

# Monitorización de estado de la herramienta en mecanizado mediante redes neuronales residuales robustas

José Joaquín Peralta Abadía\*, Mikel Cuesta Zabaljauregui, Felix Larrinaga Barrenechea

*Mondragon Goi Eskola Politeknikoa, Loramendi Kalea, 4, 20500 Arrasate, Spain*

\* E-mail: [jjperalta@mondragon.edu](mailto:jjperalta@mondragon.edu)

---

## RESUMEN

La monitorización del estado de la herramienta (TCM) tiene como objetivo mejorar la eficiencia del proceso, la calidad y los costos de mantenimiento de las herramientas mediante la supervisión de variables críticas como el desgaste de la herramienta. Este estudio propone una arquitectura de aprendizaje profundo (*deep learning*, DL) basada en redes neuronales residuales robustas (Robust-ResNet) informadas por el proceso para predecir el desgaste de las herramientas en procesos de fresado utilizando series temporales de señales internas del control numérico computarizado (CNC). La arquitectura Robust-ResNet utiliza conexiones de salto para moverse a través de múltiples capas, evitando los problemas de desvanecimiento de gradiente de otros algoritmos de redes neuronales. Se realizó una evaluación sobre la adhesión de información de proceso como entrada a la arquitectura y un mecanismo de atención entre los saltos para hacer predicciones más robustas. La arquitectura propuesta se entrenó y se puso a punto empleando un conjunto de datos de acceso libre de series temporales de fresado. En este caso concreto se han empleado señales de corriente alterna y continua junto con los valores correspondientes de desgaste de herramientas. Los resultados de este estudio demuestran los beneficios del uso de técnicas de aprendizaje profundo en la predicción del desgaste de la herramienta usando señales internas que proporciona el propio CNC. Se espera que la implementación de la arquitectura propuesta ayude a reducir los costos de mantenimiento, mejorar la calidad del producto y aumentar la eficiencia de producción en los procesos de fabricación mediante fresado.

## ABSTRACT

Tool condition monitoring (TCM) aims to improve process efficiency, quality, and tool maintenance costs by monitoring critical variables such as tool wear. This study proposes a deep learning (DL) architecture based on process-informed robust residual networks (Robust-ResNet) to predict tool wear in milling processes using time series of internal signals from the computer numerical control. The Robust-ResNet architecture uses skipping connections to move through multiple layers, avoiding the vanishing gradient problem of other neural network algorithms. In addition, an evaluation is performed on adding process information as input to the architecture and an attention mechanism between skips to make more robust predictions. The proposed architecture is trained and tested on an open-access dataset of milling time series, specifically alternating and direct current signals, and corresponding tool wear values. The results of this study demonstrate the benefits of using deep learning techniques in predicting tool wear using internal signals. The implementation of the proposed architecture is expected to help reduce maintenance costs, improve product quality, and increase production efficiency in manufacturing processes.

Keywords: desgaste de herramienta; aprendizaje profundo; industria 4.0; condición de la herramienta; resnet

## 1. INTRODUCCIÓN

Los procesos de mecanizado se utilizan ampliamente en la fabricación para conseguir piezas mecanizadas de gran precisión y una buena integridad superficial [1]. Para satisfacer los requisitos de calidad de la pieza acabada, los sistemas de monitorización del estado de la herramienta (*tool condition monitoring*, TCM) son necesarios para mejorar la calidad del producto, la fiabilidad del proceso y la eficiencia de la producción [2]. El objetivo principal de la TCM es identificar el momento adecuado para sustituir las herramientas de corte. Cambiar las herramientas demasiado pronto interrumpe los tiempos de producción, y demasiado tarde puede causar daños en el equipo, las máquinas y las piezas de trabajo.

Sin embargo, la monitorización de los procesos de mecanizado mediante TCM, en particular TCM basada en el aprendizaje profundo (*deep learning*, DL), aún no ha llegado plenamente a la industria [2]. Esto se debe a que los modelos de DL suelen requerir grandes volúmenes de datos para el entrenamiento, lo que supone un reto en los procesos de mecanizado, donde los datos no suelen estar disponibles públicamente o no están etiquetados [3]. Con el objetivo de mitigar el problema de la disponibilidad de datos, se han publicado en la literatura conjuntos de datos de acceso abierto, como el conjunto de datos de fresado de la NASA Ames/UC Berkeley [4]. Como resultado, varios autores han propuesto modelos de DL entrenados con este conjunto de datos.

Aghazadeh et al. (2018) implementaron un modelo de red neuronal convolucional (*convolutional neural network*, CNN) en combinación con la sustracción espectral de paquetes de ondículas (*wavelet packets*), utilizando las señales de corriente del conjunto de datos, logrando un error cuadrático medio (*root-mean-squared error*, RMSE) de 0,088 mm [5]. Más recientemente, Cai et al. (2020) presentaron un modelo híbrido basado en redes de memoria a largo plazo (*long short-term memory*, LSTM). El modelo se entrenó con todas las señales y condiciones de corte del conjunto de datos, utilizando cuatro casos para las pruebas y los 12 restantes para el entrenamiento y logrando un RMSE de 0,0456 mm. La capa LSTM se utilizó para la codificación temporal de las características y, a continuación, una red de regresión no lineal combinó las características temporales obtenidas de la LSTM con las condiciones de corte para realizar las predicciones [6]. Zhou y Sun (2020) propusieron una *kernel extreme learning machine* (KELM), entrenado con características del dominio del tiempo, frecuencia y tiempo-frecuencia de las señales de corriente. Se utilizaron siete casos para las pruebas y seis casos para el entrenamiento, los demás fueron descartados por errores en los datos. y obtuvieron un RMSE de 0.003 mm [7]. Otro modelo LSTM híbrido, compuesto por capas LSTM bidireccionales y LSTM codificadoras-decodificadoras, fue propuesto por Kumar et al. (2022). El modelo utilizaba características de tiempo y frecuencia extraídas de las señales de vibración del conjunto de datos, logrando un RMSE de 0,0364 mm [8]. Por último, Pillai y Vadakkepat (2022) presentaron un modelo de red convolucional 3D multivariante temporal, entrenado con características 3D de las señales obtenidas a partir de transformaciones basadas en kernel, y consiguiendo un RMSE de 0,0424 mm [9].

Aunque se ha obtenido un buen rendimiento de los modelos en experimentos científicos, el margen de error sigue siendo inaceptable para las aplicaciones industriales, donde el margen de error debe de ser menor a 10% del desgaste máximo. Además, la selección de las señales que se usan como entrada del modelo requiere un enfoque práctico e industrial. Por lo tanto, el potencial de la aplicación de DL a TCM en mecanizado requiere más investigación, como estudiar la capacidad de señales internas del control numérico computarizado (CNC), como corriente AC y DC, para hacer predicciones con modelos de DL y el uso de algoritmos de DL robustos, como las redes residuales robustas (Robust-ResNet) [10].

En este artículo se propone una estrategia de DL basada en Robust-ResNet para la monitorización del desgaste de herramientas. Para proveer la robustez, se realiza una evaluación sobre la adición de información de proceso (como las condiciones de corte) como entrada a la

arquitectura y, adicionalmente, un mecanismo de atención entre los saltos de las capas del modelo propuesto en [10]. La estrategia se comparó con modelos de DL avanzados seleccionados de la literatura reciente, utilizando como entrada las señales de corriente del conjunto de datos de acceso abierto NASA Ames/UC Berkeley. La contribución de este artículo es doble:

- Se propone una nueva estrategia Robust-ResNet informada por procesos y entrenada con señales internas (señales de corriente AC y DC) con un RMSE de 0.0293 (margen de error medio de 9.7%). Los resultados se compararon con modelos de DL avanzados seleccionados de la literatura reciente, demostrando un rendimiento de predicción comparable al estado del arte usando técnicas de preprocesamiento mínimas y solo señales de corriente.
- Un análisis de las señales de corriente del conjunto de datos NASA Ames/UC Berkeley [4] para identificar las señales internas ideales que se utilizarán como entradas para los modelos de aprendizaje DL. Las señales se analizan, se limpian y se aumentan. A continuación, se comparan dos combinaciones (sólo corriente DC y ambas señales de corriente AC y DC) en relación con su efecto sobre el rendimiento del modelo Robust-ResNet.

El resto de este estudio se estructura de la siguiente manera. La Sección 2 describe el estado del arte de TCM y Robust-ResNet y el conjunto de datos de libre acceso utilizado en este estudio. La Sección 3 describe la metodología seguida para aplicar la estrategia Robust-ResNet. A continuación, la Sección 4 presenta los resultados y la discusión. Por último, la Sección 5 presenta las conclusiones y posibles trabajos futuros.

## **2. ESTADO DEL ARTE**

### **2.1. MONITOREO DE ESTADO DE HERRAMIENTAS**

En la actualidad, la industria exige mejoras continuas en la calidad de los productos, la fiabilidad de los procesos y la eficiencia de la producción. Es por esto por lo que el desarrollo y la implantación de sistemas robustos de TCM para procesos de mecanizado, como torneado, fresado y taladrado, son inevitables. Estos sistemas deben permitir el cambio de herramientas desgastadas en el momento adecuado y deben seleccionar parámetros de corte más eficaces para reducir el riesgo de fallos catastróficos de las herramientas. La fuente clave de información para identificar las condiciones de la herramienta son las variables de proceso relacionadas con el desgaste de la herramienta (VB). Las más comunes son las magnitudes dependientes de la fuerza de corte, como la potencia, el par, las vibraciones y las emisiones acústicas, referidas como señales externas [2]. Además, estudios recientes han explorado el uso de señales internas del CNC para identificar el desgaste de la herramienta en procesos de taladrado. En este estudio se demostró que las señales externas pueden ser remplazadas por señales internas sin comprometer la fiabilidad del desgaste identificado [11].

Varios desafíos han sido identificados en el contexto de TCM, entre los cuales resaltan los dos siguientes [2]:

- Fusión de sensores: En sistemas de mecanizado complejos, el tipo, origen y cantidad de datos juegan un papel importante. Los datos generados por sensores individuales suelen proporcionar información de proceso de baja calidad. Es por esto por lo que la fusión de datos de varias salidas de sensores puede proporcionar información de proceso de alta calidad, contemplando diversos aspectos del proceso. Por lo tanto, una vista ampliada que incluya la fusión de datos de los sensores es bastante necesaria para aprovechar al máximo el potencial del TCM de mecanizado. En entornos industriales, dónde puede no

ser posible sensorizar el equipamiento, la fusión de sensores involucraría la fusión de las señales internas del CNC y las condiciones de corte.

- Brecha entre los resultados en investigación y las aplicaciones en la industria: Existe una brecha entre el estado del arte en la literatura científica y el uso de sistemas comerciales de monitorización en la industria debido a la baja eficacia de los sistemas comerciales. La literatura científica describe muchos sistemas de monitoreo de procesos altamente efectivos que utilizan múltiples sensores y técnicas avanzadas de procesamiento de señales. Sin embargo, estos sistemas suelen ser difíciles de aplicar en la industria debido a que los sistemas requieren una selección subjetiva de segmentos de señal, extracción de características elegidas manualmente y entrenamiento en el laboratorio. La solución de estos problemas a través de la automatización completa es esencial para el monitoreo de procesos industriales y permitiría el uso de algoritmos avanzados y paradigmas en sistemas comerciales sin necesidad de personal altamente capacitado.

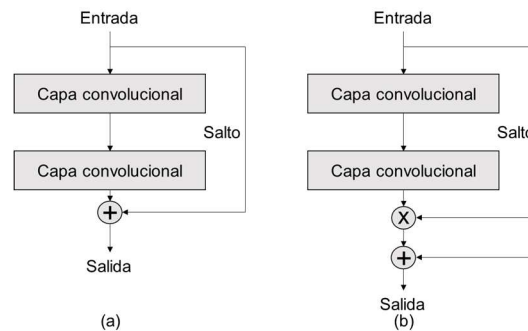
A partir de estos desafíos y en particular para sistemas basados en DL, resulta importante el diseño de modelos de DL pensados para ser aplicados a la industria. Esto involucraría entrenar modelos con datos que no hayan sido o que hayan sido ligeramente preprocesados. Además, debido a los altos costos de sensorización externa, el uso de señales internas del CNC para entrenar los modelos, así como las condiciones de corte del proceso, podría simplificar la adopción de modelos de DL en la industria.

## 2.2. REDES RESIDUALES ROBUSTAS

El aprendizaje automático (ML) y el DL son subcampos de la inteligencia artificial, que se han utilizado en TCM de mecanizado para aprender de los datos sin conocimientos previos [3]. Entre ML y DL, DL exhibe un mejor rendimiento al usar múltiples capas en su arquitectura, proveyendo una mayor capacidad para extraer y generalizar el conocimiento a partir de los datos [12]. Sin embargo, al usar un mayor número de capas, DL suele depender de macrodatos (*big data*) para poder extraer los patrones ocultos en los datos. Esto resulta problemático en procesos de mecanizado en los que la disponibilidad de datos es limitada o en los que los datos no están etiquetados. Para superar estos desafíos, resulta necesario definir experimentos cuidadosamente y recolectar grandes cantidades de datos. De esta forma, se podría entrenar modelos de DL capaces de predecir el desgaste en mecanizado efectivamente. Además, dado que los modelos de DL suelen ser específicos para cada problema, es necesario entrenar nuevos modelos cuando cambian las condiciones de corte o el entorno del proceso, dificultando la transferencia a la industria.

Debido a la profundidad de los modelos de DL, problemas como el desvanecimiento/explosión de gradiente y el sobreajuste (*overfitting*) dificultan el entrenamiento y la generalización de conocimiento [12]. Es por esto por lo que se han propuesto arquitecturas que abordan estos problemas, como las redes residuales (ResNet) [13]. Las ResNet están basadas en redes neuronales convolucionales (CNN) y realizan conexiones de salto para moverse a través de varias capas convolucionales, evitando los problemas de gradiente desvaneciente/explosivo y sobreajuste de otros algoritmos de DL. Estos saltos se hacen por bloques, a los que se refiere como unidades residuales, en los que la salida de la unidad es el resultado de la suma de elementos de la entrada de la unidad y las capas convoluciones intermedias. Sin embargo, a pesar de los beneficios de las ResNet, el desempeño de los modelos puede ser bajo debido a falta de datos y puede también disminuir al realizar predicciones con datos desconocidos. Es por esto por lo que se han propuesto ResNet robustas (Robust-ResNet) usando aprendizaje residual con mecanismo de atención [10]. Los mecanismos de atención de las Robust-ResNet funcionan como selectores de características, realzando las características significativas y suprimiendo el ruido creado por las insignificantes. Esta selección se realiza aplicando un producto matricial antes de realizar la suma de elementos, lo que da mayor peso a las características con mayor

influencia en la predicción del desgaste. La [Figura 1](#) muestra un ejemplo de una unidad residual tradicional ([Figura 1\(a\)](#)) y una unidad residual con mecanismo de atención ([Figura 1\(b\)](#)).



**Figura 1.** Tipo de unidades residuales: (a) unidad residual tradicional y (b) unidad residual con mecanismo de atención.

### 2.3. DESCRIPCIÓN DEL DATASET

En este estudio se usó el conjunto de datos de libre acceso de la NASA Ames/UC Berkeley [4] como entrada para entrenar el modelo Robust-ResNet. El conjunto de datos incluye 16 experimentos de fresado (planeado) realizados en una fresadora bajo diferentes condiciones de corte. Se emplearon tres tipos de sensores (sensores de emisión acústica (AE), sensores de vibración y sensores de corriente) recogiendo datos con una frecuencia de muestreo de 250 Hz. En concreto, los sensores recogieron señales como la corriente alterna del motor del cabezal (*smcAC*), la corriente continua del motor del cabezal (*smcDC*), la vibración de la mesa (*vib\_table*), la vibración del cabezal (*vib\_spindle*), la AE de la mesa (*AE\_table*) y la AE del cabezal (*AE\_spindle*). Las señales *smcAC* y *smcDC* fueron medidas con sensores externos. Sin embargo, en la actualidad, los CNC son capaces de registrar el consumo de corriente durante el proceso como señales internas, por lo que se han elegido estas dos características para entrenar los modelos Robust-ResNet.

Además, el conjunto de datos está enriquecido con información sobre el proceso, como el número de caso (*case*), el número de pasada (*run*), el VB y las condiciones de corte. Las condiciones de corte incluyen la profundidad de corte (DOC), la velocidad de avance (*feed*) y el tipo de material. Se realizaron un total de 167 pasadas de aproximadamente 36 s cada una, con 9000 puntos de medición por pasada. El número de pasadas por caso varió en función del grado de VB evaluado entre pasadas a intervalos irregulares, por lo que no se registró el VB en algunas pasadas. Además, el grado de desgaste superó en algunos casos el límite de VB recomendado por el fabricante.

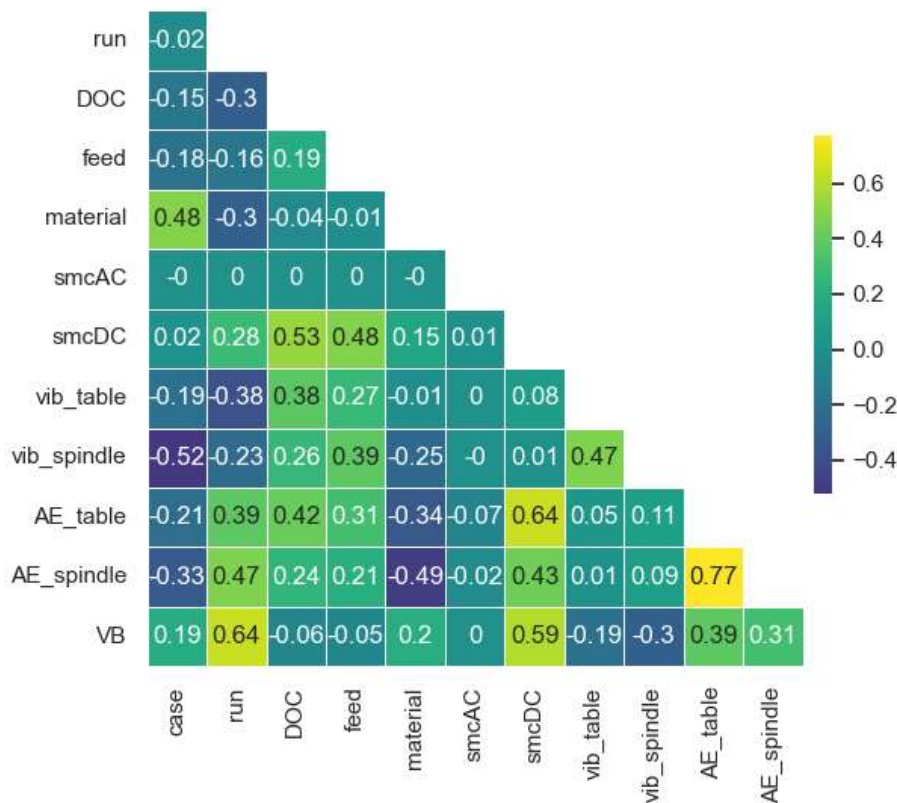
Las condiciones experimentales de los casos se presentan en la Tabla 1, e incluyen dos valores de DOC (1,5 y 0,75 mm), dos valores de avance (0,5 y 0,25 mm/rev), y dos tipos de material (1-hierro fundido y 2-acero inoxidable). Las herramientas de corte utilizadas fueron plaquitas KC710, la velocidad de corte fue de 200 m/min (826 rev/min), y el tamaño de la pieza de trabajo fue de 483 mm x 178 mm x 51 mm. Se definieron ocho combinaciones de condiciones de corte, y cada combinación se repitió una segunda vez con un nuevo juego de herramientas de corte.

Se aplicó el coeficiente de correlación de Pearson [14] al conjunto de datos, obteniendo las correlaciones entre las características del conjunto de datos, y está representado como matriz de correlación en la [Figura 2](#). De las señales, *smcDC* presentó la mayor correlación con VB y *smcAC* no presentó ninguna correlación con VB ni *smcDC*. Esto apunta a que se podría elegir la señal *smcDC* como característica más representativa del VB y la señal *smcAC* como

característica complementaria, con miras a la fusión de sensores.

**Tabla 1.** Condiciones de corte experimentales del conjunto de datos [4].

Casos	DOC	Velocidad avance	Material
1 y 9	1.5	0.5	1
2 y 12	0.75	0.5	1
3 y 11	0.75	0.25	1
4 y 10	1.5	0.25	1
5 y 16	1.5	0.5	2
6 y 15	1.5	0.25	2
7 y 13	0.75	0.25	2
8 y 14	0.75	0.5	2



**Figura 2.** Matriz de correlación del conjunto de datos [4].

La [Figura 3](#) ilustra la curva de progresión de VB para las ocho condiciones de corte del conjunto de datos, donde el color de la línea representa el tipo de material. Para cada condición, las líneas muestran la media entre el VB de las dos repeticiones y los bigotes muestran los valores de las dos repeticiones por pasada. Como para las mismas condiciones de corte hubo repeticiones que duraron más que su contraparte, se puede observar caídas en las curvas de VB medio. Sin embargo, al mirar los bigotes inferiores de los puntos, se puede apreciar que la tendencia se mantiene en ascenso una vez que la curva representa solo una repetición. Se puede observar que para el material 1 (hierro fundido), las curvas de VB tienen una mayor variabilidad, mientras que para el material 2 (acero inoxidable), las curvas de VB tienen un comportamiento

similar.




Figura 3. Curvas de progresión de VB medio de las ocho condiciones de corte experimentales.

### 3. METODOLOGÍA

La metodología para TCM usando modelos Robust-ResNet constó de dos pasos. En primer lugar, se realizó un preprocesamiento de datos mínimo en el conjunto de datos para limpiar y aumentar los datos para tener una alta cantidad de datos limpios para el entrenamiento de los modelos. En segundo lugar, se desarrollaron e implementaron modelos ResNet y Robust-ResNet, usando mecanismos de atención y/o información del proceso.

#### 3.1. PREPROCESAMIENTO

El conjunto de datos contiene mediciones recogidas durante los cortes de entrada, regulares y de salida de los experimentos. En este estudio, se omitieron las partes de las señales correspondientes a los cortes de entrada y salida, centrándose únicamente en la parte del proceso de mecanizado correspondiente a los cortes regulares. Además, como en algunos casos no se registró el VB, se realizó una interpolación lineal para utilizar todos los datos disponibles. A continuación, se evaluaron las señales de cada pasada. Los datos adquiridos en ocho de los casos estaban dañados o tenían eventos no documentados y se omitieron en este estudio, lo que dio como resultado 159 ejecuciones para el entrenamiento y las pruebas. Además, 22 ejecuciones tenían señales con valores ruidosos, lo que podría tener un impacto negativo en la capacidad de predicción de los modelos. Para predecir el VB, el comportamiento global de la señal es más importante que los eventos locales (por ejemplo, el astillado). Por lo tanto, se aplicó una media móvil de tamaño 20 para eliminar ruido en las señales, manteniendo al mismo tiempo el comportamiento global de las señales. A continuación, se presentan los dos grupos de pasadas que se limpiaron:

- Omitidos
  - Caso 1 - Pasadas 16 y 17: VB disminuye luego de la pasada 15.
  - Caso 2 - Pasada 5: Faltan datos en AE\_table.

- Caso 2 - Pasada 6: Datos corruptos en AE\_spindle.
  - Caso 7 - Pasada 4: Datos corruptos en AE\_table.
  - Caso 8 - Pasada 3: Faltan datos en AE\_table.
  - Caso 12 - Pasada 1: Datos corruptos en todas las señales.
  - Caso 12 - Pasada 12: Evento indocumentado en todas las señales.
- Con ruido
    - Caso 3 - Pasada 9.
    - Caso 7 - Pasada 8.
    - Caso 8 - Pasada 4.
    - Caso 10 - Pasadas 2 y 10.
    - Caso 11 - Pasadas 10 y 21.
    - Caso 12 - Pasadas 3 y 7.
    - Caso 13 - Pasadas 3, 6, 8, 9, 13 y 14.
    - Caso 14 - Pasadas 1, 2, 3, 6 y 10.
    - Caso 15 - Pasadas 1, 2, 3, 4, 6 y 7

### 3.2. REDES RESIDUALES ROBUSTAS

Cuatro variaciones de ResNet fueron implementadas en este estudio: (i) ResNet tradicional, (ii) Robust-ResNet informadas por el proceso, (iii) Robust-ResNet con mecanismo de atención y (iv) Robust-ResNet informadas por el proceso con mecanismo de atención, referenciadas en este estudio como ResNet, ResNet-IP, ResNet-MA y ResNet-IP-MA, respectivamente. Para las variaciones informadas por el proceso, una red neural de 1 capa oculta se usó para extraer características de las condiciones de corte y luego se combinó con la salida de las capas residuales del modelo, proveyendo información a la predicción. La arquitectura de los modelos Robust-ResNet se presenta en la [Figura 4](#), donde la capa de entrada de la información de proceso (en gris) solo aplica a ResNet-IP y ResNet-IP-MA. Todas las capas internas incluyeron normalización por lotes (*batch normalization*) y rectificador (*rectified linear unit o ReLU*) como función de activación.

Los modelos luego fueron evaluados utilizando ambas señales de corriente (*smcDC* y *smcAC*), buscando explotar las ventajas de la fusión de sensores. Además, también se evaluó el uso de únicamente la señal de corriente continua (*smcDC*). El rendimiento de los modelos se comparó con modelos de DL avanzados seleccionados de la literatura reciente, como modelos de referencia [5–9].



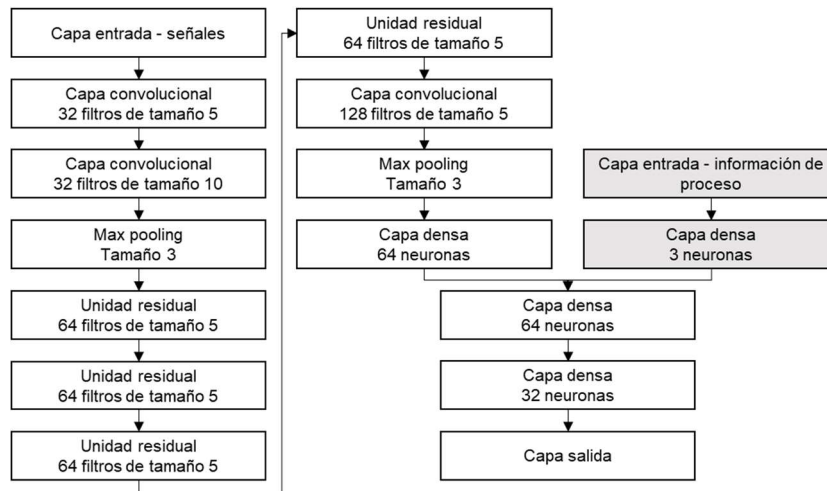


Figura 4. Arquitectura de los modelos Robust-ResNet.

#### 4. RESULTADOS Y DISCUSIÓN

Habiendo definido la metodología, se desarrollaron y entrenaron los modelos Robust-ResNet. Los datos se normalizaron usando el *z-score* para que todas las señales tuvieran magnitudes similares. Además, dado que los modelos de DL requieren datos de gran tamaño, se adoptó un enfoque de ventana deslizante para aumentar el conjunto de datos. La ventana deslizante fue de un tamaño de 250 (un segundo) y un intervalo de 25 (1/10 de segundo). Se decidió usar una ventana de tiempo menor ya que, al enfocarse en porciones de la señal, se puede facilitar la identificación de patrones ocultos en la señal por los modelos de DL. De esta manera, se aumentó el tamaño del conjunto de datos de 159 ejecuciones (o secuencias) con una longitud de secuencia de 5400 (21.6 s) a 31323 secuencias con una longitud de 250 (1 s).

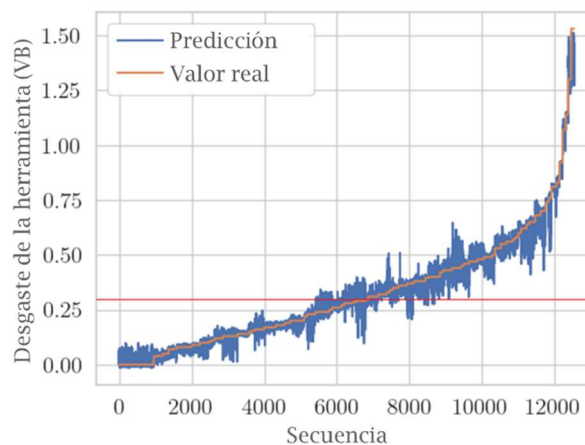
Todas las estrategias compartieron los mismos hiperparámetros de modelo. Los modelos se entrenaron durante 2000 épocas, con una parada temprana tras 200 épocas sin mejora del modelo. Todos los modelos utilizaron el optimizador ADAM [15] con una tasa de aprendizaje de 0,0001 y RMSE como función de pérdida. Para evitar el sobreajuste, se aplicó un factor de regularización L2 de 0,00001. El conjunto de datos se dividió estocásticamente en un 48% para el entrenamiento, un 12% para la validación y un 40% para las pruebas. La división se realizó estocásticamente para tener en cuenta la variabilidad en las condiciones de corte y las herramientas que pueden darse en los talleres industriales.

En la tabla 4 se presentan los resultados de los modelos agrupados por estrategias de datos de entrada, así como una comparación con los modelos de referencia. Como evaluadores de rendimiento se eligieron el coeficiente de determinación ( $R^2$ ) y el error cuadrático medio (RMSE). El rendimiento de los modelos es mejor cuando se aproxima a uno para  $R^2$  y a cero para RMSE. Los resultados de la tabla demuestran los beneficios de los modelos Robust-ResNet. En particular, el modelo ResNet-IP-MA entrenado con ambas señales de corriente obtuvo resultados sobresalientes, al comparar con los modelos de referencia. Más aun, los resultados son mejores que los obtenidos por los modelos de referencia que usan todas las señales (internas y externas). El modelo ResNet-IP-MA superó los resultados de la mayoría los modelos de referencia, con un RMSE de 0,0293 mm (margen de error medio de 9.7%) y una puntuación  $R^2$  de 0,9871. El modelo solo fue superado únicamente por el modelo KELM, el cual utiliza características de los dominios tiempo, frecuencia y tiempo-frecuencia extraídas de las señales de corriente [7]. Sin embargo, el modelo propuesto en este estudio no usó técnicas de extracción de características que añaden complejidad computacional a la monitorización, proveyendo resultados cercanos a los límites mínimos de error en la industria. De esta manera, se demostró el aumento en la calidad de la predicción al incorporar información de proceso y mecanismos de atención.

**Tabla 2.** Resultados de rendimiento de los modelos Robust-ResNet. El modelo con mejores resultados aparece resaltado en negrita.

Modelo	Todas las señales		Señales DC y AC		Señal DC		Señales vibración	
	RMSE	$R^2$	RMSE	$R^2$	RMSE	$R^2$	$R^2$	RMSE
ResNet			0.1341	0.7293	0.1426	0.6892		
ResNet-MA			0.1216	0.7773	0.1424	0.6902		
ResNet-IP			0.0362	0.9803	0.0808	0.9003		
ResNet-IP-MA			<b>0.0293</b>	<b>0.9871</b>	0.0796	0.9031		
CNN con sustracción espectral [5]					0.088			
LSTM con información de proceso [6]	0.0456							
KELM [7]			<b>0.003</b>	<b>0.9967</b>				
LSTM híbrido [8]							0.0364	0.9837
TM3C-KT [9]	0.0424							

La [Figura 5](#) presenta una comparación de la curva VB tanto para los valores reales como para los valores predichos del modelo ResNet-IP-MA, cuando se utilizan todas las entradas. Los datos se ordenaron por el valor real, ya que todos los casos y ejecuciones se aumentaron y barajaron estocásticamente durante la división. Puede observarse que el modelo predijo valores muy próximos al valor real a lo largo de la curva de desgaste, particularmente antes del desgaste recomendado por el fabricante (línea horizontal roja). De esta forma, se demuestra la eficacia y el buen rendimiento del enfoque cuando se utiliza la fusión de sensores, información de proceso y mecanismos de atención.



**Figura 5.** Curva VB del conjunto de datos de prueba. Las secuencias están ordenadas según el valor VB real.

## 5. CONCLUSIÓN Y TRABAJO FUTURO

En este artículo, se ha presentado un enfoque de monitorización TCM basado en redes residuales robustas (Robust-ResNet). El enfoque Robust-ResNet se propone para mejorar el rendimiento al predecir el desgaste de la herramienta en el mecanizado con miras a aplicaciones industriales. El enfoque se basa en los beneficios de las redes residuales, así como del enriquecimiento de la predicción mediante la información de proceso y mecanismos de atención, proveyendo mayor robustez y precisión.

El enfoque Robust-ResNet se ha validado utilizando el conjunto de datos de fresado de acceso

abierto de NASA Ames/UC Berkeley, el cuál fue aumentado y limpiado. Para las pruebas de validación se utilizó la señal *smcDC* por si sola y una combinación de las señales *smcDC* y *smcAC*. Los mejores resultados se obtuvieron utilizando ambas señales de corriente, superando considerablemente el desempeño de los modelos de referencia basados en DL y demostrando las ventajas de la fusión de sensores. Los resultados señalan la aplicabilidad industrial del enfoque, realizando predicciones de desgaste con un margen de error bajo y sin necesitar implementar métodos manuales de análisis y preprocesado de datos. En el futuro, se conducirán experimentos de mecanizado, replicando y ampliando las condiciones de corte del conjunto de datos de Nasa AMES/UC Berkeley, y se investigará la capacidad del enfoque Robust-ResNet para detectar el desgaste de las herramientas en este nuevo conjunto de datos de mecanizado. Finalmente, se estudiará la posibilidad de omitir el paso de limpieza de ruido, proveyendo mayor automatización al proceso de entrenamiento.

## 6. AGRADECIMIENTOS

Este proyecto ha recibido financiación del programa de investigación e innovación Horizon 2020 de la Unión Europea bajo el acuerdo de subvención Marie Skłodowska-Curie número 814078 y por el Departamento de Educación, Universidades e Investigación del Gobierno Vasco bajo los proyectos Ikerketa Taldeak (Grupo de Ingeniería de Software y Sistemas IT1519-22 y Grupo de investigación de Mecanizado de Alto Rendimiento IT1443-22).

## 7. REFERENCIAS

- [1] C.H. Lauro, L.C. Brandão, D. Baldo, R.A. Reis, J.P. Davim, Monitoring and processing signal applied in machining processes - A review, *Measurement*. 58 (2014) 73–86.
- [2] R. Teti, D. Mourtzis, D.M. D’Addona, A. Caggiano, Process monitoring of machining, *CIRP Annals*. 71 (2022) 529–552.
- [3] D.Y. Pimenov, A. Bustillo, S. Wojciechowski, V.S. Sharma, M.K. Gupta, M. Kuntoğlu, Artificial intelligence systems for tool condition monitoring in machining: analysis and critical review, *J Intell Manuf.* (2022) 1–43. <https://doi.org/10.1007/S10845-022-01923-2>.
- [4] A. Agogino, K. Goebel, Milling data set, (2007).
- [5] F. Aghazadeh, A. Tahan, M. Thomas, Tool condition monitoring using spectral subtraction and convolutional neural networks in milling process, *International Journal of Advanced Manufacturing Technology*. 98 (2018) 3217–3227. <https://doi.org/10.1007/s00170-018-2420-0>.
- [6] W. Cai, W. Zhang, X. Hu, Y. Liu, A hybrid information model based on long short-term memory network for tool condition monitoring, *J Intell Manuf.* 31 (2020) 1497–1510. <https://doi.org/10.1007/s10845-019-01526-4>.
- [7] Y. Zhou, W. Sun, Tool wear condition monitoring in milling process based on current sensors, *IEEE Access*. 8 (2020) 95491–95502.
- [8] S. Kumar, T. Kolekar, K. Kotecha, S. Patil, A. Bongale, Performance evaluation for tool wear prediction based on Bi-directional, Encoder–Decoder and Hybrid Long Short-Term Memory models, *International Journal of Quality and Reliability Management*. 39 (2022) 1551–1576. <https://doi.org/10.1108/IJQRM-08-2021-0291>.
- [9] S. Pillai, P. Vadakkepat, Deep learning for machine health prognostics using Kernel-based feature transformation, *J Intell Manuf.* 33 (2022) 1665–1680. <https://doi.org/10.1007/s10845-021-01747-6>.

- [10] F. Wang, M. Jiang, C. Qian, S. Yang, C. Li, H. Zhang, X. Wang, X. Tang, Residual attention network for image classification, in: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: pp. 3156–3164.
- [11] A. Duo, R. Basagoiti, P.J. Arrazola, M. Cuesta, Sensor signal selection for tool wear curve estimation and subsequent tool breakage prediction in a drilling operation, *Int J Comput Integr Manuf.* 35 (2022) 203–227.
- [12] I. Goodfellow, Y. Bengio, A. Courville, *Deep Learning*, MIT Press, 2016.
- [13] K. He, X. Zhang, S. Ren, J. Sun, Deep residual learning for image recognition, in: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: pp. 770–778.
- [14] I. Cohen, Y. Huang, J. Chen, J. Benesty, J. Benesty, J. Chen, Y. Huang, I. Cohen, Pearson correlation coefficient, *Noise Reduction in Speech Processing.* (2009) 1–4.
- [15] D.P. Kingma, J. Ba, Adam: A method for stochastic optimization, *ArXiv Preprint ArXiv:1412.6980.* (2014).