

Clasificación e identificación de desgaste en herramientas en procesos de mecanizado a través de redes neuronales

Mayra Alejandra de los Ángeles Mejía-Moreno,
Rafael Guzmán-Cabrera

Universidad de Guanajuato,
Departamento de Estudios Multidisciplinarios (Yuriria),
División de Ingenierías,
Campus Irapuato-Salamanca,
México

madla.mejiamoreno@ugto.mx

Resumen: Las operaciones de mecanizado desempeñan un papel importante en la industria metalmeccánica por eso es de gran interés poder identificar de manera temprana el desgaste de las herramientas de corte para optimizar los procesos. No identificar a tiempo este estado puede tener un gran impacto en la calidad del mecanizado, la eficiencia de la producción y afecta de manera directa los costos en la industria del corte de metales, por lo que es importante mantener bajo control el nivel del desgaste durante las operaciones de mecanizado. En este trabajo se presentan resultados utilizando distintos métodos de aprendizaje automático para la clasificación automática de imágenes con la finalidad de identificar los defectos presentados en las mismas. El preprocesamiento, la extracción y la visión artificial para extraer características relevantes de las imágenes son el primer paso para obtener valores de clasificación adecuados de un conjunto de imágenes con 2 tipos de desgastes definidos como los de más incidencia en los insertos de corte. El objetivo principal de este trabajo es evaluar estrategias para detectar de manera temprana y entrenar redes neuronales artificiales para el reconocimiento automático del desgaste utilizando imágenes de las herramientas capturadas por medio de visión por computadora. Para la evaluación del método se utilizaron tres métodos de aprendizaje automático: Redes Neuronales, Maquinas de vectores de soporte y vecinos más cercanos. Se implementaron dos escenarios de clasificación: validación cruzada y formando conjuntos de entrenamiento y prueba. Los resultados obtenidos permiten ver la viabilidad del método propuesto.

Palabras claves: Clasificación de imágenes, detección del desgaste de herramientas de corte, aprendizaje automático, visión por computadora.

Classification and Identification of Tool Wear in Machining Processes through Neural Networks

Abstract: Machining operations play an important role in the metalworking industry, which is why it is of great interest to be able to identify the wear of cutting tools early

to optimize processes. Failure to identify this condition in time can have a great impact on the quality of machining, production efficiency and directly affects costs in the metal cutting industry, so it is important to keep the level of wear under control during machining operations. In this work, results are presented using different machine learning methods for the automatic classification of images in order to identify the defects presented in them. Preprocessing, extraction and computer vision to extract relevant features from the images are the first step to obtain adequate classification values from a set of images with 2 types of wear defined as those with the most incidence in the cutting inserts. The main objective of this work is to evaluate strategies to early detect and train artificial neural networks for automatic wear recognition using tool images captured through computer vision. For the evaluation of the method, three machine learning methods were used: Neural Networks, Support Vector Machines and Nearest Neighbors. Two classification scenarios were implemented: cross-validation and forming training and test sets. The results obtained allow us to see the viability of the proposed method.

Keywords: Image classification, cutting tool wear detection, machine learning, computer vision.

1. Introducción

Las herramientas de inserto indexado se han convertido en referencia mundial en procesos de corte mecánico ya que proporcionan una mayor productividad y mecanizado de alta velocidad ideal para trabajos de acabado en acero o hierro fundido. En estas herramientas se han identificado dos tipos de desgaste comunes, cráter y flanco. En la Figura 1 y Figura 2 podemos distinguir los dos tipos de desgaste.

El reconocimiento de las condiciones generales de una herramienta de corte tiene un papel importante en la optimización de los procesos de mecanizado, ya que la predicción precisa del momento exacto para el cambio de herramienta da como resultado en muchos casos una economía efectiva: se puede lograr una mayor vida útil de la herramienta de corte, se pueden controlar las tolerancias y evitar el rechazo de piezas por deterioro de las condiciones de la herramienta [1].

El procesamiento digital de imágenes (PDI) es una herramienta ampliamente utilizada en la automatización de procesos industriales, debido a que presenta confiabilidad, eficacia y rapidez en el procesamiento [2]. El PDI es el conjunto de técnicas que se aplica a las imágenes digitales con el objetivo de mejorar la calidad o facilitar la búsqueda de información, usando como herramienta principal una computadora. Hoy en día, el PDI es un área de investigación muy específica en computación [3].

La clasificación de imágenes se refiere a la tarea de categorizar o etiquetar una imagen en función de las características de su contenido. Hay dos tipos de clasificación: supervisada y no supervisada. La clasificación supervisada parte de un conjunto conocido de clases, las cuales se definen en base al conocimiento previo del conjunto de variables.

En cambio, en la clasificación no supervisada, las clases no se establecen a priori; sólo se establece el número esperado de clases, y la definición de las clases se realiza automáticamente mediante procedimientos estadísticos [4]. Una de las técnicas más usadas para el aprendizaje automático son las redes neuronales artificiales por su potencial para reconocer patrones de información, las RNA han sido desde hace décadas herramientas para resolver problemas en cualquiera de los niveles del procesamiento de imágenes.

Esto debido a que las imágenes digitales contienen mucha información difícil de interpretar por una máquina [5]. En las operaciones de fresado, la calidad de la pieza mecanizada depende en gran medida del estado del inserto de corte. Factores como el desgaste, la corrosión o la fatiga pueden afectar el desgaste de la herramienta. Por lo tanto, el monitoreo del desgaste de la herramienta en el proceso de mecanizado ha encontrado su importancia para predecir la vida útil de la herramienta, reducir el tiempo de inactividad del equipo y optimizar los parámetros de mecanizado [6].

El propósito de este artículo es aplicar estrategias para detectar de manera temprana el desgaste de las herramientas por medio de métodos de clasificación y entrenar redes neuronales artificiales para el reconocimiento automático, utilizando imágenes de las herramientas capturadas mediante visión por computadora.

2. Metodología propuesta

Para este trabajo se quiso lograr la clasificación de un conjunto de imágenes captadas por medio de visión por computadora, estas imágenes fueron modificadas, realizando una rotación a 15° grados en sentido de las manecillas del reloj, después de tener las imágenes listas se procede a dividir en subconjuntos. El primer subconjunto cuenta 216 imágenes bajo la etiqueta de Desgaste tipo cráter, El segundo subconjunto cuenta con 216 imágenes bajo la etiqueta de Desgaste tipo flanco y el último grupo cuenta con 72 imágenes etiquetadas como “Sin desgaste”.

Estas imágenes fueron tomadas para identificar el desgaste en herramientas de corte de procesos de mecanizado conocidas como Insertos indexados. El tema que analizamos para esta investigación nos resulta muy interesante porque a través de la detección temprana del desgaste podemos minimizar los costos y el tiempo, así como podemos maximizar la producción de productos con calidad garantizada.

La metodología que se manejó para la elaboración del presente trabajo de investigación se muestra en la figura 1, en donde se ilustra de manera general los pasos que se llevaron a cabo para la elaboración de nuestra investigación. En esta sección se presenta una breve descripción de los clasificadores empleados en los experimentos para observar cual arroja mejores resultados de precisión: Clasificador de redes neuronales (NN), máquina de vectores de soporte (SVM) y K-vecinos más cercanos (K-NN). Las redes neuronales (NN) son redes que utilizan aprendizaje supervisado.

Las redes neuronales son una representación simplificada en forma de gráfico de una malla de neuronas en el cerebro humano. Los nodos son las unidades de procesamiento, y los vínculos representan las conexiones sinápticas. Para simular la fuerza de las conexiones sinápticas, un peso es asociado con cada conexión entre los nodos de la red neuronal. A cada instante, el estado de un nodo es definido por su nivel de activación. Dependiendo de ese nivel de activación el nodo envía una señal al nodo vecino; la fuerza de esa señal dependerá del peso asociado con esa conexión.

Si los valores de los pesos de una red neuronal convergen con los datos del entrenamiento se dice que el problema puede ser representado por una red neuronal [7]. Support Vector Machines (SVM). El clasificador SVM es un algoritmo de aprendizaje supervisado basado en kernel que clasifica los datos en dos o más clases. SVM está especialmente diseñado para la clasificación binaria. Durante la fase de capacitación, SVM construye un modelo, mapea el límite de decisión para cada clase y especifica el hiperplano que separa las




Fig. 1. Desgaste de Cráter.




Fig. 2. Desgaste de Flanco.

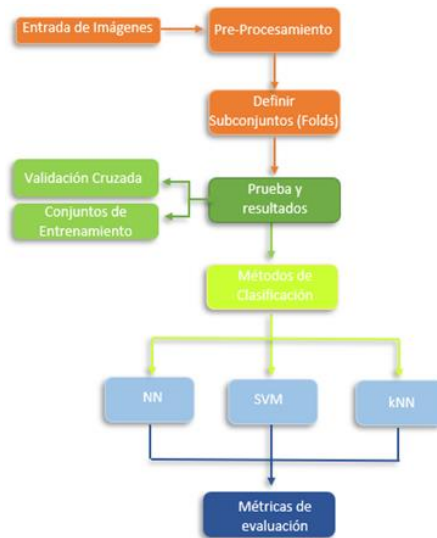


Fig. 3. Metodología propuesta.

diferentes clases. Aumenta la distancia entre las clases, incrementando el margen del hiperplano con la finalidad de ayudar a la precisión de la clasificación. SVM se puede utilizar para realizar de manera efectiva la clasificación no lineal [8].

K-NN su proceso de clasificación se obtiene por la asociación de muestras no etiquetadas a la clase mayoritaria entre las clases de las más cercanas k patrones de entrenamiento en el espacio de características. Por lo general, como una forma de evitar empates en problemas de clasificación binaria, k valor se establece en un entero impar, pero todavía puede haber empates cuando k es un entero impar cuando se trata de problemas de clasificación multiclase. Los parámetros principales para K-NN son el número k de patrones de entrenamiento a considerar para clasificar la nueva muestra y la métrica de distancia [9]. Como métricas de evaluación se utilizaron:

Área bajo la curva (AUC por sus siglas en inglés) es la métrica que mide la precisión de un modelo donde entremás cercano se encuentre a uno se considera que el modelo es más preciso [10]:

$$AUC = \int_0^1 f(x) dx$$

Tabla 1. Resultados métricas de evaluación con Validación cruzada.

Model	AUC	Precisión	Recall
kNN	0.999	0.981	0.980
SVM	1.000	0.994	0.994
NN	1.000	0.996	0.996

Tabla 2. Resultados métricas de evaluación entrenamiento 90%.

Model	AUC	Precisión	Recall
kNN	0.999	0.983	0.982
SVM	1.000	0.992	0.992
NN	1.000	0.994	0.994

Tabla 3. Resultados métricas de evaluación con Validación cruzada.

Model	AUC	Precisión	Recall
kNN	0.999	0.982	0.982
SVM	1.000	0.994	0.994
NN	1.000	0.998	0.998

Tabla 4. Resultados métricos de evaluación entrenamiento 90%.

Model	AUC	Precisión	Recall
kNN	0.999	0.987	0.986
SVM	1.000	0.992	0.992
NN	1.000	0.990	0.990

Precisión: Mide el rendimiento relacionado con las tasas de verdaderos positivos y negativos [11]:

$$Precisión = \frac{TP}{TP + FP}$$

Recall o sensibilidad es una medida que permite conocer la proporción de casos positivos que fueron correctamente clasificados. En un modelo perfecto el recall es igual a 1 para cada clase [12]:

$$Recall = \frac{tp}{tp + fn}$$

Se realizaron dos estudios experimentales, uno con el conjunto de imágenes sin pre procesar y el otro con las imágenes pre procesadas en donde se aplicó en Matlab un filtro de escala de grises, luego se realiza la binarización, se segmentó el desgaste y se extrajeron los bordes de las imágenes. Estos estudios se realizaron de esta manera porque actualmente no se cuenta con una base de datos extensa y lo que se quiso lograr es entrenar los clasificadores para que más adelante tenga un mayor impacto de la técnica de procesamiento a la hora de clasificar.

3. Resultados

A continuación, se muestran los resultados obtenidos en los experimentos realizados en un lenguaje de programación de Python. En la Tabla I. se muestran los resultados con las métricas de evaluación con Validación cruzada y en la Tabla II. Se muestra los resultados con las métricas de evaluación con un entrenamiento de 90% con las imágenes sin preprocesar. En las tablas III y IV se muestra los resultados de Validación cruzada y Conjuntos de entrenamiento para imágenes a las que se le realizaron el procesamiento.

La aplicación de la metodología sobre los experimentos nos arroja como resultado un valor de precisión del 100% utilizando redes neuronales en ambos escenarios, a pesar de que no se contaba con una base de datos amplia los clasificadores que mostraron mejor desempeño fueron Redes Neuronales y SVM, el clasificador que mostro menor desempeño en este caso fue el de Vecinos cercanos para ambos experimentos y en los diferentes escenarios de clasificación, aunque la precisión ya era alta en el primer experimento el lograr un incremento en los clasificadores que se encuentran marcados en color naranja y verde, esto es de gran ayuda pensando en cuando se cuente con conjuntos de imágenes más grandes.

Las métricas de evaluación con el mejor rendimiento que se presentaron en ambos casos fue conjuntos de entrenamiento y prueba es por eso por lo que este clasificador se convierte en el óptimo para la realización de experimentos de clasificación de desgaste.

4. Conclusión

En el presente trabajo de investigación se realizaron los experimentos y se presentan los resultados de clasificación automática de las herramientas de inserto indexado con los dos tipos de desgaste y las herramientas sin desgaste. Para hacer la clasificación se implementaron dos escenarios de clasificación: validación cruzada y conjuntos de entrenamiento y prueba, con dos bases de datos que constaban de imágenes sin realizar con extracción de bordes e imágenes con procesos de binarización, segmentación y extracción de bordes. Lo que se quería lograr con esto era definir el impacto de la metodología aplicada en ambos escenarios con diferentes conjuntos de imágenes.

Referencias

1. Byrne, G., Dornfeld, D., Inasaki, I., Ketteler, G., König, W., Teti, R.: Tool condition monitoring (TCM)—the status of research and industrial application. In: 8th CIRP Conference on Intelligent Computation in Manufacturing Engineering, Procedia CIRP 12, pp. 252 – 257 (1995)
2. Cáceres-Flórez, C. A., Ramos-Sandoval, O. L., Amaya Hurtado, D.: Procesamiento de imágenes para reconocimiento de daños causados por plagas en el cultivo de *Begonia semperflorens* (flor de azúcar). *Acta Agronómica*, vol. 64, no. 3, pp. 273–279 (2015) doi: 10.15446/acag.v64n3.42657
3. Morales-Castro, W., Guzmán-Cabrera, R.: Tuberculosis: Diagnóstico por procesamiento de imágenes. *Computación y Sistemas*, vol. 24, no. 2, pp. 875–882 (2020) doi: 10.13053/cys-24-2-3284

4. Pérez-Careta, E., Guzmán-Sepúlveda, J. R., Lozano-García, J. M., Torres-Cisneros, M., Guzman-Cabrera, R.: Classification of medical images using machine learning. *DYNA*, vol. 97, no. 1, pp. 35–38 (2022) doi: 10.6036/10117
5. Ramírez, Q. J., Chacón, M., Mario, I.: Redes neuronales artificiales para el procesamiento de imágenes, una revisión de la última década. *RIEE&C, Revista de ingeniería eléctrica, electrónica y computación*, vol. 9, no. 1, pp. 7–16 (2011)
6. Wu, X., Liu, Y., Zhou, X., Mou, A.: Automatic identification of tool wear based on convolutional neural network in planning process. *Sensors*, vol. 19, no. 18, p. 3817 (2019)
7. Godoy-Viera, Á.: Técnicas de aprendizaje de máquina utilizadas para la minería de texto. *Investigación Bibliotecológica: archivonomía, bibliotecología e información*, vol. 31, no. 71, pp. 103–126 (2017) doi:10.22201/iibi.0187358xp.2017.71.57812
8. Blanco-Murillo, D. M., García-Domínguez, A., Galván-Tejada, C. E., Celaya-Padilla, J. M.: Comparación del nivel de precisión de los clasificadores support vector machines, k nearest neighbors, random forests, extra trees y gradient boosting en el reconocimiento de actividades infantiles utilizando sonido ambiental. *Research in Computing Science*, vol. 147, no. 5, pp. 281–290 (2018)
9. Pacifico, L. D., Macario, V., Oliveira, J. F.: Plant classification using artificial neural networks. In: 2018 International Joint Conference on Neural Networks (IJCNN), IEEE, pp. 1–6 (2018) doi: 10.1109/IJCNN.2018.8489701
10. Espinosa-Zúñiga, J. J.: Aplicación de algoritmos random forest y XGBoost en una base de solicitudes de tarjetas de crédito. *Ingeniería, investigación y tecnología*, vol. 21, no. 3 (2020) doi: 10.22201/fi.25940732e.2020.21.3.022
11. Bayas, B. O., Alvarado, P. R., Toapanta, J. M., Zamora, L. S.: Análisis comparativo de modelos de aprendizaje automático para la detección de mensajes considerados como grooming online. *Centro Sur*, vol. 4, no. 3 (2021)
12. Borja-Robalino, R., Monleón-Getino, A., Rodellar, J.: Estandarización de métricas de rendimiento para clasificadores machine y deep learning. *Revista Ibérica De Sistemas y Tecnologías De Información*, 184-196 (2020)