

Aplicación de redes neuronales convolucionales a la monitorización del nivel de desgaste de herramientas en sistemas industriales de taladrado

Raúl de Santos García¹, María José Gómez Silva², Carlos Domínguez Monferrer¹,
María Henar Miguélez Garrido¹, José Luis Cantero Guisández¹

¹FABDIS, Departamento de Ingeniería Mecánica, Universidad Carlos III de Madrid, España. Email: rausanto@ing.uc3m.es
²ISCAR, Departamento de Arquitectura de Computadores y Automática, Universidad Complutense de Madrid, España.
Email: mgomez77@ucm.es

Resumen

La industria aeronáutica es un sector estratégico a nivel global y en constante crecimiento. Con esta premisa resulta interesante buscar formas de conseguir ahorros recurrentes en la fabricación de las aeronaves. En este contexto, uno de los procesos más comunes es el taladrado, en el que los altos estándares de calidad del sector hacen que las herramientas se encuentren, generalmente, infrautilizadas, ya que su reemplazo atiende a valores nominales de tiempo de vida útil con un alto margen de seguridad. La estimación del nivel de desgaste de las herramientas en tiempo real puede permitir un mayor aprovechamiento de las mismas. Este estudio se encuentra enmarcado en un proceso industrial de taladrado automático en el cual se fabrican componentes para aviones comerciales en la fábrica de Getafe de Airbus. La principal información que se extrae mediante monitorización indirecta, para no afectar al proceso, es la potencia eléctrica consumida por el husillo. Con el objetivo de extraer características relacionadas con el nivel de desgaste de la herramienta en tiempo real, la señal de potencia eléctrica ha sido procesada mediante redes neuronales convolucionales entrenadas bajo la técnica comparativa de las redes de tipo siamesas. El método propuesto palía el problema de la escasez de datos de entrenamiento, y los resultados de los experimentos realizados demuestran su capacidad para generar un espacio de características ordenado en función del nivel de desgaste de la herramienta.

Palabras clave: predicción desgaste, taladrado, procesamiento señal, redes neuronales convolucionales, redes siamesas.

Abstract

The aeronautical industry is a strategic, and constantly growing, sector at a global level. With this in mind, it is interesting to look for ways to achieve recurrent savings in the aircrafts manufacturing. Within this context, one of the most common processes is drilling, in which the high-quality standards of the sector mean that cutting tools are generally underutilized since they are replaced according to nominal values of their service life with wide security margins. The tool real-time wear level estimation can lead to a better and longer use of the tools. This study is framed in an industrial process of automatic drilling in which different component of commercial aircrafts are manufactured in the Getafe factory of Airbus. The main process information extracted is the electrical power consumed by the spindle, through indirect monitoring so to not to affect the process. In order to extract wear level-related features in real time, the power signal has been processed by convolutional neural networks under the comparative training technique of Siamese networks. This proposed method alleviates the problem of shortage of training data, and the results of the conducted experiments demonstrate its capacity to generate a features space so that is sorted according to the tool wear level.

Keywords: wear prediction, drilling, signal processing, convolutional neural networks, Siamese networks.

1. Introducción

El sector aeronáutico es un pilar estratégico a nivel mundial por su gran volumen económico. El informe de mayo de 2022 de Market Research [1] estima que, durante los próximos años, el sector de la aviación

comercial tendrá una tasa de crecimiento anual compuesto de facturación de 13,07%. Esto hace que sea interesante buscar formas de mejorar los procesos productivos de las aeronaves para obtener ahorros recurrentes en su fabricación.

Para controlar un proceso industrial productivo, dicho proceso debe ser monitorizado. Hay dos formas de realizar la monitorización de procesos, directa o indirectamente. La monitorización directa se caracteriza por utilizar sensores que se encuentran cercanos a la fuente como, por ejemplo, la medición de emisiones acústicas [2]. Por otro lado, la monitorización indirecta se basa en obtener la información que proporciona la propia máquina, sin sensores externos.

Una de las magnitudes más interesantes para monitorizar, en los procesos de fabricación industrial, es el nivel de desgaste de las herramientas de corte. El problema que puede suponer su monitorización es que se debe poder acceder a ella, lo que obliga a utilizar técnicas de monitorización directa e incurrir en mayores costes y tiempos de proceso. Por esta razón, la tendencia actual es estimar el nivel de desgaste de las herramientas de corte en vez de medirlo.

La estimación de desgaste se suele hacer utilizando diferentes técnicas de inteligencia artificial, e introduciendo diferente información del proceso industrial. Las técnicas más utilizadas son *Support Vector Machine* (SVM) [3] y las redes neuronales artificiales [4], o ANN (*Artificial Neural Network*) por sus siglas en inglés. Aunque se han evaluado otras técnicas como *Random Forest*, *K-Nearest Neighbours* o procesos Gaussianos [5].

Con respecto al desgaste de herramientas, aunque con una importante variabilidad en función del tipo y nivel de desgaste, generalmente el par torsor y la fuerza axial aumentan con el nivel de desgaste de la herramienta [6], por lo que son magnitudes interesantes para considerar. No obstante, su monitorización requiere de dinamómetros, aunque en caso de no disponer de ellos en la máquina, se puede realizar una monitorización indirecta de la potencia eléctrica consumida. El inconveniente de muestrear la potencia consumida frente a la fuerza es que, la potencia suele presentar una mayor cantidad de ruido y se ve afectada por otros factores como rozamientos, cambios de parámetros, etc. Por tanto, generalmente tiene menor precisión.

Cuando se trabaja con señales, convencionalmente se extraen descriptores y características con procesamiento de la señal [7][8]. Si se quiere automatizar la extracción de características para varios tipos de señales, se debe invertir gran cantidad de tiempo en el conocimiento de cada caso y el diseño específico de los descriptores, proceso conocido como ingeniería de características. La alternativa a este proceso es el aprendizaje automático de las características más descriptivas mediante técnicas de *deep learning*.

El tipo de modelo que se suele utilizar para el procesamiento de señales mediante *deep learning* son las redes neuronales convolucionales, o CNN (*Convolutional Neural Network*) por sus siglas en

inglés [9]. Aunque este tipo de arquitectura se utiliza, principalmente, con datos bidimensionales, como las imágenes.

Este artículo presenta un modelo basado en CNN unidimensionales para la extracción de características de señales de potencia eléctrica entrenado mediante una arquitectura siamesa. Las señales de potencia eléctrica corresponden a un proceso de taladrado automático en apilados de polímero reforzado de fibra de carbono en la fábrica de Airbus en Getafe, España. El objetivo último de la extracción de características capaces de describir implícitamente el estado de desgaste es ayudar a la estimación la vida útil restante real de las herramientas y así ampliarla con respecto a los valores nominales de seguridad empleados en la actualidad.

2. Metodología

El proceso industrial que se quiere monitorizar es un taladrado automático que se lleva a cabo en la fábrica de Airbus en Getafe, en la que se taladra un componente de un avión comercial. El avión al que pertenece el componente tiene dos versiones con diferencias estructurales, y con diferentes parámetros de corte para la herramienta de corte objeto de este estudio.

La herramienta de corte para la que se han recogido los datos de este artículo es una broca de carburo de tungsteno con recubrimiento de diamante de 4,8 mm de diámetro. Ésta taladra apilados de polímero reforzado de fibra de carbono, o CFRP (*Carbon Fiber Reinforcement Polymer*) por sus siglas en inglés, que tiene entre una y cuatro capas, con espesores variables entre ellas.

2.1. Datos

Para cada agujero taladrado, la máquina monitoriza el consumo de potencia del husillo y, de forma automática, amacena dicha señal en archivos de tipo "xml". Por tanto, los datos que se utilizan para entrenar el modelo neuronal son la potencia muestreada para cada agujero y el tipo de versión del avión, por su diferencia en los parámetros de corte.

A lo largo de la adquisición de datos del proyecto, se ha recogido la información de 13 herramientas diferentes, con un total de aproximadamente 6250 agujeros realizados.

Las señales de potencia de los agujeros de fibra de carbono tienen una forma similar a la que se puede observar en la figura 1. La principal diferencia entre señales correspondientes a distintos agujeros es que, debido a la variabilidad de espesores de las capas de cada agujero, la longitud de la parte alta de la señal puede variar.

La arquitectura diseñada para el modelo neuronal empleado requiere que todas las señales tengan la misma longitud. Sin embargo, cada señal almacenada tiene una longitud que depende del espesor del agujero y de los parámetros de corte de la versión de avión. Se debe conseguir que todas tengan la misma cantidad de

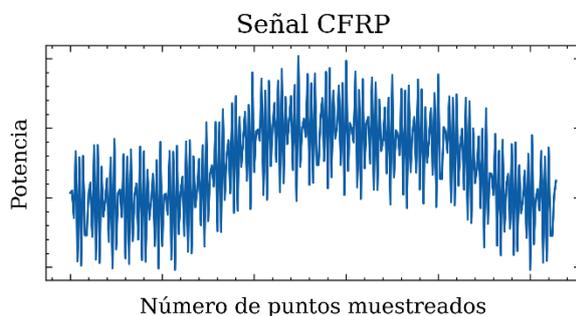


Figura 1. Forma cualitativa de las señales de potencia eléctrica de pilados de CFRP¹.

puntos. Para ello, se realiza una interpolación segmentaria, para que todas las señales de entrada a la red neuronal tengan 1024 puntos.

2.2. Anotaciones

Las características que se quiere obtener de la señal deben estar relacionadas con el nivel de desgaste de la herramienta, por tanto, para guiar el entrenamiento de la red neuronal de modo supervisado, las señales de entrada deben ir acompañadas de un valor de referencia del nivel de desgaste de la herramienta en el momento de realizar el agujero correspondiente. Con la imposibilidad de afectar al proceso industrial, la única observación que se puede llevar a cabo del desgaste de la herramienta se realiza cuando ésta se encuentra a fin de vida y abandona el sistema productivo.

La observación del desgaste realizada mediante microscopía óptica y electrónica muestra diferentes mecanismos. El principal mecanismo de desgaste es el desgaste de flanco, pero también se observa pérdida del recubrimiento de diamante y astillado del filo de corte. Además, el tipo y nivel de desgaste varía en función de la zona del filo. Para obtener un único valor representativo del nivel global de desgaste de la herramienta, se establece una clasificación en el rango de 0 a 3, que tiene en cuenta todos los tipos de desgaste observados. Siendo 0 el nivel de desgaste nulo correspondiente a una herramienta nueva, y 3 el nivel de desgaste de una herramienta que, por criterios de seguridad, no debería continuar trabajando por el riesgo de rotura de la herramienta o de generación de defectos en la pieza. Los tipos de desgastes observados son de evolución progresiva y el crecimiento de parámetros obtenidos a partir del consumo de potencia presentó una tendencia creciente aproximadamente

lineal a lo largo de la utilización de la herramienta. Por otra parte, estudios previos de evolución del desgaste en este tipo de procesos de taladrado han confirmado que la evolución del desgaste presenta una elevada linealidad con el tiempo de corte [10]. En base a este comportamiento, se establecieron valores intermedios de nivel de desgaste en tramos de 0,5 comenzando con el valor 1.

Así mismo, para caracterizar el nivel de desgaste que presenta la herramienta en cada agujero a lo largo de su vida útil, se interpola entre el nivel 0, en el primer agujero, y el nivel de desgaste observado al microscopio, en el último agujero.

Debido a la escasez de datos, las pocas observaciones que se tiene de las herramientas, y el carácter aproximado del método de etiquetado del nivel de desgaste, un entrenamiento de tipo regresión, en el que se requiera que la red aprenda a predecir el nivel de desgaste, ajustándose exactamente a una ecuación lineal, se vuelve una tarea complicada. Para lidiar con el problema de falta de datos y la calidad de la etiqueta del desgaste, se propone un entrenamiento de tipo comparativo, que sirve como paso previo a la estimación final del valor de desgaste. Con este tipo de entrenamiento se forman parejas de señales, que se comparan entre ellas. Gracias a la formación de parejas, se consigue obtener aproximadamente 1 millón de ejemplos para el entrenamiento.

2.3. Modelo neuronal

Como se ha comentado, el entrenamiento de las redes neuronales convolucionales se realiza de forma comparativa. Para ello, se utiliza el entrenamiento mediante redes de tipo siamesas (ver figura 2). En la arquitectura de redes siamesas se utiliza la misma red base para obtener un vector latente de cada una de las dos entradas. Se trata de la misma red (con los mismos parámetros) duplicada en dos ramas. Los vectores latentes contienen las características codificadas. Después se utiliza una segunda red discriminadora que compara los vectores latentes y aprende a predecir cuál de ellos corresponde a una señal en la que la herramienta presentaba un mayor nivel de desgaste.

Una vez el modelo ha sido entrenado, sólo se utiliza una de las dos ramas idénticas de red neuronal convolucional para extraer las características de la señal. Por tanto, el objetivo del entrenamiento de la CNN como redes siamesas es que se ordene el espacio latente de características en función del nivel de desgaste para que posteriormente otra red neuronal pueda aprender dicha ordenación y entender las características de cada señal relacionadas con el nivel de desgaste de las herramientas.

¹ Debido a un acuerdo de confidencialidad con Airbus, no se aportan los valores de las magnitudes de carácter sensible

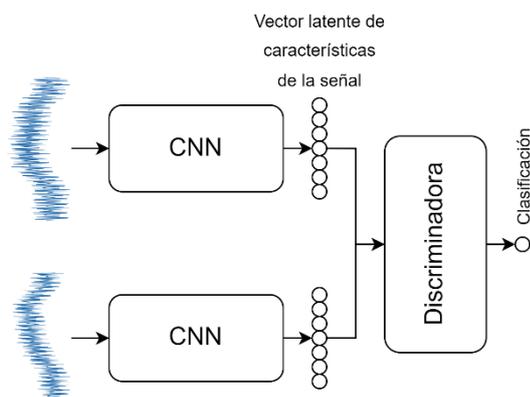


Figura 2. Esquema de entrenamiento del modelo.

La tabla 1 resume la arquitectura del modelo de red neuronal convolucional. Al tratarse la entrada de una señal que sólo tiene una dimensión, las capas convolucionales y operaciones de tipo *max pooling* son unidimensionales. Para finalizar se tienen 3 capas densas, o *fully connected*.

Tabla 1. Arquitectura de la red neuronal convolucional para la extracción de características de las señales de potencia eléctrica. El segundo parámetro del tamaño de salida de las capas es el número de canales. El parámetro N es el tamaño del vector latente, que tras diferentes experimentos se ha decidido que sea 16.

Capa	Tamaño salida	Filtro, stride	Función activación
Entrada	1024 x 1	-	-
Conv 1	1024 x 4	5, 1	ReLU
Dropout 1	1024 x 4	-	-
Pool 1	512 x 4	2, 2	-
Conv 2	512 x 8	5, 1	ReLU
Dropout 2	512 x 8	-	-
Pool 2	256 x 8	2, 2	-
Conv 3	256 x 8	5, 1	ReLU
Dropout 3	256 x 8	-	-
Pool 3	128 x 8	2, 2	-
Conv 4	128 x 8	5, 1	ReLU
Dropout 4	128 x 8	-	-
Pool 4	64 x 8	2, 2	-
Conv 5	64 x 8	5, 1	ReLU
Dropout 5	64 x 8	-	-
Pool 5	32 x 8	2, 2	-
Conv 6	32 x 8	5, 1	ReLU
Dropout 6	32 x 8	-	-
Pool 6	16 x 8	2, 2	-
Conv 7	16 x 8	5, 1	ReLU
Dropout 7	16 x 8	-	-
Pool 7	8 x 8	2, 2	-
Aplanado	64	-	-
FC 1	64	-	Lineal
FC 2	$\frac{2}{3} \cdot (64 - N) + N$	-	Lineal
FC 3	$\frac{1}{3} \cdot (64 - N) + N$	-	Lineal
Salida	N	-	Tangente hiperbólica

Con el vector latente, que tiene las características de la señal relacionadas con el nivel de desgaste codificadas, de las dos señales más la información de la versión de avión a la que pertenece cada agujero realizado, la red discriminadora debe aprender a interpretar las características para conocer cuál de las dos señales tiene un mayor nivel de desgaste. La información sobre la versión de avión a la que corresponde cada señal se aporta añadiendo una dimensión más al vector latente con un valor de -1 o un 1 según corresponda. La estimación de la red discriminadora debe ser un 0 en caso de que la primera señal (situada por encima en el esquema), tenga mayor nivel de desgaste de la herramienta y 1 en el caso contrario. Por tanto, el entrenamiento se convierte en una clasificación binaria al entrenarse los dos modelos simultáneamente, la red base y la discriminadora. La arquitectura de la red discriminadora se muestra en la tabla 2.

Tabla 2. Arquitectura del modelo de red neuronal discriminadora para el entrenamiento de tipo redes siamesas del modelo CNN para la extracción de características de señales de potencia eléctrica. N es el tamaño del vector latente que se fija en 16 tras diferentes experimentos.

Capa	Tamaño salida	Función activación
Entrada	$2 \cdot N + 2$	-
FC 1	$2 \cdot N$	ReLU
FC 2	$2 \cdot N$	ReLU
FC 3	$2 \cdot N$	ReLU
FC 4	$2 \cdot N$	ReLU
FC 5	$2 \cdot N$	ReLU
FC 6	$2 \cdot N$	ReLU
Salida	1	Sigmode

3. Resultados

3.1. Protocolo de entrenamiento

Como se ha comentado anteriormente, para el entrenamiento de este modelo se cuenta con 13 brocas que taladran apilados de polímero reforzado de fibra de carbono. Para realizar el entrenamiento se decide hacer una división de los datos en tres subconjuntos, el de entrenamiento, con el que se actualizarán los parámetros de los modelos, el de validación, con el que se monitoriza la evolución del rendimiento en la fase de entrenamientos, y el de test, con el que se evalúa el rendimiento final del modelo entrenado.

Se ha observado experimentalmente, que cada herramienta presenta su propia tendencia en cuanto a la evolución del nivel de desgaste asignado (etiqueta). Por ello, se considera que no se deben mezclar datos de la misma herramienta en los diferentes subconjuntos de datos. La división del número de herramientas que se utilizará para cada subconjunto es: 7 para entrenamiento, 3 para validación y 3 para test. Y, para agilizar el entrenamiento, se decide que los tamaños de lote serán: 32 para el subconjunto de datos de

entrenamiento y 16 para los subconjuntos de datos de validación y test.

El uso de las redes siamesas para el entrenamiento del modelo CNN para extracción de características hace que se deban formar parejas de señales. Se tiene como objetivo que las características del vector latente, codificadas por el modelo CNN, tengan relación con el nivel de desgaste de la herramienta en el momento de la realización del agujero. Por ello, para obtener comparaciones significativas, las parejas de señales deben tener una diferencia notable en el nivel de desgaste asociado. Por tanto, las parejas que se realizan con señales de agujeros taladrados por la misma herramienta se separan un mínimo de 25% del número de agujeros de vida teórica que tiene la herramienta. Y, para señales de agujeros que forman una pareja y provienen de diferentes herramientas, el nivel de desgaste tiene que tener una diferencia mínima de 1 en la escala seleccionada, que se recuerda que es de entre 0 y 3.

La función de pérdidas seleccionada para este modelo, al tratarse de un entrenamiento de clasificación binaria, es la entropía cruzada binaria. El algoritmo de optimización es AdaGrad (*Adaptative Gradients*) [11]. La tasa de aprendizaje seleccionada para los entrenamientos es de 0,001.

Al ser un entrenamiento de clasificación binaria, las principales métricas utilizadas son: el valor de la función de pérdidas, la exactitud, la curva ROC (Receiver Operating Curve) y el AUC (Area Under the Curve) de la curva ROC. La exactitud (ecuación (1)) se utiliza, principalmente, para evaluar la evolución del rendimiento de la fase de entrenamiento, y se calcula con un umbral de 0,5. La curva ROC es una curva que se construye como la razón de verdaderos positivos (ecuación (2)), o TPR (*True Positive Rate*), frente a la razón de falsos positivos (ecuación (3)), o FPR (*False Positive Rate*). El AUC, se utiliza para evaluar el rendimiento de la clasificación del modelo entrenado sobre el subconjunto de datos de test. Se calcula haciendo un barrido de umbrales entre los posibles valores de la salida, es decir, entre 0 y 1. Por tanto, el AUC indica el rendimiento de la clasificación con independencia de cuál sea el umbral que maximiza la exactitud.

$$exactitud = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$TPR = \frac{TP}{TP + FN} \quad (2)$$

$$FPR = \frac{FP}{FP + TN} \quad (3)$$

Donde:

- *TP*: número de verdaderos positivos.
- *FP*: número de falsos positivos.
- *TN*: número de verdaderos negativos.
- *FN*: número de falsos negativos.

Para evitar problemas con el sobreajuste que se suele dar tras un cierto número de iteraciones durante el entrenamiento, se utiliza la técnica de parada temprana, más conocida como *early stopping*. Esta técnica consiste en almacenar los parámetros de los modelos en el punto del entrenamiento en el que se considere que pueden proporcionar un mejor rendimiento sobre el subconjunto de datos de test. La fórmula utilizada para el *early stopping* de estos modelos es la que se puede observar en la ecuación (4).

$$ES = 0,1 \cdot \left(\frac{1}{EE} + 10 \cdot PE \right) + 0,9 \cdot \left(\frac{1}{EV} + 10 \cdot PV \right) \quad (4)$$

- *ES* valor calculado para *early stopping*.
- *EE* exactitud obtenida en el subconjunto de datos de entrenamiento.
- *PE* pérdida obtenida en el subconjunto de datos de entrenamiento.
- *EV* exactitud obtenida en el subconjunto de datos de validación.
- *PV* pérdida obtenida en el subconjunto de datos de validación.

3.2. Evaluación de los entrenamientos

Tras varios experimentos de calibración, con los que se han decidido los hiper-parámetros del entrenamiento y la arquitectura final de los modelos neuronales, se comprueba la robustez y validez del sistema realizando tres experimentos, o entrenamientos, adicionales bajo la técnica de validación cruzada. Esto consiste en realizar los tres experimentos con la misma configuración de todos los hiper-parámetros salvo la distribución de datos. Por tanto, la única diferencia entre los tres experimentos de validación cruzada es los datos de qué herramientas se utilizan en cada subconjunto de datos.

La fase de entrenamiento es la parte del entrenamiento completo en la que se optimizan los parámetros de la red para que aprenda a realizar la función requerida. Durante esta fase se monitoriza la evolución de las métricas sobre los subconjuntos de datos de entrenamiento y validación con el objetivo de finalizar el entrenamiento en la mejor iteración, punto de *early stopping*. Las métricas monitorizadas son las pérdidas (figura 3) y la exactitud (figura 4).

Con el modelo de la iteración del punto de *early stopping*, se evalúa el rendimiento del sistema sobre el subconjunto de datos de test, que no han sido utilizados previamente en la fase de entrenamiento. En esta fase de evaluación se recogen las mismas métricas que durante la fase de entrenamiento y, además, se construye la curva ROC y se calcula su AUC. Un ejemplo de curva ROC se puede observar en la figura 5. La tabla 3 recoge un resumen de la evaluación de los

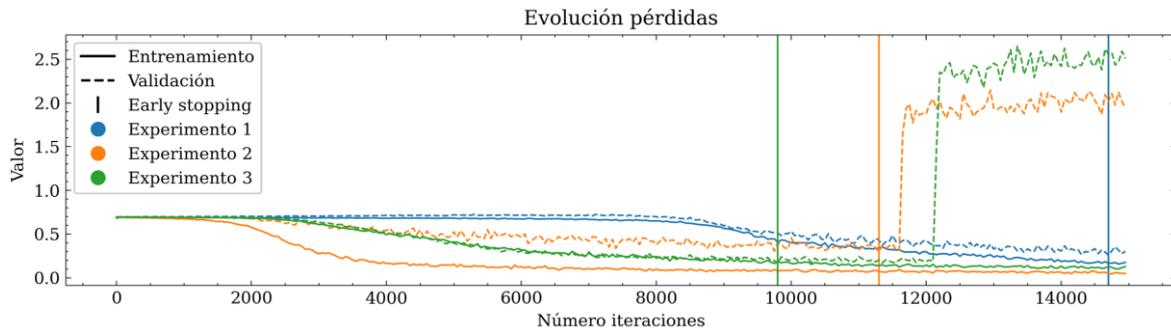


Figura 3. Evolución de las pérdidas durante la fase de entrenamiento.

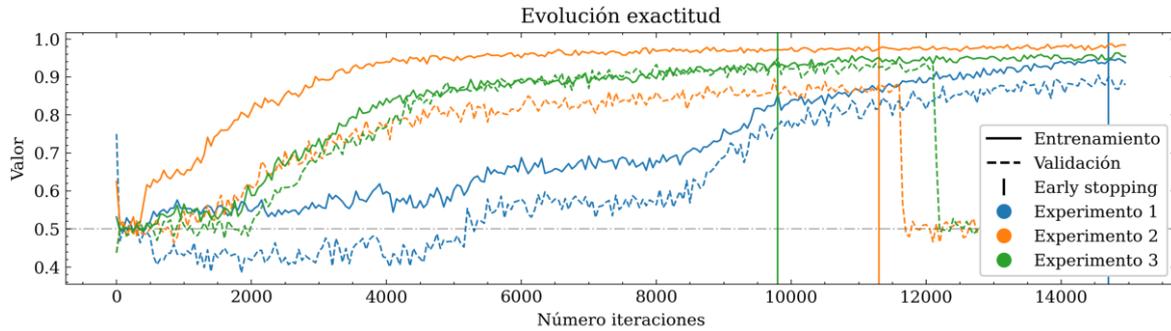


Figura 4. Evolución de la exactitud durante la fase de entrenamiento.

Tabla 3. Resultados del entrenamiento de los modelos.

	Exactitud			AUC
	Entrenamiento	Validación	Test	
Experimento 1	0,944	0,900	0,935	0,980
Experimento 2	0,974	0,880	0,944	0,983
Experimento 3	0,926	0,951	0,835	0,947

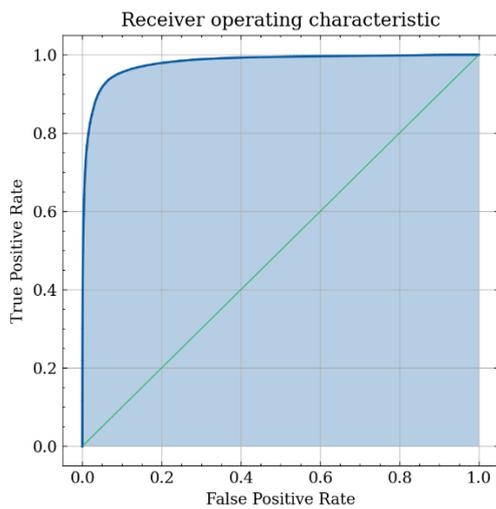


Figura 5. Curva ROC del experimento 1. Fuente: elaboración propia.

experimentos. Los valores de AUC posibles se encuentran entre 0 y 1, obteniendo valor 1 un modelo que ha aprendido a clasificar de forma perfecta los ejemplos de subconjunto de datos de test y valor 0,5 un

modelo de clasificación binaria que hace predicciones aleatorias.

3.3. Discusión

A la vista de los resultados obtenidos de la validación cruzada, se puede comprobar que el sistema es robusto frente al cambio en la distribución de los datos. Esto significa que la técnica de entrenamiento mediante redes siamesas, que hace que se formen parejas y que la cantidad de datos pase a ser de cerca de un millón, consigue que el modelo sea sólido.

Se observa que la técnica de *early stopping* consigue que los modelos no tengan sobre-ajuste. Esto, junto con la robustez que presenta el modelo frente a los datos, hace esperar que, ante nuevos futuros datos, el sistema ofrezca resultados similares.

Como las características codificadas tienen que ser interpretadas por otro modelo de red neuronal, se puede asumir que el umbral que optimiza la exactitud no es crítico y que el rendimiento del sistema está representado por el AUC. Fijándose en el valor de

AUC obtenido en los experimentos se puede concluir que el modelo ofrece buenos resultados.

El hecho de que la red neuronal discriminadora sea capaz de identificar de forma constante cuál de las dos señales de potencia corresponde a un agujero en el que la herramienta de corte tenía un mayor nivel de desgaste, indica que el modelo de red neuronal convolucional está codificando, en los vectores latentes, características relacionadas con el nivel de desgaste de la herramienta de corte.

4. Conclusiones

Se ha conseguido desarrollar un modelo capaz de extraer características de una señal de potencia relacionadas con el nivel de desgaste. La ventaja que aporta el tipo de entrenamiento realizado, mediante redes siamesas, consigue que, a pesar de tener pocos datos y muy pocas observaciones del nivel de desgaste de las herramientas de corte, se extraigan características que pueden ayudar a un siguiente modelo de red neuronal a estimar el nivel de desgaste con mayor facilidad. Además, el procesamiento de señales mediante redes neuronales hace que el modelo pueda aprovechar patrones y características imperceptibles para el ojo humano, que no se consigue extraer mediante un procesamiento convencional.

El sistema desarrollado presenta un gran potencial de generalización a otros procesos industriales en los que se utilicen herramientas de corte. Además, se ha tenido en cuenta el número de parámetros del modelo de red neuronal convolucional para no incluir más de los necesarios, por lo que la integración del modelo a un sistema productivo es posible. Lo que hace que pueda ser industrializable.

5. Agradecimientos

Los autores agradecen la ayuda y soporte financiero de AIRUBUS S.A.S. a través del proyecto CFT – AI – PJMT - DRILLING PROCESS IMPROVEMENT BASED ON DATA ANALYTICS, a la Agencia Estatal de Investigación a través del proyecto (PID2020-118480RBC22 / AEI / 10.13039 / 501100011033) y el proyecto PDC2021-121368-C21, financiado por MCIN/AEI/10.13039/501100011033 y por la Unión Europea “NextGenerationEU”/PRTR”.

6. Referencias

[1] “Commercial Aircraft Global Market Briefing 2022,” Apr. 2022. Accessed: Jul. 14, 2022. [Online]. Available: <https://www.marketresearch.com/Business-Research-Company-v4006/Commercial-Aircraft-Global-Briefing-31471939/>.

[2] K. Hamdi, G. Moreau, and Z. Aboura, “Digital image correlation, acoustic emission and in-situ microscopy in order to understand composite

compression damage behavior,” *Compos. Struct.*, vol. 258, p. 113424, Feb. 2021, doi: 10.1016/J.COMPSTRUCT.2020.113424.

[3] D. Kong, Y. Chen, N. Li, and S. Tan, “Tool wear monitoring based on kernel principal component analysis and v-support vector regression,” *Int. J. Adv. Manuf. Technol.* 2016 891, vol. 89, no. 1, pp. 175–190, Jun. 2016, doi: 10.1007/S00170-016-9070-X.

[4] F. A. Niaki, L. Feng, D. Ulutan, and L. Mears, “A wavelet-based data-driven modelling for tool wear assessment of difficult to machine materials specialising in modelling and simulation of dynamical systems. Since 2013, he joined Informed Control of Manufacturing lab at CU-ICAR working on tool condition monitoring and model-based control of manufacturing processes. A wavelet-based data-driven modeling for tool wear assessment,” *Int. J. Mechatronics Manuf. Syst.*, vol. 9, no. 2, pp. 14–16, 2016.

[5] K. Vikash Kumar and R. Sivasankara Raju, “Statistical Modeling and Optimization of Al-MMCs Reinforced with Coconut Shell Ash Particulates,” *Lect. Notes Mech. Eng.*, pp. 703–712, 2020, doi: 10.1007/978-981-15-2696-1_67/FIGURES/4.

[6] A. Caggiano, P. Centobelli, L. Nele, and R. Teti, “Multiple Sensor Monitoring in Drilling of CFRP/CFRP Stacks for Cognitive Tool Wear Prediction and Product Quality Assessment,” *Procedia CIRP*, vol. 62, pp. 3–8, Jan. 2017, doi: 10.1016/J.PROCIR.2017.03.047.

[7] C. Domínguez-Monferrer, J. Fernández-Pérez, R. D. Santos, M. H. Miguélez, and J. L. Cantero, “CFRP drilling process control based on spindle power consumption from real production data in the aircraft industry,” *Procedia CIRP*, vol. 107, pp. 1533–1538, Jan. 2022, doi: 10.1016/J.PROCIR.2022.05.187.

[8] G. Sharma, K. Umopathy, and S. Krishnan, “Trends in audio signal feature extraction methods,” *Appl. Acoust.*, vol. 158, p. 107020, Jan. 2020, doi: 10.1016/J.APACOUST.2019.107020.

[9] S. Kiranyaz, T. Ince, O. Abdeljaber, O. Avci, and M. Gabbouj, “1-D Convolutional Neural Networks for Signal Processing Applications,” *ICASSP, IEEE Int. Conf. Acoust. Speech Signal Process. - Proc.*, vol. 2019-May, pp. 8360–8364, May 2019, doi: 10.1109/ICASSP.2019.8682194.

[10] J. Fernández-Pérez, J. L. Cantero, J. Díaz-Álvarez, and M. H. Miguélez, “Influence of cutting parameters on tool wear and hole quality in composite aerospace components drilling,” *Compos. Struct.*, vol. 178, pp. 157–161, Oct. 2017, doi: 10.1016/J.COMPSTRUCT.2017.06.043.

[11] J. Duchi JDUCHI and Y. Singer, “Adaptive

Subgradient Methods for Online Learning and Stochastic Optimization * Elad Hazan,” *J. Mach. Learn. Res.*, vol. 12, pp. 2121–2159, 2011.