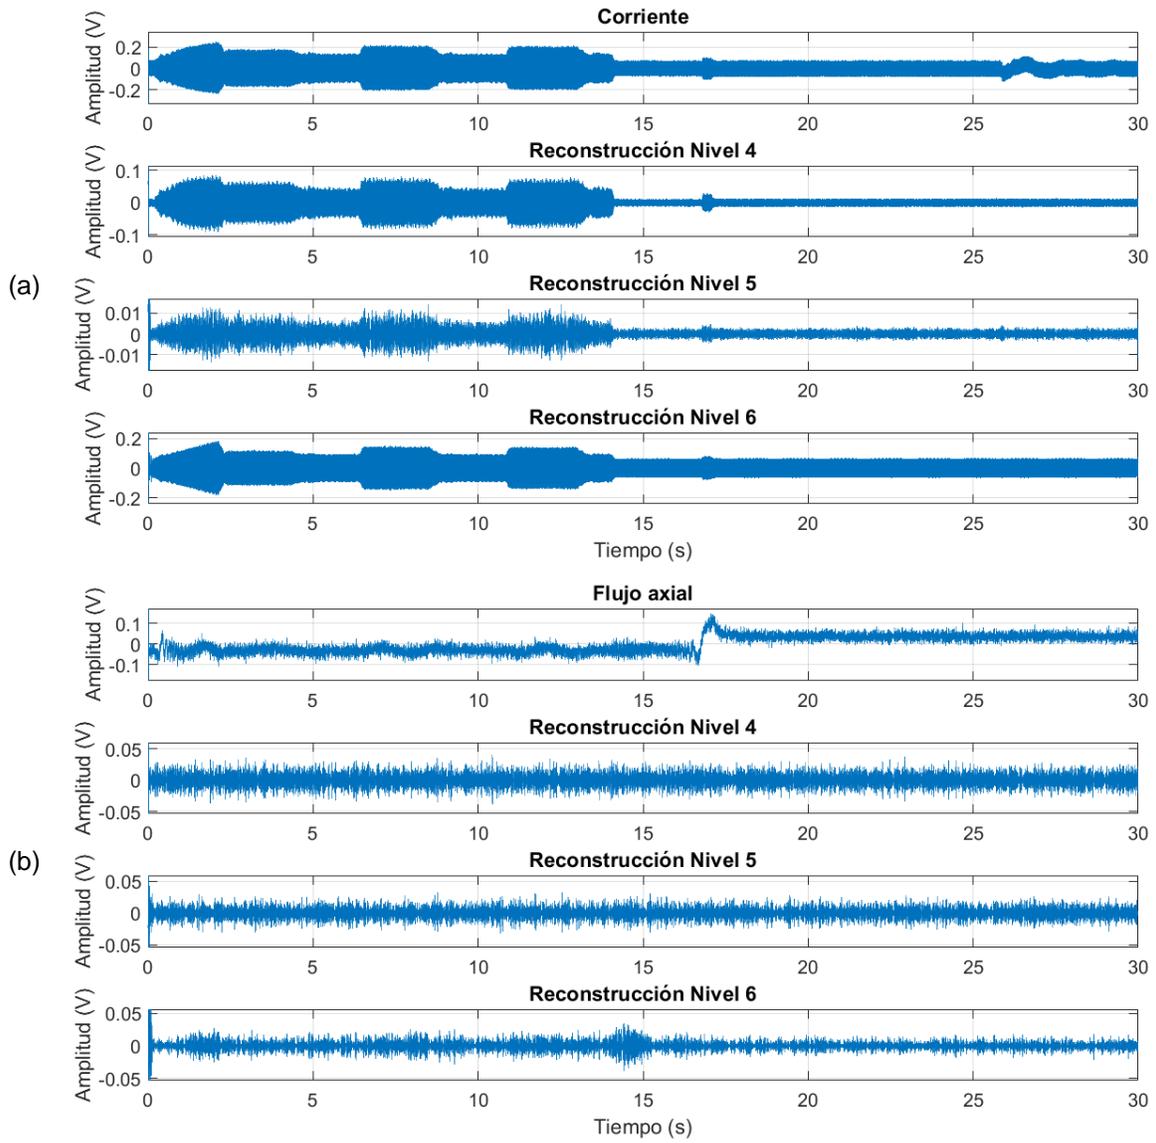


Figura 4.4. Gráficas generadas a partir del análisis con FFT para las señales anteriores: (a) señal de corriente, (b) flujo axial, (c) flujo combinado y (d) flujo radial.

Posteriormente, se obtuvieron los resultados de la descomposición y reconstrucción de las señales con el uso de la DWT. La figura 4.5 muestra los resultados para las señales de la figura 4.3, donde para cada inciso se tiene, de arriba abajo, la señal filtrada, la reconstrucción del nivel 4, 5 y 6 de la señal, los cuales fueron los niveles de reconstrucción considerados para la búsqueda con la FFT. Es evidente en todas las reconstrucciones de la señal de corriente (a) la ubicación temporal de los cortes de la pieza, así como las diferencias entre las amplitudes de las reconstrucciones. En la reconstrucción de la señal de flujo axial (b), es posible apreciar la poca aportación de información de los cortes, mientras que las reconstrucciones de la combinación de flujo (c) y el flujo radial (d) muestran mejor información de los cortes.



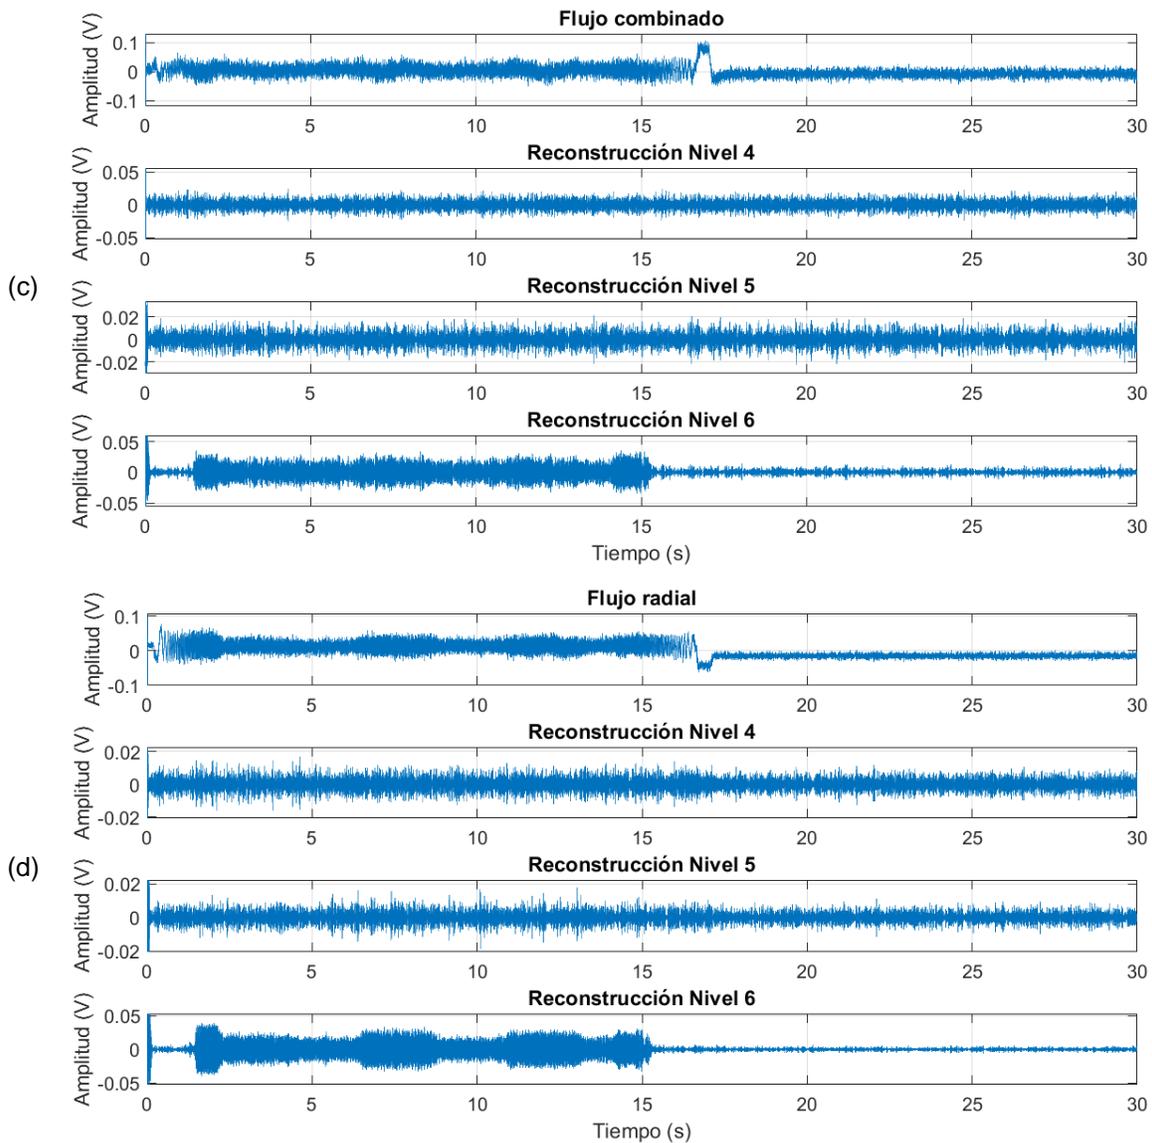


Figura 4.5. Gráficas de la reconstrucción de las señales anteriores en las bandas consideradas para el análisis: (a) corriente, (b) flujo axial, (c) flujo combinado y (d) flujo radial.

En la figura 4.6 se muestran los resultados arrojados al usar el LDA con los datos de las señales de flujo magnético, siendo (a) los resultados de las pruebas de velocidad y (b) los de avance. Como es posible observar, la reducción de dimensionalidad no arroja un resultado de separación de las condiciones de las herramientas que permita distinguir claramente entre los tres casos estudiados ya que la distribución de los datos presenta un traslape.

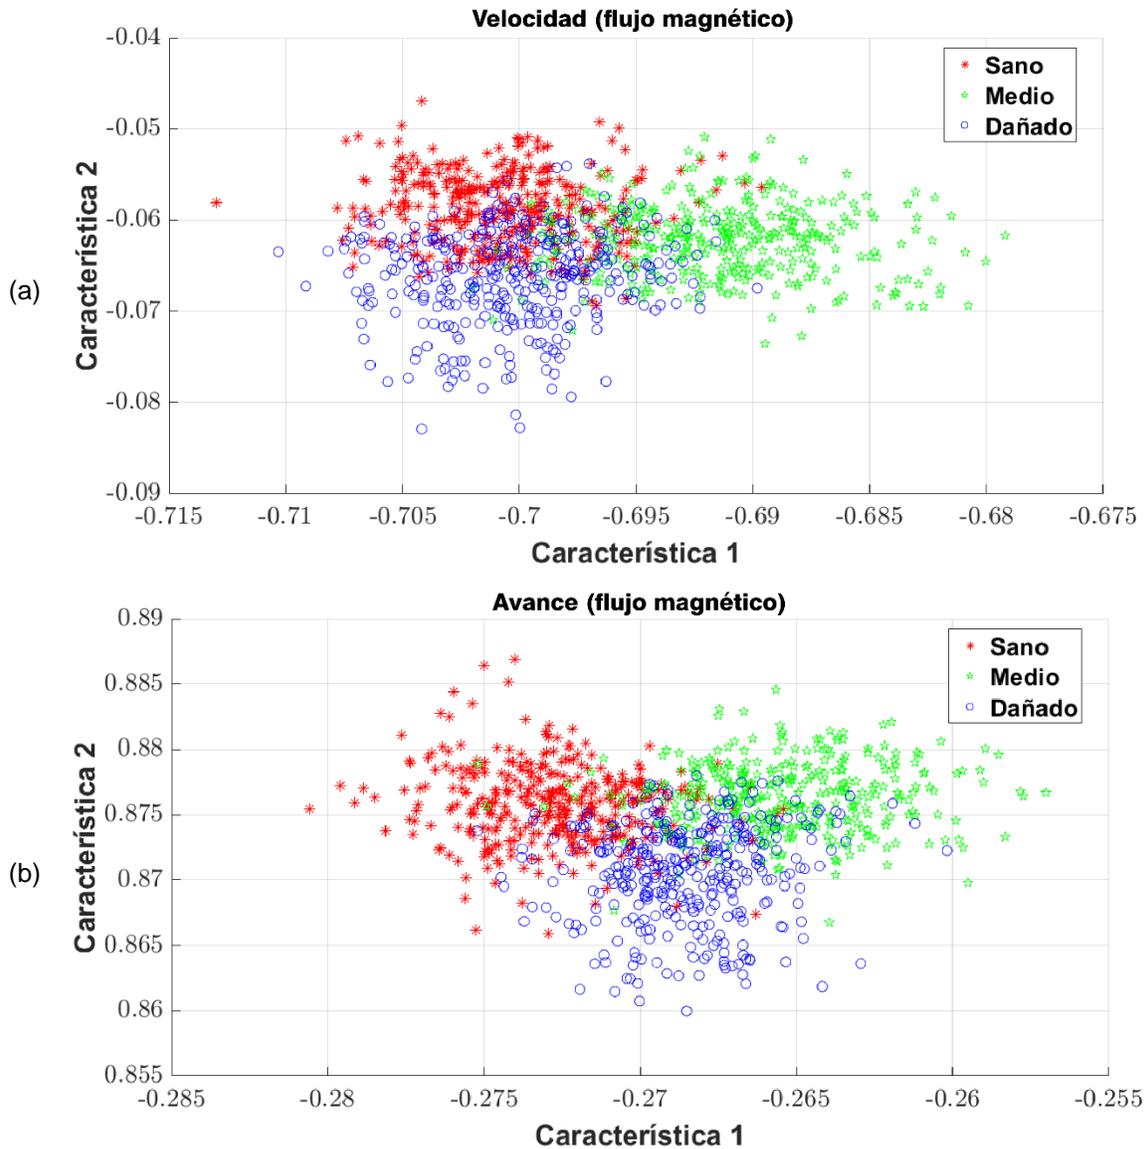


Figura 4.6. Resultados del uso de LDA sobre señales de flujo para (a) velocidad de corte y (b) avance de la herramienta.

Por otro lado, la figura 4.7 muestra los resultados de usar LDA sobre los datos de la señal de corriente, siendo (a) los resultados de las pruebas de velocidad y (b) los de avance. En este caso, es posible observar una separación más evidente de una de las condiciones, mientras el resto siguen presentando un traslape evidente.

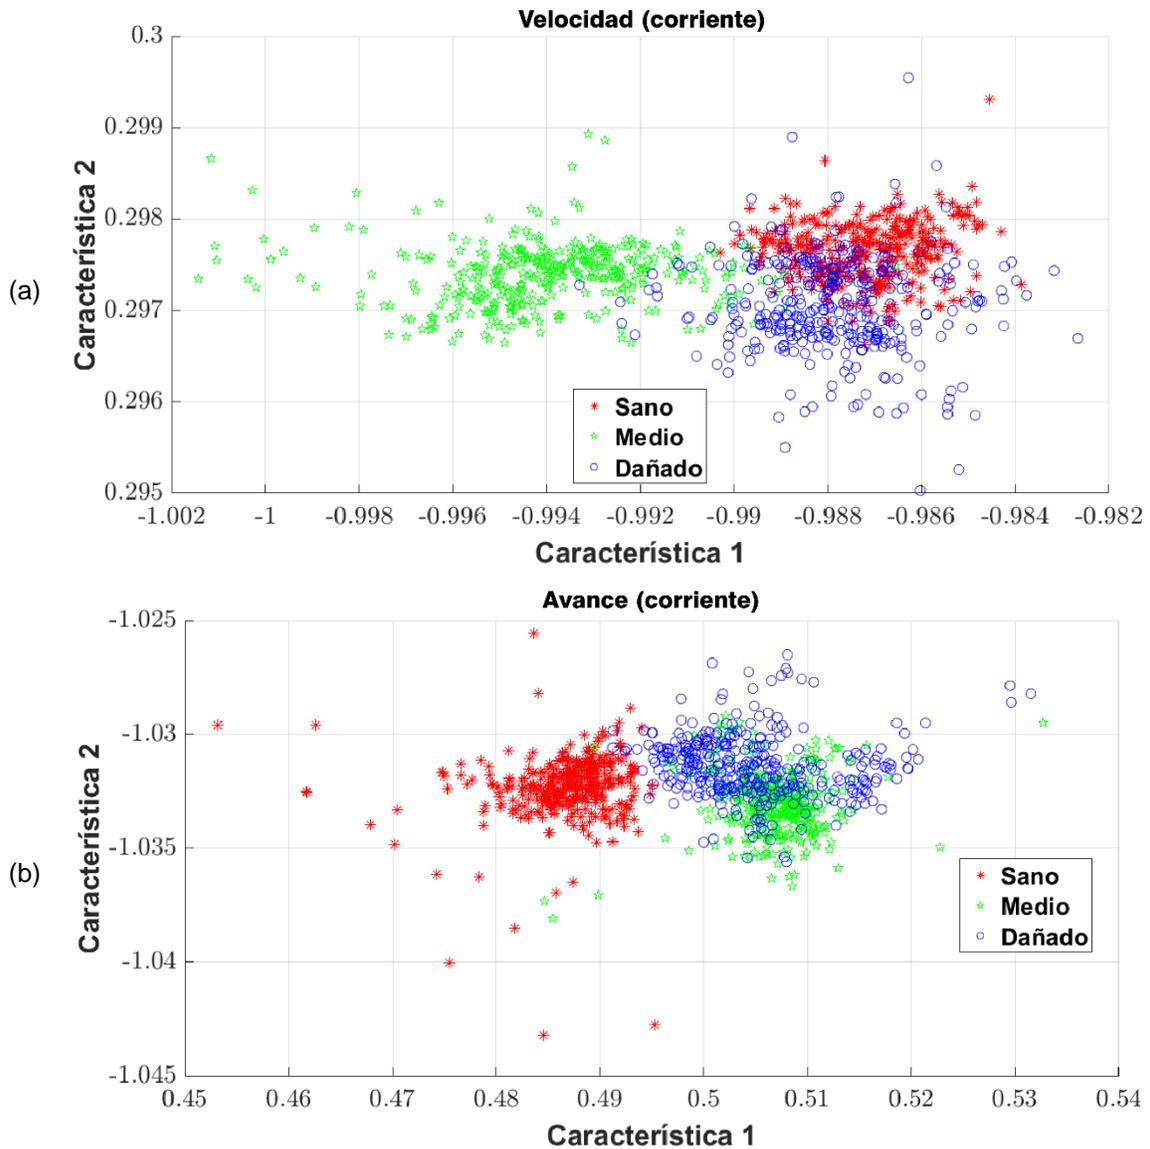


Figura 4.7. Resultados del uso de LDA sobre las señales de corriente para (a) velocidad de corte y (b) avance de la herramienta.

Finalmente, la figura 4.8 presenta los resultados de emplear LDA con la fusión de las señales de flujo y corriente, siendo (a) los resultados de las pruebas de velocidad y (b) los de avance. En este caso, es posible apreciar una mayor separación de las condiciones, llegando a tener un traslape menor entre dos de las condiciones de desgaste. Esto es de esperar ya que la fusión de datos permite obtener una mayor cantidad de información que facilite el análisis del desgaste de las herramientas, lo cual es evidente al comparar con los análisis de las variables físicas por separado en las figuras 4.6 y 4.7.

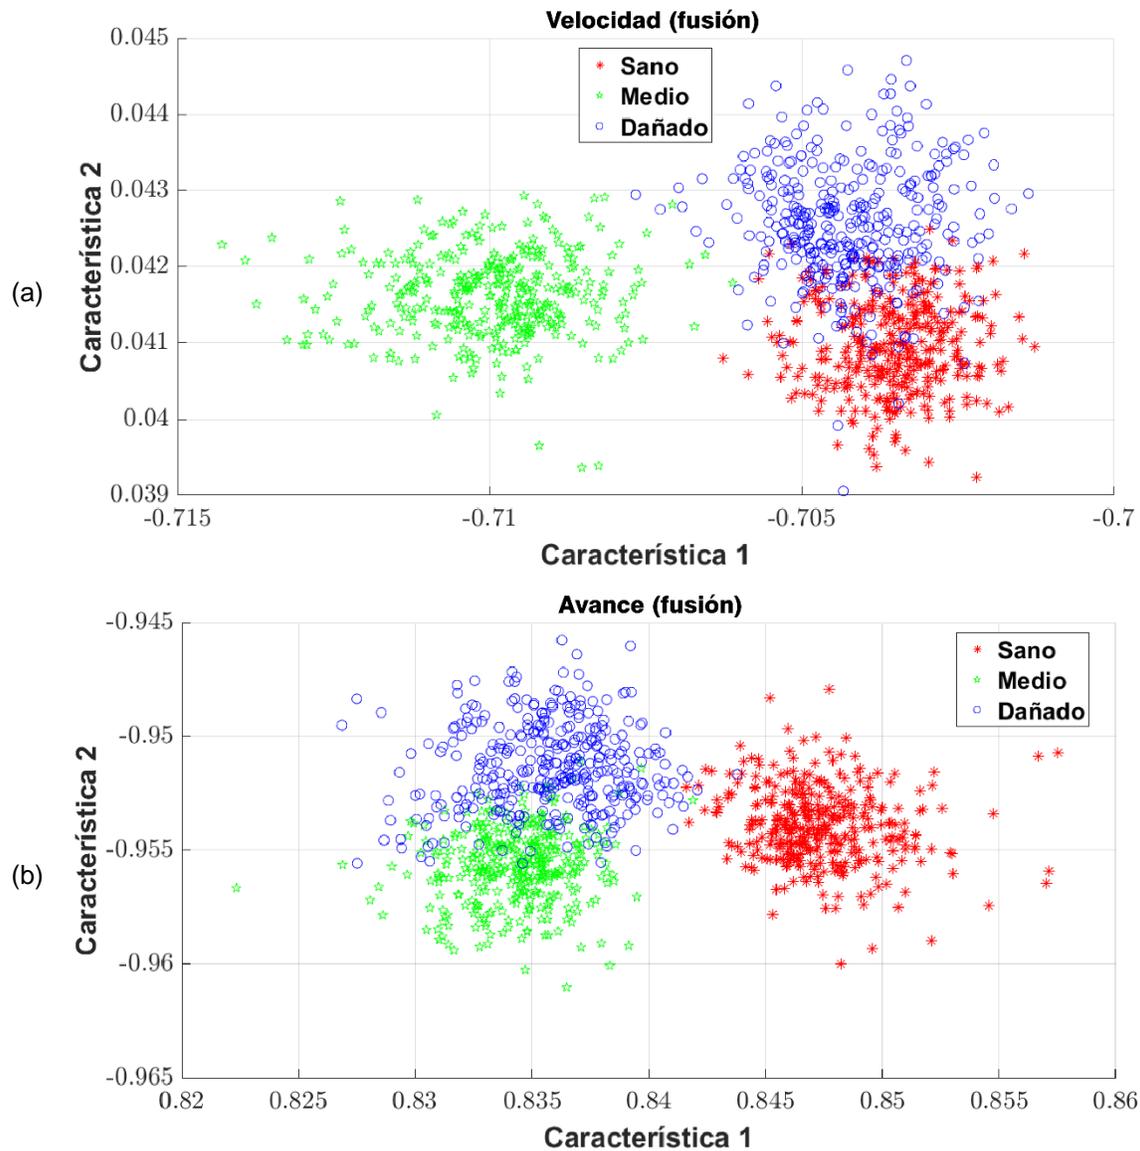
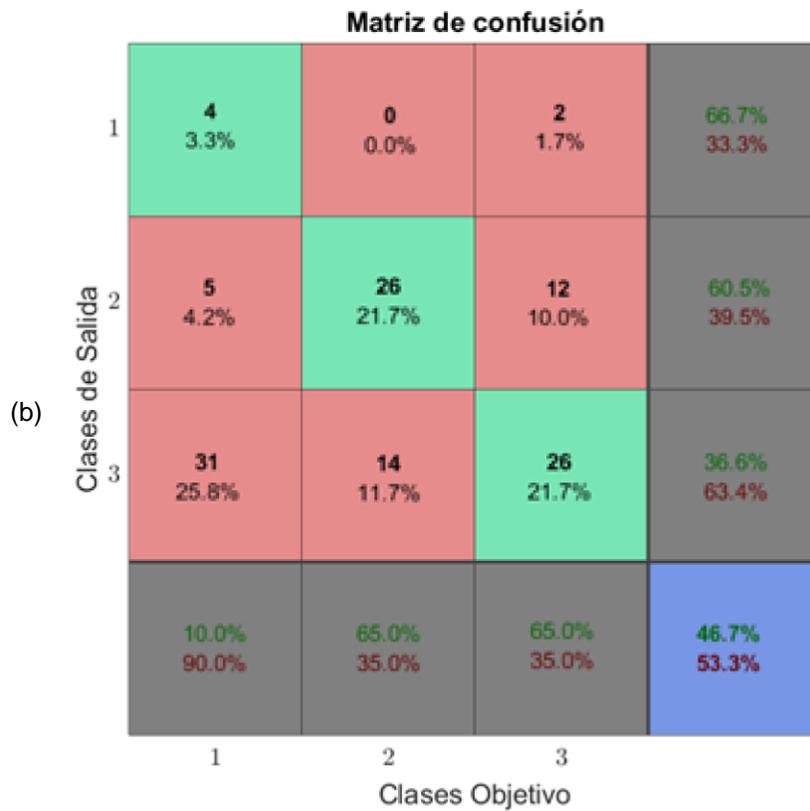
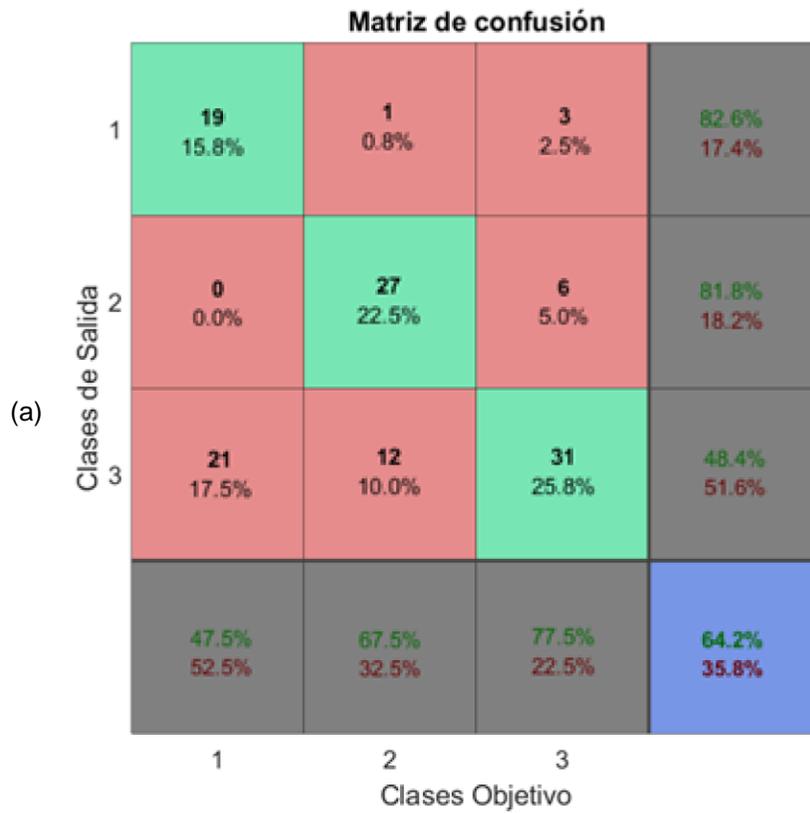


Figura 4.8. Resultados del uso de LDA con la fusión de datos para (a) velocidad de corte y (b) avance de la herramienta.

Una vez realizadas las reducciones mediante LDA, los datos se emplearon para el entrenamiento y validación de redes neuronales. La figura 4.9 muestra los resultados arrojados por la red neuronal individual para las pruebas de velocidad, siendo (a) los resultados arrojados para la clasificación de las señales de flujo, (b) corresponde a los resultados de la clasificación de señales de corriente y (c) muestra los resultados obtenidos de la fusión de los datos. Es posible observar la mejora en los resultados obtenidos al fusionar la información de todos los sensores.



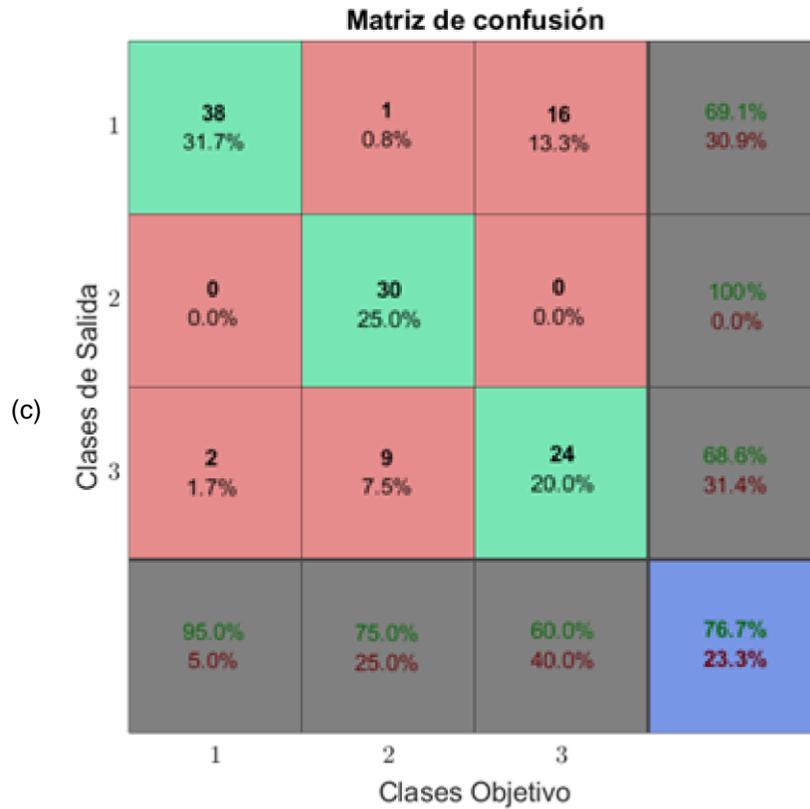
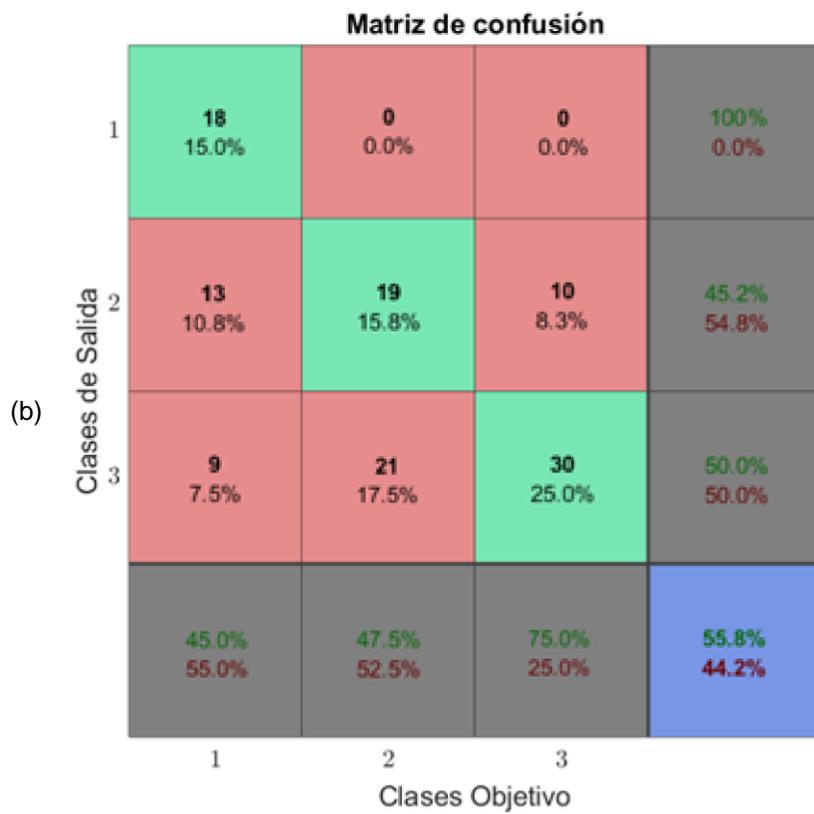
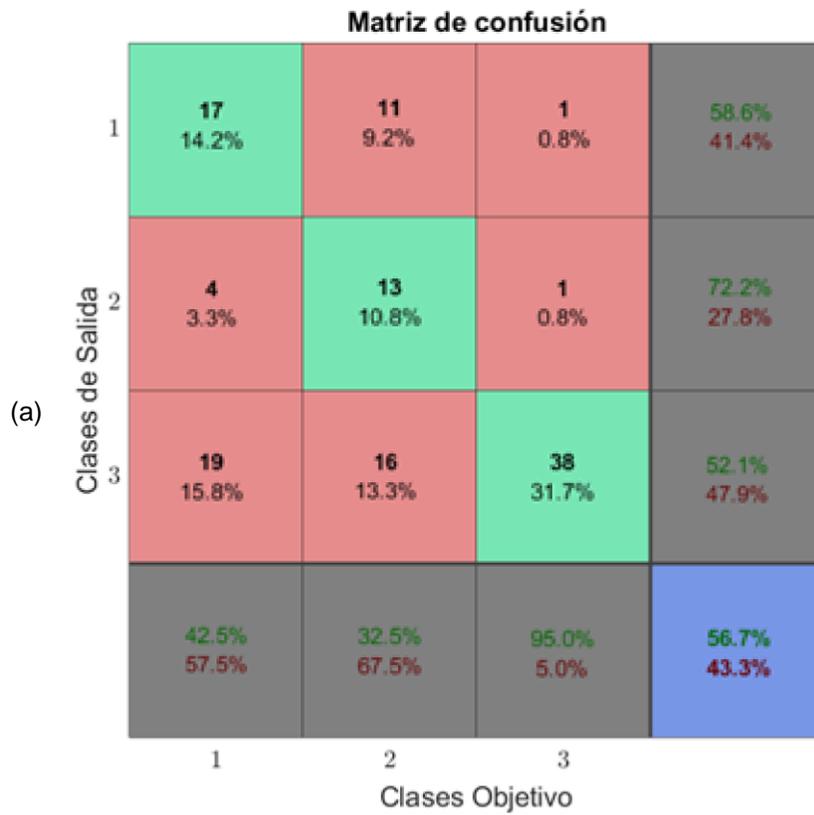


Figura 4.9. Matrices de confusión obtenidas para el análisis de las pruebas de velocidad utilizando (a) flujo magnético, (b) corriente y (c) fusión de datos.

La figura 4.10 muestra los resultados arrojados por la red neuronal individual para las pruebas de avance, siendo (a) los resultados de las señales de flujo, (b) corresponde a las señales de corriente y (c) muestra los resultados obtenidos de la fusión de los datos. En este caso también se observa una mejora en los resultados obtenidos al fusionar la información.



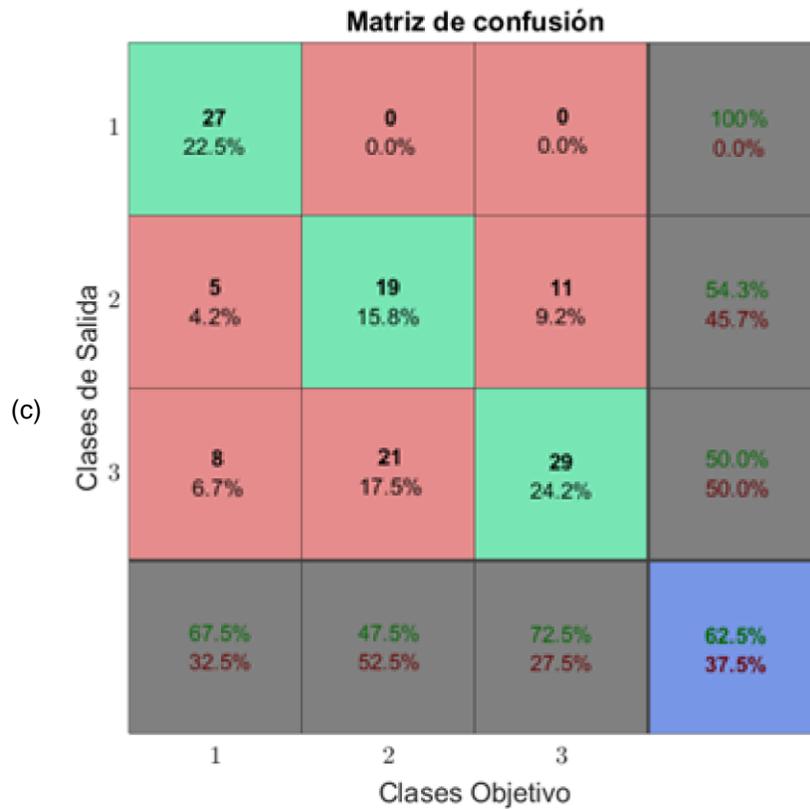


Figura 4.10. Matrices de confusión obtenidas para el análisis de las pruebas de avance utilizando (a) flujo magnético, (b) corriente y (c) fusión de datos.

Igualmente, la aplicación de la validación cruzada permitió mejorar los valores obtenidos por los sistemas. Como se comentó en el capítulo anterior, se dividió la información obtenida para cada estado de las herramientas en diez grupos de igual tamaño y se realizaron diez procesos de entrenamiento de redes neuronales y validación del modelo alternando el grupo de datos para validación, con esto se obtuvieron diez modelos o redes diferentes, las cuales en conjunto consideran todos los puntos de información obtenida, esto con la finalidad de mejorar los resultados de la clasificación. En la tabla 4.5 se muestran los resultados obtenidos en cada una de las validaciones para cada parámetro de maquinado utilizando la fusión de datos, así como el promedio de los resultados y el valor más alto obtenido resaltados.

Tabla 4.5. Resultados obtenidos con la validación cruzada.

Fold	Velocidad	Avance
1	80.8	89.2
2	97.5	94.2
3	83.3	60.0
4	90.8	75.0
5	90.8	89.2
6	85.0	90.8
7	77.5	85.0
8	95.0	89.2
9	95.8	97.5
10	70.8	88.3
<b>Promedio</b>	<b>86.73</b>	<b>85.84</b>

Es posible observar una mejora significativa en los resultados al utilizar la validación cruzada, ya que algunos de los resultados alcanzados con las redes neuronales son superiores al 95% y el promedio de los resultados de los modelos para cada parámetro incrementa considerablemente cuando se le compara con el uso de una sola red.

En cuanto a las funciones convertidas a C, se probaron en el entorno de Matlab, consiguiendo buenos resultados para la identificación del desgaste. La tabla 4.6 muestra los resultados obtenidos para la fusión de las señales de flujo y corriente utilizando una red neuronal y validación cruzada para ambos parámetros de maquinado. La tabla muestra el porcentaje de acierto para cada uno de los niveles de desgaste, así como el promedio del modelo. Es posible observar que los resultados obtenidos son cercanos a los obtenidos con el procesamiento original.

Tabla 4.6. Resultados obtenidos con la implementación de las funciones convertidas a C.

Parámetro maquinado	de	Método	Resultados obtenidos (% de acierto)			
			Inserto sano	Inserto desgaste medio	Inserto con medio dañado	Promedio del modelo
Velocidad corte.	de	Red individual	95.0	75.0	60.0	76.6666
		Validación cruzada	58.0	96.25	88.5	80.9167

<b>Avance de la herramienta.</b>	Red individual	60.0	45.0	75.0	60.0
	Validación cruzada	83.5	78.5	83.0	81.6666

#### 4.4 Análisis de los parámetros contra desgaste

Con los resultados presentados, es posible analizar la capacidad de los sistemas desarrollados para la identificación del desgaste presente en las herramientas bajo la variación individual de los parámetros de maquinado de interés en esta investigación.

##### 4.4.1 Velocidad de corte.

En la figura 4.8a es posible observar una mejor distinción entre los estados de las herramientas, teniendo un ligero traslape. Esto se ve reflejado en los resultados obtenidos por la red neuronal y el conjunto de validación cruzada de la tabla 4.5, donde éste último arroja mejores resultados en promedio, obteniendo también redes con resultados muy superiores a la red inicial.

##### 4.4.2 Avance de la herramienta.

De forma similar al parámetro anterior, la figura 4.8b muestra una mayor separación entre las condiciones de desgaste de las herramientas, lo que se traduce en mejores resultados con el sistema de clasificación de la red neuronal y el conjunto de validación de la tabla 4.5. En este caso, los resultados del promedio del modelo de validación cruzada son superiores a la red inicial, teniendo también resultados individuales que superan considerablemente a la red de la figura 4.10.

#### 4.5 Comparación de resultados con el software desarrollado.

Las funciones generadas en Matlab fueron exitosamente convertidas a C (ver Apéndice II) y probadas en el entorno de Matlab. Es posible observar la cercanía entre los resultados con redes individuales en la tabla 4.6 con los resultados de las figuras 4.9c y 4.10c. Igualmente, los valores obtenidos con la validación cruzada que se presentan en la tabla 4.6 muestran una disminución respecto a los valores promedio de la tabla 4.5, lo que puede deberse al cálculo realizado en el procesamiento de las funciones propias.

## 4.6 Conclusiones.

A partir de los resultados obtenidos, es posible concluir la efectividad de los sistemas desarrollados en la identificación del desgaste en las herramientas de corte ante la variación individual de parámetros de maquinado. Como se mencionó anteriormente, la fusión de datos permitió una mejora en la capacidad de identificación del desgaste en las herramientas de corte, lo cual es tendencia en los sistemas de identificación para mejorar la calidad de los análisis realizados. Es posible observar en las figuras 4.6, 4.7 y 4.8 la mejora en la separación de los datos al utilizar la fusión en comparación de las variables individuales. Esto se traduce en una mejora significativa al momento del análisis.

Se puede observar en las figuras 4.9c y 4.10c los resultados obtenidos al entrenar las redes neuronales para la identificación del desgaste en las señales, resultados que mejoran al someter la información a un sistema de validación cruzada, cuyos resultados se observan en la tabla 4.5. Esta validación permite obtener redes neuronales con resultados superiores y mejorando el porcentaje de efectividad promedio del conjunto, con la desventaja de requerir más poder computacional ya que deben entrenarse tantas redes como iteraciones se realicen.

Por otro lado, los resultados obtenidos con las funciones desarrolladas y convertidas a C muestran una buena capacidad de detección del desgaste, sin embargo, los resultados que se muestran en la tabla 4.6 son inferiores a los obtenidos con el procesamiento y funciones en Matlab que se muestran en las figuras 4.9c y 4.10c y la tabla 4.5. Un inconveniente presentado en esta parte del análisis fue la adecuación de las funciones y desarrollos realizados en Matlab para la conversión a C, debido a que no todas las funciones pueden ser convertidas; igualmente, la conversión e implementación de los archivos generados presenta diversas complicaciones, a lo que se suma la poca documentación en línea para la resolución de los errores presentados. Por esto, se optó por implementar las funciones en el entorno de Matlab para obtener resultados sobre el desempeño de las funciones generadas.

Con esto, se concluye que es posible identificar el desgaste en las herramientas de corte mediante el uso de sensores de flujo magnético que capturen las emisiones de flujo de dispersión del motor del husillo de un torno CNC y sensores de corriente en la alimentación del mismo, haciendo fusión de datos, la cual brinda una mayor cantidad de información para analizar, y que, al aplicarle parámetros estadísticos y no estadísticos, permite realizar una detección y clasificación del nivel de desgaste presente ante variaciones en la velocidad de corte y el avance de la herramienta, cada uno de forma individual. Con esto, se puede afirmar que los sistemas desarrollados permiten la correcta identificación del desgaste ante la variación de dichos parámetros de maquinado. Los resultados obtenidos confirman que los sistemas desarrollados pueden clasificar correctamente el desgaste bajo las condiciones de maquinado utilizadas en esta investigación, tanto con una sola red neuronal como haciendo uso de un sistema de validación cruzada de 10 iteraciones, el cual mejora los resultados obtenidos.

#### 4.7 Prospectivas.

Como prospectivas de esta investigación, se podrían utilizar más niveles de desgaste para incrementar el nivel de desgaste que sea posible detectar, haciendo una detección más progresiva que permita una mejor detección y evaluación. También podría realizarse la variación de los parámetros en conjunto, buscando que el sistema sea insensible a dicha variación, consiguiendo una detección del desgaste que permita una implementación ante condiciones de maquinado diversas.

Igualmente, se podría mejorar el procesamiento para permitir una detección en línea del desgaste, implementando el sistema durante el proceso, al modificar el procesamiento inicial para hacer uso de las señales completas o la identificación instantánea del corte sobre la pieza para reducir el impacto del desgaste sobre los maquinados.

# Bibliografía.

Allegro MicroSystems - A1324-A1325-A1326: Low Noise, Linear Hall Effect Sensor ICs with Analog Output. (s. f.). A1324, A1325, A1326: Low Noise, Linear Hall Effect Sensor ICs with Analog Output. Recuperado 4 de junio de 2020 de: <https://www.allegromicro.com/en/Products/Sense/Linear-and-Angular-Position/Linear-Position-Sensor-ICs/A1324-5-6>

Amezquita-Sanchez, J.P.; Valtierra-Rodriguez, M.; Perez-Ramirez, C.A.; Camarena-Martinez, D.; Garcia-Perez, A.; Romero-Troncoso, R.J. (2017) Fractal dimension and fuzzy logic systems for broken rotor bar detection in induction motors at start-up and steady-state regimes. *Meas. Sci. Technol.* 2017, 28, 075001. <https://doi.org/10.1088/1361-6501/aa6adf>.

Antonino-Daviu, J., Razik, H., Quijano-Lopez, A., & Climente-Alarcon, V. (2017, October). Detection of rotor faults via transient analysis of the external magnetic field. In *IECON 2017-43rd Annual Conference of the IEEE Industrial Electronics Society* (pp. 3815-3821). IEEE.

Atli, A. V., Urhan, O. Ğ. U. Z. H. A. N., Ertürk, S. A. R. P., & Sönmez, M. (2006). A computer vision-based fast approach to drilling tool condition monitoring. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 220(9), 1409-1415.

Boehlerit. (s. f.). *Oelfeldtechnologie\_Oilfield\_technology.pdf*. boehlerit.com. Recuperado 8 de febrero de 2022, de [https://www.boehlerit.com/fileadmin/user\\_upload/PDF/Oelfeldtechnologie\\_Oilfield\\_technology.pdf](https://www.boehlerit.com/fileadmin/user_upload/PDF/Oelfeldtechnologie_Oilfield_technology.pdf)

Capolino, G. A., Romary, R., Hénao, H., & Pusca, R. (2019, April). State of the Art on Stray Flux Analysis in Faulted Electrical Machines. In *2019 IEEE Workshop on Electrical Machines Design, Control and Diagnosis (WEMDCD)* (Vol. 1, pp. 181-187). IEEE.

Chen, J. C., & Susanto, V. (2003). Fuzzy logic based in-process tool-wear monitoring system in face milling operations. *The International Journal of Advanced Manufacturing Technology*, 21(3), 186-192.

cncmanual.com. (s. f.). FANUC Serie 0i Mate TC MANUAL DEL OPERADOR B-64134SP/01 pdf - CNC Manual. Recuperado 22 de enero de 2021, de <http://cncmanual.com/fanuc-serie-0i-mate-tc-manual-del-operador-b-64134sp01/>

Coşkun, E. (2020, 12 septiembre). Evolution of Cutting Tools. Sitem. <https://www.ecbyme.com/post/evolution-of-cutting-tools>

Deingenierias.com. (2020, 24 julio). Velocidad de corte avance y parámetros de torneado. De Ingenierías. <https://deingenierias.com/torno/velocidad-de-corte-avance-y-parametros-de-torneado/>

de Jesus, R. T. R., Gilberto, H. R., Ivan, T. V., & Carlos, J. C. J. (2003). Driver current analysis for sensorless tool breakage monitoring of CNC milling machines. *International Journal of Machine Tools and Manufacture*, 43(15), 1529-1534.

de Jesús, R. T. R., Gilberto, H. R., Iván, T. V., & Carlos, J. C. J. (2004). FPGA based on-line tool breakage detection system for CNC milling machines. *Mechatronics*, 14(4), 439-454.

Deng, K. (2016) Fractal. En: Liu, L., & Özsu, T. M. (2018). *Encyclopedia of Database Systems* (2nd 2018 ed.). Springer, New York, NY. <https://doi.org/10.1007/978-1-4614-8265-9>

Díaz Saldaña, G. (2021). *Evaluación del estado de las herramientas de corte en el proceso de torneado a través del análisis del flujo magnético*. [Tesis de licenciatura, Universidad Autónoma de Querétaro, Facultad de Ingeniería]. Repositorio Institucional – Universidad Autónoma de Querétaro. <http://ri-ng.uaq.mx/handle/123456789/2927>

Ding, C. (2016) Dimension Reduction Techniques for Clustering. En Liu, L., & Özsu, T. M. (2018). Encyclopedia of Database Systems (2nd 2018 ed.). Springer, New York, NY. <https://doi.org/10.1007/978-1-4614-8265-9>

Fatemi, S. M. J. R., Henao, H., & Capolino, G. A. (2008). Gearbox monitoring by using the stray flux in an induction machine based electromechanical system. MELECON 2008 - The 14th IEEE Mediterranean Electrotechnical Conference. doi:10.1109/melcon.2008.4618482

Fluke. (s. f.). Pinza de corriente de CA Fluke i3000s Flex-24, 610 mm (24 in). Recuperado 8 de febrero de 2022, de <https://www.fluke.com/es-mx/producto/accesorios/pinzas-de-corriente/fluke-i3000s-flex-24>

Frosini, L., Harlisca, C., & Szabo, L. (2015). Induction Machine Bearing Fault Detection by Means of Statistical Processing of the Stray Flux Measurement. IEEE Transactions on Industrial Electronics, 62(3), 1846–1854. doi:10.1109/tie.2014.2361115

Fu, P., Hope, A. D., & King, G. A. (2001). On-line tool condition monitoring based on a neurofuzzy intelligent signal feature classification procedure. In Practical Applications of Soft Computing in Engineering (pp. 183-197).

Ghosh, S., Naskar, S. K., & Mandal, N. K. (2018). Estimation of residual life of a cutting tool used in a machining process. In MATEC Web of Conferences (Vol. 192, p. 01017). EDP Sciences.

Haraguchi, N., Cheng, C. F. C., & Smeets, E. (2017). The importance of manufacturing in economic development: Has this changed? World Development, 93, 293-315.

Higuchi, T. (1988). Approach to an irregular time series on the basis of the fractal theory. Physica D: Nonlinear Phenomena, 31(2), 277-283.

Jiang, C., Li, S., & Habetler, T. G. (2017). A review of condition monitoring of induction motors based on stray flux. 2017 IEEE Energy Conversion Congress and Exposition (ECCE). doi:10.1109/ecce.2017.8096907

Jun, M. B., Ozdoganlar, O. B., DeVor, R. E., Kapoor, S. G., Kirchheim, A., & Schaffner, G. (2002). Evaluation of a spindle-based force sensor for monitoring and fault diagnosis of machining operations. *International Journal of Machine Tools and Manufacture*, 42(6), 741-751.

Kalpakjian, S.; Schmid, S.R. (2008). *Manufactura ingeniería y tecnología*, 5 edición; México, D.F.: Pearson Educación.

Kamperidou, V., & Barbutis, I. (2013). Lathe tool-it's development from the ancient times to nowadays. In *Wood is good-user oriented material, technology and design. Proceedings of the 24th International Scientific Conference, Zagreb, Croatia, 18th October 2013* (pp. 57-64). Faculty of Forestry, University of Zagreb.

Katz, M. J. (1988). Fractals and the analysis of waveforms. *Computers in biology and medicine*, 18(3), 145-156. [https://doi.org/10.1016/0010-4825\(88\)90041-8](https://doi.org/10.1016/0010-4825(88)90041-8)

Kene, A. P., & Choudhury, S. K. (2019). Analytical modeling of tool health monitoring system using multiple sensor data fusion approach in hard machining. *Measurement*. doi:10.1016/j.measurement.2019.05.062

Kuntoğlu, M., Aslan, A., Pimenov, D. Y., Usca, Ü. A., Salur, E., Gupta, M. K., ... & Sharma, S. (2021). A Review of Indirect Tool Condition Monitoring Systems and Decision-Making Methods in Turning: Critical Analysis and Trends. *Sensors*, 21(1), 108.

Kuntoğlu, M., & Sağlam, H. (2019). Investigation of Progressive Tool Wear for Determining of Optimized Machining Parameters in Turning. *Measurement*. doi:10.1016/j.measurement.2019.04.022

Kuntoğlu, M., & Sağlam, H. (2020). Investigation of Signal Behaviors for Sensor Fusion with Tool Condition Monitoring System in Turning. *Measurement*, 108582. doi:10.1016/j.measurement.2020.108582

Li, T., Shi, T., Tang, Z., Liao, G., Duan, J., Han, J., & He, Z. (2020). Real-time tool wear monitoring using thin-film thermocouple. *Journal of Materials Processing Technology*, 116901. doi:10.1016/j.jmatprotec.2020.116901

Li, X., Tso, S. K., & Wang, J. (2000). Real-time tool condition monitoring using wavelet transforms and fuzzy techniques. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 30(3), 352-357.

Li, Y., Mou, W., Li, J., Liu, C., & Gao, J. (2021). An automatic and accurate method for tool wear inspection using grayscale image probability algorithm based on bayesian inference. *Robotics and Computer-Integrated Manufacturing*, 68, 102079. doi:10.1016/j.rcim.2020.102079

Liu, M.-K., Tseng, Y.-H., & Tran, M.-Q. (2019). Tool wear monitoring and prediction based on sound signal. *The International Journal of Advanced Manufacturing Technology*. doi:10.1007/s00170-019-03686-2

Mikołajczyk, T., Nowicki, K., Bustillo, A., & Yu Pimenov, D. (2018). Predicting tool life in turning operations using neural networks and image processing. *Mechanical Systems and Signal Processing*, 104, 503–513. doi:10.1016/j.ymssp.2017.11.022

Moreno-Gil, J. S. (1998). *Procedimientos estadísticos*. ESIC.

Mota Valtierra, G. del C. (2019). *Desarrollo de un sistema inteligente para monitoreo de falla en procesos de fresado en máquina CNC*. [Tesis de doctorado, Universidad Autónoma de Querétaro, Facultad de Ingeniería]. Repositorio Institucional – Universidad Autónoma de Querétaro. <http://ri-ng.uaq.mx/handle/123456789/1843>

Neslušán, M., Mičičeta, B., Mičičetová, A., Čilliková, M., & Mrkvica, I. (2015). Detection of tool breakage during hard turning through acoustic emission at low removal rates. *Measurement*, 70, 1–13. doi:10.1016/j.measurement.2015.03.035

Pai, P. S., & Rao, P. K. R. (2002). Acoustic emission analysis for tool wear monitoring in face milling. *International Journal of Production Research*, 40(5), 1081–1093. doi:10.1080/00207540110107534

Patra, K. (2011, July). Acoustic emission based tool condition monitoring system in drilling. In *Proceedings of the world congress on engineering* (Vol. 3, pp. 6-8).

Polikar, R. (1996). *The wavelet tutorial*.

Prieto, M. D., Cirrincione, G., Espinosa, A. G., Ortega, J. A., & Henao, H. (2013). Bearing Fault Detection by a Novel Condition-Monitoring Scheme Based on Statistical-Time Features and Neural Networks. *IEEE Transactions on Industrial Electronics*, 60(8), 3398–3407. doi:10.1109/tie.2012.2219838

Refaeilzadeh P., Tang L., Liu H. (2016) Cross-Validation. En: Liu, L., & Özsu, T. M. (2018). *Encyclopedia of Database Systems* (2nd 2018 ed.). Springer, New York, NY. <https://doi.org/10.1007/978-1-4614-8265-9>

Rehorn, A. G., Jiang, J., & Orban, P. E. (2005). State-of-the-art methods and results in tool condition monitoring: a review. *The International Journal of Advanced Manufacturing Technology*, 26(7-8), 693-710.

Rizal, A., Hidayat, R., & Nugroho, H. A. (2017, November). Multilevel wavelet packet entropy: A new strategy for lung sound feature extraction based on wavelet entropy. In *2017 International Conference on Robotics, Automation and Sciences (ICORAS)* (pp. 1-5). IEEE.

Romary, R., Pusca, R., Lecointe, J. P., & Brudny, J. F. (2013, March). Electrical machines fault diagnosis by stray flux analysis. In *2013 IEEE Workshop on Electrical Machines Design, Control and Diagnosis (WEMDCD)* (pp. 247-256). IEEE.

Romero Troncoso, R. de J. (2004). *Procesamiento de señales para la detección de ruptura de herramientas en sistemas de manufactura por control*

*numérico computarizado*. [Tesis de doctorado, Universidad Autónoma de Querétaro, Facultad de Ingeniería].

Ross, S. M. (2007). *Introducción a la estadística*. Reverté.

Salem, S. B., Salah, M., Touti, W., Bacha, K., & Chaari, A. (2017). Stray Flux analysis for monitoring eccentricity faults in induction motors: Experimental study. 2017 International Conference on Control, Automation and Diagnosis (ICCAD). doi:10.1109/cadiag.2017.8075673

Salgado, D. R., & Alonso, F. J. (2007). An approach based on current and sound signals for in-process tool wear monitoring. *International Journal of Machine Tools and Manufacture*, 47(14), 2140–2152. doi:10.1016/j.ijmachtools.2007.04.013

Saucedo Dorantes, J. J. (2017). *Metodologías para mejorar la confiabilidad del diagnóstico de fallas en cadenas cinemáticas basado en algoritmos inteligentes y fusión de datos*. [Tesis de doctorado, Universidad Autónoma de Querétaro]. Repositorio Institucional – Universidad Autónoma de Querétaro. <http://ri-ng.uaq.mx/handle/123456789/1336>

Seland, D. (2021, 17 febrero). A ‘cutting’ history of accuracy. *Quality Magazine*. <https://www.qualitymag.com/articles/96391-a-cutting-history-of-accuracy>

Sevilla Camacho, P. Y. (2012). *Detección de fallas de herramientas de corte en maquinado CNC de alta velocidad*. [Tesis de doctorado, Universidad Autónoma de Querétaro, Facultad de Ingeniería].

Sevilla-Camacho, P. Y., Herrera-Ruiz, G., Robles-Ocampo, J. B., & Jáuregui-Correa, J. C. (2011). Tool breakage detection in CNC high-speed milling based in feed-motor current signals. *The International Journal of Advanced Manufacturing Technology*, 53(9-12), 1141-1148.

SimpleLink™ MSP432P401R high-precision ADC LaunchPad™ Development Kit. (s. f.). Texas Instruments. Recuperado 4 de julio de 2020, de <https://www.ti.com/tool/MSP-EXP432P401R>

Singhal, R., Kumar, A., Zafar, S., & Dutt, V. (2020). Evaluating Statistical Approaches for Tool Condition Monitoring in Drilling. *Optimization Methods in Engineering: Select Proceedings of CPIE 2019*, 21.

Summit Machine Tool. (2020, 5 noviembre). When Was The Metal-Working Lathe Invented? <https://summitmt.com/when-was-the-metal-working-lathe-invented/>

Trejo Hernández, M. (2010). *Monitoreo, análisis y modelado fenomenológico del desgaste de la herramienta bajo condiciones de corte variables en torno CNC*. [Tesis de doctorado, Universidad Autónoma de Querétaro, Facultad de Ingeniería]. Repositorio Institucional – Universidad Autónoma de Querétaro. <http://ri-ng.uaq.mx/handle/123456789/966>

UNISON TEK CO., LTD. (2019, 5 septiembre). History of metal processing: traditional lathe, numerical control NC lathe and computer numerical control CNC (Computer Numerical Control) machine tool. <https://unisontekco.com/history-of-metal-processing-traditional-lathe-numerical-control-nc-lathe-and-computer-numerical-control-cnc-computer-numerical-control-machine-tool/>

Wang, G., & Grosu, R. (2017). Milling-tool wear-condition prediction with statistic analysis and echo-state networks. *Challenges Technol. Innov*, 149-153.

Wang, G., Zhang, Y., Liu, C., Xie, Q., & Xu, Y. (2016). A new tool wear monitoring method based on multi-scale PCA. *Journal of Intelligent Manufacturing*. doi:10.1007/s10845-016-1235-9

Zamudio-Ramirez, I., Osornio-Rios, R. A. A., Antonino-Daviu, J. A., Razik, H., & de Jesus Romero-Troncoso, R. (2021). Magnetic flux analysis for the condition monitoring of electric machines: a review. *IEEE Transactions on Industrial Informatics*.

Zamudio-Ramirez, I., Osornio-Rios, R. A., Trejo-Hernandez, M., Romero-Troncoso, R. D. J., & Antonino-Daviu, J. A. (2019). Smart-Sensors to Estimate Insulation Health in Induction Motors via Analysis of Stray Flux. *Energies*, 12(9), 1658.

Zamudio-Ramirez, I., Ramirez-Nunez, J. A., Antonino-Daviu, J., Osornio-Rios, R. A., Quijano-Lopez, A., Razik, H., & Romero-Troncoso, R. J. (2020). Automatic diagnosis of electromechanical faults in induction motors based on the transient analysis of the stray flux via MUSIC methods. *IEEE Transactions on Industry Applications*, 1–1. doi:10.1109/tia.2020.298800

# Apéndice I. Artículos publicados.

Publicación del artículo “Relación entre Profundidad de Corte vs Desgaste de Herramientas en Torno CNC mediante el Procesamiento del Flujo Magnético Residual” en el Congreso Internacional de Investigación de Academia Journals Hidalgo 2021. Incluido en las siguientes publicaciones:

1. En el portal de Internet academiajournals.com, con ISSN 1946-5351 online, Vol. 13, 2021, #9 e indexación en la base de datos Fuente Académica Plus de EBSCOHOST, Massachusetts, Estados Unidos.
2. En el libro digital e-book titulado “Trabajos de Investigación en la Educación Superior - Hidalgo 2021”, con ISBN 978-1-939982-88-9 online.

## Relación entre Profundidad de Corte vs Desgaste de Herramientas en Torno CNC mediante el Procesamiento del Flujo Magnético Residual

Ing. Geovanni Díaz Saldaña<sup>1</sup>, Dr. Miguel Trejo Hernández<sup>2</sup>, Dr. Arturo Yosimar Jaen Cuellar<sup>3</sup>, Ing. José Pablo Pacheco Guerrero<sup>4</sup>, M.C. Israel Zamudio Ramírez<sup>5</sup>, Dr. Roque Alfredo Osornio Ríos<sup>6</sup>.

**Resumen**— El desgaste de las herramientas de corte es de gran importancia en la industria de la manufactura debido a su impacto en la calidad de las piezas fabricadas y costos de producción. Desde siempre se han desarrollado diversas técnicas de análisis para detectar y evaluar el desgaste en herramientas considerando variables físicas invasivas como corriente eléctrica, vibraciones o fuerza. Son pocos los estudios realizados entre la relación de los parámetros de corte y el desgaste en las herramientas. El análisis de flujo magnético de dispersión en máquinas de inducción ha sido estudiado últimamente como herramienta para detectar y analizar fallas, por lo que en este trabajo se utiliza el análisis del flujo magnético del motor del husillo de un torno CNC para evaluar el nivel de desgaste en herramientas de corte, considerando la variación de la profundidad de corte en el maquinado, y utilizando una metodología para el análisis basada en tiempo-frecuencia. La eficiencia de la metodología se demostró en diversas probetas maquinadas con herramientas de distintos niveles de fallo, consiguiendo relacionar el flujo disperso con el nivel de desgaste presentado en las herramientas analizadas.

**Palabras clave**— Desgaste en herramientas, flujo magnético de dispersión, motor de inducción, torno CNC, profundidad de corte.

### Introducción

La industria de la manufactura es un segmento de gran importancia en el desarrollo económico de las naciones (Haraguchi et al., 2017), y dentro de ella, el estado de las herramientas de corte empleadas dentro de los procesos es esencial ya que su estado afecta directamente a la calidad de las piezas producidas y su impacto económico es considerable, ya que hasta 25% del costo del maquinado se destina a herramientas y su falla es responsable de hasta 20% del tiempo de inactividad dentro de los procesos (Ghosh et al., 2018).

Es por lo anterior, que se han desarrollado diversas técnicas para evaluar el estado de las herramientas de corte dentro de los procesos de manufactura, siendo estas de naturaleza variada, considerando distintas variables físicas presentes dentro de los procesos: corriente consumida por los servomotores de la máquina-herramienta (Sevilla et al., 2011), fuerzas o vibraciones de la herramienta (Luo et al., 2018), emisiones acústicas (Neslušan et al., 2015), e inclusive la utilización de sistemas de visión por computadora (Thakre et al., 2019) y la combinación de distintas variables para mejorar el diagnóstico (Trejo et al., 2010) (Juregui et al., 2018). Sin embargo, estas técnicas presentan la desventaja de un carácter invasivo dentro del proceso y algunas de ellas se pueden ver afectadas por elementos propios de las operaciones de maquinado, como los sistemas de visión artificial con el uso de fluidos al maquinar. Igualmente, dentro de los procesos de maquinado existen diversos parámetros de diseño en la pieza a maquinar que influyen en la vida útil de las herramientas, siendo de los más importantes en el proceso de torneado la profundidad y la velocidad de corte, por lo que resulta importante conocer y proponer técnicas que relacionen la variación de dichos parámetros con el desgaste de la herramienta.

Por otra parte, el flujo magnético residual, de dispersión o parásito, ha sido empleado durante años para el diagnóstico del estado de máquinas de inducción, siendo capaz de detectar fallas de carácter mecánico, como fallas en los rodamientos (Frosini et al., 2014), así como fallas eléctricas como barras rotas (Park et al., 2018) (Ramírez-Núñez et al., 2018) y degradación del aislamiento (Zamudio-Ramírez et al., 2019); esto debido a que el flujo magnético está relacionado directamente al estado de la máquina, al igual que la corriente, y su naturaleza permite la obtención de información de manera no invasiva, la cual permite obtener resultados satisfactorios comparables a otras metodologías, como el análisis de corriente.

<sup>1</sup> Alumno de la Maestría en Ciencias (Mecatrónica) en la Universidad Autónoma de Querétaro.  
gdiaz17@alumnos.uaq.mx

<sup>2</sup> Profesor-Investigador en la Universidad Autónoma de Querétaro. mtrejo@hspdigital.org

<sup>3</sup> Profesor-Investigador en la Universidad Autónoma de Querétaro. ayjaen@hspdigital.org

<sup>4</sup> Alumno en la Universidad Autónoma de Querétaro. jpacheco10@alumnos.uaq.mx

<sup>5</sup> Alumno del Doctorado en Mecatrónica en la Universidad Autónoma de Querétaro.  
izamudio13@alumnos.uaq.mx

<sup>6</sup> Profesor-Investigador en la Universidad Autónoma de Querétaro (autor corresponsal).  
raosornio@hspdigital.org

## Relación entre Profundidad de Corte vs Desgaste de Herramientas en Torno CNC mediante el Procesamiento del Flujo Magnético Residual

Ing. Geovanni Díaz Saldaña<sup>1</sup>, Dr. Miguel Trejo Hernández<sup>2</sup>, Dr. Arturo Yosimar Jaen Cuellar<sup>3</sup>, Ing. José Pablo Pacheco Guerrero<sup>4</sup>, M.C. Israel Zamudio Ramírez<sup>5</sup>, Dr. Roque Alfredo Osornio Ríos<sup>6</sup>.

**Resumen**— El desgaste de las herramientas de corte es de gran importancia en la industria de la manufactura debido a su impacto en la calidad de las piezas fabricadas y costos de producción. Desde siempre se han desarrollado diversas técnicas de análisis para detectar y evaluar el desgaste en herramientas considerando variables físicas invasivas como corriente eléctrica, vibraciones o fuerza. Son pocos los estudios realizados entre la relación de los parámetros de corte y el desgaste en las herramientas. El análisis de flujo magnético de dispersión en máquinas de inducción ha sido estudiado últimamente como herramienta para detectar y analizar fallas, por lo que en este trabajo se utiliza el análisis del flujo magnético del motor del husillo de un torno CNC para evaluar el nivel de desgaste en herramientas de corte, considerando la variación de la profundidad de corte en el maquinado, y utilizando una metodología para el análisis basada en tiempo-frecuencia. La eficiencia de la metodología se demostró en diversas probetas maquinadas con herramientas de distintos niveles de fallo, consiguiendo relacionar el flujo disperso con el nivel de desgaste presentado en las herramientas analizadas.

**Palabras clave**— Desgaste en herramientas, flujo magnético de dispersión, motor de inducción, torno CNC, profundidad de corte.

### Introducción

La industria de la manufactura es un segmento de gran importancia en el desarrollo económico de las naciones (Haraguchi et al., 2017), y dentro de ella, el estado de las herramientas de corte empleadas dentro de los procesos es esencial ya que su estado afecta directamente a la calidad de las piezas producidas y su impacto económico es considerable, ya que hasta 25% del costo del maquinado se destina a herramientas y su falla es responsable de hasta 20% del tiempo de inactividad dentro de los procesos (Ghosh et al., 2018).

Es por lo anterior, que se han desarrollado diversas técnicas para evaluar el estado de las herramientas de corte dentro de los procesos de manufactura, siendo estas de naturaleza variada, considerando distintas variables físicas presentes dentro de los procesos: corriente consumida por los servomotores de la máquina-herramienta (Sevilla et al., 2011), fuerzas o vibraciones de la herramienta (Luo et al., 2018), emisiones acústicas (Neslušan et al., 2015), e inclusive la utilización de sistemas de visión por computadora (Thakre et al., 2019) y la combinación de distintas variables para mejorar el diagnóstico (Trejo et al., 2010) (Jáuregui et al., 2018). Sin embargo, estas técnicas presentan la desventaja de un carácter invasivo dentro del proceso y algunas de ellas se pueden ver afectadas por elementos propios de las operaciones de maquinado, como los sistemas de visión artificial con el uso de fluidos al maquinar. Igualmente, dentro de los procesos de maquinado existen diversos parámetros de diseño en la pieza a maquinar que influyen en la vida útil de las herramientas, siendo de los más importantes en el proceso de torneado la profundidad y la velocidad de corte, por lo que resulta importante conocer y proponer técnicas que relacionen la variación de dichos parámetros con el desgaste de la herramienta.

Por otra parte, el flujo magnético residual, de dispersión o parásito, ha sido empleado durante años para el diagnóstico del estado de máquinas de inducción, siendo capaz de detectar fallas de carácter mecánico, como fallas en los rodamientos (Frosini et al., 2014), así como fallas eléctricas como barras rotas (Park et al., 2018) (Ramírez-Núñez et al., 2018) y degradación del aislamiento (Zamudio-Ramírez et al., 2019); esto debido a que el flujo magnético está relacionado directamente al estado de la máquina, al igual que la corriente, y su naturaleza permite la obtención de información de manera no invasiva, la cual permite obtener resultados satisfactorios comparables a otras metodologías, como el análisis de corriente.

<sup>1</sup> Alumno de la Maestría en Ciencias (Mecatrónica) en la Universidad Autónoma de Querétaro.  
gdiaz17@alumnos.uaq.mx

<sup>2</sup> Profesor-Investigador en la Universidad Autónoma de Querétaro. mtrejo@hspdigital.org

<sup>3</sup> Profesor-Investigador en la Universidad Autónoma de Querétaro. ayjaen@hspdigital.org

<sup>4</sup> Alumno en la Universidad Autónoma de Querétaro. jpacheco10@alumnos.uaq.mx

<sup>5</sup> Alumno del Doctorado en Mecatrónica en la Universidad Autónoma de Querétaro.  
izamudio13@alumnos.uaq.mx

<sup>6</sup> Profesor-Investigador en la Universidad Autónoma de Querétaro (autor correspondiente).  
raosornio@hspdigital.org

Con las bases de esta investigación, se realizó la publicación como colaborador del artículo “System for Tool-Wear Condition Monitoring in CNC Machines under Variations of Cutting Parameter Based on Fusion Stray Flux-Current Processing” en el Journal “Sensors”, Special Issue Sensing Technology and Data Interpretation in Machine Diagnosis and Systems Condition Monitoring: Part B, <https://doi.org/10.3390/s21248431>

# System for Tool-Wear Condition Monitoring in CNC Machines under Variations of Cutting Parameter Based on Fusion Stray Flux-Current Processing

Arturo Yosimar Jaen-Cuellar<sup>1</sup>, Roque Alfredo Osornio-Ríos<sup>1</sup>, Miguel Trejo-Hernández<sup>1</sup>, Israel Zamudio-Ramírez<sup>1,2</sup>, Geovanni Díaz-Saldaña<sup>1</sup>, José Pablo Pacheco-Guerrero<sup>1</sup> and Jose Alfonso Antonino-Daviu<sup>2\*</sup>

<sup>1</sup> CA Mecatrónica, Facultad de Ingeniería, Campus San Juan del Río, Universidad Autónoma de Querétaro, Av. Río Mochtezuma 249, San Juan del Río, Querétaro 76807, Mexico; ayjaen@hspdigital.org (A.Y.J.-C.); raosornio@hspdigital.org (R.A.O.-R.); mtrejo@hspdigital.org (M.T.-H.); iszara@doctor.upv.es (I.Z.-R.); gdiaz17@alumnos.uaq.mx (G.D.-S.); jpacheco10@alumnos.uaq.mx (J.P.G.)

<sup>2</sup> Instituto Tecnológico de la Energía, Universitat Politècnica de València (UPV), Camino de Vera s/n, 46022 Valencia, Spain

\* Correspondence: joanda@die.upv.es; Tel.: +34-96387-7992

**Citation:** Jaen-Cuellar, A.Y.; Osornio-Ríos, R.A.; Trejo-Hernández, M.; Zamudio-Ramírez, I.; Díaz-Saldaña, G.; Pacheco-Guerrero, J.P.; Antonino-Daviu, J.A. System for Tool Wear Condition Monitoring in CNC Machine under Variation of Cutting Parameter Based on Fusion Stray Flux-Current Processing. *Sensors* **2021**, *21*, 8431. <https://doi.org/10.3390/s21248431>

**Academic Editors:** Rafal Burdzik, Mirvydas Ragalinskis, Maosen Cao, Radosław Zimroz, Chuan Fakher, Lukasz Konieczny and Guillermo Villanueva

Received: 26 October 2021

Accepted: 16 December 2021

Published: 17 December 2021

**Publisher's Note:** MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



**Copyright:** © 2021 by the author. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

**Abstract:** The computer numerical control (CNC) machine has recently taken a fundamental role in the manufacturing industry, which is essential for the economic development of many countries. Current high quality production standards, along with the requirement for maximum economic benefits, demand the use of tool condition monitoring (TCM) systems able to monitor and diagnose cutting tool wear. Current TCM methodologies mainly rely on vibration signals, cutting force signals, and acoustic emission (AE) signals, which have the common drawback of requiring the installation of sensors near the working area, a factor that limits their application in practical terms. Moreover, as machining processes require the optimal tuning of cutting parameters, novel methodologies must be able to perform the diagnosis under a variety of cutting parameters. This paper proposes a novel non-invasive method capable of automatically diagnosing cutting tool wear in CNC machines under the variation of cutting speed and feed rate cutting parameters. The proposal relies on the sensor information fusion of spindle-motor stray flux and current signals by means of statistical and non-statistical time-domain parameters, which are then reduced by means of a linear discriminant analysis (LDA); a feed-forward neural network is then used to automatically classify the level of wear on the cutting tool. The proposal is validated with a Fanuc Oi mate Computer Numeric Control (CNC) turning machine for three different cutting tool wear levels and different cutting speed and feed rate values.

**Keywords:** condition monitoring; tool wear; cutting speed; feed rate; sensors fusion; stray flux; ac current

## 1. Introduction

The manufacturing industry has been a fundamental and highly relevant sector in the economic development of many countries [1]. In this regard, the computer numerical control (CNC) machine has taken a fundamental role and is involved in many manufacturing industries. In order to obtain an increased quality production, along with maximum economic benefits (one of the main objectives pursued by the involved companies), industrial processes must be optimized by means of the different factors that can strongly influence manufacturing expenses, such as cutting tool costs, electricity costs, machining efficiency, and machined surface quality [2]. As reported in [3,4], the costs of machining and replacing the cutting tool can represent up to 25% of the total production costs, and even a slight reduction of machine cutting tool downtime improves the production rate significantly [5]. These figures and facts highlight the necessity of using cutting tools in

Igualmente, se escribió el artículo titulado “CNC lathe tool wear analysis using image processing and stray flux”, enviado al congreso internacional “IECON 2022 The 48th Annual Conference of the IEEE Industrial Electronics Society” a llevarse a cabo del 17 al 20 de octubre de 2022 en Bruselas, para la sesión especial SS1 - Advanced signal and image processing techniques for condition monitoring of Electric Machines and Drives. El artículo se encuentra en revision.

# CNC lathe tool wear analysis using image processing and stray flux

Geovanni Diaz-Saldaña  
Facultad de Ingeniería.  
Universidad Autónoma de Querétaro.  
Campus San Juan del Río, San Juan del Río,  
76807, Querétaro, México  
gdiazl7@alumnos.uaq.mx

Roque A. Osorio-Rios  
Facultad de Ingeniería.  
Universidad Autónoma de Querétaro.  
Campus San Juan del Río, San Juan del Río,  
76807, Querétaro, México  
raosorio@hsdigital.org

Irving Armando Cruz-Albarran  
Facultad de Ingeniería.  
Universidad Autónoma de Querétaro.  
Campus San Juan del Río, San Juan del Río,  
76807, Querétaro, México  
icruz@hsdigital.org

Miguel Trejo-Hernandez  
Facultad de Ingeniería.  
Universidad Autónoma de Querétaro.  
Campus San Juan del Río, San Juan del Río, 76807, Querétaro,  
México  
mtrejo@hsdigital.org

Jose A. Antonino-Daviu  
Instituto Tecnológico de la Energía  
Universitat Politècnica de València (UPV).  
Camino de Vera s/n, 46022, Valencia, Spain  
joanda@die.upv.es

**Abstract**— Within the manufacturing industry, the condition of cutting tools directly impacts the quality and costs of machining, which has driven the development of various methodologies to identify and monitor tool wear. In recent years, the stray magnetic flux has started to be used as a physical variable for wear detection, giving good results both individually and in combination with other physical quantities. The present research proposes the analysis of stray magnetic flux signals in a CNC lathe in conjunction with image analysis of the machined surfaces and the cutting tools in order to detect tool flank wear with cutting speed variation in the machining of 6061 aluminum. The results report the correct detection of the different levels of wear, demonstrating the ability of each of the methodologies to detect the level of wear regardless of the cutting speed used for machining, as well as the future improvement with the fusion of the techniques to obtain more reliable results for a robust detection system.

**Keywords**—CNC, tool wear, stray flux, image processing, cutting speed.

## I. INTRODUCTION

Industrialization and manufacturing industry have played a fundamental role in the economic growth of developing nations [1]. The objective of the manufacturing industry is the production of economical, reliable and high-quality supplies, which focuses on the surface finishes and the dimensional accuracy of the parts that largely depends on the condition of the cutting tools. Failures related to cutting tools imply an impact on production processes, being responsible for up to 20% of downtime and up to 25% of the machining cost, in addition to being used in 70-80% of their optimal life [2]. Therefore, the

This work was supported in part by the Spanish 'Ministerio de Ciencia Innovación y Universidades' and FEDER program in the framework of the 'Proyectos de I+D de Generación de Conocimiento del Programa Estatal de Generación de Conocimiento y Fortalecimiento Científico y Tecnológico del Sistema de I+D+i, Subprograma Estatal de Generación de Conocimiento' (ref. PGC2018-095747-B-I00).

development of reliable and accurate tool condition monitoring systems (TCMS) remains of great relevance, as they can reduce machining costs by 10-40% by reducing downtime and maximizing tool life [3].

Several TCMS have been developed in the turning process, mainly considering flank wear (FW). The methodologies developed are divided into two: direct methods, which require the measurement of wear by capturing images of the tool, and indirect methods, which require the use of sensors to measure physical variables during the machining process and establish relationships between them and tool wear. Regarding the direct methods, the methodologies are diverse, e.g.: in [4], a methodology for wear prediction is developed through images of the machined surface using various texture analysis and direct measurement of the worn area for validation; in [5], a direct measurement of flank wear is performed through images of the tool by implementing an artificial vision system in the work area, validated with measurements made offline with a digital microscope. Regarding the indirect methods, in [6] a review of the methodologies developed in the last two decades is carried out, pointing out the use of various sensors to measure variables such as cutting force, current, acoustic emission, vibrations, temperature, sound and image processing, as well as the trend towards sensor fusion to generate more robust systems. In many of these cases, the placement of the sensors is near the work area, so they can be invasive for the machining process. Moreover, the use of vision systems can be affected by elements of the process such as the use of coolants or performed offline after machining, as well as high costs for the use of some sensors.

In recent years, the stray magnetic flux (SF) has been used as a variable for the detection of tool wear, as reported in [7-9], providing good results in the identification and classification of tool wear, making use of several analysis techniques such as the Short Time Fourier Transform (STFT) [7], the Discrete Wavelet Transform (DWT) [8, 9], statistical and non-statistical indicators [8, 9] and the fusion of data with other physical variables [9]. In

## Apéndice II. Software desarrollado.

Los archivos en C desarrollados durante la investigación se encuentran en una carpeta compartida, a la que se puede acceder con el siguiente link:

<https://drive.google.com/drive/folders/19XD5k-FrwLoJZbzgk2A6P3wiT6-HWXZ7?usp=sharing>

Se encuentran divididos en carpetas, una por cada función desarrollada:

- `statistic_analysis`: corresponde a la función utilizada para la lectura de las señales, acondicionamiento y cálculo de los indicadores estadísticos y no estadísticos para cada uno de los parámetros de maquinado.
- `toolwearLDA`: corresponde a la función diseñada para la disminución de la dimensionalidad de la matriz de indicadores.
- `clasificacionRN`: corresponde a la función para el análisis de la información obtenida del uso de LDA, permitiendo analizar la información según el parámetro de maquinado y el uso de una red neuronal o validación cruzada.