

# Monitoreo de herramientas de corte con sonido y Aprendizaje Máquina

Carlos A. Catalán Catalán<sup>a</sup>, Horacio Canales Siller<sup>b</sup>, Celos E. Cruz González<sup>c</sup>, Mauricio Torres Arellano<sup>d</sup>

<sup>a</sup>Posgrado Interinstitucional CIDESI. Av. Pie de la Cuesta No.702, Desarrollo San Pablo, 76125 Santiago de Querétaro, Qro.

<sup>b</sup>Dirección de Tecnologías Estratégicas. Av. Pie de la Cuesta No. 702, Desarrollo San Pablo, 76125 Santiago de Querétaro, Qro.  
Gerencia de Construcción Mecánica. Dirección de Ingeniería Mecánica. Av. Pie de la Cuesta  
No. 702, Desarrollo San Pablo, 76125 Santiago de Querétaro, Qro.

<sup>d</sup>Dirección de Ingeniería Mecánica. Av. Pie de la Cuesta No. 702, Desarrollo San Pablo, 76125 Santiago de Querétaro, Qro.

Correspondencia: [carlos.catalan@posgrado.cidese.edu.mx](mailto:carlos.catalan@posgrado.cidese.edu.mx); [horaciocanales@gmail.com](mailto:horaciocanales@gmail.com); [ecruz@cidese.edu.mx](mailto:ecruz@cidese.edu.mx); [mauricio.torres@cidese.edu.mx](mailto:mauricio.torres@cidese.edu.mx).

## Resumen

En este trabajo, se presenta una metodología para detectar el estado de desgaste en cortadores a través de clasificación del sonido durante operaciones de fresado. El sonido fue grabado durante operaciones de fresado vertical con diferentes cortadores y diferente estado de desgaste (nuevos, desgastados y despostillados); el estado del desgaste fue determinado mediante la medición de la masa de cada cortador antes de las operaciones. Después del maquinado, una tarea de transferencia de conocimiento fue empleado para construir un modelo de clasificación particular para la tarea. Lo anterior se realizó utilizando una arquitectura de red neuronal convolucional llamada VGG16. Las señales acústicas fueron representadas como espectrogramas para entrenar el modelo de clasificación. Tres métricas fueron empleadas para medir el desempeño del modelo, generando una exactitud del 97.5% en el peor resultado. Finalmente, el método presentado en este trabajo puede ser empleado para el desarrollo de herramientas de monitoreo para incrementar la eficiencia del uso de herramientas, materias primas y tiempo de trabajo para brindar apoyo a talleres.

**Palabras clave:** maquinados cnc, aprendizaje máquina, monitoreo por sonido, confiabilidad de la herramienta

## Abstract

In this work, it is presented a methodology to detect tool wear states during a milling operation through sound classification. The sound was recorded during milling operations for end-mills with different wear states (brand new, worn and chipped); the wear states were determined by measuring their mass before each cutting operation. After machining, a transfer learning task was implemented for custom classification of the sound. The above, by using the VGG16 deep neural network architecture. The sound data were represented as spectrogram images for the classification model training. Three different metrics were used to measure the model performance, showing 97.5 % in the worst result. In addition, the results showed that sound data have enough information to train classification models for cutting tools wear detection. Finally, the method presented in this paper can be used for the development of monitoring tools for the support of machining workshops; thus increase the efficiency of their tools, raw materials, and machining time.

**Keywords:** cnc machining, machine learning, sound monitoring, tool soundness

---

Artículo arbitrado

---

Recibido:

15 de octubre de 2022

Aceptado:

04 de noviembre de 2022

## Introducción

Las planeaciones de la producción y de las tareas son actualmente de suma importancia en los talleres productivos. Se podría decir que están presentes en las bases de la industria moderna. El desgaste prematuro o falla de las herramientas de corte es probablemente el problema más importante en los talleres de maquinado. Esto se debe a que, una vez que los filos de una herramienta se rompen, pueden crear defectos en el producto en cualquier fase de producción. Lo anterior tiene como consecuencia el desperdicio de las materias primas, así como del tiempo de maquinado, costo de energía y horas de labor (TechSolve, 2022). Por esta razón, un área de interés de la investigación y la tecnología es la minimización de la probabilidad de falla de las herramientas de corte. El monitoreo de las condiciones de las herramientas no es un tema nuevo cuando se trata de optimizar recursos en los talleres. Teti y sus colaboradores (2010) resumen una serie de sensores, técnicas de procesamiento de señales y estrategias de decisión para el monitoreo de la calidad durante el proceso de maquinado. Diferentes técnicas y enfoques han sido aplicados para lograr sistemas de monitoreo de las condiciones de las herramientas (TCMs). Snr, D. E. D. (2000) presenta un resumen de algunos métodos que han sido usados para el desarrollo de este tipo de sistemas.

Rizal y sus colaboradores (2017) analizaron cómo detectar y clasificar el desgaste de las herramientas en operaciones de fresado utilizando un arreglo de múltiples sensores y un sistema Mahalanobis-Taguchi (MTS) con herramientas de acero AISI P20+Ni. Las condiciones de las herramientas utilizadas fueron catalogadas como afiladas, desgaste medio y desgaste crítico. Herramientas de análisis como vectores ortogonales (*Orthogonal arrays*) y la relación señal-ruido (*signal-to-noise ratio*) son empleadas para identificar las variables de importancia en el proceso de maquinado y posteriormente construir un modelo reducido con ellas. Los resultados indican que las condiciones de

desgaste medio y crítico pueden ser detectadas satisfactoriamente en aplicaciones en tiempo real. Kuntoğlu y Sağlam (2019) realizaron una investigación del desgaste progresivo en las herramientas de corte para determinar los parámetros de corte óptimos en torneado. Los autores determinaron que la velocidad de corte, el avance y el tipo de herramienta tienen un aporte del 44 %, 18 % y 34 % respectivamente en el desgaste. La adquisición de datos se logró mediante el censado de emisiones acústicas y la fuerza de corte tangencial. Los comportamientos y resultados similares pueden ser esperados en operaciones de fresado. Los autores concluyen que un sistema TCM fue exitosamente implementado, sin embargo, este tipo de censado suele ser intrusivo y caro.

Un tipo de sistema que ha sido ampliamente adoptado debido a su baja intrusión en la máquina y el proceso es a través del sonido. Es conocido que el sonido producido durante el maquinado es una buena fuente de información del estado real del fenómeno. El sonido producido durante el maquinado se debe a la deformación plástica de la pieza durante el maquinado, la deformación plástica de las virutas, el contacto friccional entre el filo y la pieza, el contacto friccional entre el filo del restrillo y las virutas, las virutas generadas por el desgaste del cortador, las colisiones entre las virutas y la herramienta, rupturas de las virutas y la fractura de la herramienta son mencionadas como posibles fuentes por Liang y Dornfeld. (1989).

El campo de los sistemas TCM ha visto diferentes enfoques para abordar las limitaciones de diversos algoritmos de toma de decisiones. Un enfoque que ha sido menos estudiado hasta años recientes es el del Aprendizaje Máquina (*Machine Learning - ML*). Kothuru y sus colaboradores (2018) desarrollaron una aplicación de señales sonoras audibles para la detección del desgaste de herramientas utilizando ML. Los investigadores exploraron el uso del sonido como un método de censado, para detectar el desgaste y falla durante

operaciones de fresado, por medio del modelado de máquinas de soporte de vectores (*Support Vector Machines - SVM*) como algoritmo de toma de decisiones. Los resultados del algoritmo propuesto mostraron predicciones precisas en la detección del desgaste (bajo varias condiciones) con un rápido tiempo de respuesta, lo cual implica que el modelo puede ser utilizado en procesos en tiempo real para sistemas TCM.

Una rama más especializada del ML con métodos más robustos es el llamado Aprendizaje Profundo (*Deep Learning - DL*). En muchas áreas tales como las finanzas, la seguridad, la visión artificial, entre otras, el DL ha mostrado un mejor desempeño en las tareas de predicción y/o clasificación. Sick (2002) llevó a cabo una síntesis de los sistemas de monitoreo del desgaste de las herramientas con Redes Neuronales (RNs) y los sistemas de censado indirecto. Aquí se abordan, tanto los enfoques utilizados para enfrentar la problemática, así como los resultados, ventajas y desventajas de cada uno de ellos. Se discute porque dichos sistemas no han sido exitosos hasta la actualidad. También se señalan posibles direcciones futuras para las investigaciones y como muchas de las recomendaciones planteadas en el documento pueden ser utilizadas para otros procesos de maquinado.

Twardowski y sus colaboradores (2021), a través de métodos de ML, detectaron el estado de desgaste de las herramientas de corte. Diferentes rangos de frecuencia de las emisiones acústicas fueron empleados como entradas a los algoritmos. Árboles de clasificación y regresión (CART), Redes Neuronales *Multi-layer Perceptron* (MLP) y *k*-vecinos más cercanos (*k*-NN) fueron evaluados; de lo cual resultó que las redes neuronales fueron el algoritmo con peor desempeño. No obstante, este resultado pudo deberse a la simplicidad de la arquitectura utilizada.

Liu y su equipo de colaboradores (2019) aplicaron algunos modelos de regresión y de RNs para

predecir el estado de los cortadores de acuerdo a la norma ISO8688. La señal de audio adquirida en el proceso de fresado fue transformada por la descomposición de wavelets con el fin de utilizar estos resultados como entradas para los algoritmos. El mejor modelo para predecir el desgaste fue una regresión cubica lineal junto con la RN, con un 8.59 % y 7.20 % de error, respectivamente. Además, este estudio concluyó que las características en el dominio del tiempo-frecuencia generaron mejores resultados que un análisis en el dominio del tiempo.

Cooper y sus colaboradores (2020) exploraron el desempeño de dos arquitecturas de redes neuronales convolucionales (1D y 2D) en la clasificación del sonido producido en una fresadora vertical. Comprobaron que la señal acústica cruda transformada a un espectrograma generó mejores resultados que los modelos que utilizaron solamente el dominio del tiempo o algún tipo de procesamiento a dicha señal. El estudio se realizó utilizando un solo tipo de herramienta (cortadores de una pulgada de insertos de carburo IC328) y material (acero 1018). Dicho modelo alcanzó una exactitud promedio del 99.5 % en la clasificación de las herramientas en un modo binario (herramientas nuevas y desgastadas). Mas materiales y tipos de herramientas deben ser verificados para comprobar la viabilidad de un sistema basado en este enfoque, así mismo, una clasificación binaria carece de información del verdadero estado de la herramienta.

Los métodos de DL han mostrado un desempeño superior en tareas de clasificación de imágenes (LeCun et al., 2015, p. 436). Jaiswal y Patel. (2018) presentan una metodología para clasificar sonido a través de imágenes y redes neuronales. Sin embargo, los sistemas TCM no han visto un uso relevante de RNs debido a la necesidad de grandes bases de datos para entrenar los modelos de una manera confiable. En años recientes, la falta de datos de entrenamiento ha sido abordada por una técnica llamada *Transfer Learning* (TL) (Zhuang et al., 2020, p. 43). Esta técnica consiste en reutilizar modelos

previamente entrenados en tareas similares y que se saben tuvieron muy buen desempeño en ellas y, posteriormente, con un proceso de ajuste fino (Fine Tuning), la red es reentrenada con los nuevos datos para mejorar la exactitud en la nueva tarea. Estos dos procesos permiten abordar el problema de datos insuficientes en redes neuronales.

Como se mencionó anteriormente, la necesidad de monitorear el desgaste o el daño ejerce un rol importante en la industria y las actividades de investigación. Por tal motivo, el objetivo de esta investigación es contribuir a los esfuerzos para desarrollar una herramienta no intrusiva y confiable de monitoreo a través del sonido que haga uso de las cualidades de las RNs y el TL. Lo anterior, se hará por medio de pruebas experimentales en dos materiales diferentes (Aluminio 6061T6 y acero 4041T), tres diferentes velocidades de corte y avance (para cada material) con herramientas de corte en tres diferentes condiciones de desgaste. Las condiciones de las herramientas fueron categorizadas de acuerdo a su peso y, basados en la suposición de que la masa de la herramienta está ligada a su desgaste.

## Método

En este experimento, barras de aluminio 6061T6 y acero SAE 4140T de 80x80x50 mm fueron empleadas para las pruebas de maquinados. Las densidades ( $\delta$ ) de los materiales son  $2.7 \text{ g/cm}^3$  y  $7.70 \text{ g/cm}^3$  respectivamente. Para los maquinados se utilizaron cortadores con recubrimiento de tungsteno verticales de 10 mm de diámetro y 4 filos. Las condiciones de los cortadores fueron catalogadas de tres maneras: 1) nueva, 2) desgastada y 3) despostillada; estas condiciones fueron determinadas mediante una inspección visual y validadas mediante la masa de cada cortador. La masa fue medida por medio de una báscula *Ohaus Scout Compass* con resolución de 0.001 g y 0.003 g de incertidumbre. Cada cortador fue medido cinco veces y el promedio es el valor reportado.


Para la adquisición de datos, fue realizado un desbaste en las barras de aluminio y acero en una fresadora CNC VF-6 HASS. Sin embargo, debido a las propiedades de maquinabilidad diferentes de cada material, los parámetros para su desbaste son diferentes. Dichos parámetros fueron seleccionados según las tablas de maquinado para cada material, profundidades de corte y tipo de cortador.

Un experimento de tres factores (avance, velocidad de corte y calidad de la herramienta) fue planteado para estudiar el sonido producido. En total 18 experimentos fueron realizados, tres combinaciones de parámetros, tres diferentes cortadores y dos materiales. La Tabla 1 muestra los parámetros de corte utilizados para los dos materiales propuestos.

Numero de combinación	Parámetro	Materiales	
		6160T6	4140T
1	Avance [m/min]	2228	1114
	Velocidad corte [rpm]	891.2	445.6
2	Avance [m/min]	2864	1432
	Velocidad corte [rpm]	1145.6	572.8
3	Avance [m/min]	3819	1750
	Velocidad corte [rpm]	1527.6	700


**Tabla 1.** Combinación de parámetros de corte para cada material. Fuente: elaboración propia.

Un micrófono de cardiode fue fijado a una distancia de 10 cm del área de trabajo, como se puede observar en la Figura 1. El sonido fue adquirido con una laptop y el software de uso libre ‘Audacity’ empleando una resolución de conversión análoga-digital de 32 bits de profundidad a una frecuencia de 88,2 kHz.



**Figura 1.** Montaje para la adquisición del sonido. Fuente: elaboración propia.

Con la finalidad de detectar el estado actual de la herramienta se entrenó una Red Neuronal Convolutiva (RNC) llamada VGG16. Este modelo es originalmente empleado para predecir clases en grandes bases de imágenes, pero empleando la transferencia de conocimiento (*Transfer Learning*) y aplicando un proceso de Ajuste fino (*Fine Tunning*) el modelo puede ser reutilizado para los fines de esta investigación. Las señales de audio adquiridas fueron seccionadas y transformadas a espectrogramas con la finalidad de tener una representación visual del sonido, para posteriormente ser suministrado al modelo de red. La Figura 2 muestra el esquema del Modelo VGG16 usado en esta investigación.



**Figura 2.** Esquema del modelo VGG16. Fuente: elaboración propia.

Una vez entrenada la RN, ésta puede usarse para monitorear el estado actual de las herramientas de corte, lo cual es una tarea de clasificación. Para comprobar el desempeño del modelo es necesario evaluarlo bajo sus cuatro posibles resultados: Verdaderos Positivos (VP), Falsos Positivos (FP), Verdaderos Negativos (VN) y Falsos Negativos (FN). Las métricas de *Precision* (Pr), *Recall* (Rc) y F1-score (en inglés) son empleadas para tales fines. Sus


respectivas ecuaciones se muestran en las Ecuaciones 1, 2 y 3, respectivamente.

$$Pr = \frac{VP}{VP+FP} \quad (1)$$

$$Rc = \frac{VP}{VP+FN} \quad (2)$$

$$F1score = 2 \frac{Pr \cdot Rc}{Pr+Rc} \quad (3)$$

Pr nos indica, de todos los que fueron predichos perteneciente a una clase, cuantos realmente pertenecen a dicha clase. Rc nos indica que porcentaje somos capaces de identificar de las observaciones que pertenecen a una clase en particular somos capaces de identificar. Finalmente, F1-score es la media geométrica de *Precision* y *Recall*. En la Figura 3 se resume la metodología seguida en este trabajo.



**Figura 3.** Metodología de investigación. Fuente: elaboración propia.

## Resultados

El peso de los tres cortadores fue determinado según la metodología descrita en la sección anterior. Las herramientas de mayor uso presentaron un menor peso debido a la pérdida de material por su uso previo. Los resultados se presentan en la Tabla 2.

Calidad cortador	Masa (g)
Nuevo	69.39
Usado	69.10
Despillado	69.87

**Tabla 2.** Peso de los cortadores antes del maquinado. Fuente: elaboración propia.

Una vez adquiridas las señales acústicas para cada experimento, éstas fueron divididas en tres clases identificadas de la siguiente manera: una para los cortes con la herramienta nueva; dos para los cortes hechos con la herramienta de uso y tres para la

herramienta fracturada. La RN VGG16 fue entrenada con estos datos. En la Figura 4 se puede observar el proceso de entrenamiento y validación de la red.




Figura 4. Entrenamiento y validación del modelo VGG16. Fuente: elaboración propia.

Se puede observar que la RN logra alcanzar un error mínimo aproximado de 0.08 en la etapa de validación. Posteriormente, el modelo es probado con datos que no fueron usados en el entrenamiento. Obteniendo los resultados mostrados en la matriz de confusión de la Figura 5. Se verifica los resultados obtenidos en la gráfica de entrenamiento y validación.




Figura 5. Matriz de confusión. Prueba del modelo final. Fuente: elaboración propia.

En la Tabla 3 se resumen los resultados para las métricas mencionadas en la sección anterior. En general se puede apreciar un buen desempeño en cada una de las clases, siendo la clase 3 aquella que obtuvo

un desempeño más pobre pero siendo aun así muy bueno.

Métrica	Nueva (1)	Usada (2)	Fracturada (3)	Promedio
Precision (%)	98.9	97.9	96.2	97.6
Recall (%)	99.2	98.4	97.9	98.5
F1-Score (%)	99.1	98.2	97.1	98.1

Tabla 3. Resultados de las métricas de desempeño. Fuente: elaboración propia.

## Discusión y conclusiones

En las secciones pasadas se mostró que el sonido puede ser usado para identificar el estado de desgaste de las herramientas de corte durante el desbaste. Los resultados sugieren que la información contenida en los datos de sonido post-procesados (espectrogramas) contienen suficiente información para entrenar un modelo de clasificación (para ambos materiales, acero y aluminio) y obtener un desempeño de alta precisión. Esto significa que hay una correlación positiva entre el sonido y el estado de la herramienta de corte.

El sonido producido durante el maquinado se debe a diversos fenómenos que ocurren durante el proceso y éstos, a su vez, dependen de los parámetros y herramientas usadas; por lo cual se recomienda más investigación para determinar si el modelo puede predecir otros factores, por ejemplo, la masa removida y si esto es repetible con diversos parámetros y/o herramientas. Por esta razón, los resultados presentados en este documento deben ser considerados como una solución heurística para la detección del desgaste en herramientas de corte y, posiblemente, sean sólo de utilidad para la metodología y diseño experimental presentadas en las secciones anteriores. A pesar de esta posibilidad, la metodología descrita en este documento puede ser usada para diferentes diseños experimentales mientras suficientes datos de entrenamiento se tengan para ajustar el modelo. El uso de RNs ha sido subestimado para su uso industrial debido a las limitaciones de los datos para entrenar los modelos; sin embargo, con este experimento futuras investigaciones pueden ser motivadas y probar así que

la Transferencia de Conocimiento (*Transfer Learning*) es un buen método para sortear estos obstáculos. Para una implementación en tiempo real se deberá considerar la latencia de respuesta del modelo presentado debido al procesamiento que se debe realizar a los datos (sonido). Este proceso podría ser lento en comparación con el corte en tiempo real y tener un desfase en la detección.

Basados en los resultados presentados anteriormente, se concluye lo siguiente: la RNC VGG16 se ajusta adecuadamente al propósito de detectar el desgaste de la herramienta a través del sonido debido a su habilidad para reconocer patrones en imágenes y clasificarlas. En promedio las tres métricas utilizadas para evaluar el desempeño del modelo obtuvieron un resultado superior al 97.5 %. A pesar de que resultados similares fueron obtenidos en otras investigaciones, se debe tener cuidado y considerar más aspectos para uso industrial. Lo anterior abre nuevas líneas para conducir futuras investigaciones en la optimización de la latencia y la influencia de otros parámetros o fenómenos durante el maquinado.

## Referencias

- 5 Hidden Problems That Can Inhibit Your Shop's Machining Efficiency (and How to Correct Them). (2022, 14 junio). TechSolve. <https://www.techsolve.org/5-hidden-problems-that-can-inhibit-your-shops-machining-efficiency-and-how-to-correct-them/>
- Teti, R., Jemielniak, K., O'Donnell, G., & Dornfeld, D. (2010). Advanced monitoring of machining operations. *CIRP annals*, 59(2), pp. 717-739.
- Liang, S. Y., and Dornfeld, D. A. (1989). Tool Wear Detection Using Time Series Analysis of Acoustic Emission. *ASME. J. Eng. Ind. August 1989*; 111(3), pp.199-205.
- Snr, D. E. D. (2000). Sensor signals for tool-wear monitoring in metal cutting operations—a review of methods. *International Journal of Machine Tools and Manufacture*, 40(8), pp. 1073-1098.
- Rizal, M., Ghani, J. A., Nuawi, M. Z., & Haron, C. H. C. (2017). Cutting tool wear classification and detection using multi-sensor signals and Mahalanobis-Taguchi System. *Wear*, 376, pp. 1759-1765.
- Kuntoğlu, M., & Sağlam, H. (2019). Investigation of progressive tool wear for determining of optimized machining parameters in turning. *Measurement*, 140, pp. 427-436.
- Kothuru, A., Nooka, S. P., & Liu, R. (2018). Application of audible sound signals for tool wear monitoring using machine learning techniques in end milling. *The International Journal of Advanced Manufacturing Technology*, 95(9), pp. 3797-3808.
- Sick, B. (2002). On-line and indirect tool wear monitoring in turning with artificial neural networks: a review of more than a decade of research. *Mechanical systems and signal processing*, 16(4), pp. 487-546.
- Twardowski, P., Tabaszewski, M., Wiciak-Pikuła, M., & Felusiak-Czyryca, A. (2021). Identification of tool wear using acoustic emission signal and machine learning methods. *Precision Engineering*, 72, pp. 738-744.
- 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*, 103(9), pp. 3361-3373.
- Cooper, C., Wang, P., Zhang, J., Gao, R. X., Roney, T., Ragai, I., & Shaffer, D. (2020). Convolutional neural network-based tool condition monitoring in vertical milling operations using acoustic signals. *Procedia Manufacturing*, 49, pp. 105-111.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), pp. 436-444.
- Jaiswal, K., & Patel, D. K. (2018, November). Sound classification using convolutional neural networks. In *2018 IEEE International Conference on Cloud Computing in Emerging Markets (CCEM)* (pp. 81-84). IEEE.
- Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., & He, Q. (2020). A comprehensive survey on transfer learning. *Proceedings of the IEEE*, 109(1), pp. 43-76.