

## Aplicación de técnicas de IA en mecanizado

Ander Martin-Rebe<sup>1</sup>, Haizea Gonzalez-Barrio<sup>2</sup>, Alain Gil-Del-Val<sup>3</sup>, Txomin Ostra-Beldarrain<sup>4</sup>

<sup>1</sup> Escuela de Ingeniería de Bilbao (UPV/EHU), España. Email: 97andermartin@gmail.com

<sup>2</sup> Escuela de Ingeniería de Vitoria (UPV/EHU) y Centro de Fabricación Avanzada Aeronáutica (CFAA), España. Email: haizea.gonzalez@ehu.eus

<sup>3</sup> TECNALIA, Basque Research and Technology Alliance (BRTA) y Universidad Internacional de La Rioja, España. Email: alain.gil@tecnalia.com, alain.gildelval@unir.net

<sup>4</sup> TECNALIA, Basque Research and Technology Alliance (BRTA), España. Email: txomin.ostra@tecnalia.com

### Resumen

El boom de la digitalización permite disponer de un volumen de datos que provienen de máquinas herramienta en su etapa operativa. El análisis de estos datos puede ayudar a obtener mejoras en el ámbito del mantenimiento de las máquinas, pero también mejoras en los procesos de fabricación que realizan las máquinas herramienta. El objetivo del proyecto consiste en desarrollar algoritmos o técnicas basadas en Inteligencia Artificial, que permitan analizar datos procedentes de centros de mecanizado, que faciliten procesos más productivos, desatendidos o robustos. Se parte de los datos históricos de dos centros de mecanizado en pleno rendimiento productivo que fabrican una variedad muy amplia de piezas diferentes. Se busca a través de los datos encontrar patrones que permitan controlar el funcionamiento adecuado de cada herramienta. El control se basará en el funcionamiento de la herramienta para las mismas condiciones en un histórico de datos. El núcleo del trabajo es el pre-procesamiento de los datos (eliminación de pausas y momentos no productivos, división de datos por operaciones, identificación del tipo de operaciones) y el estudio de las alternativas existentes de *Machine-Learning* que pueden ayudar a modelizar el funcionamiento de la herramienta utilizando las variables apropiadas

**Palabras clave:** Inteligencia Artificial, Mantenimiento predictivo, Máquina-Herramienta, Análisis de datos.

### Abstract

The digitization boom makes available a volume of data coming from machine tools in their operational stage. The analysis of this data can help to obtain improvements in the field of machine maintenance, but also improvements in the manufacturing processes performed by machine tools. The objective of the project is to develop algorithms or techniques based on Artificial Intelligence, which allow the analysis of data from machining centers, to facilitate more productive, unattended or robust processes. The starting point is the historical data of two machining centers in full productive performance that manufacture a wide variety of different parts. The data is used to find patterns that allow to control the proper operation of each tool. The control will be based on the performance of the tool for the same conditions in a data history. The core of the work is the pre-processing of the data (elimination of non-productive moments, division of data by operations, identification of the type of operations) and the study of the existing Machine-Learning alternatives that can help to model the operation of the tool using the appropriate variables.

**Keywords:** Artificial intelligence, Predictive maintenance, Machine-tool, data analysis

### 1. Introducción

En la década actual, la globalización y el concepto de economía circular implican la necesidad de las

empresas de adquirir ventajas competitivas para su situación en el mercado. En el caso de un sector como el aeronáutico, esta competitividad conlleva un aumento de la complejidad de cara a los diseños y

componentes, más concretamente los de turbomaquinaria. A su vez, esto afecta directamente a los procesos de fabricación, productos y la dinámica de la cadena de suministro. Para hacer frente a estos desafíos, el concepto de Industria 4.0 trae consigo conceptos como la resiliencia, la reconfigurabilidad y la flexibilidad. Es aquí donde coge fuerza el concepto de fábrica o fabricación inteligente. El Internet industrial de las cosas (IIoT), junto con la tecnología de la información, las redes de sensores, los controles informatizados y el software de gestión de la producción son requisitos básicos para una empresa en el mercado actual [1].

Cabe destacar que el flujo de información y los datos obtenidos durante los procesos de fabricación son uno de los activos más importantes de las empresas, sin embargo, la óptima gestión de Big Data es, a su vez, uno de los mayores desafíos que se presentan. La correcta gestión de datos marca una diferencia y ofrece una ventaja competitiva, esto es, empresas que han basado sus decisiones basadas en datos presentan unos resultados de un 5% más en términos de productividad y un 6% más en rentabilidad que empresas afines [2]. Sin embargo, la correcta gestión de los datos es, a día de hoy, un hándicap y, por lo tanto, un tema actual de investigación. Como es el caso de la importancia de saber qué datos seleccionar a la hora de analizarlos y poder sacar conclusiones de ellos, ya que un exceso de datos también puede ser perjudicial.

Por ello, optimizar la recogida y el análisis de datos se ha convertido en un aspecto de vital importancia para muchas empresas [3] y se espera que la Inteligencia Artificial juegue un papel clave, especialmente la rama del *Machine Learning*, que permite un autoaprendizaje de las máquinas a partir de la información ya procesada sin necesidad de ser programadas explícitamente para ello.

Cabe destacar que el *Machine Learning* no está especialmente relacionado con ningún sector o campo de aplicación, sino que se puede utilizar en diversos sectores como la fabricación, la construcción, el diseño de materiales, la aviación, la informática, la seguridad, la ingeniería nuclear, la ingeniería térmica, la ingeniería eléctrica y la electrónica, la automoción, la biomedicina, la farmacia, la empresa, etc. Sin embargo, las aplicaciones industriales de estas tecnologías son todavía escasas y generalmente se limitan a un pequeño grupo de grandes empresas.

Más concretamente en el ámbito de la fabricación, se han realizado numerosos trabajos con el fin de ampliar el conocimiento en esta área. Para mejorar la calidad de los productos, D. Muhr et al. [3] adaptaron los parámetros de fabricación en función de las características específicas de cada pieza inicial, con el

fin de optimizar la calidad y sostenibilidad. Para ello, aplicaron un modelo de regresión lineal, identificando los parámetros del proceso y, a continuación, utilizaron valores de series temporales para obtener parámetros más exactos. B. Rolf et al. [4], demostró la viabilidad del uso de un algoritmo genético para resolver un problema de programación de taller de flujo híbrido con tiempos de preparación dependientes de la secuencia. El algoritmo presentó algunas soluciones buenas al cabo de unos segundos, lo que implicaría la posibilidad de toma de decisiones en tiempo real. Por otro lado, X. Yuan et al. [5], se centró en el modelado de sensores, donde se había aplicado hasta el momento una Red Neuronal. Muchos de ellos han centrado sus esfuerzos en los parámetros y variables de corte de los procesos de mecanizado, como el fresado o el torneado, como es el caso de Khasawneh et al. [6] que combinan técnicas de *Machine Learning* supervisado con Análisis de Datos Topológicos. En el caso de M. Hashemitaheeri et al. [7], se realizó la predicción de las fuerzas de corte específicas y las temperaturas máximas durante los procesos de mecanizado ortogonal aplicando la regresión de vectores de soporte y la regresión de procesos gaussianos. Con respecto a la aplicación del *Machine Learning*, Y. Zhang et al. [8] desarrollaron modelos de regresión gaussiana capaces de predecir no sólo las fuerzas de corte, sino también la rugosidad superficial y la vida de la herramienta en procesos de torneado de alto avance.

Finalmente, en lo relativo al conocimiento de *Machine Learning* y *Deep Learning*, T. Kotsiopoulos [9] que realizó un estado del arte detallando los algoritmos más importantes utilizados en la Industria 4.0. Discutiendo y evaluando cada uno de ellos en términos de aplicabilidad, características y eficiencia.

En este trabajo se presenta una metodología para la óptima gestión y tratamiento de datos de una línea de producción de fabricación aeronáutica, analizando las distintas combinaciones de parámetros, tanto de proceso como de máquina, para su preparación y posterior aplicación de algoritmos de fabricación inteligente *Machine Learning*. Además, se presenta una serie de resultados derivados tanto de la depuración como de la estructuración. Finalmente, se plantea la posibilidad de aplicar las técnicas de IA que mejor se adaptan a los datos de producción.

## 2. Metodología

Las piezas del sector aeronáutico se caracterizan por sus exigentes tolerancias y requisitos mecánicos, por lo que prima la calidad. A lo largo de este trabajo, se presenta una metodología para el tratamiento de datos de procesos de fabricación obtenidos a partir de una línea de producción habitual de una empresa del sector de fabricación aeronáutica. Dada la dificultad

presentada, no derivada de ensayos establecidos sino de líneas activas de producción, la definición de una metodología óptima es crucial para la gestión y tratamiento de un gran volumen de datos.

La metodología propuesta está estructurada en 5 fases principales: (a) Obtención de datos para posteriormente pre-procesarlos, (b) resultado del pre-procesamiento en un data-set o conjunto de datos limpio y estructurado para la aplicación de modelos IA; (c) un análisis del potencial de los datos y de algunas técnicas de IA definiendo una estrategia antes de generar modelos a través de estrategias *machine learning*; (d) implementación de los modelos y estrategias y (e) análisis de resultados y conclusiones.

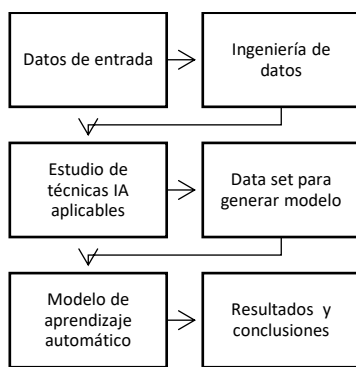


Figura 1. Flujograma de la metodología

### 2.1. Obtención de datos

Inicialmente, se evalúan los datos obtenidos del proceso. Para ello, se toman los datos de partida en formato HDF de dos centros de mecanizado horizontales que fabrican piezas de aluminio para el sector aeronáutico. Se presentan un total de 45 parámetros obtenidos a 5 Hz de diferentes fuentes de origen, algunos del control interno de las máquinas, otros mediante sensores externos instalados previamente y otros directamente del programa CNC que se carga en las fresadoras.

Cabe destacar que, las piezas de las que se disponen los datos se fabrican en pequeñas tiradas, o incluso en lotes únicos. Además, la variedad geométrica que se presenta es muy amplia, considerando la rigidez de las piezas un factor crítico. Se puede hacer una distinción de numerosas referencias, diferenciando herramientas, operaciones y piezas, estando interrelacionadas entre sí puesto que se fabrican con diferentes herramientas y a cada pieza se le realizan diferentes operaciones.

En cuanto a las herramientas, el desgaste que se observa es lento y su vida útil prolongada al tratarse de la mecanización de un material relativamente dúctil. En lo que respecta a las mismas, la información relativa a las herramientas es el número

identificador y si está en la posición de trabajo, posicionada en el husillo, y cuál es la herramienta que se gestiona en el PLC.

Para realizar la gestión y tratamiento de los datos, se ha utilizado la herramienta de programación Python con la cual se han importado los datos. Primero se han importado los datos de todos los parámetros asociados a un día de producción y, a medida que se ha avanzado en el conocimiento de los datos, se ha ido extrapolando el estudio a periodos más amplios de producción.

### 2.2. Pre-procesamiento

En esta segunda fase, se realiza el pre-procesamiento de todos los datos que puedan ser relevantes en el proceso de fabricación y habiliten la aplicación de técnicas de IA. Por ello, el pre-procesamiento de los datos se ha dividido en 4 tareas principales:

#### 2.2.1. Selección de parámetros relevantes

Mediante la representación gráfica de las 45 señales, la comparación normalizada y búsqueda de correlación se ha determinado cuales son los parámetros que mejor describen el proceso de fabricación o ayudan a entender el desarrollo de las operaciones.

Se han reducido los parámetros a los recogidos en la Tabla 1.

Tabla 1. Parámetros relevantes y sus unidades.

Parámetros relevantes.	
Parametro	unidad
Velocidad de giro del husillo	1/min
Carga del husillo	%
Valor RMS de vibración	mg
Corriente del motor de cada eje	A
Posición de cada eje	mm
Velocidad de avance	mm/min
Programa Activo	Identificador
Subprograma activo	Identificador
Estado del programa	Identificador
Desplazamiento rápido. G00 activo	Binario
Herramienta activa en el husillo	Identificador

Los parámetros, velocidad de giro del husillo, velocidad de avance, posición de cada eje y herramienta activa en el husillo guardan la información que ha utilizado el operario a la hora de generar con herramientas CAM el programa CNC, Es la información relevante que define el proceso.

Por otro lado, la carga del husillo, el valor RMS de vibración y la corriente del motor de cada eje son parámetros del proceso. El valor RMS de vibración

esta medida por unos acelerómetros externos que dan a esta señal mayor sensibilidad que al resto. Se desarrolla en cierto modo de forma paralela a la carga del husillo.

Por otro lado, las señales desplazamiento rápido y estado del programa ayudan a discernir entre los momentos productivos del mecanizado y los momentos en los que la máquina no trabaja.

Por último, las señales programa activo y subprograma activo son importantes para estructurar los datos por piezas y herramientas.

Se han clasificado según su tipología en base a la clasificación que hace Dorina Weichert et al. en [10] y se ha tenido en cuenta cuales son parámetros internos captados por la máquina y aquellos obtenidos mediante sensorización externa del centro de mecanizado. Entre los parámetros recogidos en la Tabla 1 únicamente el valor RMS de vibración es externo.

### 2.2.2. Depuración de los datos

Se conoce la importancia de la depuración de los datos para su correcta interpretación y gestión. Para ello, en esta tarea se han filtrado los datos que no corresponden a momentos productivos, en los que se puede asegurar que no se produce arranque de viruta. Para ello, se ha utilizado la información que aportan las siguientes señales: Estado del programa, subprograma activo, velocidad de giro, herramienta activa en el husillo, avance rápido, velocidad de avance y carga.

### 2.2.3. Estructura de los datos

Los datos originales, de los que han sido filtradas las partes en las que no se produce arranque de viruta, son señales temporales a 5 Hz. En esta tarea del trabajo se han agrupado los datos en fragmentos o partes para facilitar el análisis y tratamiento de los mismos:

- a) Piezas fabricadas utilizando la señal programa activo.
- b) Subprogramas o, lo que es lo mismo, por partes mecanizadas por la misma herramienta en cada pieza.
- c) Agrupar los datos por operaciones, partes mecanizadas por la misma herramienta a una velocidad de giro de la herramienta constante.

En este trabajo agrupar los datos por piezas es poco beneficioso ya que la modelización se ha realizado para que sea eficaz a la hora de fabricar una pieza totalmente nueva con operaciones no realizadas con

anterioridad. Sin embargo, modelizar el funcionamiento de la herramienta o el comportamiento cuando se realiza algún tipo de operación concreta sí puede ofrecer información relativa para piezas nuevas ya que se mecanizan con las mismas herramientas y se les realizan operaciones similares.

### 2.2.4. Obtención de información del proceso oculta en los datos

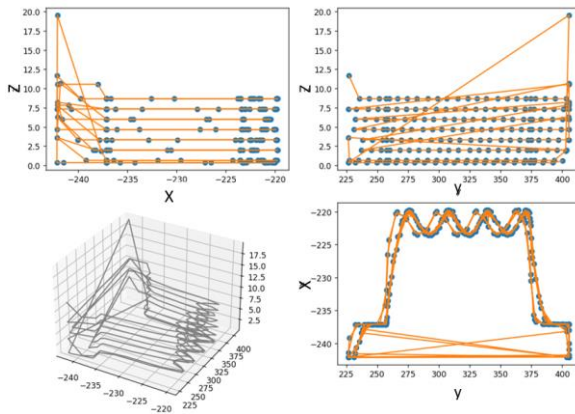
Para terminar con el pre-procesamiento de los datos se ha hecho un análisis cualitativo y cuantitativo de los mismos.

Por un lado, se han analizado las señales de carga del husillo y valor RMS con detenimiento, ya que se consideran las señales más representativas del arranque de viruta o del proceso de mecanizado. Se han planteado, entre otras, las siguientes hipótesis en cuanto a su desarrollo:

- a) El nivel del valor de la carga caracteriza cada herramienta de forma que cada una de las herramientas trabaja siempre con un nivel de carga similar.
- b) Los niveles de carga de las herramientas son mayores cuando las herramientas se utilizan durante las operaciones de desbaste, y menores cuando realizan operaciones de acabado.
- c) Las herramientas quedan agrupadas según la variedad de valores de carga con los que trabajan o según la variedad de instantes en la fabricación de las piezas en las que se activan.

Las anteriores son las hipótesis más significativas que se han planteado, sin embargo se han visto limitadas por la amplia variedad de operaciones o condiciones de uso que tiene cada herramienta. La casuística es muy amplia. Del análisis de esas señales, con la idea de modelizar el funcionamiento de las herramientas o las operaciones, se ha concluido que es necesaria la utilización de más parámetros para lograr describir el proceso.

Por otro lado, se han representado las posiciones de las herramientas únicamente para los datos de arranque de viruta. Un ejemplo se muestra en la **Figura 2** en la que se aprecia una operación de contorno con una estrategia z-level. Este ejercicio de ingeniería inversa ha aportado información relativa al proceso ejecutado:



**Figura 2.** Ejemplo de la representación de las posiciones de la herramienta para una operación.

En primer lugar, ha permitido descubrir el tipo de operaciones o estrategias a las que se destina cada herramienta, se han identificado planeados, contorneados z-level, taladros, ranurados con penetración axial y ranurados con penetración en rampa entre otros. Lo que ha permitido hacer una clasificación de las herramientas según el tipo de operación o recorrido que realizan.

En segundo lugar, al identificar las estrategias z-level se ha calculado la profundidad de corte ( $a_p$ ) para esos casos. Es un parámetro muy relevante en operaciones de mecanizado por lo que se ha incluido en la lista de parámetros relevantes. El desafío presente en esta obtención de  $a_p$  es notable para el primero de los niveles ya que no cuenta con referencia previa y para las operaciones que no son Z-level puesto que se desconocen los saltos entre niveles.

También, se ha hecho un estudio de las herramientas que más se utilizan, concluyendo que al mecanizar aluminio una misma herramienta se puede utilizar con diferentes fines. Por ejemplo, la misma herramienta que se utiliza para realizar un desbaste con otras condiciones de corte se utiliza para realizar un acabado.

### 3. Estudio de alternativas IA

Tras el pre-procesamiento de los datos, se ha obtenido una estructura de datos organizada por operaciones en la que cada operación tiene una clave que guarda señales constantes como la velocidad de avance o herramienta activa y señales temporales como la carga y el valor RMS de vibración, entre otras. Además, se ha adquirido un conocimiento más extenso del tratamiento de datos y de la necesidad del mismo.

En el estudio de las alternativas IA por un lado se ha fijado la estrategia que se desea desarrollar y por otro lado da tipología de *machine-learning*.

Se han planteado estrategias de mantenimiento predictivo similares a las planteadas en los artículos [11] y [12], el problema reside en la limitada información relativa al estado de la máquina o herramienta. Tampoco se tiene información de la calidad de las piezas fabricadas para plantear un desarrollo de un clasificador de operaciones entre correctas y fallidas.

En este trabajo no se ha tenido acceso al control del proceso por lo que se centra en la búsqueda de la optimización sin la posibilidad de actuar sobre los parámetros. En ese sentido, se encuentran 3 aproximaciones en el artículo [10]:

- Análisis de la causa raíz:** Consiste en buscar patrones en los datos extrayendo características relevantes del caso. Primero se entrena un modelo para dichas características y cuando no se ajusta a lo establecido se busca la causa raíz de ese cambio o esa anomalía.
- Predicción temprana del resultado de fabricación:** Consiste en predecir ciertos aspectos de la fabricación antes de que todo el proceso se haya llevado a cabo evitando el coste de procesos innecesarios o habilitando la posibilidad de tomar acciones correctivas ante fallos.
- Sistemas de diagnóstico:** Consiste en mostrar una alarma cuando la condición de un componente es anómala, se está convirtiendo anómala o requiere de acciones correctivas.

Por otro lado, las estrategias de machine learning se dividen en tres grupos principales:

- Aprendizaje supervisado:** el modelo aprende una función que calcula un output para una serie de inputs. El aprendizaje supervisado requiere de un entrenamiento o ajuste para el cual necesita que los datos estén etiquetados en parejas de input-output.
- Aprendizaje no supervisado:** busca y presenta una estructura interesante de los datos. No existe un resultado correcto, aprende de las características de los datos. Cuando se insertan nuevos datos se clasifican a partir de lo aprendido. Se utiliza sobre todo para clustering (agrupación) y reducción dimensional.
- Aprendizaje reforzado:** aprende por sí mismo de las recompensas y sanciones, entonces se genera el modelo para lograr el objetivo. El resultado se puede estimar a partir del modelo.

Hay que recordar que son datos no supervisados, esto es, no se cuenta con etiquetas de la calidad de la fabricación. Además, al ser centros de mecanizado en pleno rendimiento fabricando piezas destinadas al mercado aeronáutico, se ha asumido que todos los datos recibidos corresponden a piezas que han sido mecanizadas de forma correcta. A pesar de que esto ha encaminado el trabajo a la utilización de

aprendizaje automático no supervisado, se ha propuesto la utilización de uno de los parámetros disponibles como etiqueta para la aplicación de estrategias supervisadas.

Finalmente, se ha decidido implementar un planteamiento que es una mezcla de la predicción temprana del resultado de fabricación y un sistema diagnóstico. El análisis de la causa raíz se deja en manos del responsable de la mecanización.

Para ello, se propone, la aplicación de algoritmos de regresión que se pueden encontrar en la biblioteca de Python Sklearn: árboles de regresión, bosques aleatorios, Adaboost, Gradient Tree Boosting, Histogram-Based Gradient Boosting y redes neuronales entre otros; para predecir el valor de una de las variables del proceso utilizando como predictores otras variables de las que se dispone. Las variables predictoras se deben escoger con cautela, ya que varía su idoneidad dependiendo del tipo de operación que realiza cada herramienta, por lo que la IA se aplica a las herramientas de forma individualizada. La estrategia desarrollada emite un aviso o una alarma cuando la medición se desvía de la predicción más allá de un límite que se fija en función de la herramienta y los parámetros de mecanizado. De esta forma se consigue la detección de un aumento fuera de lo habitual de algún parámetro de proceso para las condiciones de mecanizado aplicadas. Esto puede resultar útil, entre otras ventajas, para detectar a tiempo errores y evitar el derroche de recursos, para detectar problemas de las máquinas y poder actuar de forma preventiva o para trabajar en reprogramar operaciones para que sus solicitaciones de carga no sean elevadas.

#### 4. Resultados

Ante el reto que supone enfrentarse a una serie de datos de los cuales apenas se tiene conocimiento, en este trabajo, mediante la ingeniería de datos, se han adecuado los datos obteniendo los siguientes beneficios: se han reducido el volumen de datos de forma que solo queden los datos que recogen el mecanizado en su sentido más estricto, la interacción entre pieza y herramienta, el arranque de viruta; se ha facilitado la obtención de información de los datos, conocer mejor el proceso y la utilización de los centros de mecanizado, y permite diferentes aproximaciones a la aplicación de la IA.

Estos beneficios se han logrado mediante la depuración de los datos en base al conocimiento de los procesos de mecanizado, los parámetros disponibles y la estructura que se ha dado a los datos. A continuación, se recogen más en detalle los resultados tanto de la depuración como de la estructuración.


#### 4.1. Resultados de la depuración

Las series de datos se han filtrado dejando a un lado los datos que corresponden a momentos no productivos del proceso. Para determinar en qué instantes se produce arranque de viruta se dirige el estudio al análisis de las cargas que registra el husillo o las vibraciones. Es cierto que un nivel bajo o nulo de la carga o del valor RMS de vibración puede indicar que la máquina está parada o no mecanizando, pero, por ejemplo, durante el cambio de herramienta o cambio de la velocidad de giro la carga toma valores elevados y no se está produciendo mecanización.


Dicho esto, la filtración se ha basado en los parámetros que se obtienen directamente de la lectura CNC o parámetros de estado de la máquina. Tras la filtración, se reduce considerablemente el número de datos de forma beneficiosa porque se han eliminado datos que no corresponden a los instantes de arranque de viruta. No obstante, el filtrado es probable que todavía pueda presentar algún instante en el que no se produce arranque de viruta. Sin embargo, se ha decidido no profundizar en la filtración para no perder datos que pueden ser importantes respecto al mecanizado, por ejemplo, el inicio y la finalización de cada pasada de mecanizado.

Como caso práctico, se presenta que en junio de 2020 el primer centro de mecanizado registra 12175201 instantes a 5 Hz de los cuales 10016361 (82,27 %) corresponden a programas y subprogramas en ejecución y tras aplicar la filtración quedan 1693951 instantes (13,91% del total y 16,91 % de los subprogramas en ejecución).

Las **Figura 3** y **Figura 4** muestra la diferencia entre la carga durante la fabricación de una pieza aplicando los criterios de filtro y sin aplicarlos.



**Figura 3.** Carga del husillo sin aplicar criterios de filtro para pieza ejemplo.



**Figura 4.** Carga del husillo tras aplicar criterios de filtro para pieza ejemplo.

Por un lado, esta información puede ser útil para el control del tiempo de uso de las herramientas y el ciclo de vida de las mismas, a la hora de plantear un mantenimiento predictivo o preventivo si se registrasen los cambios de herramienta por desgaste.

Por otro lado, eliminar los datos ajenos a la interacción entre las herramientas y la pieza permite conocer únicamente las posiciones de la herramienta sobre la pieza lo cual es muy interesante.

**4.2. Resultados de la estructuración**

Las series se han dividido de forma que los datos han quedado organizados por programas, subprogramas y operaciones y piezas. Esto facilita la obtención de información de la fabricación. Es decir, es fácil encontrar el tamaño de los lotes en los que se fabrica cada referencia, contar durante un periodo de tiempo cuantas piezas se han fabricado en general o para cada referencia, comprobar qué herramientas se utilizan para fabricar cada pieza y en qué orden. Estos tan solo son ejemplos de las ventajas que aporta al análisis esta estructuración.

Para llevar a cabo esta división las señales utilizadas han sido *Programa Activo*, *Subprograma activo* y *Velocidad de giro del husillo*. En la **Figura 5** se muestran tres graficas aplicando un zoom de izquierda

a derecha para ilustrar la características de las señales *Programa Activo* (naranja), *Subprograma activo* (azul) y entender la división y agrupación hecha.

En la gráfica de la izquierda se muestran las señales mencionadas, con programa activo con valor mayor a 9999999 se está fabricando una pieza. Con esta información se ha dividido y organizado los datos por programas y subprogramas.

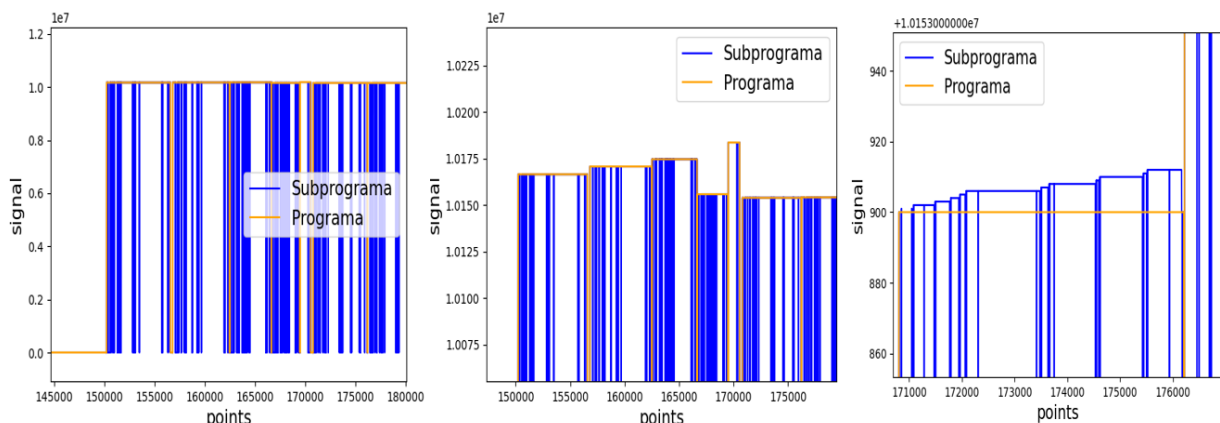
Para separar los datos por operaciones se ha hecho uso de la variable *Velocidad de giro del husillo* que durante todos los subprogramas no se mantiene constante indicando que en cada subprograma puede haber más de una operación.

De esta forma, se ha logrado dividir y agrupar las señales por, programas, subprogramas y operaciones; pero para que esta información sea accesible de cara a aplicar estrategias IA debe guardarse de forma adecuada.

En este trabajo se ha creado un diccionario de operaciones donde cada clave esta formada por 12 cifras, las 6 primeras corresponden a la referencia del programa, las dos siguientes hacen referencia al subprograma, la antepenúltima y la anterior diferencian las operaciones y las dos últimas cuentan el número de veces que se ha realizado la misma operación, el número de veces que se ha fabricado el modelo. Los valores asociados a las claves se agupan en una lista donde se pueden almacenar las variables y la información deseada, tanto como número si se trata de información asociada a una parte (la velocidad de giro del husillo o la herramienta que utiliza), o como lista si se trata de una serie temporal como la carga, las corrientes o el valor RMS de vibración.

**5. Conclusiones**

En este trabajo se ha propuesto trabajar en un sentido concreto con los algoritmos de *machine learning* porque se ha fijado como objetivo inicial plantear una estrategia que sea apropiada tanto para piezas fabricadas previamente como para la primera fabricación de un modelo.



**Figura 5.** Zoom de las señales programa activo y subprograma activo para la división de las señales.

Por eso, la aplicación del aprendizaje autónomo se ha realizado sobre las herramientas queriendo definir un patrón de funcionamiento para las mismas. A pesar de ello la principal aportación de este trabajo es la estructuración de los datos que permite plantear muy diversos enfoques para la aplicación del *machine learning*:

- Se puede tomar como sujeto de análisis la fabricación de una referencia concreta, ya sea referencia de programa, subprograma u operación donde para cada repetición los parámetros deben desarrollarse de igual o similar manera.
- Se puede tomar como sujeto de análisis un tipo de operación concreta, taladrado, por ejemplo, y analizar las brocas que se destinan a taladrados similares de forma conjunta caracterizando el taladrado;
- Fijar el análisis del correcto funcionamiento en las herramientas de forma individualizada.

Estas tan solo son unas de las primeras premisas para el acercamiento a un planteamiento de aplicación de aprendizaje automático sobre datos de mecanizado similares a los que se han utilizado en este trabajo, sin embargo, siempre hay que tener muy en cuenta los datos que se tienen y el objetivo que se busca ya que esas dos consideraciones van a condicionar totalmente la aplicación de la IA.

En este trabajo se ha propuesto una estrategia enfocada en cada una de las herramientas, logrando un modelo independiente a la pieza que se fabrica. Las regresiones propuestas son capaces de predecir el valor de una variable de proceso para su funcionamiento habitual en función de los parámetros de mecanizado y otras variables de proceso.

## 6. Agradecimientos

Este proyecto ha recibido financiación del programa de investigación e innovación Horizonte 2020 de la Unión Europea con referencia n° 95830 y n° 862025 y del programa ELKARTEK del Gobierno Vasco (Proyecto OPTICED, bajo el contrato n° KK-2021/00003).

## 7. Referencias

- [1] G. Gomez-Escudero, P. Fernandez-De Lucio, H. Gonzalez-Barrio, A. Calleja-Ochoa, I. Ayesta-Rementeria y L. Lopez-De La Calle Marcaide, «MACHINE LEARNING IN THE FIELD OF MANUFACTURING.», *Dyna*, vol. 96, n° 6, pp. 600-604, 2021. Disponible en: <https://doi.org/10.6036/10197>
- [2] A. McAfee y E. Brynjolfsson, «Big data: the management revolution.», *wiki.uib.ne*, 2012. Disponible en: <https://wiki.uib.no/info310/images/4/4c/McAfeeBrynjolfsson2012-BigData-TheManagementRevolution-HBR.pdf>
- [3] D. Muhr, S. Tripathi y H. Jodlbauer, «An adaptive machine learning methodology to determine manufacturing process parameters for each part.», *Procedia Computer Science*, vol. 180, pp. 764-711, 2021. Disponible en: <https://dx.doi.org/10.1016/j.procs.2021.01.325>
- [4] B. Rolf, T. Reggelin, A. Nahhas, S. Lang y M. Müller, «Assigning dispatching rules using a genetic algorithm to solve a hybrid flow shop scheduling problem.», *Procedia Manufacturing*, vol. 42, n° 1, pp. 442-449, 2022. Disponible en: <https://dx.doi.org/10.1016/j.promfg.2020.02.051>
- [5] X. Yuan, Y. Gu y Y. Wang, «Supervised Deep Belief Network for Quality Prediction in Industrial Processes.», *IEEE TRANSACTIONS ON INSTRUMENTATION AND MEASUREMENT*, vol. 70, pp. 2503711-2503711, 2021. Disponible en: <https://dx.doi.org/10.1109/TIM.2020.3035464>
- [6] F. A. Khasawneh, E. Munch y J. A. Perea, «Chatter Classification in Turning using Machine Learning and Topological Data Analysis.», *IFAC-PapersOnLine*, vol. 51, n° 14, p. 195–200, 2018. Disponible en: <https://dx.doi.org/10.1016/j.ifacol.2018.07.222>
- [7] M. Hashemitaheri, S. M. R. Mekarthy y H. Cherukuri, «Prediction of specific cutting forces and maximum tool temperatures in orthogonal machining by Support Vector and Gaussian Process Regression Methods.», *Procedia Manufacturing*, vol. 48, pp. 1000-1008, 2020. Disponible en: <https://dx.doi.org/10.1016/j.promfg.2020.05.139>
- [8] Y. Zhang y X. Xu, «Machine learning cutting force, surface roughness, and tool life in high speed turning processes.», *Manuf. Lett.*, vol. 29, pp. 84-89, 2021. Disponible en: <https://dx.doi.org/10.1016/J.MFGLET.2021.07.005>
- [9] T. Kotsiopoulos, P. Sarigiannidis, D. Ioannidis y D. Tzovaras, «Machine Learning and Deep Learning in smart manufacturing: The Smart Grid paradigm.», *Comput. Sci. Rev.*, vol. 40, p. 100341, 2021. Disponible en: <https://dx.doi.org/10.1016/J.COSREV.2020.100341>
- [10] D. Weichert y P. Link, «A review of machine learning for the optimization of production processes.», *The International Journal of Advanced Manufacturing Technology*, vol. 104, pp. 1889-1902, 2019. Disponible en: <https://link.springer.com/article/10.1007/s00170-019-03988-5>
- [11] E. Quatrini, «Machine learning for anomaly



- detection and process phase classification to improve safety and maintenance activities.,» *Journal of Manufacturing Systems*, vol. 56, pp. 117-132, 2020. Disponible en: <https://www.sciencedirect.com/science/article/pii/S0278612520300765>
- [12] W. J. Lee, H. Yun, H. Kim, M. B. Jun y J. W. Sutherland, «Predictive Maintenance of Machine Tool Systems Using Artificial Intelligence Techniques Applied to Machine Condition Data,» *Procedia CIRP*, vol. 80, pp. 506-511, 2019. Disponible en: <https://www.sciencedirect.com/science/article/pii/S2212827118312988>
- [13] «1. Supervised learning — scikit-learn 1.1.1 documentation,» [En línea]. Available: [https://scikit-learn.org/stable/supervised\\_learning.html#supervised-learning](https://scikit-learn.org/stable/supervised_learning.html#supervised-learning). [Último acceso: 6 2022].