

## Modelado Neuroborroso Transductivo del Proceso de Taladrado de Alto Rendimiento

Agustín Gajate, Bruno Caballero, Diego Martín, Rodolfo E. Haber

Centro de Automática y Robótica– UPM-CSIC  
Ctra. Campo Real Km 0.200, Arganda del Rey, 28500 Madrid, España  
Rodolfo.haber@car.upm-csic.es

Resumen: Este artículo trata el modelado de uno de los procesos de fabricación más utilizados y menos conocido: el proceso de taladrado de alto rendimiento. El modelado se lleva a cabo por medio de uno de los métodos más recientes de inferencia neuro-borrosa denominado *Transductive Weighted Neuro-Fuzzy Inference system* (TWNFI). Este paradigma propuesto por Song y Kasabov (2006) está basado en métodos de aprendizaje transductivo. De este modo es capaz de crear un modelo local para cada entrada a un determinado sistema. El alto potencial de esta novedosa técnica radica en su capacidad para crear modelos predictivos de procesos reales a partir de datos experimentales del propio proceso. Para demostrar los beneficios de este método se muestra su aplicación para el modelado del proceso de taladrado de alto rendimiento, considerado de alta complejidad.

Palabras Clave: modelado transductivo, modelo predictivo, inferencia neuro-borrosa, retardos, taladrado de alto rendimiento.

### 1. INTRODUCCIÓN

En la actualidad se han producido grandes progresos en las técnicas y métodos para el modelado de sistemas complejos y de gran escala (Haber et al. 2004). Sólo a través de un modelo o una representación similar se puede llegar a comprender, evaluar, controlar y optimizar de forma efectiva un sistema. La tarea de modelado de un proceso trata de obtener una representación del comportamiento del mismo por medio de representaciones matemáticas (ecuaciones diferenciales, ecuaciones integrales, etc.). La complejidad y no linealidad de algunos procesos, convierten a la tarea del modelado por medio de técnicas clásicas en una labor difícil y costosa.

Las tecnologías de fabricación ocupan gran parte de los procesos industriales en todo el mundo. Entre ellas, los procesos de mecanizado y, en especial, el proceso de taladrado de alto rendimiento, tienen una gran importancia ya que son claves en sectores tan relevantes como el aeronáutico, aeroespacial y del automóvil. Un proceso de mecanizado está compuesto por sub-procesos tales como taladrado (30%), torneado (20%), fresado (16%), roscado (15%), grabado (6%) y otra serie de procesos (13%) (Rivero *et al.*, 2006). A pesar de su importancia en el conjunto de procesos, el taladrado de alto rendimiento, es uno de los menos automatizados de la industria.

Estos procesos involucran maquinaria y materiales muy costosos así como operadores expertos. De ahí que cualquier modelo que sea capaz de describir de forma eficiente los procesos físicos que tienen lugar, es esencial para la mejora y optimización de estos sistemas. Ciertamente la optimización de la productividad y la minimización de los fallos y los riesgos de rotura de máquinas y herramientas son tareas muy difíciles de llevar a cabo sin modelos tal y como demuestran Haber et al. (2005a), Haber et al. (2005b) y Haber et al (2006).

Las características del taladrado de alto rendimiento como proceso electromecánico complejo limita el uso de las herramientas matemáticas clásicas para su modelado (Gajate et al. 2009). Cuando las técnicas clásicas no son viables, no se dispone de un modelo matemático exacto o éste es muy complejo por el alto número de variables y parámetros que lo hacen computacionalmente ineficiente, las técnicas de Inteligencia Artificial, y en específico las técnicas híbridas, pueden desempeñar un papel esencial. Entre estas técnicas, las neuro-borrosas están ocupando lugares más relevantes. De este modo, se pueden superar algunas limitaciones relacionadas con el conocimiento exacto de las no linealidades del proceso y las dificultades relativas a la representación cuasi-lineal o lineal de un proceso no lineal.

Por otra parte, cada vez son más frecuentes los procesos en red que conectan sistemas, controladores, supervisores, sensores y actuadores distribuidos a lo

largo de toda el área de trabajo. Ante esta situación se hace necesario el empleo de buses de campo y redes de comunicación capaces de garantizar tiempo real. Dicha característica implica incluir en los modelos los retardos introducidos por estas redes y otros retardos intrínsecos a la propia dinámica de estos procesos.

En este trabajo se propone el uso de TWNFI (*Transductive Weighed Neuro-Fuzzy Inference system*) (Song and Kasabov, 2006) para la obtención de un modelo predictivo simple entrada – simple salida (SISO) que relacione la fuerza media de corte con velocidad de avance en el proceso de taladrado de alto rendimiento. El uso de modelos predictivos incorpora una serie de ventajas muy importantes en el control de procesos con dinámica muy compleja (Camacho and Bordons, 2004).

Es importante señalar que TWNFI, a diferencia de otras técnicas híbridas, hereda las ventajas potenciales de las técnicas puras, lo cuál motivó su elección. Entre ellas, no encontramos con:

- Neuronal: excelente habilidad para modelar cualquier función no lineal con un alto grado de precisión y con una alta capacidad de aprendizaje Alique et al.,(2000), Haber et al. (2001), Haber et al. (2002), Haber y Alique (2004).
- Borroso: transparencia semántica y tratamiento de la imprecisión e incertidumbre (Peres et al. 1999).
- Neuroborroso: donde combinan redes neuronales y sistemas de inferencia borrosa (Haber et al. 2005).
- Transductivo: los sistemas clásicos de inferencia inductiva tratan de obtener un modelo general para después aplicarlo a casos particulares. En los sistemas de inferencia transductivos se estima un modelo en un único punto del espacio, utilizando solo información relacionada con dicho punto (Vapnik, 1998).

Varios han sido los trabajos dedicados a la obtención de un modelo matemático para el proceso de taladrado, y que relacionan la fuerza de corte con alguna otra variable del proceso (*e.g.* geometría de la herramienta, velocidad de rotación, velocidad de avance, profundidad de corte, etc.) entre los cuales destacan los trabajos de Kim, *et al.* (1994), Landers, *et al.* (2004), Del Toro, *et al.* (2007) y Del Toro, *et al.* (2008). Por otra parte, también existen trabajos de modelación del proceso de taladrado y otros procesos de mecanizado mediante la utilización de redes neuronales. El objetivo final es la utilización de la fuerza de corte en el control y en la monitorización del estado de la herramienta (Haber and Alique,

2003; Haber *et al.*, 2004; Lee *et al.*, 1996; Sheng and Tomizuka, 2006), Gajate et al. (2009).

Una de las principales aportaciones de este trabajo es la utilización del nuevo paradigma a procesos de fabricación reales, ya que su aplicación estaba restringida a series temporales y al diagnóstico médico. En este trabajo se propone además un método simple, rápido y preciso de modelar un proceso altamente complejo.

Este artículo se estructura de la siguiente manera: en la sección 2 se describen los métodos utilizados; en la sección 3 se presentan los resultados obtenidos y finalmente en la sección 4 se presentan las conclusiones y las líneas de trabajo futuro.

## 2. MATERIALES Y MÉTODOS

### 2.1 Inferencia transductiva

La mayoría de los métodos de aprendizaje utilizados en inteligencia artificial utilizan inferencia inductiva, en la cual se deriva un modelo general a partir de los datos de entrenamiento facilitados al sistema. Este modelo se aplica posteriormente a los nuevos datos de entrada al mismo sistema. En contraste con este tipo de estrategias, encontramos métodos de inferencia o modelado transductivos. Estos métodos estiman un modelo (función) en un único punto del espacio de trabajo. Para cada nuevo dato que tenga que ser procesado, se buscan los ejemplos más cercanos entre los datos conocidos, con el objetivo de crear un nuevo modelo para aproximar el valor de la función en el nuevo estado.

Entre las ventajas de los métodos transductivos sobre los inductivos podemos destacar que, en ocasiones, crear un modelo válido para todo espacio o región de operación es una tarea difícil y en algunos casos no necesaria. La generación dinámica de modelos permite la ampliación del conocimiento (representado como el conjunto de datos conocidos) de manera sencilla, permitiendo el aprendizaje incremental *on-line*. Además, estas estrategias tienen capacidad de funcionar correctamente con un conjunto de entrenamiento reducido.

Este tipo de técnicas se han utilizado para aplicaciones de reconocimiento de texto (Joachims, 1999), predicción de series temporales y, fundamentalmente, en aplicaciones de diagnóstico médico (Song and Kasabov, 2005).

### 2.2 Modelado predictivo

Un modelo predictivo se utiliza, como su propio nombre indica, para predecir la evolución de un determinado proceso en los instantes futuros. En la mayoría de los casos el empleo de modelos predictivos conlleva la utilización de modelos

regresivos, es decir, tiene en cuenta estados anteriores.

La utilización de modelos predictivos en el control de procesos permite controlar una gran variedad de procesos, desde procesos muy simples hasta procesos con dinámicas complejas tales como procesos con grandes retardos o tiempos muertos, procesos de fase no mínima, procesos inestables o procesos multivariados. Entre otros factores, estas capacidades se deben a que internamente se introducen componentes anticipativas y de forma natural se compensan algunas perturbaciones.

### 2.3 Técnicas neuro-borrosas

Las técnicas neuro-borrosas combinan los paradigmas de la lógica borrosa y las redes neuronales con el fin de aprovechar las ventajas de ambas técnicas.

Las técnicas de inferencia borrosas permiten expresar incertidumbre en los sistemas basados en reglas pero, a su vez, presentan algunas desventajas. Por ejemplo, no existen métodos universales para transformar el conocimiento humano en reglas borrosas. Esto se plasma, entre otros factores, en la dificultad que existe para ajustar los parámetros de las funciones de pertenencia de manera óptima. Sin embargo, estos sistemas han dado muy buenos resultados prácticos en el campo del modelado y control.

Por otra parte las redes neuronales permiten obtener y ajustar modelos de manera sencilla. El problema de estas técnicas es que el conocimiento aparece de forma implícita (valores numéricos sin un significado fácilmente reconocible) en forma de “caja negra” y suelen fallar cuando se producen comportamientos fuera de la región de entrenamiento.

La hibridación de estos dos paradigmas permite aprovechar las ventajas de ambos, consiguiendo la sencillez de ajuste de las redes neuronales y a la vez disponiendo de conocimiento explícito expresado en un conjunto de reglas *if-then*.

### 2.4 TWNFI

TWNFI es un sistema de inferencia dinámica neuro-borrosa con generalización local (Song y Kasabov, 2006). Este tipo de generalización implica la creación de modelos generales para sub-espacios del problema. En el modelo creado por TWNFI las funciones de pertenencia borrosas son *gaussianas*, tanto en los antecedentes como en los consecuentes de las reglas *if-then* (sistema de inferencia tipo

Mamdani). A su vez, estas funciones son derivables, lo que permite el uso de un algoritmo de propagación hacia atrás de los errores para el aprendizaje. En la figura 1 se pueden observar los distintos pasos que sigue TWNFI para la creación del modelo. A continuación se procede a detallar cada uno de estos pasos más en profundidad.

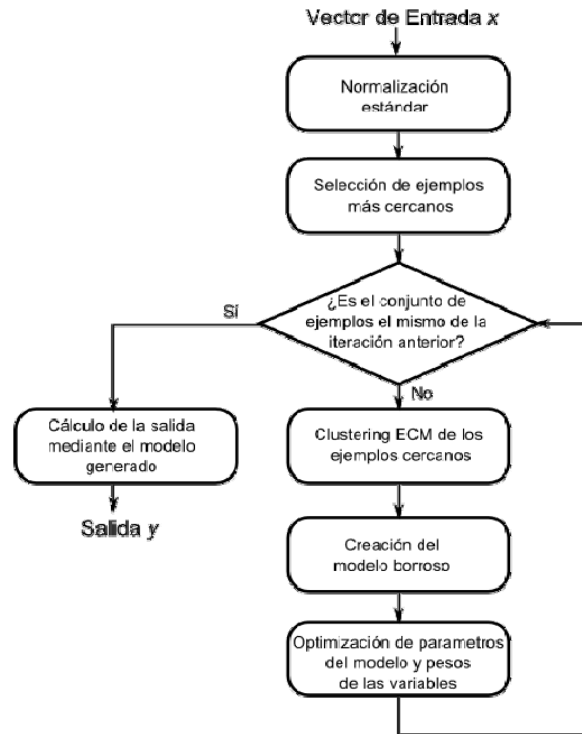


Figura 1. Diagrama de bloques del algoritmo TWNFI.

Las entradas al sistema TWNFI pueden estar expresadas con distintas unidades de medida, tal y como sucede en este trabajo. Entonces, antes de llevar a cabo la inferencia, la normalización de datos es recomendable. En este caso se ha llevado a cabo por medio de (1).

$$x' = \frac{x - \mu_x}{\sigma_x} \quad (1)$$

donde  $\mu_x$  es la media,  $\sigma_x$  es la desviación estándar y  $x$  es el conjunto de datos conocidos.

Tal y como se ha mencionado anteriormente, el modelo se crea a partir de los ejemplos conocidos más cercanos a cada nuevo dato de entrada. Para la selección de este subconjunto de ejemplos se utiliza la distancia euclídea normalizada con pesos (2). El tamaño de este subconjunto es un parámetro del

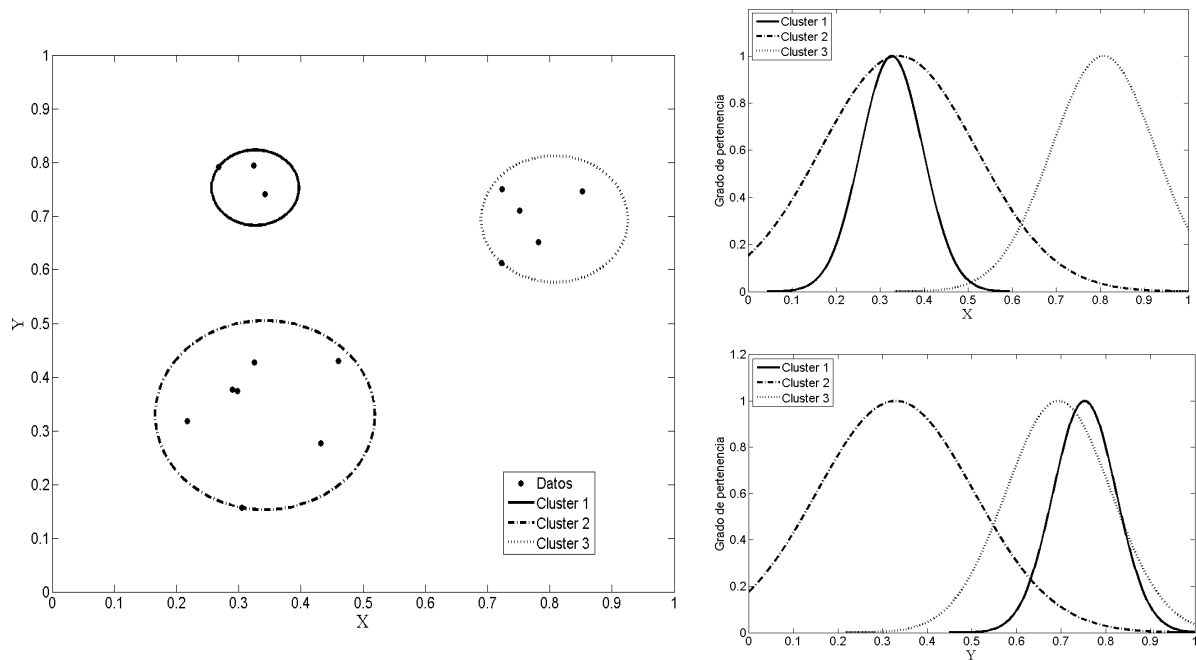


Figura 2. Ejemplo del algoritmo ECM para dos entradas y las funciones de pertenencia generadas a partir de sus resultados.

algoritmo. Los pesos  $w_j$  de cada componente del vector se obtienen en el proceso de ajuste del modelo.

$$\|x - y\| = \left[ \frac{1}{P} \sum_{j=1}^P w_j |x_j - y_j|^2 \right]^{\frac{1}{2}} \quad (2)$$

A partir de los ejemplos cercanos se deben construir dinámicamente las funciones de pertenencia borrosas. Para ello se utiliza el algoritmo de agrupamiento *Evolving Clustering Method* (ECM) (Song y Kasabov, 2001). Se trata de un algoritmo *on-line* de una ejecución para el agrupamiento dinámico en un conjunto de datos. Comienza con un conjunto inicial para el primer dato. Para los siguientes datos decide en función de las distancias, si añadirlo a un conjunto existente (actualizando el centro y el radio del mismo) o crear un nuevo conjunto. Los conjuntos resultantes son circulares y se utilizan para crear las funciones de pertenencia *gaussianas*. Para ello, el centro del conjunto se toma como centro de la *gaussiana*, y el radio como anchura (ver figura 2).

Una vez obtenidas las funciones de pertenencia, se aplica el algoritmo de descenso por gradiente para optimizar los pesos y los parámetros de las reglas borrosas. Para ello se utiliza como conjunto de entrenamiento el formado por los ejemplos cercanos anteriormente seleccionados.

Tras realizar todos estos pasos, se comprueba que el conjunto de vecinos más cercano no haya cambiado debido a los nuevos pesos de las variables. Si eso ocurre, se vuelve a crear un modelo para ese nuevo conjunto tomando como pesos de partida los obtenidos en la iteración anterior. Si no, el modelo se usa para predecir la salida correspondiente al vector

de entrada. De esta manera se optimiza el peso de cada variable en función de su importancia dentro del sub-espacio en el que se aproxima la función.

En el algoritmo, el desemborronado se hace mediante el método del centro del área modificado. La función resultante es derivable, y se puede construir una función de error cuadrático ponderado de la siguiente forma (3):

$$E = \frac{1}{2} v_i [f(x_i) - t_i]^2 \quad (3)$$

donde  $f(x_i)$  es la función de desemborronado que produce la salida del predictor,  $t_i$  son los valores objetivo, y  $v_i$  es una medida que indica la cercanía de cada punto objetivo al punto que se pretende predecir. Derivando esta función de error se obtienen las ecuaciones necesarias para el algoritmo de descenso por gradiente.

## 2.5 Modelado del proceso de taladrado de alto rendimiento

De todas las variables que influyen en el proceso de taladrado, la fuerza de corte es la más importante. Tal y como demostraron Kim, *et al.* (1994), el incremento en la tasa de arranque de material guarda relación directa con el mantenimiento de la fuerza constante en toda la operación.

A partir del análisis sistémico del proceso y del conocimiento técnico del mismo, basta con considerar al sistema de una entrada y una salida. Como entrada se tiene la velocidad de avance ( $f$ ), y como salida, la fuerza media de corte ( $F$ ). Se ha

comprobado experimentalmente que la fuerza de corte tiene una relación directa a la velocidad de avance y que el proceso tiene una ganancia cuya magnitud depende del material de la pieza con el que se este trabajando y del diámetro de la broca.

Otro de los puntos importantes a tener en cuenta en la obtención del modelo es representar la dinámica del proceso lo más fielmente posible y, para ello, es necesario incluir los retardos inherentes a la propia dinámica de la máquina en particular. Además, se ha de tener en cuenta la utilización posterior de este modelo. En vistas de que las líneas de investigación apuntan al control en red de este tipo de procesos (Verbruggen, *et al.*, 2002; Breanan, *et al.*, 2002; Murray, *et al.*, 2003), es necesario incluir en el modelo el retardo producido por el envío de señales a través de la arquitectura de la red.

En este trabajo se considera como entrada la velocidad de avance ( $f$ ), y como salida, la fuerza media de corte ( $F$ ). Además, al tratarse en este caso de un modelo predictivo, se discretizan las entradas con el objetivo de almacenar estados anteriores. El sistema interpreta como entradas el avance actual y el avance en instantes anteriores de tiempo, así como los estados anteriores de la salida del propio proceso (fuerza de corte obtenida experimentalmente). En la sección experimental de este trabajo se abordará cuál es el número óptimo de estados anteriores de la variable de entrada.

### 3. RESULTADOS

Al tratarse de un modelo experimental, el modelo se va a crear a partir de datos obtenidos experimentalmente en ensayos de taladrado de alto rendimiento.

Todos los datos utilizados en este trabajo se han extraído de ensayos reales llevados a cabo en un centro de mecanizado de alta velocidad Kondia HS1000 equipado con un CNC abierto Sinumerik 840D. Los datos del CNC fueron transmitidos a un ordenador a través de una red PROFIBUS (figura 3). A su vez las decisiones se toman en dicho ordenador y vuelven a transmitirse al proceso a través de la misma red. En los experimentos se utilizó una broca de diámetro 10 mm Sandvik R840-1000-30-A0A de metal duro integral con recubrimiento de TiN/TiAlN.

Una de las primeras decisiones a tomar es conformar una base de datos de entrenamiento adecuada para el trabajo a desarrollar. En este trabajo se trata de demostrar la eficacia del algoritmo con una base de datos reducida. Es por ello, por lo que para la obtención de los modelos se utilizan únicamente los datos extraídos de una única prueba experimental (178 muestras). Con una base de datos más rica el ajuste se realiza con un menor error, sin embargo, también conlleva una mayor carga computacional

incompatible con alguno de los procesos reales de taladrado de alto rendimiento.

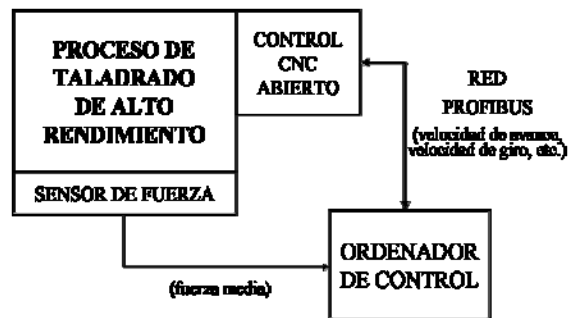


Figura 3. Arquitectura del proceso de taladrado de alto rendimiento.

Una vez definidos los datos de entrenamiento, otro parámetro a fijar es el número de entradas al algoritmo, es decir, el número de variables con sus respectivos estados anteriores. Después de estudiar el algoritmo con diversas entradas para predecir el comportamiento del proceso, se ha llegado a la conclusión de que el número óptimo de entradas al proceso es de tres. La distribución de estas entradas es: avance en el propio instante de tiempo  $f(t)$ , avance en el instante anterior de tiempo  $f(t-1)$  y fuerza obtenida en el instante anterior  $F(t-1)$ . En la elección de este parámetro se ha intentado elegir un compromiso entre error y comportamiento dinámico a través de diversas pruebas.

El modelo mostraba un mejor comportamiento si se introducían los datos de la salida del proceso en el instante anterior, ya que modelaba más adecuadamente la dinámica del sistema. Por otra parte, el utilizar un mayor número de estados anteriores no mostraba un mejor ajuste y por el contrario si que producía una carga computacional mayor en el algoritmo.

Todos estos comentarios se ven reflejados numéricamente en la figura 4 y en la tabla 1. En esta tabla y en las siguientes el error mostrado es el IAE (*Integral Absolute Error*). Los datos de la tabla y de la gráfica son el resultado de introducir en el algoritmo unos datos distintos (procedentes de otra prueba experimental) de los almacenados en su base de entrenamiento.

$$IAE = \sum_{i=1}^n |y(i) - \hat{y}(i)| / \sum_{i=1}^n y(i) \quad (6)$$

Todos los datos de tiempo mostrados en esta tabla y en las posteriores se han obtenido ejecutando el algoritmo TWNFI sobre un ordenador con procesador Intel Celeron a 2.20 GHz con sistema operativo Windows 2000.




Figura 4. Respuesta de los distintos modelos en función del número de entradas al mismo.

Tabla 1: Resultados de tiempo y error para distinto número de entradas al algoritmo TWNFI

Denominación	Entradas	Tiempo Respuesta	IAE %
Orden 1	$f(t)$	0.65 ms	22.54
Orden 1+1	$f(t), F(t-1)$	1.12 ms	3.94
Orden 2+1	$f(t), f(t-1), F(t-1)$	1.47 ms	4.46
Orden 3+1	$f(t), f(t-1), f(t-2), F(t-1)$	1.93 ms	5.08
Orden 4+1	$f(t), f(t-1), f(t-2), f(t-3), F(t-1)$	2.27 ms	5.26
Orden 3+2	$f(t), f(t-1), f(t-2), F(t-1), F(t-2)$	2.50 ms	5.26
Orden 2+2	$f(t), f(t-1), F(t-1), F(t-2)$	2.02 ms	4.83

Otros de los parámetros configurables en el algoritmo TWNFI son: el número de vecinos más próximos; el radio inicial de los conjuntos y su valor umbral; las iteraciones y el ratio del ajuste *backpropagation*. En la figura 5 se muestra la respuesta del modelo predecido por TWNFI con distinto número de vecinos.




Figura 5. Respuesta del modelo TWNFI en función del número de vecinos.

Tabla 2: Resultados de tiempo y error para distinto número de vecinos del algoritmo TWNFI

Nº Vecinos	Tiempo Respuesta	IAE %
2	0.79 ms	2.91
5	1.47 ms	4.46
10	2.78 ms	5.91
15	3.87 ms	6.90

A la vista de los resultados se decide la elección de dos vecinos en el algoritmo ya que la respuesta de dicho modelo presenta una dinámica mejor que el resto de comportamientos. Tras la realización de diversas pruebas se opta por establecer un valor umbral de agrupamiento ( $D_{thr}$ ) de 1.

En cuanto a la propagación hacia atrás de los errores, son suficientes 20 iteraciones del algoritmo para obtener unos buenos resultados. El aumento en el número de iteraciones no mejora sustancialmente el error y si carga al algoritmo con excesivas operaciones. Se ha optado por emplear una tasa de aprendizaje de 0.001.

Por último, para realizar una correcta validación del modelo se lleva a cabo un análisis de correlación (7). El error proporcionado por el modelo es comparado muestra a muestra para determinar si existe alguna contribución residual procedente de los datos, es decir, si existen dinámicas que no están bien representadas por el modelo. En la figura 6 se muestra el análisis de autocorrelación comprobándose que el modelo conforma el 95 % del intervalo de confianza y puede representar las dinámicas del sistema adecuadamente.

$$\hat{p}_k = \frac{\sum_{i=k}^{N-(k+1)} (y(i) - \hat{y}(i))(y(i+k) - \hat{y}(i+k))}{\sum_{i=0}^{N-1} (y(i) - \hat{y}(i))^2} \quad (7)$$




Figura 6. Función de autocorrelación del error en la predicción de la fuerza del proceso de taladrado.

#### 4. DISCUSIÓN

En este trabajo se ha aplicado por primera vez uno de los paradigmas de la hibridación, el sistema de inferencia neuro-borroso transductivo TWNFI, a un proceso de fabricación real y en específico al modelado del proceso de taladrado de alto rendimiento. Se ha comprobado además que es una herramienta sencilla y computacionalmente viable para el modelado de procesos reales.

Por otra parte, el hecho de crear un modelo para cada entrada a partir de únicamente sus vecinos más cercanos muestra un mejor ajuste que el empleo de modelos lineales. TWNFI permite realizar predicciones aceptables con un número muy reducido de datos y permite la integración dinámica de nuevo datos sin un entrenamiento explícito.

En el sistema presentado, la selección de parámetros depende del problema concreto que se esté tratando. En nuestro caso, el incremento en el número de vecinos consigue una respuesta más suave y que no es tan sensible a las fluctuaciones características del modelo. Conclusión que puede ser válida para otros procesos físicos reales. Este incremento se debe realizar dentro de unos límites debido a que si no se acercaría a un modelo inductivo, con las desventajas que esto conlleva (tiempo de creación del modelo y peor ajuste en el sub-espacio en el cual se quiere aproximar la función).

El método desarrollado es completamente válido para el modelado en otras condiciones. Basta con introducir en la base de entrenamiento datos experimentales en las condiciones de trabajo requeridas.

El uso de estos modelos resulta muy apropiado para estrategias de control de procesos. Es decir, se

pueden crear modelos directos e inversos del proceso para posteriormente introducirlos en lazos de control por modelo interno y optimizar estos procesos. En esa dirección apuntan los trabajos futuros donde se tratará el control a través de internet y *Ethernet*.

#### REFERENCIAS

- Breanan, R.W., M. Fletcher and D.H. Norrie (2002). "An agent based approach to reconfiguration of real-time distributed control systems". *IEEE Transactions on Robotics and Automation*, **18**, pp. 444-451.
- Camacho, E. and Bordons, C. (2004). "Control Predictivo: Pasado, Presente y Futuro". *Revista Iberoamericana de Automática e Informática*, **1**, pp. 5-28.
- Del Toro, R. M., Schmittiel, M. C., Haber-Guerra, R. E., and Haber-Haber, R. (2007). System identification of the high performance drilling process for network-based control. In ASME 2007 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference, pp. 827-834. American Society of Mechanical Engineers.
- Del Toro-Matamoros, R., Haber, R., Pamies, J., and Bustillo, A. (2008). "Modelling and simulation of the high-speed milling process based on MATLAB-SIMULINK". *Revista de Metalurgia* **44**, pp. 176-188.
- Gajate, A., and Haber, R. E. (2009) "Control Neuroborroso en red. Aplicación al proceso de taladrado de alto rendimiento". *Revista Iberoamericana de Automática e Informática Industrial RIAI* **6**, pp. 31-38.
- Gajate, A., Haber, R. E., Alique, J. R., and Vega, P. I. (2009). "Transductive-weighted neuro-fuzzy inference system for tool wear prediction in a turning process". In International Conference on Hybrid Artificial Intelligence Systems, pp. 113-120. Springer, Berlin, Heidelberg.
- Haber, R. E., Haber, R., Peres, C., Alique, A., and Ros, S. (2001). Model of the milling process on the basis of cutting force: A Neural network approach. Paper presented at the Advances in Neural Networks and Applications (N. Mastorakis Ed.), Artificial Intelligence Series, World Scientific and Engineering.
- Haber, R. E., Haber, R., Alique, A., Ros, S., and Alique, J. R. (2002). Dynamic model of the machining process on the basis of neural networks: from simulation to real time application. Paper presented at the International Conference on Computational Science.
- Haber, R.E. and Alique, A. (2003). "Intelligent process supervision for predicting tool wear in machining processes". *Mechatronics*, **13**, pp. 825-849.
- Haber, R., Jiménez, J., Jimenez, A., and Lopez-Coronado, J. (2004). "Cutting force model for high speed machining process". *Revista de Metalurgia*, **40**, 247-258.

- Haber, R. E., y Alique, J. R. (2004). Nonlinear internal model control using neural networks: an application for machining processes. *Neural Computing and Applications*, **13**(1), 47-55.
- Haber, R.E., Alique, J.R., Alique, A., and Haber, R.H. (2005). "Controlling a complex electromechanical process on the basis of a neurofuzzy approach". *Future Generation Computer System*, **21**, pp 1083-1095.
- Haber, R. E., Cantillo, K., and Jiménez, J. E. (2005). "Networked sensing for high-speed machining processes based on CORBA". *Sensors and Actuators A: Physical* **119**, pp. 418-426.
- Haber-Guerra, R., Liang, S. Y., Alique, J. R., and Haber-Haber, R. (2006). "Fuzzy control of spindle torque in high-speed milling processes". *Journal of manufacturing science and engineering* **128**, pp. 1014-1018.
- Haber, R. E., Haber-Haber, R., Toro, R. M. d., & Alique, J. R. (2007). Other Applications-Using Simulated Annealing for Optimal Tuning of a PID Controller for Time-Delay Systems. An Application to a High-Performance Drilling Process. Lecture Notes in Computer Science, 4507, 1155-1162.
- Joachims, T. (1999). "Transductive Inference for Text Classification using Support Vector Machines". *Proceedings of ICML 16th International Conference on Machine Learning*, pp 200-209.
- Kim, J. B., Lee, S. J. and Park, Y. P. (1994). "Stable and efficient drilling process by active control of the thrust force". *Mechanical Systems and Signal Processing*, **8**, pp. 585-595.
- Landers, R. G., Ulsoy, A. G. and Ma, Y. H. (2004). "A comparison of model-based machining force control approaches". *International Journal of Machine Tools & Manufacture*, **44**, pp. 733-748.
- Lee, B.Y., Liu, H.S. and Tarn, Y.S. (1998). "Modeling and optimization of drilling process". *Journal of Materials Processing Technology*, **74**, pp 149-157.
- Martín, D., Caballero, B., and Haber, R. (2008). "Optimal Tuning of a Networked Linear Controller Using a Multi-Objective Genetic Algorithm. Application to a Complex Electromechanical Process". In Innovative Computing Information and Control, 2008. ICIC'08. 3rd International Conference on", pp. 91-91. IEEE.
- Murray, R.M., K.J. Astrom, S.P. Boyd, R.W. Brockett and G. Stein (2003). "Future directions in control in an informatic-rich world". *IEEE Control Systems Magazine*, April, pp 20-32.
- Peres, C. R., Guerra, R. E. H., Haber, R. H., Alique, A., and Ros, S. (1999). "Fuzzy model and hierarchical fuzzy control integration: an approach for milling process optimization". *Computers in Industry*, **39**(3), 199-207.
- Rivero, A., Aramendi, G., Herranz, S. and López de Lacalle, L. N. (2006). "An experimental investigation of the effect of coatings and cutting parameters on the dry drilling performance of aluminium alloys", *The International Journal of Advanced Manufacturing Technology*, **28**, No. 1-2., pp 1-11.
- Sheng, Y. and Tomizuka, M. (2006). "Intelligent modeling of thrust force in drilling process". *Journal of Dynamic Systems Measurement and Control-Transactions of the Asme*, **128**, pp 846-855.
- Song, Q. and Kasabov, N.K. (2001). "ECM – A novel on-line, evolving clustering method and its applications". *Proceedings of the fifth biannual conference on artificial neural networks and expert systems*, pp 87-92.
- Song, Q. and Kasabov, N.K. (2005). "NFI: A Neuro-Fuzzy Inference Method for Transductive Reasoning". *IEEE Transactions on Fuzzy Systems*, **13**, No. 6, pp 799-808.
- Song, Q. and Kasabov, N.K. (2006). "TWNFI - A transductive neuro-fuzzy inference system with weighted data normalization for personalized modelling". *Neural Networks*, vol **19**, pp 1591-1596.
- Vapnik, V. (1998). *Statistical Learning Theory*, John Wiley & Sons Inc., cap. 8.
- Verbruggen, H.B. et al. (2002). "IFAC2002 milestone report on computer control". *Plenary Papers, Survey Papers and Milestones*, pp. 233-241.