

OPTIMIZACIÓN DE PARÁMETROS DE CNC DE ACUERDO A CRITERIOS DE PRODUCTIVIDAD USANDO UN MODELO DE MÁQUINA BASADO EN REDES NEURONALES

Javier Arenas López¹, Rosa Basagoiti Astigarraga², Maite Beamurgia Bengoa¹, Jorge Martínez de Alegría Sáenz de Castillo¹

¹ FAGOR AOTEK S.C. Calle Torrebaso Pasealekua, 4 – 20540 Eskoriatza (Gipuzkoa). Tfno: +34 943 039800, jarenas@aotek.es

² Mondragon Goi Eskola Politeknikoa S.Coop. Departamento de Electrónica e Informática. Goiru, 2 – 20500 Arrasate-Mondragón (Gipuzkoa). Tfno: +34 943 712185

Recibido: DD/MM/AA – Revisado: DD/MM/AA – Aceptado: DD/MM/AA - DOI: <https://dx.doi.org/10.6036>(A cumplimentar por el Editor)

OPTIMIZATION OF CNC PARAMETERS ACCORDING TO PRODUCTIVITY CRITERIA USING A MACHINE MODEL BASED ON NEURAL NETWORKS

ABSTRACT:

Every machine-tool user wants to maximize the productivity of their machines looking for balance between speed, precision and lifetime of mechanical components. Nevertheless, because CNCs have wide-ranging use, their correct parametrization for each case is key to achieving the desired objectives; on the other hand, minimizing the numbers of experimental tests to be performed on the machine is essential to reduce time and costs of the set-up process. In order to solve both difficulties, this paper presents a tool to give final user necessary information to properly adjust CNC parameters according to productivity criteria. The method makes use of experimental data to obtain a model of the machine based on neural networks. With this model machining time, geometric error and smoothness of any piece to be manufactured can be predicted, and therefore minimizing test on the real machine and recommending the appropriate values for the CNC.

Keywords: optimization, CNC, neural network, model, machine tool, productivity criteria.

RESUMEN:

Todo usuario de máquina-herramienta desea maximizar la productividad de sus máquinas buscando el compromiso entre rapidez, precisión y durabilidad de los elementos mecánicos. Sin embargo, debido a que los CNCs son generalistas, su correcta parametrización para cada caso resulta clave para lograr los objetivos deseados; por otro lado, minimizar el número de pruebas a realizar sobre la máquina es fundamental para reducir el tiempo y los costes del proceso de puesta en marcha. Para conjugar ambas problemáticas en esta investigación se propone dotar al usuario de una herramienta que proporcione la información necesaria para ajustar correctamente los parámetros del CNC de acuerdo a criterios de productividad. El método utiliza datos extraídos en ensayos empíricos para la obtención de un modelo de la máquina basado en redes neuronales. Este modelo permite predecir el tiempo de mecanizado, el error geométrico y la suavidad del movimiento para cualquier pieza a fabricar, minimizando de esta forma las pruebas sobre la máquina real y recomendando los valores adecuados para el CNC.

Palabras clave: optimización, CNC, red neuronal, modelo, máquina herramienta, criterios de productividad.

1.- INTRODUCCIÓN

A lo largo de las últimas décadas, el sector de la máquina herramienta ha tenido que hacer frente a un notable incremento de las demandas por parte de los fabricantes y de los usuarios finales. La industria desea aumentar sus índices de productividad en los procesos de fabricación, mejorando indicadores como el tiempo de mecanizado o la precisión geométrica de las piezas, todo ello sin menoscabo de la vida útil de los componentes mecánicos. Todos estos requisitos condicionan los algoritmos de generación de trayectoria del CNC, siendo por tanto crucial su correcta parametrización. Tradicionalmente los usuarios de máquina-herramienta parten de un archivo CAD de la pieza que se desea fabricar y mediante un sistema CAM generan el programa-pieza que será ejecutado por el CNC. Sin embargo,

	<p>OPTIMIZACIÓN DE PARÁMETROS DEL CNC DE ACUERDO A CRITERIOS DE PRODUCTIVIDAD USANDO UN MODELO DE MÁQUINA BASADO EN REDES NEURONALES</p>	<p>Disciplina UNESCO</p>
<p>Rev. 2 del 9/ene/2012</p>	<p>J Arenas López, R Basagoiti Astigarraga, M Beamurgia Bengoa, J Martínez de Alegría Sáenz de Castillo</p>	<p>Subdisciplina</p>

dependiendo del ajuste de los parámetros de generación de trayectoria, fundamentalmente aquellos que tienen que ver con las estrategias de corte rápido, también denominado *High Speed Cutting* (HSC), la trayectoria final que realice la máquina puede ser significativamente diferente, aun habiendo partido del mismo programa-pieza. Cuál es el ajuste adecuado dependerá de las necesidades de cada caso y es el usuario final de la máquina el que debe tomar la decisión. Debido a que este ajuste no es trivial, habitualmente se recurre a realizar diferentes pruebas de mecanizado con el consiguiente aumento de los tiempos de puesta en marcha y gasto de material.

Todas estas circunstancias han motivado la presente investigación, cuyo objetivo es proporcionar al usuario de CNC una herramienta que le facilite el conjunto de parámetros de HSC adecuado a sus necesidades en cada momento. A este conjunto de parámetros se le denominará en adelante *actuador*. Como núcleo central de esta herramienta se plantea obtener un modelo de la máquina que represente de manera fiel el comportamiento real, y que se pueda utilizar para hacer pruebas offline, llegando al actuador idóneo minimizando las pruebas en la máquina real.

De esta forma se describe en el siguiente apartado el estado del arte que ha ayudado a encauzar la investigación. A continuación se detallan los pasos realizados con el fin de obtener un modelo de máquina basado en redes neuronales. Se explica posteriormente cómo se puede obtener un modelo equivalente reduciendo la cantidad de datos necesaria y por último se expondrán los resultados comparando los datos obtenidos con el modelo respecto a los obtenidos en una máquina real.

2.- ESTADO DEL ARTE

La primera cuestión que se plantea a la hora de afrontar esta investigación es determinar cuáles son los criterios de productividad relevantes para el usuario de CNC. Analizando el estado del arte, se pueden encontrar múltiples referencias a investigaciones donde se proponen metodologías para optimizar la trayectoria desde diferentes criterios de productividad. Así por ejemplo en [1] se desarrolla un procedimiento para obtener la trayectoria óptima minimizando el tiempo. Sin embargo, el simple hecho de reducir el tiempo de mecanizado no siempre tiene los resultados deseados, ya que hay otras variables importantes a tener en cuenta. Por ello en [2] se apunta también a conseguir una trayectoria de tiempo mínimo pero esta vez teniendo en cuenta generaciones de consigna con limitación de *jerk*. El *jerk* es la derivada de la aceleración y, tal y como se apunta en [2], magnitudes excesivas de *jerk* provocan una reducción de la vida útil de los elementos mecánicos. Otras investigaciones, como [3] y [4], abordan la generación de trayectoria teniendo en cuenta las restricciones que puede haber en los ejes. Tal y como explica [5], el tipo de trayectoria puede tener un impacto importante en la vida útil de los elementos mecánicos de la máquina por lo que es fundamental introducir criterios de suavidad en el ajuste de los algoritmos de control [6].

Por otro lado, existe una extensa bibliografía que aborda la minimización del error geométrico tanto desde un punto de vista de análisis offline [7], [8] como realizando una estimación online [9], [10]. Queda claro por tanto que estos tres criterios (tiempo, suavidad y error) son claves para el ajuste de los parámetros de generación de la trayectoria de acuerdo a las necesidades de la producción. Una vez fijados los criterios productivos, el siguiente paso es obtener un modelo que permita analizarlos, reduciendo en lo posible el tiempo de pruebas en la máquina real.

Centrando la búsqueda en el sector de la máquina herramienta hay una gran cantidad de referencias que hacen uso de modelos del sistema para abordar diferentes problemáticas. Así por ejemplo, [11] utiliza modelos empíricos para evaluar el consumo de energía, [8] para obtener el error geométrico y [12] para realizar un mantenimiento predictivo de los cabezales. En los últimos años el desarrollo de gemelos digitales ha tenido una gran repercusión y es en la actualidad uno de los mayores campos de investigación [13]. Tradicionalmente desde un punto de vista de ajuste de los lazos de control el modelo más utilizado es aquel que se basa en un sistema de dos masas unidas por un elemento muelle-amortiguador [14]. El problema de estos modelos es que implican una identificación de los parámetros de la máquina que no siempre es sencilla [15]. Este inconveniente junto con el aumento de las capacidades de cálculo de los CNC actuales está haciendo que la investigación aplicada se plantee el uso de modelos más avanzados. Entre ellos destaca en el estado del arte el uso de redes neuronales.

Las redes neuronales han sido utilizadas para mejorar la fabricación con máquina-herramienta en diferentes aspectos. Por ejemplo, para reducir el error geométrico [16], [17] o para el control de la rugosidad de la superficie del producto [18], [19]. En estos artículos también se describe, que tanto el error geométrico y la rugosidad, dependen del tiempo de ejecución, cuanto más tiempo se utilice para fabricar las piezas, menor error geométrico y menor rugosidad tendrán,

	<p>OPTIMIZACIÓN DE PARÁMETROS DEL CNC DE ACUERDO A CRITERIOS DE PRODUCTIVIDAD USANDO UN MODELO DE MÁQUINA BASADO EN REDES NEURONALES</p>	<p>Disciplina UNESCO</p>
<p>Rev. 2 del 9/ene/2012</p>	<p>J Arenas López, R Basagoiti Astigarraga, M Beamurgia Bengoa, J Martínez de Alegría Sáenz de Castillo</p>	<p>Subdisciplina</p>

pero la productividad se verá afectada [8]. Se ve así como la introducción de objetivos de productividad obliga a llegar a compromisos entre los distintos criterios.

La investigación [20] describe cómo utilizar las redes neuronales para ajustar dinámicamente los parámetros de corte en tiempo real. Explica las limitaciones existentes y la importancia de los parámetros de corte. Por ello sugieren una red neuronal para determinar qué parámetros de corte son necesarios en cada caso. El artículo [21] también habla sobre la optimización de los parámetros de corte del CNC en tiempo real, entre ellos la profundidad de pasada radial y el avance por diente, utilizando una red neuronal como modelo.

Con ese enfoque, en la presente investigación se decide utilizar redes neuronales para la optimización de los parámetros de HSC, creando así un modelo de máquina que simule su comportamiento. Existen multitud de tipos diferentes de redes neuronales [22], pero tras un análisis del estado del arte y considerando las características del problema planteado hay tres tipos de redes que se pueden considerar. Por un lado, la red tipo NARX (*Nonlinear Autoregressive networks with exogenous inputs*) es una red dinámica recurrente con retardos, lo que implica que tiene en cuenta estados anteriores para calcular la siguiente salida [18]. La red de Memoria a Largo Corto Plazo o LSTM (del inglés, *Long Short-Term Memory*) [23], [24], es una red neuronal recurrente capaz de procesar multitud de datos. Es muy versátil y eficiente en campos como el reconocimiento de imágenes y conducción autónoma entre otros. Y el último tipo considerado es una red neuronal convolucional o CNN (del inglés, *Convolutional Neural Networks*) [25], estas redes son muy efectivas para las tareas de visión artificial, como en la clasificación y segmentación de imágenes entre otras aplicaciones. Analizando pros y contras de cada tipología, se decide afrontar la investigación utilizando una red tipo NARX, por su habilidad de memorizar valores pasados de la entrada y de la salida para obtener una nueva salida más precisa.

3.- DESARROLLO

El objetivo por tanto de la investigación es proporcionar al usuario final una herramienta que le indique cuál es el actuador que mejor se adecue a sus demandas de tiempo, error geométrico y suavidad. En la Figura 1 se muestran las fases utilizadas.

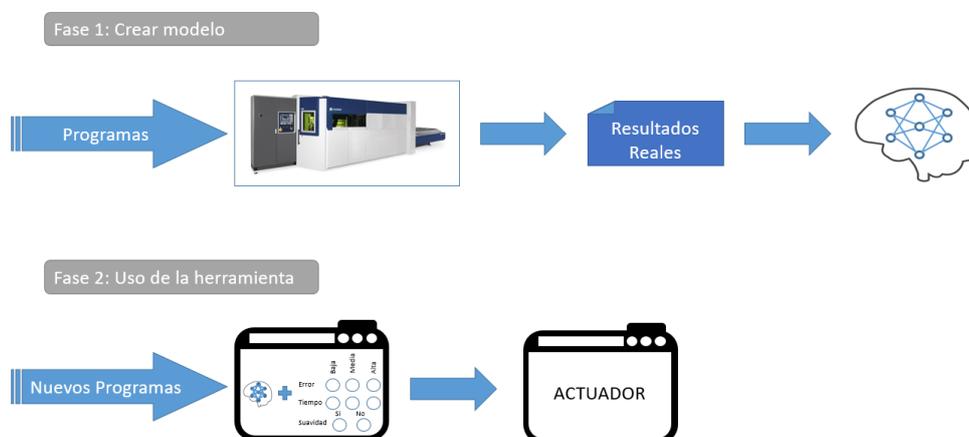


Fig. 1: Esquema general de la metodología

El objetivo de la primera fase es la obtención del modelo de la máquina basado en redes neuronales tipo NARX. Para ello primero se ejecutan varios programas en la máquina y se recogen los datos tal y como se explica en el apartado 3.1. A continuación se entrena la red neuronal con estos datos, ver apartado 3.2, obteniendo por tanto un modelo de la máquina. Esta fase sólo será necesario hacerla una vez puesto que el modelo es único para cada máquina, independientemente de la pieza que se quiera fabricar. Sólo tendría sentido repetir esta fase si hay un cambio significativo en los componentes de la máquina.

Una vez realizada la fase 1, el usuario ya podrá hacer uso de la herramienta (fase 2). Para ello cargará el nuevo programa-pieza que quiera fabricar y elegirá los criterios de productividad, siendo el resultado el actuador recomendado. No todas las opciones son posibles puesto que no existe el actuador que sea al mismo tiempo el más

	<p>OPTIMIZACIÓN DE PARÁMETROS DEL CNC DE ACUERDO A CRITERIOS DE PRODUCTIVIDAD USANDO UN MODELO DE MÁQUINA BASADO EN REDES NEURONALES</p>	<p>Disciplina UNESCO</p>
<p>Rev. 2 del 9/ene/2012</p>	<p>J Arenas López, R Basagoiti Astigarraga, M Beamurgia Bengoa, J Martínez de Alegría Sáenz de Castillo</p>	<p>Subdisciplina</p>

rápido, el más preciso y el más suave, por eso hay ciertos condicionantes en cuanto a los requisitos que el usuario puede establecer, pero una vez validados, la herramienta indica cuál es el actuador más adecuado.

El usuario final puede testear en un simulador CNC el programa en cuestión con el actuador seleccionado, lo que le permitiría saber cuál es el tiempo que va a tardar en mecanizarse la pieza y cuáles son las velocidades y aceleraciones máximas que se van a alcanzar. Indicadores que le permiten evaluar si el actuador satisface sus necesidades sin tener que realizar ninguna prueba sobre la máquina. A continuación se explican los diferentes pasos que intervienen en cada una de las fases.

3.1.- RECOGIDA DE DATOS

Como se ha indicado anteriormente el primer paso es la obtención de los datos de la máquina que permitan obtener el modelo. En esta investigación se ha utilizado una máquina láser de tres ejes con motores lineales, pero la metodología es exportable a cualquier tipo de máquina. La máquina dispone de un CNC y reglas fabricadas por FAGOR para la regulación de los ejes. El CNC dispone de una aplicación tipo *datalogger* que permite guardar cualquier variable del sistema de forma síncrona. Para este estudio se han capturado las posiciones, velocidades y aceleraciones de los ejes, todos ellas proporcionadas por las reglas instaladas en la máquina. Además se ha incorporado en el cabezal un acelerómetro (fabricado por DIS Sensors, referencia QG40-KAXY-4,0E) para tener un mejor indicador de la suavidad del movimiento.

Una vez definidas las variables a guardar, es necesario asegurar que los datos tengan suficiente variedad para que sean útiles a la hora de entrenar la red neuronal. Se necesita por tanto definir un set de pruebas con un conjunto de programas y actuadores que se ejecute en la máquina para obtener los datos.

A la hora de elegir los actuadores, se ha tomado como punto de partida una investigación anterior [26] que elige 17 configuraciones de HSC, siendo éstas las más representativas de los criterios de productividad planteados. De esta forma se asegura tener una gama de estrategias de generación de trayectoria lo más amplia posible pero sin eternizar la recogida de datos.

En cuanto a los programas, se han tomado 8 programas-pieza reales del usuario de la máquina, diferentes entre sí, pero sin ningún patrón ni ninguna característica especial. Se ha optado por no utilizar programas concretos para asegurar la generalización de la metodología.

Por tanto, para la recogida de datos se han ejecutado en máquina 8 programas, parametrizando en el CNC los 17 actuadores para cada uno de ellos, lo que hace un total de 136 ejecuciones de programa para componer el set de datos que se ha utilizado. El tiempo total que ha llevado la toma de datos ha sido de 5 horas aproximadamente. Esta duración dependerá lógicamente del tamaño de los programas seleccionados.

A partir de los datos recogidos, se han calculado los indicadores necesarios para poder evaluar los criterios de productividad. El procedimiento para cada uno de ellos se explica a continuación:

- **Tiempo de ejecución:** Por cada ejecución de programa y actuador correspondiente se obtiene un fichero de datos. En cada fichero se almacena la trayectoria realizada punto a punto, por lo que con la suma total de puntos almacenados, y sabiendo que el tiempo de muestreo es de 4ms, se calcula el tiempo de ejecución.
- **Error geométrico:** Se calcula comparando los puntos obtenidos de la máquina con los puntos del programa-pieza inicial. De esta forma el error geométrico se calcula punto a punto por la diferencia entre ambos registros. Como indicador se utiliza el error cuadrático medio (RMSE).
- **Suavidad de la trayectoria:** La suavidad describe el comportamiento brusco o suave que puede tener la máquina y por consiguiente las vibraciones que pueden afectar a la calidad de la pieza. Como indicador de la suavidad se ha utilizado una fórmula matemática basada en el *jerk* descrita en [26].

3.2.- MODELO BASADO EN REDES NEURONALES

Las redes neuronales son un algoritmo basado en un gran conjunto de unidades neuronales simples (neuronas artificiales) de forma aproximadamente análoga al comportamiento observado en los cerebros biológicos. La información de entrada atraviesa la red neuronal (donde se somete a diversas operaciones) calculándose unos valores de

	<p>OPTIMIZACIÓN DE PARÁMETROS DEL CNC DE ACUERDO A CRITERIOS DE PRODUCTIVIDAD USANDO UN MODELO DE MÁQUINA BASADO EN REDES NEURONALES</p>	<p>Disciplina UNESCO</p>
<p>Rev. 2 del 9/ene/2012</p>	<p>J Arenas López, R Basagoiti Astigarraga, M Beamurgia Bengoa, J Martínez de Alegría Sáenz de Castillo</p>	<p>Subdisciplina</p>

salida. Cada neurona está conectada con otras a través de unos enlaces, de tal forma que el valor de su salida es el de la neurona anterior multiplicado por un peso. Estos pesos en los enlaces pueden incrementar o inhibir el resultado de activación de las neuronas adyacentes. De forma iterativa, las redes neuronales alteran los pesos y sesgos de las neuronas hasta que se aproximan a la solución del problema. Para consultar y/o profundizar en los conceptos básicos de las redes neuronales se recomienda [28].

Las redes neuronales son ampliamente utilizadas en problemas de clasificación, reconocimiento, optimización, aproximación de funciones y predicción. Para el problema planteado en esta investigación, se requiere la predicción de una serie temporal no lineal, por lo que, como se ha explicado anteriormente, la arquitectura tipo NARX se considera la más conveniente. Es una red neuronal de entrenamiento supervisado, es decir, se parte de un conjunto inicial de entradas y de un conjunto de salidas objetivo para obtener el modelo entrenado. En la configuración serie-paralelo (lazo abierto), el valor de salida obtenido se predice con los valores presentes y pasados de la entrada y con los datos pasados de la salida objetivo. En la configuración paralela (lazo cerrado), la predicción se realiza con los datos presentes y pasados de la entrada y con los valores pasados de la propia predicción de la salida. Para su utilización en entornos reales, la red debe estar configurada de forma paralela, sin embargo, para su entrenamiento se realiza una primera fase en configuración serie-paralelo y a continuación un entrenamiento en lazo cerrado [18].

3.2.1 Entrenamiento

Como es habitual, para llevar a cabo el entrenamiento se ha seleccionado un subconjunto del set completo de datos. En este caso se han utilizado los datos correspondientes a 5 de los 8 programas, con todos sus actuadores. Durante el entrenamiento, la red actualiza sus pesos y sesgos para ajustarse a la salida esperada. Los pesos modulan la influencia de la entrada en la salida y el sesgo controla la activación de las diferentes neuronas.

El entrenamiento se ha realizado en dos fases: lazo abierto y lazo cerrado. Inicialmente, la red se entrena con los valores reales de salida (lazo abierto), de esta forma la red empieza a generar los pesos y sesgos que necesita. A continuación, se pasa a la configuración de lazo cerrado y por tanto la red se entrena con los propios valores generados, usando los valores reales de salida sólo para la verificación. Esto genera una red más robusta y optimiza el tiempo de entrenamiento [18]. La red neuronal se puede entrenar desde un primer momento en lazo cerrado, pero necesita más tiempo para poder ajustar los pesos y sesgos, al no tener ninguna primera referencia. Una vez que la red está entrenada, debe estar en lazo cerrado para su utilización.

La red neuronal resultante ha sido entrenada tanto con los datos del eje X como los del eje Y, para comprobar su capacidad de generalización.

3.2.2 Validación

Una vez que la red neuronal se ha entrenado, se han utilizado un subconjunto de datos formado por dos de los programas no utilizados en el entrenamiento, con sus respectivos actuadores. De esta forma se han ido entrenando sucesivamente redes neuronales con distinto número de capas, neuronas y retardos. En la Tabla 1 se muestran algunos de los resultados obtenidos más relevantes.

RMSE Validación	Nº Capas ocultas	Nº neuronas	Nº retardos
9,77E-06	1	20	2
1,75E-05	1	8	3
1,84E-05	2	12 4	6
2,67E-05	1	20	1
2,94E-05	1	12	3
3,45E-05	2	8 3	2

Tabla 1. Resultados de las redes neuronales

Por tanto, una vez realizada la validación, se concluye que el modelo de red neuronal tipo NARX con el que se han obtenido mejores resultados, consta de una capa oculta de 20 neuronas y 2 retardos. En la Figura 2, se observa la arquitectura de la red.

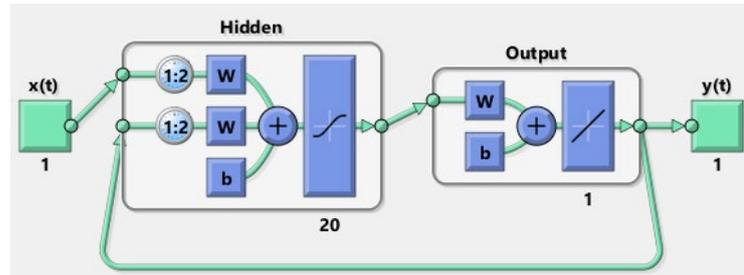


Fig. 2: Red neuronal NARX con 1 capa oculta de 20 neuronas y 2 retardos

3.2.3 Reducción de los datos de entrenamiento

Un inconveniente que se puede argumentar en contra de la metodología planteada es la necesidad de disponer de varias horas de máquina, con el fin de obtener los datos necesarios usados en el entrenamiento de la red neuronal, tal y como se ha explicado en el apartado 3.1. Este tiempo puede ser relevante en ciertos procesos de producción e iría en contra de uno de los objetivos de esta investigación: reducir los tiempos de puesta en marcha de las máquinas. Es cierto que este procedimiento sólo es necesario hacerlo una vez durante toda la vida útil de la máquina, pero aun así se plantea la cuestión de si es factible conseguir un modelo basado en la misma tipología de red neuronal, es decir, con el mismo número de capas, neuronas y retardos obtenidos en el apartado anterior, pero entrenándola con un conjunto menor de datos, que por tanto minimice el tiempo de máquina necesario para obtenerlos.

Con este objetivo se ha llevado a cabo un análisis del conjunto de 17 actuadores de los que se ha partido originalmente. La hipótesis es que si bien este conjunto de actuadores es significativo para abarcar todas las posibles generaciones de trayectoria, no tienen por qué ser todos relevantes a la hora de obtener el modelo de la máquina.

Para comprobarlo, se han utilizado los datos reales de entrada y salida para realizar un proceso de identificación de la máquina obteniendo el diagrama de Bode. El objetivo es determinar qué actuadores aportan información significativa sobre las características mecánicas de la máquina, con la idea de poder utilizar sólo ese subconjunto para el entrenamiento de la red neuronal. Haciendo ese análisis se aprecia que hay un conjunto amplio de actuadores a partir de cuyos resultados es muy complicado identificar correctamente la máquina. En la Figura 3 se puede ver la diferencia entre la identificación utilizando el actuador 1 (arriba) y el actuador 5 (abajo). Como se puede comprobar, en el diagrama de Bode del actuador 1 se aprecia una resonancia a una frecuencia de 24 Hz que no aparece en la identificación del actuador 5. Por tanto, se puede deducir que el actuador 1 aporta una información más útil para la obtención del modelo que el actuador 5. Con este procedimiento se ha conseguido simplificar el conjunto de 17 actuadores hasta dejarlo en sólo 4.

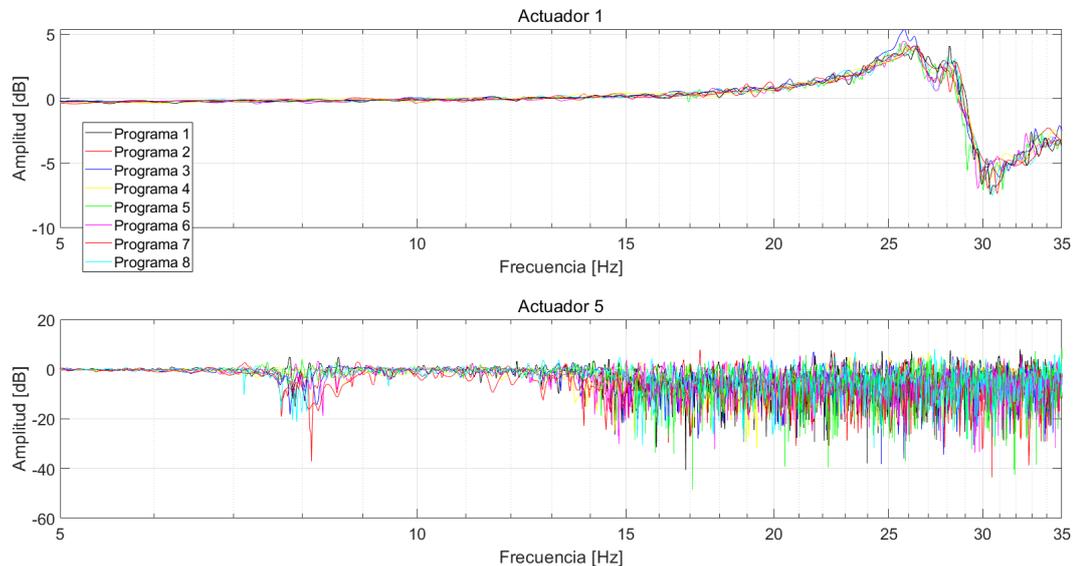


Fig. 3: Diagrama de Bode para el actuador 1 y actuador 5

Una vez reducido significativamente el conjunto de datos, se ha procedido a entrenar con ellos una red neuronal de la misma topología que la de la Figura 3, siguiendo el mismo procedimiento que se ha explicado anteriormente.

4.- RESULTADOS

Una vez obtenido el modelo de red neuronal y haberlo entrenado con los datos reales de la máquina llega el momento de evaluar si el modelo es capaz de proporcionar una información fiable del comportamiento de la máquina. Para ello se ha escogido el programa-pieza que no había sido utilizado ni en el entrenamiento ni en la validación de la red neuronal. Para validar los resultados se han tomado los datos de este programa en la máquina, y se han calculado los indicadores de cada criterio de productividad para clasificar los 17 actuadores. Esta clasificación se expone de manera gráfica en la Tabla 2.

Como se puede ver se han dividido los criterios en varios subgrupos. Tanto el error geométrico como el tiempo en tres categorías diferentes y la suavidad en dos. El grado alto, medio y bajo es relativo a cada máquina y no implica un nivel cuantitativo concreto. De esta forma cada actuador se sitúa en el recuadro que mejor representa las prestaciones que da para el programa y la máquina utilizada. Como se puede apreciar hay cuadros que quedan en blanco ya que hay ciertos requisitos que son incompatibles; por ejemplo, como resulta lógico, no es posible mecanizar en un tiempo mínimo y obteniendo a su vez el mínimo error posible. Esta distribución de los actuadores según sus prestaciones es la que se quiere replicar utilizando exclusivamente los datos obtenidos con el modelo de la red neuronal.

		Tiempo		
		alto	medio	bajo
Error Geométrico	alto			1* 2* 3* 4*
	medio	16 17	6 10 15 7 11 8 13 9 14	
	bajo	5 12		

* Actuadores **NO** Suaves

Tabla 2: Datos de máquina real

Para ello se simula la red neuronal entrenada obtenida en el apartado 3.2.1 utilizando como señal de entrada el mismo programa y los mismos actuadores que los usados en la máquina para generar la Tabla 2. Con los resultados obtenidos en las simulaciones y con el mismo criterio de cálculo de indicadores y distribución en grupos se elabora la Tabla 3. Como se puede observar comparando con la Tabla 2, los actuadores quedan distribuidos en los mismos grupos si atenemos a los criterios de error geométrico y tiempo, solo en cuanto a la suavidad hay alguna leve diferencia. Esto implica que la red neuronal predice con un nivel de fiabilidad muy alto las prestaciones de los diferentes actuadores y por tanto es una herramienta válida para que el fabricante pueda elegir la mejor parametrización del CNC en función de su máquina, la pieza a ejecutar y sus criterios de producción. Es importante remarcar que si bien el proceso de entrenamiento de la red neuronal lleva un tiempo considerable, la simulación del modelo es lo suficientemente rápida como para que se pueda realizar in-situ en el propio CNC y elegir el actuador deseado.

		Tiempo		
		alto	medio	bajo
Error Geométrico	alto			1* 2* 3* 4
	medio	16 17	6 10 15 7 11 8 13 9 14	
	bajo	5 12		

* Actuadores **NO** Suaves

Tabla 3: Datos de la red neuronal

En la Tabla 4 se muestran los resultados obtenidos con la red neuronal creada reduciendo los datos de entrenamiento, según se ha descrito en el apartado 3.2.3. Como se puede apreciar comparando con la Tabla 2 y Tabla 3 se observa que la distribución de actuadores de acuerdo a los criterios de error geométrico y tiempo es la misma en todos los casos, habiendo únicamente variaciones en la clasificación de la suavidad.

		Tiempo		
		alto	medio	bajo
Error Geométrico	alto			1* 2 3 4
	medio	16 17	6 10 15 7 11 8 13 9 14	
	bajo	5 12		

* Actuadores **NO Suaves**

Tabla 4: Datos de la red neuronal entrenada con datos reducidos

Estos resultados validan la reducción en la cantidad de datos necesaria para entrenar la red neuronal, dividiendo en una quinta parte el tiempo en máquina necesario para obtener el set de datos.

5.- CONCLUSIONES

En esta investigación se ha desarrollado una herramienta que aconseja al fabricante cuál es la mejor parametrización posible para el CNC en función de su máquina, su pieza y los criterios de productividad deseados. El método se fundamenta en el uso de un modelo basado en redes neuronales entrenadas con datos reales obtenidos en la máquina. Al contrario que en otras publicaciones donde se plantea la optimización de un único objetivo, en esta investigación se aborda un análisis global del problema, y se tienen en cuenta tres criterios productivos diferentes buscando llegar a un compromiso que satisfaga las necesidades del usuario en función de su máquina y de la pieza a fabricar.

Se ha demostrado que las conclusiones obtenidas a partir de los resultados proporcionados por un modelo basado en redes neuronales son equivalentes a las que se podrían obtener a partir de los datos reales. De esta forma se minimiza notablemente la cantidad de pruebas a realizar sobre la máquina real y se facilita al fabricante un criterio para poder cambiar la parametrización del CNC de forma sencilla en función de sus necesidades. Además se expone un método que permite reducir significativamente la cantidad de datos requerida para el entrenamiento del modelo.

	<p style="text-align: center;">OPTIMIZACIÓN DE PARÁMETROS DEL CNC DE ACUERDO A CRITERIOS DE PRODUCTIVIDAD USANDO UN MODELO DE MÁQUINA BASADO EN REDES NEURONALES</p>	<p style="text-align: center;">Disciplina UNESCO</p>
<p>Rev. 2 del 9/ene/2012</p>	<p style="text-align: center;">J Arenas López, R Basagoiti Astigarraga, M Beamurgia Bengoa, J Martínez de Alegría Sáenz de Castillo</p>	<p style="text-align: center;">Subdisciplina</p>

REFERENCIAS

1. Chang Y, Tsao T. "Minimum-time contour tracking with model predictive control approach". *Proceedings of the American Control Conference*. p. 1821–1826. 2014. DOI: 10.1109/ACC.2014.6859414.
2. Mattmüller J, Gisler D. "Calculating a near time-optimal jerk-constrained trajectory along a specified smooth path". *International Journal of Advanced Manufacturing Technology*. Vol. 45, no. 9–10, p. 1007–1016. 2009. DOI: 10.1007/s00170-009-2032-9.
3. Bharathi A, Dong J. "A Smooth Trajectory Generation Algorithm for Addressing Higher-Order Dynamic Constraints in Nanopositioning Systems". *Procedia Manufacturing*. Vol. 1, p. 216–225. 2015. DOI: 10.1016/j.promfg.2015.09.006.
4. Zhang Y, Zhao M, Ye P et al. "Optimal curvature-smooth transition and efficient feedrate optimization method with axis kinematic limitations for linear toolpath". *International Journal of Advanced Manufacturing Technology*. Vol. 99, no. 1–4, p. 169–179. 2018. DOI: 10.1007/s00170-018-2496-6.
5. Pawlus W, Hansen MR, Choux M et al. "Mitigation of Fatigue Damage and Vibration Severity of Electric Drivetrains by Systematic Selection of Motion Profiles". *IEEE/ASME Transactions on Mechatronics*. Vol. 21, no. 6, p. 2870–2880. 2016. DOI: 10.1109/TMECH.2016.2573587.
6. Constantinescu D, Croft EA. "Smooth and time-optimal trajectory planning for industrial manipulators along specified paths". *Journal of Robotic Systems*. Vol. 17, no. 5, p. 233–249. 2000. DOI: 10.1002/(SICI)1097-4563(200005)17:5<233::AID-ROB1>3.0.CO;2-Y.
7. Li B, Zhang H, Ye P. "Error constraint optimization for corner smoothing algorithms in high-speed CNC machine tools". *International Journal of Advanced Manufacturing Technology*. Vol. 99, no. 4, p. 635–646. 2018. DOI: 10.1007/s00170-018-2489-5.
8. Lam D, Manzie C, Good M. "Multi-axis model predictive contouring control". *International Journal of Control*. Vol. 86, no. 8, p. 1410–1424. 2013. DOI: 10.1080/00207179.2013.770170.
9. Li X, Zhao H, Zhao X et al. "Interpolation-based contour error estimation and component-based contouring control for five-axis CNC machine tools". *Science China Technological Sciences*. Vol. 61, no. 11, p. 1666–1678. 2018. DOI: 10.1007/s11431-017-9204-y.
10. Pi S, Liu Q, Liu Q. "A novel dynamic contour error estimation and control in high-speed CNC". *International Journal of Advanced Manufacturing Technology*. Vol. 96, no. 1–4, p. 547–560. 2018. DOI: 10.1007/s00170-018-1629-2.
11. Jiang Z, Gao D, Lu Y et al. "Electrical energy consumption of CNC machine tools based on empirical modeling". *International Journal of Advanced Manufacturing Technology*. Vol. 100, no. 9–12, p. 2255–2267. 2019. DOI: 10.1007/s00170-018-2808-x.
12. Moreira LC, Li WD, Lu X et al. "Supervision controller for real-time surface quality assurance in CNC machining using artificial intelligence". *Computers and Industrial Engineering*. Vol. 127, no. December 2018, p. 158–168. 2019. DOI: 10.1016/j.cie.2018.12.016.
13. Luo W, Hu T, Zhang C et al. "Digital twin for CNC machine tool: modeling and using strategy". *Journal of Ambient Intelligence and Humanized Computing* [online]. Vol. 10, no. 3, p. 1129–1140. 2019. DOI: 10.1007/s12652-018-0946-5.
14. Zirn O, Batzies E, Weikert S et al. "State control of servo drives with flexible structural components". *Conference Record - IAS Annual Meeting (IEEE Industry Applications Society)*. Vol. 4, p. 1760–1766. 2006. DOI: 10.1109/IAS.2006.256773.
15. Balmès E. "Frequency domain identification of structural dynamics using the pole/residue parametrization". *IMAC XIV - 14th International Modal Analysis Conference - Noise and Vibration Harshness (NVH)*. 1996.
16. Vinod P, Reddy T, Sajin S et al. "Real-time Positioning Error Compensation for a Turning Machine Using Neural Network". *Procedia Materials Science*. Vol. 5, no. March 2014, p. 2293–2300. 2014. DOI: 10.1016/j.mspro.2014.07.472.
17. Kazem BI, Zangana NFH. "A Neural Network Based Real Time Controller for Turning Process". *Jordan Journal of Mechanical and Industrial Engineering* [online]. Vol. 1, no. 1, p. 43–55. 2007.

18. Huang P. "Neural Networks-Based-In-Process Adaptive Surface Roughness Control (NN-IASRC) System In End-Milling Operations". 2002.
19. Rosdy B, Kollar K, Moser J et al. "Surface Roughness Prediction for CNC Milling Process using Artificial Neural Network". *Epilepsia*. Vol. 57, no. Supplement 2, p. 190. 2016. DOI: <http://dx.doi.org/10.1111/epi.13609>.
20. Joo J, Yi GR, Cho H et al. "Dynamic planning model for determining cutting parameters using neural networks in feature-based process planning". *Journal of Intelligent Manufacturing*. Vol. 12, no. 1, p. 13–29. 2001. DOI: 10.1023/A:1008995312224.
21. Samek D, Bilek O. "Modeling of CNC Machining Process - Artificial Neural Networks Approach 2 Initial Experiments 3 Data Modeling". p. 168–173.
22. Meireles M, Almeida P, Simões M. "A comprehensive review for industrial applicability of artificial neural networks". *IEEE Transactions on Industrial Electronics*. Vol. 50, no. 3, p. 585–601. 2003. DOI: 10.1109/TIE.2003.812470.
23. Lai G, Chang W, Yang Y et al. "Modeling Long- and Short-Term Temporal Patterns with Deep Neural Networks". [online]. no. July. 2017.
24. Gonzalez J, Yu W. "Non-linear system modeling using LSTM neural networks". *IFAC-PapersOnLine* [online]. Vol. 51, no. 13, p. 485–489. 2018. DOI: 10.1016/j.ifacol.2018.07.326.
25. Wang J, Ma Y, Zhang L et al. "Deep learning for smart manufacturing: Methods and applications". *Journal of Manufacturing Systems*. Vol. 48, no. January, p. 144–156. 2018. DOI: 10.1016/j.jmsy.2018.01.003.
26. Basagoiti RM, Martínez de Alegria J, Beamurgia M et al. "FATIMA: Fabricación avanzada y técnicas de Inteligencia Artificial en las máquinas". *Acta del XXI Congreso Máquina-Herramienta*. no. October. 2017.
27. Agatonovic-Kustrin S, Beresford R. "Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research". *Journal of Pharmaceutical and Biomedical Analysis*. Vol. 22, p. 717-727. 2000. DOI: 10.1016/S0731-7085(99)00272-1.