

INTELIGENCIA COMPUTACIONAL EMBEBIDA PARA LA SUPERVISIÓN DE PROCESOS DE MICROFABRICACIÓN

Fernando Castaño

Centro de Automática y Robótica (UPM - CSIC), Ctra. Campo Real km. 0,200, SN, 28500, Arganda del Rey, España, fernando.castano@car.upm-csic.es

Rodolfo E. Haber

Centro de Automática y Robótica (UPM - CSIC), Ctra. Campo Real km. 0,200, SN, 28500, Arganda del Rey, España, rodolfo.haber@car.upm-csic.es

Gerardo Beruvides

Centro de Automática y Robótica (UPM - CSIC), Ctra. Campo Real km. 0,200, SN, 28500, Arganda del Rey, España, gerardo.beruvides@car.upm-csic.es

Resumen

En este artículo se presenta el desarrollo e implementación de una estrategia de supervisión de un proceso de microfabricación. El método propuesto está basado en técnicas de Inteligencia Artificial, embebidas en una plataforma de tiempo real para la monitorización inteligente de procesos. La contribución se centra fundamentalmente en dos modelos para la estimación en proceso (on-line) de la rugosidad superficial (R_a), a partir de la mínima información sensorial posible. El primero de estos modelos está basado en un algoritmo para el modelado híbrido incremental (HIM), cuyos parámetros óptimos se obtienen a partir de un método estocástico, representado por el temple simulado. El segundo está basado en un algoritmo de agrupamiento borroso generalizado (GFCM), incorporado en un sistema de inferencia de una estructura neuroborrosa. Esta estrategia se embebe en una plataforma para una ejecución en tiempo real y en paralelo junto con el resto de estrategias y métodos. Finalmente, se hace una validación en una plataforma experimental, utilizada como soporte tecnológico, lo cual permite el aprovechamiento mutuo de las experiencias alcanzadas y la mejora de los resultados obtenidos. Este resultado científico y técnico, supone un salto cualitativo importante sin precedentes en la investigación industrial en el campo de la microfabricación.

Palabras Clave: agrupamiento borroso, inteligencia artificial, embebido, microfabricación, modelado híbrido incremental, Fuzzy C-Means, rugosidad superficial.

1 INTRODUCCIÓN

La microfabricación se puede definir en realidad como una colección de tecnologías que se utilizan en la fabricación de micro dispositivos, surgiendo como una respuesta al incremento en la demanda de microcomponentes/productos en varias áreas tecnológicas, principalmente, de la industria aeroespacial, la biomedicina, la electrónica, de la energía e industria óptica [9].

Esta tendencia va indisolublemente relacionada con a una serie de problemas asociados al tamaño de piezas y componentes. Como solución, actualmente la comunidad científica propone el desarrollo de estrategias para la supervisión del estado del proceso basada en modelos. Una de las variables fundamentales que se monitoriza para conocer el estado del proceso, es el acabado superficial.

En este trabajo se propone el diseño de un modelo de estimación de la rugosidad superficial on-line, basado en técnicas de inteligencia artificial, con el objetivo de monitorizar el proceso y/o realizar acciones correctivas en el mismo si los valores no se sitúan en los rangos deseados.

En la literatura a la que se ha tenido acceso se encuentran diferentes trabajos relacionados con la utilización de técnicas basadas en Inteligencia Artificial para el modelado de la rugosidad superficial y así, poder controlar el acabado superficial. Por ejemplo, Azouzi y Guillot [1] aplicaron parámetros de corte y dos componentes de la fuerza de corte para la estimación en línea del acabado de la superficie y las desviaciones dimensionales, utilizado redes neuronales y una fusión sensorial. También, en base a una red neuronal, Huang y Chen [8] utilizan un enfoque estadístico para correlacionar la rugosidad superficial y la fuerza de corte en las operaciones de fresado.

conformarán las reglas borrosas. No obstante, no todos los algoritmos neuroborrosos utilizan la potencialidad extra que aportan los algoritmos de agrupamiento borrosos. Los algoritmos de agrupamiento borrosos tienen la ventaja de mantener intacta la borrosidad de los datos (un dato puede pertenecer a varios grupos) a la hora de crear las funciones de pertenencia y, por tanto, las reglas borrosas *if-then* [14].

Ciertamente, aunque son multitud los algoritmos de agrupamiento borroso que se han desarrollado en los últimos años, los algoritmos más clásicos como *Fuzzy c-means* (FCM), *Gustafson-Kessel* (G-K), *Gath-Geva* (G-G) y *Fuzzy k-Nearest Neighbor* (F-kNN), son los más comúnmente aplicados.

Por tanto, para el diseño de los modelos experimentales de variables representativas del proceso de microfabricación, se han escogido de antemano precisamente por tener características y tener un buen comportamiento para los problemas considerados en este trabajo, dos propuestas de modelos. Estas propuestas se muestran en la Figura 2.




Figura 2: Las dos propuestas de modelo basadas en técnicas de inteligencia artificial para supervisión de procesos

Como primera propuesta, está la técnica de modelado híbrido incremental y en particular, en este trabajo, se ha seleccionado como modelo local una técnica de agrupamiento borroso K-NN. Su elección se debe a que en la mayoría de los problemas reales, no es fácil resolver la estructura del modelo y es en esos casos, cuando se recurre a técnicas que se basan en el uso de un modelo genérico simple que se va ajustando iterativamente. Este primer algoritmo ya fue explorado en nuestro grupo a través de los trabajos [3, 12]. Por otro lado, como segunda propuesta se ha seleccionado un sistema neuro-borroso y para la creación de sus funciones de pertenencia se ha optado por un algoritmo de agrupamiento borroso generalizado *C-Means*. En este caso, su elección se debe a que estas técnicas son efectivas en los procesos que disponen de pequeñas cantidades de datos experimentales, como son los procesos de fabricación en la micro escala.

3.1 PRIMERA PROPUESTA

La primera propuesta es el algoritmo de modelado híbrido incremental (HIM) [11]. Esta técnica ha usado un modelo básico o global que captura el comportamiento general del sistema y le superpone un modelo local que captura el comportamiento local del mismo. En este trabajo, como caso particular, se ha elegido como modelo global el ajuste de un polinomio de grado m mediante el algoritmo de mínimos cuadrados. Como modelo local se utiliza una estrategia de suavizado local basada en el algoritmo de agrupamiento borroso F-kNN (*Fuzzy k-Nearest Neighbors*) [13], debido a su sencillez, facilidad de interpretación y una buena precisión. KNN consiste en promediar los puntos más cercanos al punto objetivo, asumiendo que puntos cercanos tienen un valor similar. Para el cálculo de la cercanía se usó la norma euclídea.

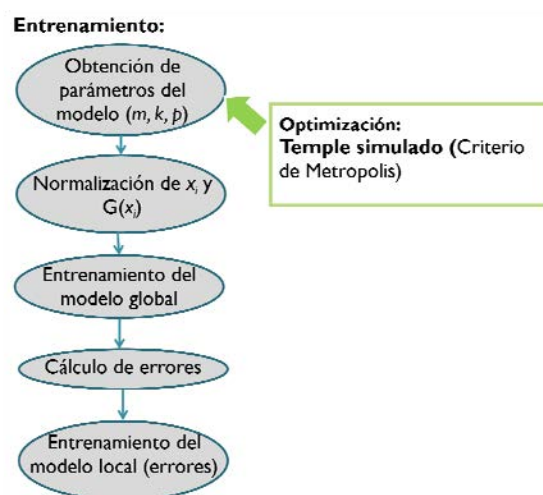


Figura 3: Pasos seguidos en el entrenamiento del modelo incremental

En la Figura 3 se aprecia el aporte dado en este trabajo en la fase de entrenamiento del algoritmo HIM, que ha sido la optimización de los parámetros mediante un método de búsqueda metaheurística como es el de temple simulado y más específicamente, mediante su implementación práctica a través del criterio de Metropolis. Esto se debe a que el algoritmo de HIM necesita un ajuste previo de los parámetros como paso inicial del entrenamiento. Se consideró este método porque ya había sido aplicado con éxito anteriormente por su buena y demostrada capacidad de convergencia [6].

3.2 SEGUNDA PROPUESTA

La segunda propuesta es el conjunto formado por el sistema neuroborroso junto a la técnica de agrupamiento borroso *C-Means* para la creación de las funciones de pertenencia. El diagrama de flujos

del algoritmo asociado a esta propuesta se muestra en la Figura 4.

Es importante resaltar que ante todas las posibles variantes existentes en la literatura sobre este algoritmo, se seleccionó la técnica que generaliza el índice de borrosidad, añadiendo un parámetro α que permite, según su valor, adoptar diferentes comportamientos entre el “Fuzzy-C-Means” y el “Fuzzy-C-Means” con particiones borrosas mejoradas [15]. Igualmente, también se ha considerado la opción que modifica el algoritmo “Fuzzy-C-Means”, mejorando las particiones borrosas a través de una modificación en la función objetivo [7]. Por ello, en este trabajo se propone una versión extendida del algoritmo de agrupamiento borroso generalizado “c-Means” con particiones borrosas mejoradas.




Figura 4: Diagrama de flujos del algoritmo asociado a la segunda propuesta de modelo (GFCM)

A pesar de que esta técnica ofrece muy buenos resultados en clasificación, aún no se han aprovechado las potencialidades que ofrece este nuevo algoritmo de agrupamiento para modelar sistemas a través de un sistema neuro-borroso. Por tal razón, se ha incorporado este algoritmo de agrupamiento a una estructura neuro-borrosa tipo mamdani, como la que se muestra en la Figura 5. Este tipo de sistemas utilizan funciones de pertenencia borrosas para determinar tanto los antecedentes como los consecuentes de las reglas “if-then”.




Figura 5: Diagrama de flujos del algoritmo asociado a la segunda propuesta de modelo (GFCM)

La incorporación del algoritmo de agrupamiento borroso en el sistema de inferencia implica establecer el modo mediante el cual se crean las reglas borrosas. Sin embargo, en este trabajo se decide adoptar una condición de diseño bastante extendida, que consiste en elegir el número de reglas igual al número de clúster obtenidos [5]. Una de las ventajas que tiene este tipo de sistemas, es que si las funciones de pertenencia son derivables, se pueden utilizar algoritmos de aprendizaje supervisado, como es el de retropropagación de errores.

3.3 AJUSTE Y EVALUACIÓN DE LOS MODELOS

El siguiente paso dentro del método propuesto es el ajuste de los parámetros de las dos propuestas de modelos. Para la primera propuesta de modelo, los valores de los parámetros del modelo HIM obtenidos en el ajuste fueron: un polinomio de primer orden ($m = 1$), un vecino $k = 1$ y un coeficiente de borrosidad $p = 1.27$.

En cambio, para la segunda propuesta de modelo, los valores de los parámetros del modelo GFCM obtenidos en el ajuste por prueba y error, fueron: un número de clústeres $c = 6$, un umbral $\epsilon_1 = 1$, índice de borrosidad $p = 1,2$, parámetro $\alpha = 0.9$, número iteraciones $IT = 1000$, una tasa de aprendizaje de 0.056 , un umbral $\epsilon_2 = 10^{-4}$ y un número de iteraciones $IT = 400$.

Como resultado del ajuste, se concluye que aunque ambos modelos predicen con bastante exactitud la rugosidad superficial, resulta interesante señalar que el error medio absoluto es de un 9% para GFCM y por tanto, mucho más alto que el obtenido con HIM (0.2%).

Además, se validaron los modelos en ensayos experimentales con otras condiciones de operación y se evaluó su desempeño mediante las siguientes cifras de mérito (Tabla 1): suma de errores cuadráticos (SSE), ruido en la suma de errores cuadráticos (NSSE), error de predicción final (FPE), varianza estimada de ruido (ENV) y error relativo medio (MRE).

Tabla 1: Comparación entre las cifras de mérito de ambas propuestas de modelo.

Índices de desempeño	HIM	GFCM
SSE	52912.44	193454.35
NSSE	16.60	31.74
FPE en %	16.95	35.97
ENV	33.55	67.72
MRE en %	16.71	15.08

Tal y como se observa en la Figura 6, ambos modelos predicen con bastante exactitud la rugosidad superficial. Por tanto, se hace difícil tomar una decisión sobre cuál de ambas propuestas de modelo sea la embebida en la plataforma software. Como el objetivo final es comprobar la ejecución en tiempo real de la estimación de la rugosidad, se elige arbitrariamente GFCM. Posteriormente se demuestra que este modelo presenta unas muy buenas prestaciones, en lo que a facilidad de implementación e integración se refiere.

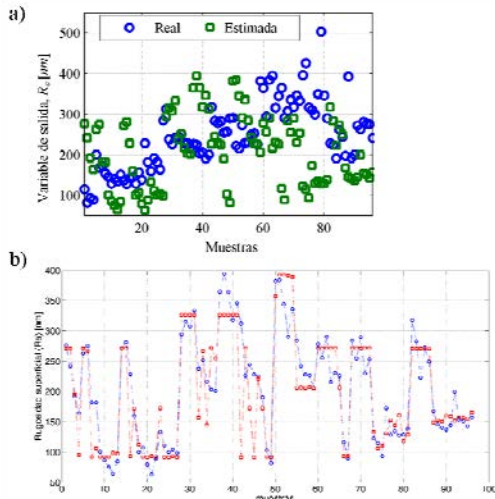


Figura 6: Respuesta de la rugosidad superficial media estimada con respecto a la rugosidad real medida en ambas propuestas de modelos, (a) HIM y (b) GFCM.

4 INTEGRACIÓN DE LA ESTRATEGIA Y MÉTODO EN UN PLATAFORMA

A continuación se resume la que es posiblemente la mayor contribución de este artículo, que es, precisamente, el desarrollo e implementación de una plataforma e inteligencia computacional, compuesta por la estrategia y método embebido desarrollado en la sección anterior. El desarrollo de esta plataforma lleva asociada una integración, tanto a nivel hardware como software, del algoritmo de modelado GFCM.

4.1 ARQUITECTURA HARDWARE

En la Figura 7, se puede apreciar una imagen de toda la integración hardware realizada. Cabe resaltar los dos sensores utilizados: el sensor inteligente de conductancia y el acelerómetro piezoeléctrico mono-axial. También, destacar la plataforma de tiempo de real de National Instruments PXI-1050, en la que se encuentra insertada la tarjeta de adquisición PXI-6259 y el módulo embebido PXI-8187.

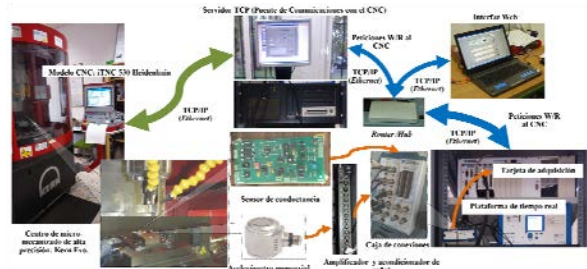


Figura 7: Visión global del sistema de monitorización inteligente de tiempo real desarrollado

4.2 PLATAFORMA SOFTWARE

En esta subsección se describe la plataforma software. El ciclo de ejecución del programa principal está compuesto por diferentes tareas que se ejecutan de forma secuencial y continua, tales como: inicialización, configuración, reserva de recursos, entre otras. Esto permite la monitorización de procesos de fabricación de larga duración. Dentro del flujo de datos del programa principal, se destaca la tarea de monitorización (Figura 8).

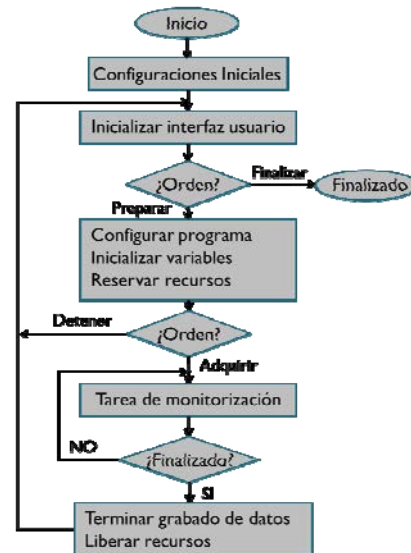


Figura 8: Plataforma software. Diagrama de flujos del ciclo de ejecución del programa principal

Esta tarea constituye el núcleo principal de funcionamiento del programa y consiste en una serie

de bucles o hilos de ejecución en paralelo. Fue, precisamente, en unos de estos hilos donde se embebió el modelo GFCM para la estimación de la rugosidad superficial.

4.3 EVALUACIÓN FINAL DE LA PLATAFORMA

Como etapa final del desarrollo de este trabajo, se realizó una validación rigurosa en tiempo real, mediante una ejecución simultánea y en paralelo de todos sus hilos. Para ello, se han realizado ensayos en operaciones de micro-mecanizado para evaluar el desempeño del sistema desarrollado.




Figura 9: Resultado de la estimación de la rugosidad superficial durante una operación de microfresado de ranuras. (a) Valor de Ra estimado, (b) y su correspondiente error

Agradecimientos

Este trabajo ha sido realizado parcialmente gracias al apoyo del Ministerio de Economía y Competitividad y los fondos FEDER a través del proyecto CONMICRO (DPI2012-35504). Los autores también quisieran agradecer al proyecto “IOSENSE: Flexible FE/BE Sensor Pilot Line for the Internet of Everything project” con referencia PCIN-2015-123, cofinanciado por ECSEL JU y MINECO.

Referencias

- [1] R. AZOUZI and M. GUILLOT, *On-line Prediction of Surface Finish and Dimensional Deviation in Turning Using Neural Network Based Sensor Fusion*, International Journal of Machine Tools and Manufacture, 37 (1997), pp. 1201–1217.
- [2] G. BERUVIDES, F. CASTAÑO, R. QUIZA and R. E. HABER, *Surface roughness modeling and optimization of tungsten-copper alloys in micro-milling processes*, Measurement, 86 (2016), pp. 246-252.
- [3] F. CASTAÑO, R. E. HABER, R. M. D. TORO, G. BERUVIDES and R. E. HABER, *Application of hybrid incremental modeling for predicting surface roughness in micromachining processes*, Computational Intelligence for Engineering Solutions (CIES), 2014 IEEE Symposium on, 2014, pp. 54-59.
- [4] S. Z. CHAVOSHI, *Modelling of surface roughness in CNC face milling of alloy stellite 6*, International Journal of Computational Materials Science and Surface Engineering, 5 (2013), pp. 304-321.
- [5] A. GAJATE, R. E. HABER, P. I. VEGA and J. R. ALIQUÉ, *A transductive neuro-fuzzy controller: Application to a drilling process*, IEEE Transactions on Neural Networks, 21 (2010), pp. 1158-1167.
- [6] R. E. HABER, R. HABER-HABER, A. JIMÉNEZ and R. GALÁN, *An optimal fuzzy control system in a network environment based on simulated annealing. An application to a drilling process*, Applied Soft Computing Journal, 9 (2009), pp. 889-895.
- [7] F. HÖPPNER and F. KLAWONN, *Improved fuzzy partitions for fuzzy regression models*, International Journal of Approximate Reasoning, 32 (2003), pp. 85-102.
- [8] B. HUANG and J. CHEN, *An In-process Neural Network-based Surface Roughness Prediction System Using a Dynamometer in End Milling Operations*, International Journal of Advanced Manufacturing Technology, 21 (2003), pp. 339-347.
- [9] M. D. NGUYEN, M. RAHMAN and Y. S. WONG, *Simultaneous micro-EDM and micro-ECM in low-resistivity deionized water*, International Journal of Machine Tools and Manufacture, 54-55 (2012), pp. 55-65.
- [10] S. PALANI, U. NATARAJAN and M. CHELLAMALAI, *On-line prediction of micro-turning multi-response variables by machine vision system using adaptive neuro-fuzzy inference system (ANFIS)*, Machine Vision and Applications, 24 (2013), pp. 19-32.
- [11] W. PEDRYCZ and K. C. KWAK, *The development of incremental models*, IEEE Transactions on Fuzzy Systems, 15 (2007), pp. 507-518.
- [12] F. PENEDO, R. E. HABER, A. GAJATE and R. M. D. TORO, *Hybrid Incremental Modeling Based on Least Squares and Fuzzy $\langle \text{formula } \text{formulatyp}=\text{"inline"} \rangle \langle \text{img } \text{src}=\text{"images/tex/523.gif"} \text{ alt}=\text{"K"} \rangle \langle \text{/formula} \rangle$ -NN for Monitoring Tool Wear in Turning Processes*, IEEE Transactions on Industrial Informatics, 8 (2012), pp. 811-818.
- [13] S. B. ROH, T. C. AHN and W. PEDRYCZ, *The refinement of models with the aid of the fuzzy k-nearest neighbors approach*, IEEE Transactions on Instrumentation and Measurement, 59 (2010), pp. 604-615.

- [14] R. XU and D. WUNSCH II, *Survey of clustering algorithms*, IEEE Transactions on Neural Networks, 16 (2005), pp. 645-678.
- [15] L. ZHU, F. L. CHUNG and S. WANG, *Generalized fuzzy C-means clustering algorithm with improved fuzzy partitions*, IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics, 39 (2009), pp. 578-591.