



MODELACIÓN EMPÍRICA DE LA FUERZA DE CORTE EN EL PROCESO DE MICROFRESADO DE Ti6Al4V

Iván La Fé Perdomo¹, Ramón Quiza¹, Gerardo Beruvides², Rodolfo Haber²

¹Grupo de Investigación en Fabricación Avanzada y Sostenible (GIFAS) Universidad de Matanzas, Autopista a Varadero, km 3½, Matanzas 44740, Cuba.

²Group of advanced Automation of Machines, Highly complex processes and Environments Centre for Automation and Robotics (GAMHE), Madrid, España.

¹e-mail: ivan.lafe@umcc.cu

RESUMEN

Los modelos precisos y fiables, que describan el comportamiento de las variables involucradas, son un requisito importante para seleccionar procesos de micromaquinado de aleaciones de titanio, las cuales juegan un papel fundamental en la manufactura moderna, especialmente en campos tales como la industria aeroespacial y médica. Este trabajo presenta la modelación de la fuerza de corte en un proceso de microfresado de ranuras en Ti6Al4V. Los modelos propuestos relacionan la fuerza de corte con el régimen de corte (o sea, la velocidad, el avance y la profundidad de corte axial), utilizando una regresión lineal múltiple y un sistema de inferencia borroso. Ambos enfoques fueron comparados considerando no solo la bondad de ajuste sino también su velocidad computacional. Los resultados mostraron que ambas técnicas fueron capaces de ofrecer modelos con elevada precisión y computacionalmente eficientes. Comparativamente, los modelos borrosos mostraron mayor bondad de ajuste pero menor eficiencia computacional que los modelos basados en la regresión múltiple.

PALABRAS CLAVES: microfresado, fuerzas de corte, modelación, regresión lineal múltiple, lógica borrosa.

EMPIRICAL MODELING OF THE CUTTING FORCE IN THE MICROMILLING PROCESS OF Ti6Al4V

ABSTRACT

Accurate, reliable models, describing the behavior of the involved variables, are an important prerequisite for selecting optimal micromachining process of titanium alloys, which play a key role in modern manufacturing, especially in fields such as aerospace and medical industries. This work presents the modeling of the cutting force in a grooves micromilling process of Ti6Al4V. The proposed models correlate the cutting force with the cutting parameters (i.e., cutting speed, feed and axial depth of cut), by using a multiple linear regression and a fuzzy inference system. Both approaches were compared by considering not only their goodness of fit but also their computational speed. Outcomes showed that the fuzzy models have higher correlation than the corresponding regression-based-models. Nevertheless fuzzy models require more computational time than regression-based-models; therefore, selecting the most convenient model depends on the specific application.

KEY WORDS: micro milling, cutting forces, modeling, multiple linear regression, fuzzy logic.

1. INTRODUCCIÓN

Los procesos de micromaquinado han ganado mucha aceptación en la industria manufacturera debido a la creciente demanda de componentes miniaturizados [1]. Dentro de los procesos de micromaquinado cabe resaltar el microfresado por la gran variedad elementos de geometría compleja que pueden ser obtenidos mediante esta operación. Por esta razón grandes esfuerzos se hacen en esta área en particular. Muchas de las



investigaciones realizadas están encaminadas al desarrollo de modelos para predecir las fuerzas de corte en el proceso [2–4].

Debido a las pequeñas dimensiones de la herramienta uno de los parámetros más importantes a tener en cuenta en el microfresado es la fuerza de corte [5]. Cualquier incremento en estos valores puede causar excentricidad, deflexión hasta incluso puede dañar la herramienta [6]. Sin embargo la obtención de un modelo de regresión estadística para los parámetros del microfresado no es una tarea sencilla debido a las no linealidades y el alto nivel de ruido presente en los datos experimentales [7].

Una de las técnicas más empleadas para la modelación de estas complejas relaciones es la lógica borrosa [8-9]. Los sistemas de inferencia borrosa pueden tratar con fenómenos físicos inciertos donde no es muy conocida la relación entre los parámetros que intervienen.

El objetivo de este trabajo es obtener dos modelos, uno basado en regresión estadística y el otro mediante el empleo de lógica borrosa; los cuales puedan representar y emular comprensivamente el comportamiento físico de la fuerza de corte ante determinados parámetros del proceso de microfresado.

El artículo está dividido en cinco secciones. Después de la introducción se explica el equipamiento que se empleó para llevar a cabo los experimentos. En la tercera sección se presentan los modelos obtenidos por regresión lineal múltiple y lógica borrosa para la fuerza de corte en herramientas de 0,5 y 1,0 mm de diámetros, mientras que en la cuarta se exponen los principales resultados de la modelación. Finalmente la última sección está dedicada a las conclusiones y líneas futuras de trabajos sobre el tema.

2. EQUIPAMIENTO Y ESTUDIO EXPERIMENTAL

Para el estudio experimental del proceso de microfresado se empleó como pieza de trabajo una aleación de titanio-aluminio-vanadio (Ti6Al4V) y como herramientas fueron empleadas microfresas de 0,5 y 1,0 mm de diámetros.

Se tuvieron en cuenta tres parámetros de corte fundamentales; la velocidad de corte (v_c), el avance (f) y la profundidad de corte axial (a_p).

Con el objetivo de obtener la mayor información del estudio experimental fue seleccionado un factorial completo como diseño para realizar los experimentos. Se establecieron tres niveles para la velocidad de corte y cuatro para el avance y la profundidad axial de corte, (ver Tabla 1). Para cada punto experimental se realizaron tres réplicas.

Tabla 1. Niveles de los factores para ambos diámetros de la herramienta

Factores experimentales	d = 0.5 mm				d = 1.0 mm			
	Niveles experimentales							
Velocidad de corte, v_c [m/min]	32	52	72	60	90	120		
Avance, f [$\mu\text{m}/\text{tooth}$]	5	10	15	20	25	30	35	40
Profundidad axial de corte, a_p [μm]	13	20	27	34	70	90	110	130

Las corridas experimentales fueron realizadas en un centro de maquinado de alta precisión *Kern Evo*, equipado con un dinamómetro piezoeléctrico *Kistler Minidyn 9256* para registrar las tres componentes de la señal de fuerza (F_x , F_y , F_z) con una sensibilidad para las mediciones en los eje x y z de pC/N y 13 pC/N para el eje- y . El rango de medición de las fuerzas está entre -250 N y 250 N.

Todos los datos de la señal fueron recopilados en un NI 6251 (*National Instruments data acquisition card*), con una frecuencia de muestreo de 50 kHz y fueron procesados en un PXI-8187 (*National Instruments high performance*) (ver Fig. 1) acoplado al controlador.

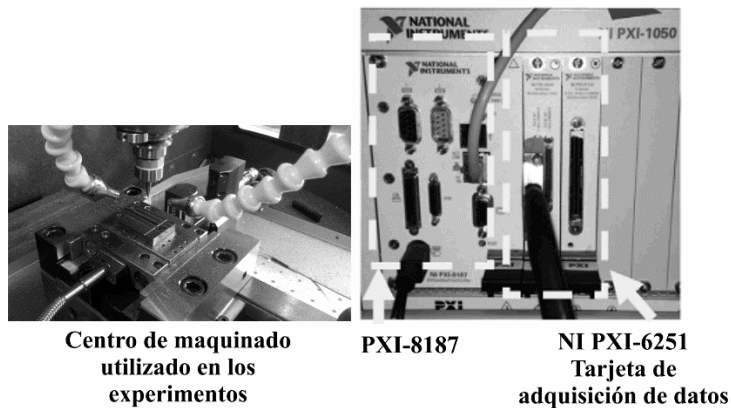


Figura 1: Equipamiento utilizado en los experimentos.

La fuerza de corte resultante:

$$F_C = \sqrt{F_x^2 + F_y^2 + F_z^2} \quad (1)$$

fue determinada para cada punto experimental. Entonces, el valor medio de la señal de fuerza correspondiente a la acción de un diente de la herramienta se obtuvo superponiendo y promediando todas las muestras (ver Fig.2).




Figura 2: Procesamiento de los datos de la fuerza de corte.

Después del procesamiento de los datos, 144 valores fueron obtenidos para la fuerza de corte resultante, coincidiendo con las 3 réplicas para 48 puntos experimentales.

3. MODELACIÓN

Regresión lineal múltiple

Para la obtención de los primeros modelos se empleó la regresión lineal múltiple (RLM). La RLM es una generalización de la regresión lineal ya que esta tiene en consideración más de una variable independiente. En este caso en particular, la relación entre el logaritmo de la variable dependiente (F_C) y el logaritmo de las variables independientes (v_c, f, a_p) fue empleado para generar los modelos exponenciales, descrito en Eq. (2) para la herramienta de 0,5 mm de diámetro y Eq. (3) para la de 1,0 mm de diámetro. Todos los modelos y algoritmos fueron desarrollados en *Matlab 2015a*. El *Statistic and Machine Learning Toolbox v10.0* fue usado en el caso específico de la modelación por regresión múltiple.

$$F_C = 0.1145a_p^{0.5184} f^{0.4785} \quad (2)$$

$$F_C = 0.0021a_p^{1.2687} f^{0.5857} \quad (3)$$

Los modelos de regresión tienen un coeficiente de correlación R^2 de 0,82 y 0,91 respectivamente, lo que significa que el primer modelo explica solo el 82% de variabilidad en la variable dependiente y el segundo modelo ajustado responde por más del 90% de la variabilidad que puede ocurrir en la variable dependiente.



El análisis de varianza a ambos modelos de regresión se hizo teniendo en cuenta que: las variables independientes (f y a_p) son controladas mediante el diseño de experimentos y no existe correlación entre los valores muestrales de las variables explicativas ya que el coeficiente de correlación de *Pearson* es 0. Además a los residuales de ambos modelos se le aplicaron 2 pruebas, *Shapiro-Wilks* ($p\text{-value}^1 = 0.10$ y $p\text{-value}^2 = 0.17$) y *Kolmogorov-Smirnov* ($p\text{-value}^1 = 0.087$ y $p\text{-value}^2 = 0.093$) para comprobar la normalidad en la distribución. Todos los valores de la probabilidad asociada a las pruebas antes mencionadas fueron superiores a 0.05 por lo que se puede afirmar que los errores en las predicciones siguen una distribución normal con un nivel de confiabilidad del 95% (ver Fig.3).




Figura 3: Representación gráfica de la distribución normal de los residuales, a) modelo para herramienta de 0.5 mm de diámetro; b) modelo para herramienta de 1.0 mm de diámetro

El ANOVA de los modelos estadísticos se resume en las Tabla 2 y 3 demostrando que existe una relación estadísticamente significativa entre la fuerza de corte y las dos variables independientes incluidas en el modelo. La velocidad de corte fue removida de los modelos porque la prueba *t-Student* demostró que este término no es significativo a un nivel de confiabilidad del 95%.

Tabla 2. ANOVA para el modelo estadístico de la fuerza de corte para herramienta de 0,5 mm de diámetro.

Fuente	Sum de cuadrados	Grados de libertad	Media cuadrática	F-ratio	p-value
Modelo	4,646	2	2,323	100	0,000
Residuales	1,045	141	0,023		
Total	5,691	143			

Tabla 3. ANOVA para el modelo estadístico de la fuerza de corte para herramienta de 1,0 mm de diámetro.

Fuente	Sum de cuadrados	Grados de libertad	Media cuadrática	F-ratio	p-value
Modelo	4,630	2	2,315	228,8	0,000
Residuales	0,455	141	0,010		
Total	5,085	143			

Otros parámetros asociados a la calidad de los modelos obtenidos son, el error estándar de las estimaciones (*SEE*) Eq. (4) y el error medio absoluto (*MAE*) Eq. (5). La razón principal por la cual se calcularon estos errores es para dar la mayor cantidad de información posible de la precisión del modelo.

$$SEE = \sqrt{\frac{\sum (F_c - \hat{F}_c)^2}{M}} \quad (4)$$

¹ Para el modelo la herramienta de 0.5 mm de diámetro.

² Para el modelo la herramienta de 1.0 mm de diámetro.



$$MAE = \frac{1}{M} \sum_{i=1}^M |F_c - \hat{F}_c| \quad (5)$$

Donde \hat{F}_c es la fuerza de corte predicha y M el número de muestras.

Sistema de inferencia borrosa (FIS)

Un sistema de inferencia borrosa del tipo *Mamdani* fue empleado también para la modelación de la fuerza de corte, este modelo tuvo dos parámetros de entrada (f, a_p). En todos los casos se usaron funciones de membresía *Gaussiananas*. Dicho modelo fue creado usando el *Matlab Fuzzy Logic Toolbox* (versión 2.2.17). Cada variable de entrada fue fuzzificada en un número de *clusters*, N (en el modelo fueron utilizados 50 clusters). Entonces, N reglas de inferencias fueron aplicadas a las variables de entrada fuzzificadas, las que consecuentemente se combinaron para obtener la distribución de los valores de salida. Finalmente la salida es desfuzzificada por el método del centroide (ver Fig. 2).

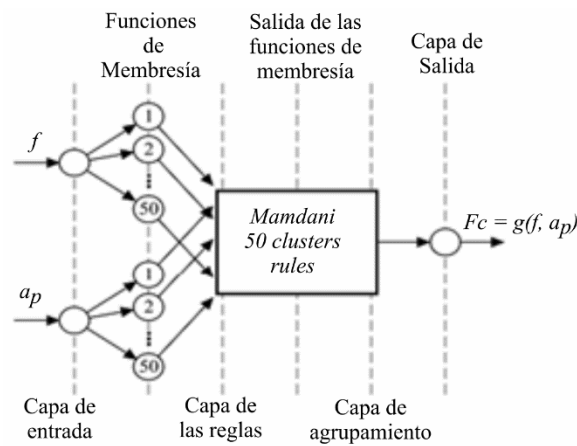


Figura 4: Representación gráfica del modelo empleado.

4. RESULTADOS Y DISCUSIÓN

Para establecer una comparación de los modelos obtenidos se muestran a continuación una serie de resultados y gráficos que evidencian la precisión y ajuste de los mismos.

En la figura 5 se muestran las superficies de respuesta de los modelos de regresión y lógica borrosa para las dos herramientas empleadas en los experimentos.

Los modelos ajustados evidencian el aumento de la fuerza de corte con el respectivo incremento de las variables de decisión (f, a_p).

En la figura 6 se muestra una comparación gráfica de los residuales contra los valores predichos, para la regresión y el modelo borroso. Cabe destacar que al aplicar la prueba de Goldfeld – Quandt que permite detectar la presencia de heteroscedasticidad en el modelo se comprobó que los datos en estudio son homocedásticos.

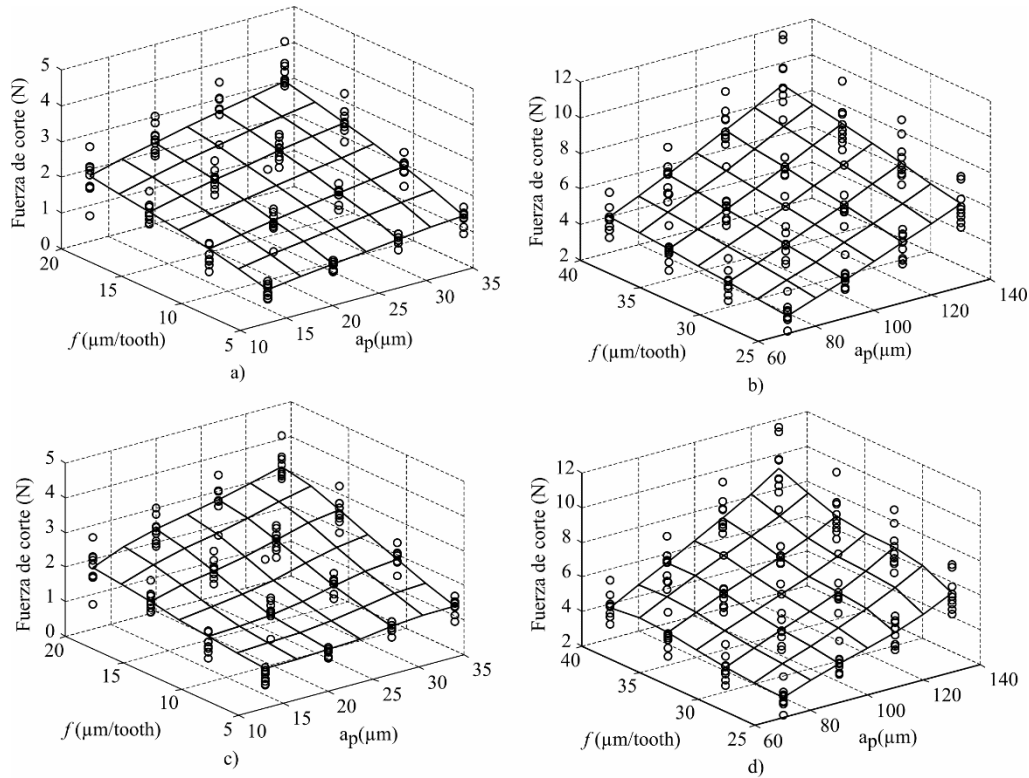


Figura 5: Superficies de respuesta, a) RLM para herramienta de 0,5 mm de diámetro; b) RLM herramienta de 1,0 mm de diámetro; c) Sistema de inferencia borrosa para herramienta de 0,5 mm de diámetro; d) Sistema de inferencia borrosa para herramienta de 1,0 mm de diámetro.

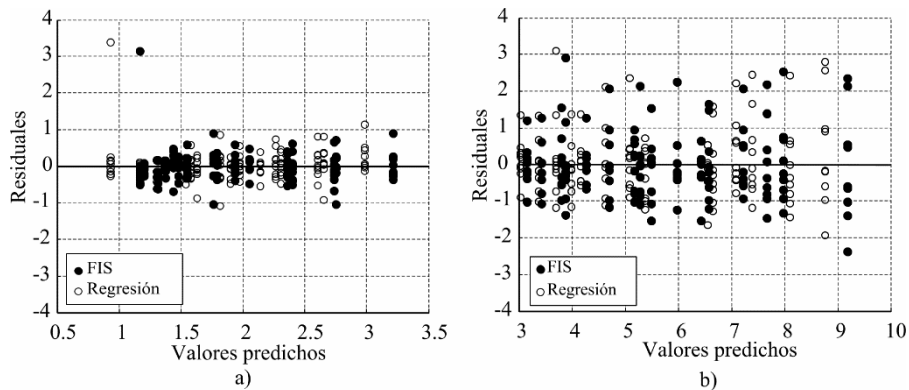


Figura 6: Residuales contra valores predichos, a) herramienta de 0,5 mm de diámetro; b) herramienta de 1,0 mm de diámetro.

Con los modelos de lógica borrosa se alcanzaron valores del coeficiente de determinación R^2 de 91% y 95% (ver Fig. 7a), también los errores asociados a la calidad del modelo (SEE y MAE) fueron menores en el FIS en relación con su correspondiente regresión, evidenciando un mejor ajuste de esta técnica de modelación, esto se justifica en la capacidad que tienen los sistemas de inferencia difusa para tratar con las altas no linealidades y ruido en los datos causado por la naturaleza compleja del fenómeno de corte en el micromaquinado.

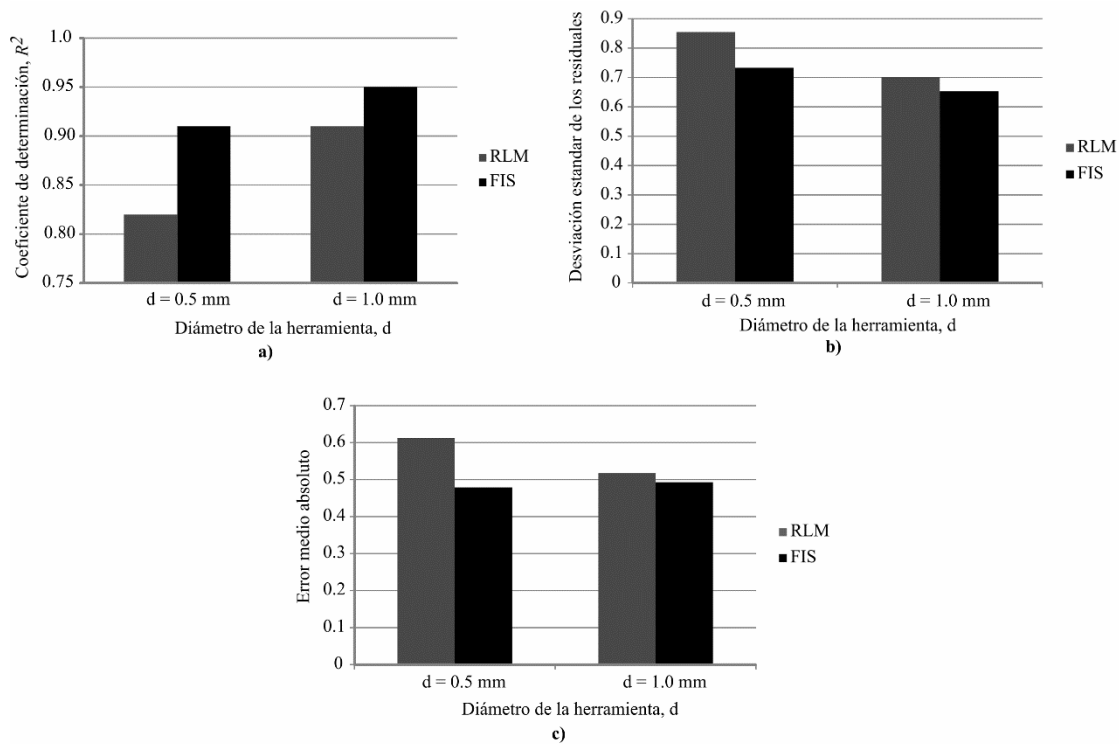


Figura 7: Gráfica comparativa resumen de los modelos; a) coeficiente de correlación, b) desviación estándar de los residuales, c) error absoluto medio.

Finalmente el tiempo de ejecución de los modelos de regresión ($8.73 \cdot 10^{-7} \pm 3.43 \cdot 10^{-9}$ s) es 16 veces menor en comparación con el del FIS ($1.45 \cdot 10^{-5} \pm 7.51 \cdot 10^{-8}$), lo que evidencia el único inconveniente a la hora de aplicar esta técnica de modelación.

5. CONCLUSIONES

Los modelos obtenidos mostraron gran precisión (elevados coeficientes de determinación y bajos errores asociados a las predicciones). Los sistemas de inferencia difusa evidenciaron un mayor rendimiento que sus equivalentes modelos de regresión, especialmente en cuanto a la distribución de los residuales.

Los resultados corroboran la capacidad de los modelos borrosos de tratar con diferentes condiciones de corte sobrepasando las limitaciones de los modelos de regresión.

Los resultados obtenidos, permitirán realizar nuevos experimentos en orden de continuar la validación de los modelos propuestos con el objetivo de extender su aplicabilidad a otros materiales, condiciones de corte y otros procesos de micromaquinado.



REFERENCIAS

1. ANANDAN, K. P; TULSIAN, A.S; DONMEZ, D and OZDOGANLAR, O.B. “A technique for measuring radial error motions of ultra-high-speed miniature spindles used for micromachining”. *Precision Engineering*, 2012, vol. 36, núm. 1, pp. 104-120.
2. TLUSTY, J; MACNEIL, P. “Dynamics of cutting forces in end milling”. *Ann. CIRP24/1*, 1975, pp. 21–25.
3. ENGIN, S; ALTINTAS, Y. “Generalized modelling of milling mechanics and dynamics: part I and part II”. *University of British Columbia, Department of Mechanical Engineering*, 2010.
4. BAO, W.Y; TANSEL, I.N. “Modelling micro-end-milling operations, part I and part II”. *International Journal of Machine Tools and Manufacture*, 2000, vol. 40, pp. 2155–2192.
5. KLINE, W.A; DeVor, R.E. “The effect of run-out on cutting geometry and forces in end milling”. *International Journal of Machine Tool Design and Research*, 1983, vol. 23, núm (2-3), pp. 123–140.
6. SUTHERLAND, J.W; DeVor, R.E. “An improved method for cutting force and surface error prediction in flexible end milling systems”. *Journal of Engineering for Industry*, 1986, vol. 108, núm. 4, pp. 269–279.
7. BERUVIDES, G; QUIZA, R; DEL TORO, R and HABER R.E. “Sensing systems and signal analysis to monitor tool wear in microdrilling operations on a sintered tungsten–copper composite material”. *Sensors and Actuators A: Physical*, 2013, vol. 199, pp. 165-175.
8. LIAN, R.J. “Adaptive self-organizing fuzzy sliding-mode radial basis function neural-network controller for robotic systems”. *IEEE Transactions on Industrial Electronics*, 2014, vol. 61, núm. 3, pp. 1493-1503.
9. GUILLAUME, S. “Designing fuzzy inference systems from data: An interpretability-oriented review”. *IEEE Transactions on Fuzzy Systems*, 2001, vol. 9, núm. 3, pp. 426-443.



INFORMACIÓN SOBRE LOS AUTORES



Iván La Fé Perdomo. Recibió el título de Ingeniero Mecánico (título de oro) en 2014 en la Universidad de Matanzas. En la actualidad se desempeña como profesor instructor en la Universidad de Matanzas y pertenece al Grupo de Investigación en Fabricación Avanzada y Sostenible. Principales líneas de investigación: modelación y optimización de procesos de manufactura y diseño mecánico.



Ramón Quiza. Recibió el título de Ingeniero Mecánico (título de oro) en 1999 y el título de Doctor en Ciencias Técnicas en el 2004 en la Universidad de Matanzas donde en la actualidad se desempeña como jefe del Grupo de Investigación en Fabricación Avanzada y Sostenible. Sus principales líneas de investigación son: modelación y optimización de procesos de maquinado y aplicaciones de inteligencia artificial.



Rodolfo E. Haber. Obtuvo el título de Ingeniero en Automática (título de oro) en la Universidad de Oriente en 1992. En 1995 recibe una beca de doctorado otorgada por la Oficina Española de Colaboración Científica en España. Recibe su título de doctor en Ingeniería Industrial en la Universidad Politécnica de Madrid en 1999. En ese mismo año se une, como profesor asistente, al departamento de Ingeniería en Computación de la Escuela Técnica en la Universidad Autónoma de Madrid. Ha publicado artículos en revistas especializadas y capítulos de libros. Sus principales líneas de investigación incluyen la teoría de control y sus aplicaciones, soluciones hardware-software, técnicas de soft-computing, control clásico y adaptativo, control supervisorio y procesos electromecánicos complejos.



Gerardo Beruvides. Graduado de Ingeniería Mecánica (título de oro) en 2010 y de Master en Ingeniería Asistida por Computadora en 2012 ambos en la Universidad de Matanzas (Cuba). Posteriormente trabajó como profesor asistente en dicha universidad desde el 2010 hasta 2014. Actualmente, posee una beca completa de doctorado para Formación de Personal Investigador (FPI), concedida por el Ministerio de Economía y Competitividad de España. Desde el año 2014, forma parte del grupo GAMHE perteneciente al Centro de Automática y Robótica (CAR) de Madrid. Sus líneas de investigación se centran en el modelado y la optimización de los procesos de micro y macro-mecanizado basado en técnicas de inteligencia artificial. Ha publicado varios artículos sobre estos temas y es miembro de la junta revisora de algunas revistas internacionales.