



**Escuela Politécnica Superior
Departamento de Ingeniería Informática**

**ARQUITECTURA E INTELIGENCIA COMPUTACIONAL EMBEBIDA
PARA LA SUPERVISIÓN DE PROCESOS. APLICACIÓN A UN
PROCESO DE MICROFABRICACIÓN.**

TESIS DOCTORAL

**Autor:
Fernando Castaño Romero**

**Director:
Dr. D. Rodolfo E. Haber Guerra**

Madrid, Abril de 2016

Título de la Tesis: Arquitectura e inteligencia computacional embebida para la supervisión de procesos. Aplicación a un proceso de Microfabricación.

Autor: D. Fernando Castaño Romero

Director: Dr. D. Rodolfo E. Haber Guerra

Tutor: Prof. D. Francisco de Borja Rodríguez Ortiz

Miembros del Tribunal de Defensa de la Tesis Doctoral:

Presidente: Prof. D. Pablo Varona Martínez

Vocales: Dr. D. Antonio Ramón Jiménez Ruiz

Prof. D. Fernando Matía Espada

Prof. Dña. Matilde Santos Peñas

Secretario: Prof. Dr. Manuel Sánchez-Montañés Isla

Suplentes: Prof. D. Manuel Ferre Pérez

Dr. Dña. Maria Carmen García-Alegre
Sánchez

*A mis padres,
porque todo lo que soy se lo debo a ellos,
por su apoyo innegable, incondicional e infinito*

*A mi hermano,
por ver en mi un ejemplo a seguir
, lo que me ayuda a mejorar cada día*

AGRADECIMIENTOS

Llevo tiempo queriendo llegar al punto de tener que dedicar tiempo a escribir estas líneas, aunque resulta difícil expresar en tan poco espacio el cúmulo de sensaciones, estrés, tensión y recuerdos que resumen todo lo vivido durante este periodo. En una sola frase.... se podría decir que mi ordenador portátil se ha convertido en un compañero de viaje más. A partir de ahora ya puede descansar en el lugar al que pertenece, mi mesa de escritorio.

Estas líneas también me dan la oportunidad de poder agradecer a los míos... a las personas que me han apoyado y ayudado, el haber permanecido siempre ahí.

Quisiera comenzar por dos personas que han tenido mucho que ver en que esta tesis haya visto la luz. La primera de ellas es Rodolfo Haber, mi director de tesis. Creo que lo mucho o poco que yo tenga de investigador se lo debo a él. Rodolfo es quién me ha aconsejado, ayudado, apoyado, orientado, dirigido e incluso abroncado durante esta etapa. Gracias a su seriedad, profesionalidad, trabajo y tiempo, las cosas han sido mucho más fáciles y se han podido llevar a cabo gran parte de los retos propuestos. La otra persona es Raúl , un amigo, que desde el primer momento siempre ha confiado en mi trabajo, siempre se ha mostrado dispuesto a colaborar y siempre ha ofrecido su apoyo. Aunque oficialmente no aparezca en el documento, siempre lo he considerado el co-director de esta tesis. A ambos, muchas gracias por todo.

Cierto es también que las victorias se consiguen en equipo, y mi equipo lo han formado mis compañeros y grandísimos amigos (o “*brothers*”, tal y como solemos llamarnos) del grupo GAMHE del CAR. Muchas gracias Gerardo y Antonio. Dentro del CAR, muchas han sido también las personas a las que tengo algo que agradecer: a algún miembro del grupo Autopía (Jorge y Carlos), a “Lola” y a “Nacho”, a Bego... y, en general, a toda la gente que hace que trabajar en el centro sea un auténtico lujo.

Finalmente, mi mayor agradecimiento va para mis padres, Fernando y Pilar y a mi hermano, Fabián. Me siento muy orgulloso de mi familia...soy quien soy, gracias a ellos. Dentro de mi familia, también agradecer a mis abuelas, Rosa y Victoria, por su cariño y apoyo incondicional. Un recuerdo especial para los que ya no están entre nosotros, mis abuelos y en

especial, a mi abuelo Fabián... te tengo y te tendré siempre muy presente en mi memoria. Ya finalizando con mi familia, agradecer el apoyo que siempre he tenido de mis tíos y tías, y quisiera nombrar, a mi tío Lorenzo, muchas gracias por tus ánimos y por haber creído siempre que esta Tesis se realizaría.

No quiero olvidarme de mis amigos del “poblao”, Francisco y Migue, a los que siempre he considerado y consideraré mi familia.

Por último, y no por ello menos importante (más bien todo lo contrario) tengo que agradecer demasiadas cosas a Laura. Fundamentalmente ha sido mi fuente de energía durante los últimos meses y la persona que más me ha ayudado a seguir para adelante... Por no hablar de la comprensión que me ha ofrecido, su cariño, su siempre reconfortante sonrisa... muchas gracias por todo lo que le ha tocado y nos tocará vivir en primera persona. Laura no podría pertenecer a otra familia que no fue la familia Márquez-Japón. Agradecemos todo el apoyo e interés que habéis mostrado siempre hacia mí y hacia la finalización de esta tesis.

A todos, GRACIAS... y enhorabuena... ya que este éxito no es solo mío... es nuestro.

RESUMEN

En esta Tesis Doctoral se presenta el diseño, desarrollo e implementación de estrategias de supervisión de procesos. Los métodos propuestos están basados en técnicas de Inteligencia Artificial (AI, *Artificial Intelligence*), embebidos en una plataforma de tiempo real, modular, en red y reconfigurable, para la monitorización inteligente de sistemas complejos. Las estrategias de supervisión sugeridas en este trabajo permiten que algoritmos computacionalmente eficientes puedan ser embebidos, y garantizar de este modo un funcionamiento en tiempo real adecuado en su aplicación a procesos no lineales y con dinámicas relativamente rápidas. En este sentido, es importante abordar desde sistemas sensoriales apropiados hasta la selección e implementación de los métodos y modelos a utilizar, así como la transmisión y el procesamiento de los datos en tiempo real.

El siglo XXI se ha caracterizado por el aprovechamiento y la aplicación de técnicas y procedimientos en el ámbito de las Ciencias de la Computación, las tecnologías de la información y las comunicaciones y la ingeniería de control a sectores productivos y de servicios emergentes. El motivo fundamental radica en el gran impacto que han conseguido los métodos de supervisión y monitorización en la eficiencia de los procesos y servicios asociados. En esta Tesis Doctoral, las estrategias desarrolladas son aplicadas a la supervisión de un proceso de microfabricación, en concreto, el proceso de microfresado de alta precisión. Este proceso se ha escogido por su mayor impacto productivo en los años venideros y al mismo tiempo por tener asociado un mayor número de desafíos científicos y técnicos relacionados, por ejemplo, con la herramienta de corte, las vibraciones y los acabados superficiales. En general, los sistemas clásicos de supervisión en los procesos en la micro escala fallan debido a que carecen de información sensorial relevante o porque las estrategias de toma de decisión no están suficientemente preparadas para hacer frente a determinados comportamientos emergentes y responder a determinados eventos.

El diseño e implementación de la arquitectura computacional modular, en red y reconfigurable para la supervisión inteligente en tiempo real, tiene en cuenta los análisis de diferentes tipos de sensores, estrategias de procesamiento y metodologías de extracción de

patrones de comportamiento de las señales representativas en estos procesos complejos. La capacidad de reconfiguración y portabilidad de esta arquitectura está sustentada en dos procedimientos de acondicionamiento de los diferentes módulos al proceso que se desea supervisar. Estos procedimientos, que son brevemente descritos a continuación, tienen una precisión dependiente de los diferentes modelos y algoritmos embebidos e integrados en la arquitectura.

El primer procedimiento, se basa en una metodología computacional de caracterización experimental en tiempo real de procesos complejos. Como caso de estudio, ésta ha sido aplicada al área de contacto entre la punta de la herramienta de corte y la pieza en operaciones de microfresado. Como resultado, en esta Tesis se desarrolla un sensor inteligente de conductancia para la detección del contacto eléctrico herramienta–pieza de trabajo en materiales conductores. Las señales proporcionadas por este sensor son utilizadas como entradas al algoritmo embebido que está basado en un conjunto de reglas y una máquina de estados finitos para la detección del estado del corte y rotura de la herramienta en procesos de micromecanizado.

El segundo procedimiento, consiste en el desarrollo de dos algoritmos basados en técnicas de Inteligencia Artificial para el modelado de una variable representativa y esencial del proceso, como es la rugosidad superficial. En esta Tesis se hacen dos propuestas y se hace un análisis comparativo de ambas. El primero es un algoritmo para el modelado híbrido incremental (i.e., HIM en inglés), cuyos parámetros óptimos se obtienen a partir de un método estocástico, representado por el temple simulado (i.e., SA en inglés). La segunda propuesta está basada en un algoritmo de agrupamiento borroso generalizado (i.e., GFCM en inglés), cuyos parámetros fueron ajustados mediante un algoritmo de retro-propagación de errores.

Como parte de la metodología científica de la Tesis Doctoral, todas las estrategias desarrolladas son validadas rigurosamente 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.

En primer lugar, la metodología de caracterización experimental se corrobora mediante la comparación entre los resultados teóricos y experimentales obtenidos y la utilización de diferentes cifras de mérito o índices de comportamiento (ej., histogramas, MRE, entre otros) durante operaciones de microfresado. La materialización de esta prometedora línea de investigación es el sensor inteligente de conductividad desarrollado, robusto, fiable, de bajo coste y alta velocidad de respuesta, con una alta precisión en la detección del contacto eléctrico herramienta-pieza. Además, los algoritmos embebidos computacionalmente eficientes de ayuda al proceso de toma de decisiones ofrecen unos resultados muy satisfactorios en la monitorización del estado del corte y rotura de la herramienta (ej., tasa de acierto).

En segundo lugar, los estudios comparativos de los dos modelos de predicción de la rugosidad superficial muestran unos resultados realmente muy alentadores, corroborados con ensayos masivos en la fase final de validación (ej., SSE, NSSE, FPE, ENV, MRE, entre otros). En el caso de HIM, después del ajuste óptimo sobre la base del algoritmo de temple simulado, el resultado de la evaluación determina que el modelo predice adecuadamente la rugosidad superficial, a pesar que el error relativo medio es superior al obtenido durante la fase de entrenamiento. Esta precisión suele ser suficiente ya que hay muchas aplicaciones emergentes como es el caso de los componentes aeronáuticos, en los que el cien por ciento es verificado. Por tanto, la rugosidad superficial estimada en tiempo de ejecución, incluso con error, ofrece recomendaciones inteligentes sobre la calidad del proceso de micromecanizado y ayuda en la determinación de acciones correctivas y acciones específicas en el control de calidad.

Además de las aportaciones expuestas anteriormente, otras contribuciones de esta Tesis Doctoral constituye la demostración de la incorporación y ejecución en tiempo real del modelo GFCM en el módulo de arquitectura diseñada, aplicada a la monitorización inteligente basada en modelos, en paralelo con el resto de algoritmos de supervisión inteligente. La elección de GFCM surge fruto de la comparación de ambos modelos, debido a que su error en la estimación de la rugosidad superficial es bastante menor que el obtenido con HIM.

De forma resumida, la contribución fundamental de esta Tesis Doctoral es que a partir de la mínima información sensorial posible (señal de aceleración y señales del sensor de conductancia) y de la mínima cantidad de información sobre las condiciones de corte (avance por diente), se puede monitorizar en tiempo real el estado del proceso de corte en la micro escala y predecir en proceso la rugosidad superficial. Este resultado científico y técnico, supone un salto cualitativo importante sin precedentes en la investigación industrial en el campo de la Microfabricación.

Algunos de los resultados parciales alcanzados durante las diferentes etapas de desarrollo de esta Tesis Doctoral, han sido sometidos a la consideración de la comunidad científica internacional. Investigadores de diferentes campos tales como las ciencias de la computación, la inteligencia artificial, la electrónica y automática, la ingeniería de fabricación, la ingeniería mecánica y los procesos de transformación de metales, entre otros, han valorado de forma positiva el carácter heterogéneo, multidisciplinar e interdisciplinar de las aportaciones realizadas.

ABSTRACT

This PhD dissertation presents the design, development and implementation of strategies for process supervision. The proposed methods are based on techniques of Artificial Intelligence (AI), embedded in a real time platform, modular, networked, and reconfigurable, for intelligent monitoring of complex systems. The supervision strategies suggested in this work enable that computationally efficient algorithms may be embedded, and thus ensure proper operation in real time in its application to non-linear processes and with relatively fast dynamics. In this sense, it is important to address from appropriate sensory systems to the selection and implementation of methods and models to use, as well as the transmission and processing of data in real time.

The XXI century has been characterized by the exploitation and application of techniques and procedures in the field of Computer Science, Information and Communications Technologies, and Control Engineering in productive sectors and emerging services. The main reason lies in the large impact that the supervision and monitoring methods have reached in the efficiency of processes and associated services. In this PhD dissertation, the developed strategies are applied to the supervision of a microfabrication process in particular, the high-precision micromilling process. In general, the conventional monitoring systems in the micro-scale processes fail because they lack relevant sensory information or because the decision-making strategies are not sufficiently prepared to address certain emerging behaviours and respond to certain events.

The design and implementation of the computational architecture, modular, networked, and reconfigurable, for intelligent real-time monitoring, takes into account the analysis of different types of sensors, processing strategies, and methodologies for extraction of behaviour patterns of the representative signals in these complex processes. The reconfiguration and portability capability of this architecture is based on two procedures for conditioning of the different modules to the process to be monitored. These procedures, which are briefly described below, have an accuracy in function the different models and algorithms; embedded and integrated into the architecture.

The first procedure is based on a computational methodology for experimental characterization in real time of complex processes. As a case study, it has been applied to the contact area between the cutting tool and workpiece in micromilling operations. As a result in this dissertation, a conductance intelligent sensor for detecting the electrical contact tool-workpiece in conductive materials is developed. The signals provided by this sensor are used as inputs to the embedded algorithm that is based on a set of rules and knowledge bases, and a finite state machine for detecting the cutting states and tool breakage in micromachining processes.

The second procedure involves the development of two algorithms based on Artificial Intelligence techniques for modelling a representative and essential variable of the process, such as surface roughness. In this dissertation two proposals and a comparative analysis between the two are made. The first is an algorithm for Hybrid Incremental Modelling (HIM), whose optimal parameters are obtained from a stochastic method, represented by Simulated Annealing (SA). The second proposal is based on a Generalized Fuzzy Clustering C-Means algorithm (GFCM), whose parameters were fitted by a Backpropagation Errors algorithm.

As part of the scientific methodology of this Thesis, the developed control strategies are rigorously evaluated in an experimental platform which is used as technological support. This method enables a mutual exploitation of the acquired experiences and an improvement of the results obtained.

First, the methodology of experimental characterization is confirmed by comparing the obtained theoretical and experimental results, and the utilization of different merit figures or performance indices (eg., Histograms, MRE, etc.) during micromilling operation. The materialization of this promising line of research is the development of an intelligent conductance sensor, robust, reliable, low cost and high speed response, with high accuracy in detecting the electrical contact tool-piece. In addition, the embedded computationally efficient algorithms computationally for aid to decision-making process provide very satisfactory results in monitoring the cutting state and tool breakage (eg., Hit rate).

Secondly, comparative studies of the two models for predicting surface roughness show some really very encouraging results, which are corroborated with massive tests in the final validation phase (eg., SSE, NSSE, FPE, ENV, MRE, among others). In the case of HIM, after optimal fit based on the algorithm of simulated annealing, the result of the evaluation determines that the model adequately predicts the surface roughness, even though the average relative error is higher than that obtained during the training phase. This accuracy is usually enough as there are many emerging applications such as aeronautical components, in which one hundred percent is verified. Therefore, the surface roughness estimated at runtime, even with errors, provides intelligent recommendations on the quality of micro-machining process and helps in determining corrective actions and specific actions in quality control.

In addition to the contributions discussed above, other contributions of this PhD thesis are the demonstration of the incorporation and real-time execution of the model GFCM in the module of the architecture designed, applied to intelligent monitoring based on models in parallel with other algorithms of intelligent supervision. The choice of GFCM arises as result of the comparison of the two models, because their error in the estimation of surface roughness is considerably lower than that obtained with HIM.

Briefly, the fundamental contribution of this PhD thesis is that from the minimum sensory information as possible (acceleration signal and signals of conductance sensor) and the minimum amount of information on the cutting conditions (feed per tooth) can be monitored in real time the status of the cutting process on the micro scale and predict on-line surface roughness. This scientific and technical result represents a quantum leap unprecedented in industrial research in the field of microfabrication.

During the development stages of this Thesis, some of the partial achieved results have been submitted for consideration by the international scientific community. Researchers from different fields such as computer science, artificial intelligence, electronics and automation, manufacturing engineering, mechanical engineering and metallurgical engineering, among others, have positively evaluated the multidisciplinary and interdisciplinary of some contributions of the reported work.

TABLA DE CONTENIDO

LISTA DE FIGURAS	XVII
LISTA DE TABLAS.....	XXIII
INTRODUCCIÓN	1
Objetivos	3
Metodología	5
Estructura del trabajo	5
CAPÍTULO 1 ESTADO DEL ARTE	9
1.1 Sistemas embebidos e inteligentes en la supervisión de procesos complejos.....	10
1.2 Operaciones de Microfabricación como proceso electromecánico complejo.....	20
1.3 Tiempo real e Inteligencia artificial en la monitorización de procesos de micromecanizado	25
CAPÍTULO 2 SISTEMA SENSORIAL Y PROCESAMIENTO PARA EXTRACCIÓN DE CARACTERÍSTICAS EN PROCESOS COMPLEJOS	33
2.1 Métodos de extracción de características en procesos complejos.....	34
2.2 Acondicionamiento y pre-procesamiento de los datos experimentales	35
2.2.1 Procesamiento en el dominio del tiempo.....	37
2.2.2 Procesamiento en los dominios de frecuencias y tiempo-frecuencias	38
2.3 Sensores y arquitecturas sensoriales en procesos de microfabricación	42
2.4 Plataforma multi-sensorial para la caracterización de procesos de microfabricación	47
2.5 Extracción de patrones de comportamiento basados en información sensorial. Caso de estudio, el proceso de microtaladrado.....	49
2.5.1 Análisis inicial de la respuesta temporal de las señales sensoriales	51
2.5.2 Evaluación del comportamiento de los parámetros característicos de las señales respecto al uso de la herramienta.....	53
2.6 Resultados de la extracción de características de las señales.....	54
2.6.1 Dominio del tiempo. Métodos estadísticos.....	54
2.6.2 Dominio tiempo frecuencias. FFT, WT y HHT	55
2.7 Resultados del análisis de correlación R^2 y capacidad de generalización	56

2.8	Conclusiones	58
CAPÍTULO 3 SELECCIÓN DE ALGORITMOS DE MODELADO DE PROCESOS COMPLEJOS		
		61
3.1	Formalización del algoritmo de modelado híbrido incremental, HIM.....	63
3.1.1	Modelo híbrido incremental, HIM.....	64
3.1.2	Modelo global.....	64
3.1.3	Modelo local.....	64
3.1.4	Modelo incremental.....	65
3.2	Optimización de los parámetros del modelo híbrido incremental en base al algoritmo de temple simulado	67
3.3	Desarrollo de una aplicación de modelado de sistemas complejos basada en el algoritmo híbrido incremental (HIM)	73
3.4	Formalización del algoritmo de modelado generalizado de agrupamiento borroso (GFCM).....	74
3.4.1	Algoritmo borroso <i>C-Means</i> con particiones borrosas mejoradas.....	74
3.4.2	Algoritmo borroso <i>c-Means</i> generalizado con particiones borrosas mejoradas	76
3.4.3	Creación de las reglas por medio de un método de inferencia neuroborrosa tipo Mamdani <i>Neuro-fuzzy System</i>	79
3.5	Aprendizaje del modelo en base al algoritmo de retro-propagación de errores	81
3.6	Desarrollo de una aplicación de modelado de sistemas complejos basada en el algoritmo GIFP-FCM.....	83
3.7	Conclusiones	83
CAPÍTULO 4 CARACTERIZACIÓN EXPERIMENTAL DE PROCESOS FÍSICOS. APLICACIÓN AL PROCESO DE MICROFABRICACIÓN.....		
		87
4.1	Fundamentación teórica de la resistencia de contacto en operaciones de fabricación.....	89
4.1.1	Operaciones de fresado plano y ranura.....	93
4.1.2	Operaciones de fresado de contorno.....	93
4.2	Propuesta de un método de caracterización experimental. Aplicación al proceso de microfresado.....	94
4.2.1	Configuración del sistema de medición del tiempo de contacto.....	95
4.2.2	Diseño del protocolo experimental	96
4.2.3	Tiempo en el contacto filo de la herramienta - material	99
4.3	Resultados de la comparación entre la caracterización teórica y experimental del tiempo de contacto. Mínimo error relativo.....	101
4.4	Conclusiones	102
CAPÍTULO 5 SENSOR INTELIGENTE Y ALGORITMOS DE DETECCIÓN DEL ESTADO DEL PROCESO.....		
		105
5.1	Diseño hardware del sensor de conductancia. Especificaciones y configuración.....	106
5.1.1	Especificaciones, extracción de características y filtrado.....	107
5.1.2	Configuración e implementación del sensor de conductancia.....	108
5.1.3	Caracterización del proceso de corte	109

5.2	Diseño de un algoritmo computacionalmente eficiente para la detección del estado del proceso de corte.	111
5.3	Diseño de un procedimiento para la detección de interrupciones en el proceso de corte	114
5.4	Integración del sistema sensorial y el sistema de toma de decisiones	118
5.5	Resultados experimentales.....	119
5.6	Conclusiones.....	121
CAPÍTULO 6 MODELADO REPRESENTATIVO DE CIERTAS VARIABLES DEL PROCESO. RUGOSIDAD SUPERFICIAL		123
6.1	Necesidad de modelos predictivos de la calidad superficial.....	124
6.2	Elección de variables representativas del proceso de micromecanizado	128
6.3	Diseño experimental inicial. Base de datos para el modelado	130
6.4	Generación del modelo representativo del proceso de microfabricación	134
6.4.1	Obtención de un modelo híbrido incremental (HIM).....	136
6.4.2	Obtención del modelo por agrupamiento borroso GFCM.....	138
6.5	Evaluación de los modelos de estimación de la rugosidad superficial on-line.....	139
6.5.1	Validación del modelo de estimación en base al algoritmo HIM.....	140
6.5.2	Validación del modelo de estimación en base al algoritmo GFCM	141
6.5.3	Estudio comparativo.....	142
6.6	Conclusiones.....	144
CAPÍTULO 7 ARQUITECTURA Y SISTEMA EMBEBIDO PARA SUPERVISIÓN DE PROCESOS.....		147
7.1	Arquitectura hardware para el sistema inteligente embebido. Conexión al centro de micromecanizado.	149
7.1.1	Plataforma NI PXI de tiempo real. Portabilidad y conectividad.	150
7.1.2	Sensores y sistema de adquisición.....	151
7.1.3	Servidor de comunicaciones TCP/IP para peticiones de acceso R/W al CNC de la máquina.	153
7.2	Implementación software del sistema embebido para monitorización inteligente	156
7.2.1	Procesamiento de las señales de vibración.....	161
7.2.2	Cliente de comunicaciones TCP/IP para peticiones W/R con el PC servidor	162
7.2.3	Descripción de los módulos embebidos del sistema inteligente.....	163
7.2.4	Interfaz hombre-máquina o usuario. Descripción del funcionamiento.....	166
7.3	Ensayos de evaluación de supervisión inteligente de procesos de microfresado, a nivel de laboratorio	168
7.3.1	Diseño experimental.....	169
7.3.2	Monitorización del estado de la operación de corte y detección de interrupciones	170
7.3.3	Estimación de la rugosidad superficial. Viabilidad de integración	173
7.4	Ensayos de evaluación de supervisión inteligente de procesos de microfresado, a nivel industrial	175
7.5	Conclusiones.....	179
CONCLUSIONES		181

Lista de publicaciones	192
Trabajo futuro.....	193
BIBLIOGRAFÍA.....	197
ANEXO I. GLOSARIO DE TÉRMINOS.....	217

LISTA DE FIGURAS

Figura 1.1. Diferentes áreas de conocimiento presentes en esta Tesis Doctoral.....	9
Figura 1.2. Esquema de un sistema típico embebido de tiempo real	12
Figura 1.3. Taxonomía básica del <i>soft-computing</i> (Bonissone et al., 1999 [27]).....	14
Figura 1.4. Algunas estrategias de <i>soft-computing</i> para sintonizar controladores difusos.....	15
Figura 1.5. Sistema híbrido neuroborroso para modelado de procesos.....	17
Figura 1.6. Arquitectura ANFIS equivalente.	18
Figura 1.7. Organigrama de las diferentes técnicas de Microfabricación.	21
Figura 1.8. Ejemplos de operaciones de micromecanizado tradicional. a) Proceso de microtorneado y b) proceso de microtaladrado.	23
Figura 1.9. Ejemplos de operaciones de micromecanizado no convencional. (a) Mecanizado electro-químico. (b) Micromecanizado ultrasónico (Micro USM). (Imágenes adaptadas de [129]).....	23
Figura 1.10. Imagen del laboratorio disponible en el Centro de Automática y Robótica (UPM- CSIC) para investigaciones en procesos de microfabricación.....	31
Figura 2.1. Diagrama de una estrategia de procesamiento de señales. (Adaptación de Teti et al., 2010 [133])	35
Figura 2.2. Esquema de acondicionador de señal de EA. (Adaptación de Teti et al., 2010 [133])	36
Figura 2.3. Algoritmo de filtrado con fase cero.	36
Figura 2.4. Variables que aportan información relevante sobre los procesos de mecanizado. (Teti et al., 2010 [133]).....	42
Figura 2.5. Sistema multi-sensorial para la monitorización del desgaste en procesos de: a) mecanizado de alta velocidad (Haber et al., 2004 [181]) y b) microfresado (Jemielniak et al., 2008 [182])......	43
Figura 2.6. Algunos de los elementos de la plataforma multi-sensorial para identificación.....	47
Figura 2.7. Perfil de la operación de microtaladrado	50
Figura 2.8. Detalle del borde de un micro agujero de 0.1 mm de diámetro: (a) primero y (b) último agujero.....	50
Figura 2.9. Posición de los sensores de fuerza y vibración.	51

Figura 2.10. a), d) y g) Respuesta temporal de la señal de fuerza de corte en el eje Z. b), c), e), f), h) e i) Respuesta temporal de las señales de los acelerómetros, en los ejes Z e Y, respectivamente.....	52
Figura 2.11. Variación de la longitud de la herramienta respecto al uso en base a las mediciones del láser, a) $d = 1$ mm, b) $d = 0.5$ mm y c) $d = 0.1$ mm.	53
Figura 2.12. Parámetros estadísticos respecto al número de agujeros, para la fuerza en el eje Z con la mayor velocidad de avance. a) $D = 0.1$ mm, b) $D = 0.5$ mm y c) $D = 1$ mm.	54
Figura 2.13. Evolución de la energía de la FFT respecto a la frecuencia, para la vibración en el eje Y con la menor velocidad de avance. a) $D = 0.1$ mm, b) $D = 0.5$ mm y c) $D = 1$ mm	55
Figura 2.14. Evolución de las componentes de energía de la WT con respecto al número de agujeros, para la fuerza en el eje Z con la mayor velocidad de avance. a) $D = 0.1$ mm, b) $D = 0.5$ mm y c) $D = 1$ mm.	55
Figura 2.15. Evolución de la energía de la HHT respecto a los máximos locales, para la vibración en el eje Z con la menor velocidad de avance. a) $D = 0.1$ mm, b) $D = 0.5$ mm y c) $D = 1$ mm.....	56
Figura 3.1. Pasos seguidos en el entrenamiento del modelo incremental.....	67
Figura 3.2. Pasos seguidos en la evaluación del modelo incremental.....	67
Figura 3.3. Algoritmo de Metrópoli de aceptación-rechazo.....	71
Figura 3.4. Interfaz de la aplicación HIM creada para el modelado de sistemas.....	73
Figura 3.5. Descripción del algoritmo de agrupamiento GIFP-FCM.....	78
Figura 3.6. Ejecución del algoritmo GFCM implementado, con datos generados artificialmente, y parámetros y resultado de cada agrupamiento (centros).....	78
Figura 3.7. Arquitectura del sistema neuroborroso tipo Mamdani con algoritmo de agrupamiento GIFP-FCM.....	80
Figura 3.8. Esquema de la retro-propagación de errores.....	82
Figura 3.9. Interfaz de usuario del algoritmo GFCM desarrollado.....	83
Figura 4.1. Pieza de material resistivo y ecuación de su resistencia eléctrica.....	89
Figura 4.2. ϕ_{st} y ϕ_{ex} para diferentes posiciones de la herramienta con respecto a la pieza. a) Operación de ranura. b) Operación de planeo. c) Operación de contorno.....	92
Figura 4.3. a) Circuito equivalente del principio de operación de medición de esparcimiento. b) Plataforma experimental de medición.....	96
Figura 4.4. Diseño experimental del perfil de microfresado. a) Valores de f_n en función de la posición en el eje X. c) Imagen de la probeta de ensayos siguiendo una operación con perfil de ranura plana.....	97
Figura 4.5. Señales digitales procedentes de las mediciones en la plataforma experimental durante una operación de microfresado de ranura, $N_f = 2$, $D = 0.5$ mm, $n = 45000$ rpm y $f = 200$ mm/min.....	98
Figura 4.6. Comportamiento de la señal digital durante una operación de contorno, a) a través de todo el perfil de la pieza de trabajo, b) durante la entra en la pieza, y c) el intervalo de tiempo durante la salida del material.....	99
Figura 4.7. Histogramas sobre la distribución de las mediciones de los valores del tiempo de contacto, $N_f = 2$, $D = 0.5$ mm, $n = 45000$ rpm y $f = 200$ mm/min. a) Operación de	

ranura, $a_e = D = 0.2 \text{ mm}$, y de contorno, b) $a_e = D / 2 = 0.1 \text{ mm}$ y (c) $a_e = D / 8 = 0.0625 \text{ mm}$.	100
Figura 5.1. Circuito equivalente del principio de funcionamiento del sensor de conductancia.	106
Figura 5.2. Características extraídas de las señales ($V_{STP,slow}$ y $V_{STP,fast}$) sobre el estado de corte en una operación de microfresado. (a) Entrando y (b) Saliendo.	107
Figura 5.3. Diagrama de bloques del sensor de conductividad inteligente	109
Figura 5.4. Estados del proceso corte en operaciones de micro fresado: una ranura plana.	110
Figura 5.5. Comportamiento de las señales digitales, de entrada y procesadas, durante una operación de ranura, $N_f = 2$, $D = 0.4 \text{ mm}$, $n = 24000 \text{ rpm}$, $f = 100 \text{ mm/min}$, $a_p = 0.1 \text{ mm}$ y $a_e = 0.4 \text{ mm}$, a) entrada de la herramienta al material y b) salida del material.	113
Figura 5.6. Comportamiento de la señal analógica $V_{Z,MH,FAST}$ durante una operación de microfresado de ranura, $N_f = 2$, $D = 0.2 \text{ mm}$, $n = 40000 \text{ rpm}$, $f = 96 \text{ mm/min}$, $a_p = 0.05 \text{ mm}$ y $a_e = 0.2 \text{ mm}$, a) entrada de la herramienta al material y b) rotura y salida abrupta del material.	115
Figura 5.7. Diagrama del comportamiento esperado de las señales digitales durante los estados del proceso de corte.	115
Figura 5.8. Resumen del sistema sensorial incluido en el sistema de monitorización en tiempo real.	119
Figura 5.9. Montaje de la pieza sobre una plataforma que actúa como aislamiento electromecánico. a) Diagrama y (b) fotografía.	120
Figura 5.10. Esquema del comportamiento esperado de la variable de salida del algoritmo de detección del estado de corte.	120
Figura 5.11. Estado del corte durante operaciones de micro fresado con $D = 200 \mu\text{m}$, $N_f = 2$, $n = 45000 \text{ rpm}$, $a_e = 200 \mu\text{m}$ y $a_p = 200 \mu\text{m}$, a) $f = 50 \text{ mm/min}$, b) $f = 100 \text{ mm/min}$ y c) $f = 200 \text{ mm/min}$.	121
Figura 6.1. Posicionamiento y medición de la rugosidad superficial en una pieza mecanizada.	125
Figura 6.2. Diagrama del proceso a modelar, y las variables de entrada y salida	128
Figura 6.3. Comportamiento de la rugosidad superficial ante la variación en el avance por diente.	129
Figura 6.4. a) Sistema de adquisición y procesamiento. b) Instalación del acelerómetro en la pieza a fabricar.	131
Figura 6.5. Perfil del diseño experimental con cambios en la velocidad de avance.	131
Figura 6.6. Esquema de las zonas que se toman el valor rms total para cada velocidad de avance en cada sección de la ranura completa.	132
Figura 6.7. Rugosidad superficial en un perfil ranura con una herramienta de diámetro $1000 \mu\text{m}$, a) perfil de rugosidad completo, b) perfil de rugosidad en la primera sección de la ranura y c) perfil de rugosidad en tres regiones de la sección seleccionada.	133
Figura 6.8. Configuración en la interfaz de usuario de los parámetros utilizados en el etrenamiento del HIM.	137
Figura 6.9. Representación gráfica obtenida durante el aprendizaje y obtención del modelo HIM	137

Figura 6.10. Rugosidad superficial real (azul) frente a rugosidad estimada (rojo) basada en el modelo GFCM.	139
Figura 6.11. Aplicación del algoritmo de temple simulado a la optimización de los parámetros (m , k_n , p) de HIM.	140
Figura 6.12. Representación gráfica obtenida durante la evaluación del modelo de HIM.....	141
Figura 6.13. Vista ampliada de la respuesta del modelo GFCM con respecto a la rugosidad real medida con el perfilómetro.	142
Figura 6.14. a) Comportamiento de la rugosidad real frente a la estimada (validación en proceso). b) Comportamiento del error en proceso durante las operaciones de microfresado.	144
Figura 7.1. Diagrama de la arquitectura hardware del sistema de monitorización inteligente en tiempo real.	148
Figura 7.2. Visión global del sistema de monitorización inteligente de tiempo real desarrollado.....	150
Figura 7.3. Vista general de la plataforma PXI y sus componentes principales.....	151
Figura 7.4. a) Detalle de la instalación del equipo de medida y acondicionamiento de señal. b) Detalle del sensor de conductancia; y c) bornes del sensor de conductancia (en cabezal y pieza) y acelerómetro.	152
Figura 7.5. Plataforma PXI instalada y los módulos adquisición que la componen.....	153
Figura 7.6. Sección del código correspondiente al programa principal del servidor TCP/IP.....	155
Figura 7.7. Interfaz de usuario del servidor de datos del CNC.....	155
Figura 7.8. Diagrama de flujos del programa principal del sistema de monitorización.	157
Figura 7.9. Hilos de ejecución en paralelo del lazo principal.....	158
Figura 7.10. Sección del código en <i>Labview</i> del núcleo principal de la aplicación.	160
Figura 7.11. Código desarrollado para la adquisición de señales analógicas.	161
Figura 7.12. Filtrado de señal de vibración: filtro IIR de Butterworth, pasa-banda, orden 6 y frecuencias de corte de 100 Hz a 20 kHz.....	162
Figura 7.13. Sección del código implementado correspondiente al programa principal (bucle de ejecución continua).	162
Figura 7.14. Bucle de adquisición, procesamiento de las señales digitales provenientes del sensor de conductancia, monitorización del estado del corte y detección de roturas.	164
Figura 7.15. Sección del código en <i>Labview</i> donde se incrusta la llamada a la función de estimación de la rugosidad superficial. Llamada a la función “EvaluatePoint” en DLL.....	165
Figura 7.16. Interfaz de usuario del prototipo desarrollado.....	167
Figura 7.17. Ejemplo de un archivo de información y errores de una operación de microfresado de ranuras (Caso no. 3).	170
Figura 7.18. Estado del corte durante operaciones de microfresado: a) Caso no. 1, b) Caso no. 4, c) Caso no. 5, d) Caso no. 14, e) Caso no. 22 y f) Caso no. 11.....	171
Figura 7.19. Diagrama de barras para la tasa de acierto de todos los ensayos respecto a: a) profundidad radial, a_e , b) estados del corte y c) velocidad de avance.....	173

Figura 7.20. Secciones de la interfaz de usuario del sistema de monitorización inteligente durante una operación de ranura, herramienta de 1800 μm de diámetro, a) sección “Parámetros del sistema” y b) sección de resultados de los algoritmos, “Estado del corte” y “Rugosidad estimada”.....	174
Figura 7.21. Resultado de la estimación de la rugosidad superficial para el Caso no. 18, durante una operación de microfresado de ranura. a) Valor de Ra estimado para toda la operación y, b) su correspondiente error relativo obtenido en la estimación.....	175
Figura 7.22. a) Vista del montaje y configuración en la máquina Mori SEIKI, b) su cabezal y mordaza, c) pieza a mecanizar y sensor de vibración en el eje Z y d) pieza mecanizada con uno de los bornes del sensor de conductancia.....	176
Figura 7.23. Resultado final de la realización de las operaciones en la pieza.....	176
Figura 7.24. Detección de los estados del corte, durante la fabricación industrial de la pieza compleja. a) Caso. no. 1 y b) Caso no, 2.	177
Figura 7.25. Resultado de la estimación de la rugosidad superficial para el Caso no. 3 de ensayo de fabricación industrial de la pieza. a) Valor de Ra estimado para toda la operación y, b) su correspondiente error relativo obtenido en la estimación.	178

LISTA DE TABLAS

Tabla 1.1. Sistemas de supervisión inteligente basados en técnicas de AI y sistemas embebidos de procesos complejos.	19
Tabla 1.2. Aplicación de la monitorización directa a diferentes procesos complejos.	26
Tabla 1.3. Técnicas de AI en la supervisión de procesos de micromecanizado.	28
Tabla 1.4. Sistemas inteligentes en la automatización de procesos de micromecanizado.	29
Tabla 2.1. Sensores piezoeléctricos para sistemas de monitorización [189-191].	44
Tabla 2.2. Precisión en el posicionamiento de la Kern Evo UPMC.	48
Tabla 2.3. Características de las herramientas.	49
Tabla 2.4. Condiciones nominales para la operación de microtaladrado.	50
Tabla 2.5. Valores del desgaste de la herramienta en longitud (Δl).	53
Tabla 2.6. Evaluación comparativa (capacidad de generalización vs. correlación) del rendimiento del modelo de regresión.	58
Tabla 4.1. Condiciones de operación del diseño experimental.	96
Tabla 4.2. Mínimo error relativo entre los valores teóricos y los valores experimentales de t_c	101
Tabla 5.1. Estados de las operaciones de corte, antecedentes y descripción.	111
Tabla 5.2. Reglas que establecen el estado del contacto herramienta-pieza.	114
Tabla 5.3. Tiempos de transición en operaciones de ranuras, $N_f = 2$ y $a_e = D$	116
Tabla 5.4. Toma de decisiones sobre el estado del corte y la herramienta a partir del estado anterior y el estado preliminar establecido mediante el procesamiento de señales.	117
Tabla 6.1. Los datos utilizados para obtener los diferentes modelos.	135
Tabla 6.2. Criterios de error en la fase de entrenamiento de HIM.	137
Tabla 6.3. Configuración de los parámetros utilizada en el entrenamiento de GFCM.	138
Tabla 6.4. Criterios de error obtenidos en el aprendizaje de GFCM.	138
Tabla 6.5. Criterios de error obtenidos en la validación de HIM.	140
Tabla 6.6. Criterios de error obtenidos en la validación de GFCM.	141
Tabla 6.7. Resultados comparativos de ambos modelos, HIM y GFCM.	143

Tabla 7.1. Protocolo diseñado para las comunicaciones TCP/IP (Cliente - Servidor).	154
Tabla 7.2. Cuadro de tiempos de los hilos de ejecución.....	159
Tabla 7.3. Listado de funciones que componen las bibliotecas definidas para los dos módulos embebidos.	163
Tabla 7.4. Archivos de informe y almacenamiento de salida del sistema de monitorización.	168
Tabla 7.5. Condiciones nominales de operación para los ensayos de evaluación.	169

INTRODUCCIÓN

Las últimas décadas hemos asistido al progreso incesante de los medios de cómputo de bajo coste, arquitecturas computacionales abiertas y ligeras y el uso masivo de las técnicas de inteligencia artificial. En la actualidad la conjunción de arquitecturas y algoritmos eficientes, métodos computacionales avanzados en sistemas intermediarios y las estrategias inspiradas en la Teoría de Sistemas, la Automática y las Neurociencias, han enriquecido el arsenal a disposición de los investigadores para afrontar los nuevos retos de la industria del siglo XXI.

Los procesos de fabricación no están ajenos a este progreso incesante, con tres pilares fundamentales: mayor precisión, tolerancias más precisas y pequeñas, y mejores acabados superficiales. Los procesos de fabricación tienen, por su variedad y complejidad, un gran impacto en el producto nacional bruto de Europa. Se estima que la actividad de fabricación representa aproximadamente el 22 % del PNB europeo, además un 75 % del PIB y un 70% del empleo a nivel europeo están relacionados con la fabricación [1].

Esta Tesis Doctoral se enmarca en la actividad investigadora de un grupo de reconocido prestigio. Se trata del grupo de investigación GAMHE (Grupo de Automatización Avanzada de Máquinas, Entornos y Procesos Altamente complejos), perteneciente al Centro de Automática y Robótica (UPM-CSIC), que tiene entre sus líneas principales de investigación, el empleo de sistemas inteligentes para la monitorización y control de procesos complejos y la optimización de procesos, en concreto, los procesos de mecanizado de alto rendimiento y precisión.

En la actualidad, se ha incrementado la demanda de mayores eficiencias y se han impuesto nuevos criterios de rentabilidad. Estos desafíos técnicos se agudizan cuando se trata de componentes cada vez más pequeños, más compactos y con mayores funcionalidades. Tales requisitos sólo pueden ser satisfechos si el sistema de producción está altamente automatizado y es extremadamente flexible. A pesar de ello, la inversión económica en la industria en nuevos sistemas inteligentes de supervisión y modelado representa únicamente el 10 % del total necesario a invertir. Estas son razones poderosas para seleccionar uno de los procesos

más modernos y emergentes dentro de los sistemas de fabricación en la micro escala, el proceso de micromecanizado mecánico, para el diseño e implementación de un sistema de monitorización y supervisión inteligente a partir de una arquitectura.

El éxito en la implementación de un sistema supervisor depende fundamentalmente de tres factores: la robustez del sistema sensorial, la calidad de la información medida y de las técnicas de diagnóstico usadas para procesar la información sensorial. Se han llevado a cabo estudios avanzados en sensores y en algoritmos de procesamiento de señal. No obstante, los procedimientos de aprendizaje y de toma de decisión usados para asociar la información sensorial con las condiciones del proceso deben ser perfeccionados, si se aspira a una supervisión efectiva de procesos de fabricación. Para ello se recurre a modernos sistemas de procesamiento y estrategias de supervisión basadas en técnicas de Inteligencia Computacional (CI).

La Inteligencia Computacional (CI) aglutina a un conjunto de metodologías que incluye, entre sus miembros, la lógica borrosa, la neuro-computación, la computación evolutiva y la computación probabilística, y se considera el lugar donde convergen todas las tecnologías emergentes del razonamiento. Estos métodos de *soft-computing* han probado ser efectivos en muchas aplicaciones y constituyen la base en esta investigación para mejorar los esquemas de monitorización disponibles en la actualidad. A pesar de ello, no se han dejado de explorar técnicas más simples y clásicas pero no por ello menos efectivas y precisas. Así, un sistema de monitorización para sistemas electromecánicos complejos puede estar formado por tres niveles, a saber: un nivel de aprendizaje del conocimiento, un nivel de experiencia basado en reglas borrosas y un nivel de adaptación para ajustar las reglas de acuerdo con las condiciones del entorno, basado en los algoritmos genéticos. A pesar de los progresos, se requiere profundizar en el desarrollo de nuevas estrategias híbridas que permitan compartir los beneficios de cada metodología computacional y que sean viables de ser aplicadas en tiempo real.

Los trabajos relacionados con la supervisión y monitorización de los procesos de microfabricación comienzan a ser frecuentes en la literatura. Sin embargo, a partir de la literatura a la que se ha tenido acceso, se puede concluir que hay muy pocos trabajos dirigidos hacia la monitorización de múltiples variables, que estén basados en técnicas de inteligencia artificial y con capacidad de ser embebidas en sistemas de tiempo real. Los resultados que muestran en el estado del arte son todavía muy incipientes sobre todo por la carencia de plataformas de cómputo abiertas, de tiempo real y que sean capaces de soportar aplicaciones embebidas con estrictos requisitos de tiempo de procesamiento y limitado ancho de banda para afrontar los retos de la dinámica de los procesos en la micro escala. Con esta Tesis Doctoral se pretende generar nuevos conocimientos científicos y técnicos sobre este tema, así como contrastar experimentalmente las aportaciones en el campo de la supervisión inteligente de determinados procesos de fabricación, proponiendo una metodología susceptible de ser

aplicada a otros procesos físicos complejos con el fin de mejorar la calidad de la producción o en general, aumentar la productividad [2].

Objetivos

El objetivo principal de este trabajo es diseñar, desarrollar e implementar una arquitectura e inteligencia computacional embebida para la supervisión de procesos, y considerar el caso real de un proceso de Microfabricación. El método propuesto debe estar sustentado en un sistema abierto en el que puedan integrarse o embeberse diferentes herramientas basadas en Inteligencia Artificial (ej., técnicas de *soft-computing*), junto con diseños e implementaciones a nivel hardware. Esta arquitectura podría materializarse en una plataforma de tiempo real, modular, en red y reconfigurable, para la monitorización y supervisión inteligente de sistemas complejos.

Asimismo, se trata de lograr que las estrategias de supervisión propuestas en este trabajo permitan que algoritmos computacionalmente eficientes puedan ser embebidos, y asegurar de este modo un funcionamiento adecuado en tiempo real, y que puedan ser aplicados a procesos no lineales y con dinámicas relativamente rápidas. En este sentido, serán analizados desde sistemas sensoriales apropiados hasta la selección e implementación de los métodos y modelos a utilizar, así como la transmisión y el procesamiento de los datos en tiempo real. De este modo, es evidente el carácter heterogéneo, multidisciplinar e interdisciplinar al que nos enfrentamos con el desarrollo de esta Tesis Doctoral.

En esta Tesis Doctoral, las estrategias desarrolladas serán aplicadas a la supervisión de un proceso de microfabricación, en concreto, el proceso de microfresado de alta precisión. Este proceso ha sido escogido por su mayor impacto productivo en los años venideros y al mismo tiempo, por tener asociado un mayor número de desafíos científicos y técnicos, por ejemplo, con la vida útil de la herramienta de corte, la influencia de las vibraciones y los estrictos acabados superficiales. En general, los sistemas clásicos de supervisión fallan debido a que carecen de información sensorial relevante o porque las estrategias de toma de decisión no están suficientemente preparadas para hacer frente a determinados comportamientos emergentes y responder a determinados eventos. En la actualidad, esta situación se ha convertido en una fuerza impulsora para el desarrollo de las estrategias de supervisión inteligentes.

El trabajo que se presenta en esta Tesis doctoral se enmarca dentro de diferentes áreas de conocimiento y temáticas desde la ingeniería mecánica y la microfabricación hasta la Electrónica, la Automática y la ingeniería de Control. A priori se prevé que para poder alcanzar el objetivo principal de esta Tesis sea necesario la abstracción de diferentes retos científicos y técnicos en la conjunción de las diferentes áreas de conocimiento presentes en esta Tesis Doctoral. El área de conocimiento que actúa como eje central de esta Tesis y sobre

el que giran el resto de contribuciones (Sistemas Embebidos y Tiempo Real, Electrónica, Automática e ingeniería de Control, Mecánica y procesos de Fabricación) es la ingeniería Informática. La conjunción de estas diferentes áreas a través de la Informática se materializará en soluciones a problemas inherentes a un proceso físico complejo en el ámbito de la Mecánica y los procesos de Fabricación en la micro escala.

El planteamiento de este objetivo tiene asociado los siguientes **retos científicos y técnicos** parciales:

1. Analizar diferentes tipos de sensores, arquitecturas multi-sensoriales, técnicas de procesamiento y extracción de patrones de comportamiento de las señales representativas de las variables típicas en procesos complejos. Estudio particular del proceso de microfresado y microtaladrado.
2. Diseñar e implementar una metodología computarizada, innovadora y eficiente, de caracterización experimental de procesos. Aplicación a la caracterización de variables representativas del proceso de micromecanizado.
3. Investigar sobre nuevos desarrollos de sensores y desarrollar hardware sensorial adicional para obtener información relevante de variables representativas de procesos complejos. Caso de estudio, sensor especializado en procesos de micromecanizado.
4. Desarrollar e implementar un algoritmo computacionalmente eficiente basado en técnicas de Inteligencia Artificial para la monitorización del estado de los procesos físicos complejos. Estudio del caso particular del proceso de micromecanizado mecánico.
5. Diseñar e implementar algoritmos de modelado basados en técnicas de Inteligencia Artificial (ej., *soft-computing*) para el modelado de variables representativas. Además aplicar técnicas de optimización y aprendizaje para el ajuste de los parámetros de los modelos obtenidos. Aplicación al caso particular de la estimación de la rugosidad superficial en operaciones de micromecanizado.
6. Realizar un estudio comparativo y evaluación de todos y cada uno de los algoritmos y modelos desarrollados para determinar la viabilidad de embeber uno de ellos en la arquitectura de tiempo real.
7. Diseñar e implementar una arquitectura de tiempo real, en red, modular y reconfigurable que contenga, como mínimo, un sistema embebido de tiempo real, sensores, sistema de adquisición de señales, sistema intermediario, módulo cliente-web, etc. En el sistema se integrarán los algoritmos y modelos embebidos para la supervisión inteligente de procesos.
8. Aplicar y evaluar la plataforma en la monitorización inteligente del proceso de micromecanizado mecánico. Las variables a supervisar serán el estado del proceso de corte y la herramienta de corte, y la rugosidad superficial.

Metodología

Esta investigación se desarrollará en una serie de etapas centradas principalmente en el trabajo experimental. Con ello, se busca que las propuestas que se presenten estén sustentadas no solo en una hipótesis y desarrollos teóricos, sino, principalmente, en resultados evaluados experimentalmente.

En la etapa de fundamentos teóricos, se hará una revisión crítica de los fundamentos teóricos necesarios en la investigación. Se hará una exploración de los métodos inteligentes e implementaciones embebidas que se aplican en la actualidad en los sistemas de supervisión inteligente de procesos complejos y que se recogen en la literatura. Estas estrategias se basarán en la selección, modificación, adaptación e integración de los más convenientes paradigmas dentro de los sistemas sensoriales, procesamiento e identificación de características en las señales sensoriales, arquitecturas embebidas, modelado y técnicas de inteligencia artificial.

Por último, se harán los ajustes y el refinamiento de los métodos propuestos a partir del estado de la técnica en el ámbito de aplicación de esta investigación, y de las propias iteraciones de las fases experimentales que se pretenden desarrollar.

El trabajo experimental será la fase inicial y parte muy importante de la investigación, ya que será la base para aplicar y evaluar las estrategias o métodos elegidos, así como del diseño de la arquitectura embebida en la que se implementará el sistema, y a partir de la cual se pretenden obtener resultados significativos. Dichas estrategias se configurarán de acuerdo con las características específicas de las señales generadas por los procesos estudiados. Esto implica que los procesos de toma de datos, pre-procesamiento y modelación serán concebidos, implementados y validados a partir de dichas señales.

Esta parte experimental se verá altamente favorecida por la disponibilidad de un laboratorio único en la Comunidad de Madrid y en el CSIC para las investigaciones en el campo de los procesos de fabricación en la micro escala, que está dotado de los dispositivos necesarios que permitirán, sin dudas, llevar a cabo una de las tareas más importantes en la metodología científica: la evaluación experimental. Igualmente, se dispone de un sistema de medición (sensores y tarjetas DAQ) tales como sensores de fuerza, aceleración, emisión acústica y tarjetas de digitalizadoras.

Estructura del trabajo

El trabajo consta de 7 capítulos, además de un acápite de conclusiones, donde se resumen los aportes de mayor relevancia y propuestas de líneas de investigación futuras.

En el Capítulo 1 se realiza una revisión del estado de la ciencia y la técnica en los paradigmas elegidos dentro del amplio universo que ponen a nuestra disposición la Teoría

General de Sistemas, la Electrónica y Automática, las técnicas de Inteligencia Artificial y las Ciencias de la Computación. Se presenta, además, una breve revisión de los procesos de microfabricación y específicamente los de micromecanizado, como caso real de procesos electro-mecánicos complejos, presentando cómo han evolucionado estos procesos y las tendencias actuales hacia un aprovechamiento de la complementariedad con otras áreas científicas y tecnológicas.

El Capítulo 2 se inicia con un estudio de técnicas de procesamiento y filtrado de señales, junto a un estudio de los sensores y sistemas multi-sensoriales disponibles en la literatura. Como consecuencia, se propone una arquitectura multi-sensorial en red, a nivel de laboratorio, que se utilizará para la medición de la señales proveniente de los sensores, relacionadas con las variables físicas medibles más representativas del proceso complejo. El proceso considerado es la operación de microtaladrado, al que se aplican una estrategia de extracción de características consistente en dos etapas. Primero, se analizan exhaustivamente las características de las señales en busca de posibles patrones de comportamiento, ya sean temporales o en frecuencia, y su posible relación con el estado de la herramienta. En segundo lugar, se establecen unas relaciones causa efecto entre la información sensorial y el uso de la herramienta mediante regresión estadística. Estos resultados son corroborados experimentalmente mediante unos índices estadísticos, como son la correlación R^2 y la capacidad de generalización.

El Capítulo 3 recoge la formalización, y posterior desarrollo, de dos algoritmos basados en técnicas de *soft-computing* para el modelado de variables. Por una parte, debido al interés que despierta en la actualidad el uso de técnicas no paramétricas o de modelo libre, el estudio se ha centrado en el algoritmo de modelado híbrido incremental (HIM, *Hybrid Incremental Modelling*). Por otra parte, el estudio se ha enfocado hacia las técnicas más usuales para obtener modelos de los procesos de fabricación que son las técnicas de regresión borrosa o neuroborrosa. Por tanto, una de las técnicas elegidas es el algoritmo de agrupamiento borroso generalizado (GFCM, *Generalized Fuzzy C-Means*), del que se abordan las ideas esenciales y conceptuales. Asimismo, se seleccionan del amplio espectro de técnicas existentes, dos estrategias de optimización y ajuste de parámetros de los modelos, para cada uno de los algoritmos. Los elegidos son el de temple simulado y el algoritmo de retro-propagación de errores. Las técnicas seleccionadas serán posteriormente utilizadas en el Capítulo 6 en el modelado de una variable representativa del proceso de microfabricación, como es la rugosidad superficial.

El Capítulo 4 presenta el diseño de una metodología novedosa y computacionalmente eficiente de caracterización experimental de procesos complejos. Esta metodología está basada en la medición, acondicionamiento y procesamiento en tiempo real del voltaje eléctrico generado por el paso de una señal auto-excitada a través de un sistema complejo. Específicamente, el sistema complejo caso de estudio en esta Tesis Doctoral es la resistencia

eléctrica formada por la interacción dinámica entre la herramienta de corte y la pieza de trabajo en operaciones de micromecanizado. Estos resultados son aplicables a las operaciones de mecanizado por arranque de viruta en materiales conductores.

En el Capítulo 5 se describe la materialización de la evidencia física de los resultados obtenidos en la metodología de caracterización experimental del Capítulo 4. Se trata del diseño de un sensor que puede ser empleado para la medición de la conductancia entre el filo de la herramienta y el borde del material, cuando existe un contacto eléctrico entre ellos. Este sistema se incluye dentro de un sistema sensorial para una detección de alta precisión del contacto herramienta / pieza en tiempo real en operaciones de microfabricación. Las señales, proporcionadas por este sensor, son utilizadas como entradas al algoritmo embebido computacionalmente eficiente basado en un conjunto de reglas y una máquina de estados finitos para la detección del estado del corte y roturas de la herramienta en procesos de micromecanizado.

El Capítulo 6 se centra, principalmente, en mostrar los beneficios de las técnicas de modelado, optimizaciones de parámetros y aprendizaje, escogidas y desarrolladas en el Capítulo 3, mediante la aplicación de éstas al campo de las tecnologías de microfabricación, específicamente en las operaciones de microfresado. Se hace necesario, por tanto, que se establezcan unas relaciones causa-efecto entre la información sensorial, el estado del proceso de micromecanizado y la calidad dimensional y superficial (rugosidad superficial). Estas relaciones, se han formalizado a través de dos tipos de modelos, los cuáles serán comparados con el objetivo de determinar cuál de ellos será embebido definitivamente en el sistema de tiempo real y que será descrito en el Capítulo 7.

El Capítulo 7 describe una arquitectura de tiempo real, en red, modular y reconfigurable, cuya distribución y organización ha tenido en cuenta los resultados y recomendaciones de los estudios, diseños, experimentaciones, desarrollos e implementaciones llevados a cabo en todos los capítulos anteriores para un funcionamiento preciso, robusto, con baja carga computacional, adecuado tiempo de respuesta y eficiencia. También se destacan dos de los módulos más importantes del sistema embebido de tiempo real que son: el módulo de detección de estado del proceso y rotura de la herramienta, y el módulo de predicción de la rugosidad superficial on-line. Por último, todo el conjunto se ha validado mediante una serie de ensayos de supervisión (a nivel de laboratorio e industrial) del estado del proceso de corte, la herramienta y la rugosidad superficial on-line durante la realización de operaciones de microfabricación, específicamente operaciones de microfresado.

CAPÍTULO 1

ESTADO DEL ARTE

La forma de alcanzar el objetivo principal de esta Tesis Doctoral únicamente es posible mediante la abstracción de diferentes retos científicos y técnicos parciales correspondientes a la conjunción de todas y cada de las diferentes áreas de conocimiento presentes en esta Tesis Doctoral. El área de conocimiento que actúa como eje central de esta Tesis y sobre el que giran el resto (Sistemas Embebidos y Tiempo Real, Electrónica, Automática e ingeniería de Control, Mecánica y procesos de Fabricación) es la ingeniería Informática. La conciliación de estas diferentes áreas a través de la Informática es la materialización de esta disertación con el fin último de dar soluciones a los problemas en la Mecánica y los procesos de Fabricación (ver Figura 1.1).

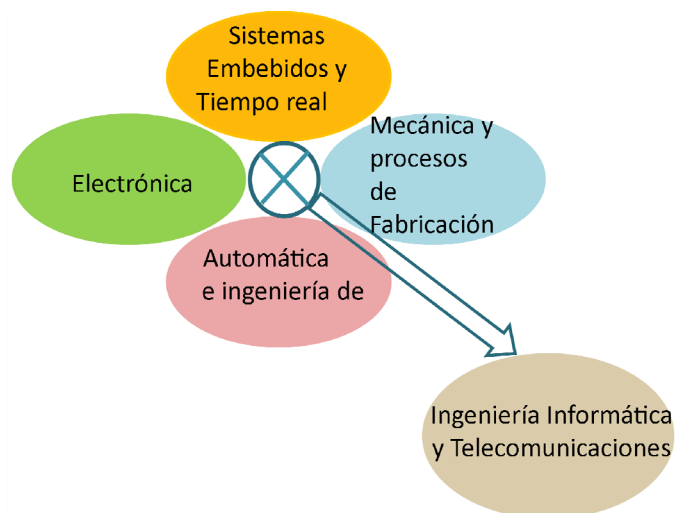


Figura 1.1. Diferentes áreas de conocimiento presentes en esta Tesis Doctoral

Debido a este carácter multidisciplinar, interdisciplinar y heterogéneo resaltable en esta Tesis Doctoral, el estado del arte se encaja en este sentido, a través de un enfoque que

pretende generar unas contribuciones en todos estos campos, sin entrar en profundidad en ninguno de ellos, ya que esto resultaría temporalmente hablando irrealizable e inalcanzable.

Esto motiva que se haya optado en darle relevancia en esta revisión al desarrollo de métodos computacionalmente eficientes en la supervisión inteligente de procesos en tiempo real. Se profundiza en el estado de la ciencia y la técnica en el elemento conjuntivo que permite articular todas las interrelaciones entre las diferentes áreas de conocimiento que se tratan en esta Tesis Doctoral, que es la ingeniería Informática y específicamente, los Sistemas Informáticos, las Ciencias de la Computación y los Sistemas Embebidos de Tiempo real.

Por lo tanto, en este capítulo se presenta una breve revisión del estado de la ciencia y la técnica en los paradigmas elegidos dentro del amplio espectro que representan las diferentes áreas de conocimiento involucradas en esta Tesis Doctoral tales como las arquitecturas y algoritmos computacionales eficientes, métodos computacionales avanzados en sistemas intermediarios y las estrategias inspiradas en la Teoría de Sistemas, Sistemas de Tiempo Real y Embebidos, la Electrónica y Automática y las Neurociencias, y en concreto, resaltando **la conjunción** de las mismas. Se presenta además, un resumen de los procesos de microfabricación, como un caso de estudio de procesos electromecánicos complejos, presentando cómo han evolucionado estos procesos y las tendencias actuales hacia un aprovechamiento efectivo de la complementariedad con otras áreas científicas y tecnológicas.

El capítulo se divide en tres secciones. En la primera (sección 1.1) se muestra una revisión de las diversas técnicas provenientes, fundamentalmente, de las Ciencias de la Computación y la Ingeniería de Sistemas Electrónicos vinculadas con la Inteligencia Artificial, con vistas de ser aplicadas al modelado y supervisión en tiempo real de procesos físicos. Como procesos electromecánicos complejos a caracterizar y modelar, en la sección 1.2 se realiza una introducción a los procesos de micromecanizado, presentando su evolución y tendencias actuales. Finalmente, en la sección 1.3, se recogen varias de las aportaciones disponibles en la literatura, que demuestran la viabilidad de aplicar una arquitectura de tiempo real, modular y en red, con capacidad de integrar diferentes estrategias de supervisión de procesos de microfabricación y específicamente, de micromecanizado, que estén basadas en técnicas de Inteligencia Artificiales.

1.1 Sistemas embebidos e inteligentes en la supervisión de procesos complejos

Hay muchas interpretaciones sobre la naturaleza de un sistema de tiempo real; sin embargo, todas tienen en común la noción de tiempo de respuesta: *“el tiempo que precisa el sistema para generar la salida a partir de alguna entrada asociada”* [3]. En este sentido, en la literatura existen definiciones derivadas de ésta: *“hay un límite estricto de tiempo por el cual un sistema debe proporcionar una respuesta, independientemente del algoritmo*

empleado " (O'Reilly et al. [4]); "*capacidad del sistema para garantizar una respuesta después (definido de dominio) de que haya transcurrido un tiempo fijo*" (Laffey et al. [5]) y; "*[un sistema] diseñado para funcionar con una medida bien definida de reactividad*" (Georgeff, 1989 [6]); y por tanto, incompletas debido a la falta del término "*determinismo*" en la definición. No es hasta el año 1988, dónde Stankovic presenta un excelente análisis de los sistemas de tiempo real, estableciendo algunas de las deficiencias de los enfoques actuales [7]. Aquí, la palabra temporalidad se considera en el contexto del sistema total. Para ilustrar las distintas formas de definición de los "sistemas de tiempo real" se proporcionan dos definiciones adicionales.

En 1982, Young define un sistema de tiempo real como [8]: "*...cualquier actividad o sistema de proceso de información que tiene que responder a un estímulo de entrada generado externamente **en un periodo finito y especificado.***"

El proyecto Sistemas de Cómputo Predeciblemente Confiables (PDCS) proporciona la definición siguiente (Randell et al., 1995, [9]): "*...Un sistema de tiempo real es aquél al que se le solicita que reaccione a estímulos del entorno (incluyendo el paso del tiempo físico) **en intervalos del tiempo dictados por el entorno.***"

En su sentido más general, todas estas definiciones cubren un amplio rango de actividades de los computadores. Afortunadamente, normalmente no es un desastre si la respuesta no se produce en ese tiempo y es por eso, que surge una diferenciación entre las definiciones de tiempo real estricto (*hard*) [10] y no estricto (*soft*) [11].

En un sistema de tiempo real, estricto o no estricto, el computador interfiere normalmente directamente con algún equipamiento físico, y se dedica a monitorizar o controlar la operación de dicho equipamiento. Una característica fundamental de todas estas aplicaciones es el papel del computador como componente del proceso de información en un sistema de ingeniería más grande. Esta es la razón por la que tales aplicaciones se conocen como **sistemas embebidos**.

Hoy en día, son cada vez más los sistemas embebidos de tiempo real implementados de forma distribuida [12-14]. Estos sistemas embebidos distribuidos pueden estar formados desde un par de controladores hasta varios cientos. La distribución y paralelismo en el diseño de sistemas embebidos de tiempo real aumentan los retos de la ingeniería y requieren un nuevo marco metodológico basado en middleware. Con este enfoque, Brinkschulte et al. [15] desarrollaron un middleware que soporta el diseño de sistemas de tiempo real distribuidos heterogéneos y que permite el uso de pequeños microcontroladores como nodos de cálculo.

Por lo tanto, los sistemas de tiempo real y embebidos poseen una serie de características significativas, que son según Reichenbach et al. [16]: grandes y complejos, con capacidad de manipular números reales, extremadamente fiables y seguros, con control concurrente de los

distintos componentes separados del sistema, funcionalidades de tiempo real, posibilidad de implementación eficiente y en entorno de ejecución, entre otros.

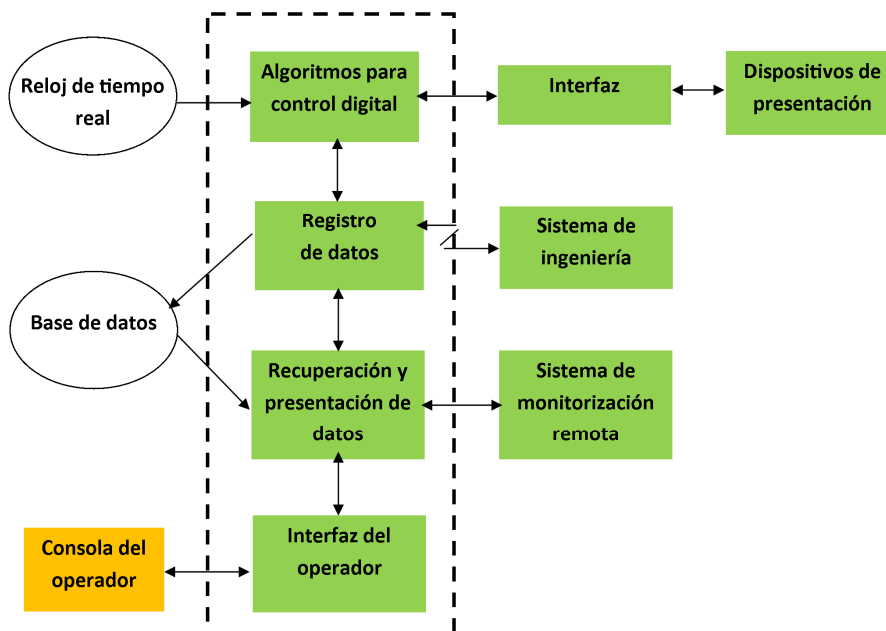


Figura 1.2. Esquema de un sistema típico embebido de tiempo real

En la Figura 1.2 se representa de forma esquemática, un sistema embebido típico. El software que controla las operaciones del sistema suele estar organizado y estructurado en módulos (módulo para los algoritmos embebidos, módulo de registro de los estados, módulo para el almacenamiento de los datos o base de datos y módulos para la interacción con el operador, entre otros). Este último surge debido a la naturaleza de los sistemas embebidos que requieren componentes de computador para interactuar con el mundo externo, en lo que viene a denominarse **interacción o interfaz hombre-máquina** (HMI, *Human-Machine Interface*) [17].

Algunos sistemas y arquitecturas para la monitorización del estado de procesos en tiempo real han sido implementados en una plataforma embebida, aunque en general se han decantado por la ejecución sobre PCs. Estos sistemas han comenzado a evolucionar surgiendo, por ejemplo, soluciones basadas en FPGA (*Field Programmable Gate Array*) capaces de producir los mismos resultados pero con costes computacionales inferiores [18, 19]. Debido a la relación coste-eficacia de la nueva generación de dispositivos de microcontroladores es económicamente factible embeber un número de ellos dentro de una máquina o proceso para formar una red de sensores distribuidos [20]. De especial relevancia es la opción prevista para desplegar **módulos de toma de decisiones** cerca de la fuente de la información [21].

Los procesos complejos se caracterizan por su comportamiento variable y no lineal en el tiempo, definiendo una secuencia de estados de operación del sistema. El control de las perturbaciones constituye una de las principales desventajas cuando se trata de llevar el comportamiento del sistema a un estado de funcionamiento óptimo. **Por tanto, las arquitecturas de supervisión en tiempo real basada en el conocimiento surgen como un intento de garantizar y justificar la calidad de la respuesta del sistema**, frente a cualquier situación adversa o perturbaciones. Sin embargo, la recuperación y el procesamiento de los conocimientos útiles desde el sistema de control es una tarea compleja, ya que una gran cantidad de datos en bruto procedentes de los sensores debe ser analizada y ser actualizada constantemente [22]. En consecuencia, si el tiempo de respuesta impuesto al proceso a supervisar en el desarrollo de sus tareas es muy limitado, se requiere una alta actualización temporal de los conocimientos sobre el sistema y una gran generación de conocimiento de gran calidad de los datos cuantitativos procedentes de los sensores del sistema. Debido a esto, en la literatura a la que se ha tenido acceso se aprecia una clara tendencia hacia la utilización de otro tipo de estrategias como son las descritas a continuación.

Es por ello que si se trata de simular el comportamiento inteligente de sistemas que requieran una representación exacta y compleja del conocimiento (Turing [23]), se recurra a la inteligencia artificial (AI, *Artificial Intelligence*). Dentro del amplio espectro de las técnicas de AI, una de las ramas con mayor desarrollo científico y tecnológico en los últimos años, basada principalmente de las sinergias entre las técnicas básicas de la AI, es el "*Soft-Computing*". El término fue acuñado por Lotfi Zadeh [24] y cubre una amplia gama de métodos para el diseño de sistemas inteligentes. En contraste con los métodos analíticos, las metodologías de *soft-computing* imitan la conciencia y cognición en varios aspectos importantes: pueden aprender de la experiencia; pueden universalizar en dominios donde la experiencia directa está ausente; y, a través de arquitecturas de computación paralelas que simulan los procesos biológicos, pueden realizar el mapeo desde las entradas hasta las salidas más rápidamente que las representaciones analíticas inherentemente en serie (Zadeh [25]).

El *soft-computing* se considera el lugar donde convergen todas las tecnologías emergentes del razonamiento y aglutina a un conjunto de metodologías, como las que se pueden ver en la Figura 1.3. Por ejemplo, una de ellas son los algoritmos de tipo heurísticos que se emplean en muchas aplicaciones de *soft-computing* como valiosas herramientas capaces de proporcionar soluciones donde los algoritmos exactos no son capaces de encontrarlas y además, donde el espacio de búsqueda es demasiado grande para una búsqueda exhaustiva y es necesario encontrar soluciones cercanas a la óptima [26]. La clasificación de las diferentes subclases de algoritmos heurísticos se obtiene a partir de su fuente de inspiración, la cual puede estar basada en: procesos naturales, sociales, físicos, entre otros.




Figura 1.3. Taxonomía básica del *soft-computing* (Bonissone et al., 1999 [27])

Existe una primera subclase de estos algoritmos basada en la ejecución mediante un proceso iterativo de una heurística subordinada que combina de forma inteligente diferentes conceptos para explorar y dinamitar el espacio de búsqueda [28]. Estos algoritmos se denominan meta-heurísticos [29]. Como segunda subclase están los algoritmos cuya fuente de inspiración son las colonias de animales sociales en lo que viene a denominarse inteligencia de enjambre (SI, *swarm intelligence*) [30-37]. Por ejemplo, el comportamiento de las hormigas da lugar al algoritmo de optimización de colonia de hormigas (ACO, *Ant Colony Optimization*) [38], mientras que las sincronías de las bandadas de aves y de peces define el algoritmo de optimización por enjambre de partículas (PSO, *Particle Swarm Optimisation*) [39].

Otra gran subclase de algoritmos heurísticos constituye la que denominaremos algoritmos de simulación de procesos físicos (SPF), perteneciente a la gran clase de algoritmos de tipo Monte Carlo [40]. Mediante la simulación del comportamiento de diferentes sistemas físicos, exploran el espacio de soluciones, transformándolas de forma iterativa.

Entre los métodos de mayor popularidad que comparten este enfoque se encuentran el algoritmo de ascenso a colinas (HC, *Hill Climbing*) [41], temple simulado (SA, *Simulated Annealing*) [42, 43], búsqueda tabú (TS, *Tabu Search*) [28], entre otros. Otro de los algoritmos que vale la pena mencionar, es el algoritmo de entropía cruzada (CE, *Cross Entropy*) [44] que fue desarrollado con el objetivo de simular eventos raros, con probabilidades muy pequeñas y con requisitos de alta precisión en su estimación.

Existe una amplia variedad de técnicas heurísticas y subclases derivadas de ellas, que han sido aplicados y pueden emplearse de forma combinada con otros componentes del *soft-computing*, como son, además de las técnicas mencionadas con anterioridad, los algoritmos de búsqueda directa (ej.: algoritmo de optimización de Nelder-Mead (NM) [45]) y producto de la hibridación de métodos heurísticos (ej.: algoritmos meméticos), por solo mencionar algunos.

La Figura 1.4 muestra algunas de las estrategias más importantes del *soft-computing*, propuesto inicialmente por Bonissone et al. [46], Bonissone [27] y después actualizado en trabajos posteriores por Verdegay et al. [26]. A continuación, para cada uno de los componentes básicos, se relacionan algunas de sus técnicas más conocidas:

- **Computación probabilística:** redes bayesianas [47] y sistemas Dempster-Shafer [48], utilizados para el desarrollo de modelos probabilísticos

- **La computación borrosa y lógica multi-elevada:** sistemas algebraicos de lógica multi-elevada y sistemas de inferencia borrosa con sus dispositivos lógicos borrosos, ya sean de tipo Mandami [49] o de tipo Takagi-Sugeno-Kang (TSK) [50, 51].
- **Neuro-computación:** redes neuronales (NN, *Neural Networks*) artificiales anticipativas (FNN, *Feedforward NN*) y redes neuronales recurrentes (RNN, *Recurrent NN*). El primer subconjunto está formado por el “perceptrón” de capa simple (NN SL, *NN Single Layer*), el “perceptrón” multicapa (MLP, *Multiple Layer Perceptron*), las redes neuronales de base radial (RBF, *Radial Basis Function*) [52], las redes conocidas como controlador del modelo aritmético del cerebelo (CMAC, *Cerebellar Model Arithmetic Controller*) [53], las redes neuronales aumentadas (*Augmented FNN*) [54] y las redes neuronales dinámicas aditivas de tiempo continuo (CS-DNN, *Continuous-time Additive Dynamic NN*) [55], entre otras. Del segundo se destacan los mapas auto-organizados de Kohonen (Kohonen SOM, *Self-Organizing Map*) [56], las redes de Hopfield [57], los modelos de red basados en la teoría de la resonancia adaptativa (ART, *Adaptive Resonance Theory*) [58], las redes de almacenamiento a corto y largo plazo (LSTM, *Long Short Term Memory*) propuestas por Hochreiter y Schmidhuber [59] y las redes neuronales de conexión estocástica (SCN, *Stochastic Connection Neural networks*) [60].

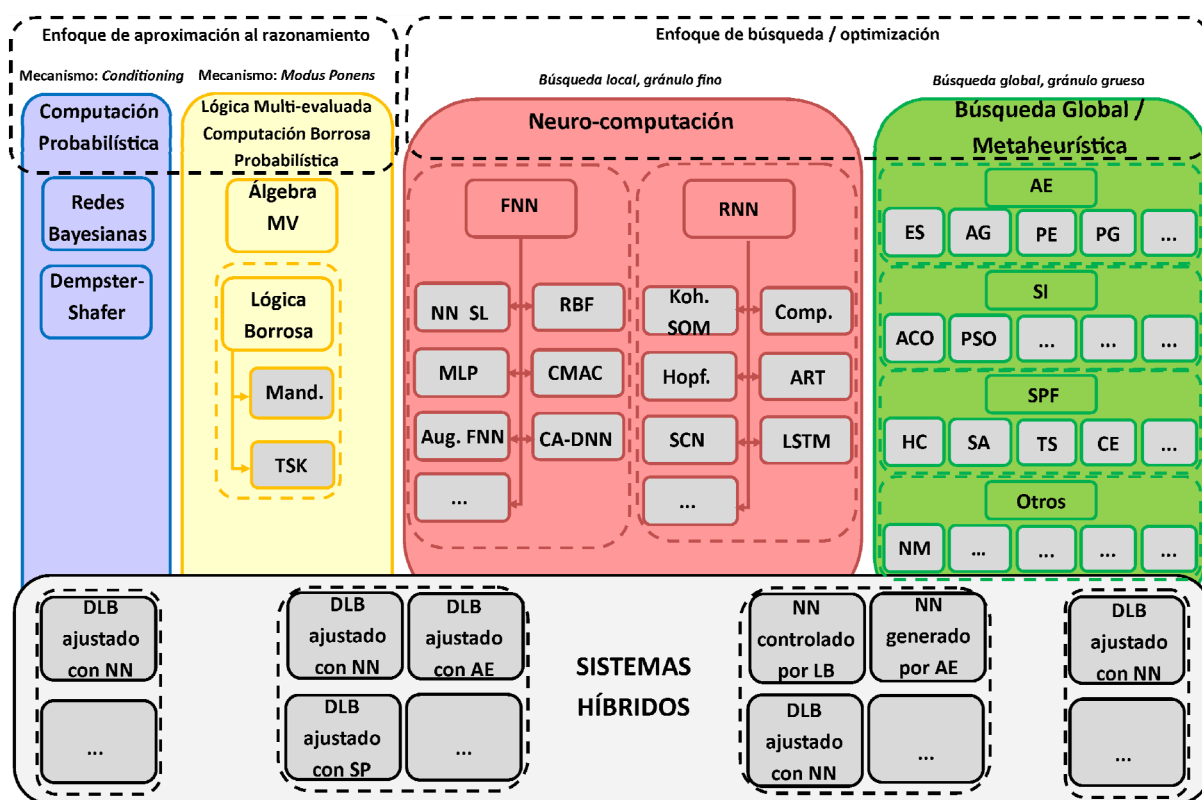


Figura 1.4. Algunas estrategias de *soft-computing* para sintonizar controladores difusos. (Del Toro, 2011 [61] y Haber et ál, 2014 [62])

- **Búsqueda global y meta-heurísticas:** algoritmos evolutivos (AE), inteligencia de enjambre (SI) y algoritmos de simulación de procesos físicos (SPF) [63], la programación genética (PG) [64], programación evolutiva (PE) [65], estrategias de evolución (ES, *Evolution Strategies*) [66] y algoritmo de búsqueda directa de Nelder-Mead (NM).

A través de la hibridación de algunas de estas técnicas, tal y como puede verse en la Figura 1.4, es posible diseñar **sistemas inteligentes híbridos** que pueden ser utilizadas para el modelado y control de procesos físicos, y de esta manera, poder hacer frente a la imprecisión e incertidumbre inherente a algunos de estos procesos.

Por un lado, la combinación de las técnicas probabilísticas con las estrategias borrosas, ha desembocado en los denominados modelos probabilísticos híbridos. Por ejemplo, la probabilidad de eventos borrosos [67] y la veracidad de eventos borrosos [68] se sitúan en esta categoría. Por otro lado, están los denominados sistemas neuronales híbridos basados en la hibridación de estrategias de neuro-computación, lógica borrosa y técnicas de optimización, para actuar sobre la estructura, los pesos en cada nodo y los parámetros de la red neuronal. En lugar de utilizar métodos clásicos de entrenamiento se han propuesto algoritmos evolutivos aplicados hacia un entrenamiento optimizado de las redes, como puede ser la **retro-propagación de errores** [69]. Maniezzo [70], Fogel et ál [71] y McDonnell y Waagen [72] tratan el tema de la evolución simultánea de los pesos y la topología de la red, mientras que Jacobs [73] y Arabshahi et al. [74] se centran en la modificación de los parámetros de control de las estrategias de aprendizaje mediante un control borroso de las redes.

Con el objetivo de mejorar el desempeño de la hibridación de la lógica borrosa con los algoritmos evolutivos, uno de los trabajos pioneros en este sentido es el propuesto por Herrera y Lozano (ej. algoritmos genéticos) [75], el cual ha generado una tendencia aún extendida en la actualidad. Esta tendencia se desvía hacia tres tipos de estrategias: los sistemas genéticos borrosos, los sistemas bio-inspirados y el control borroso de los parámetros de los algoritmos evolutivos.

Por otra parte, están las iniciativas de hibridación entre estrategias borrosas con algunos de los componentes de la neuro-computación y las estrategias de optimización. Por ejemplo, relacionado con los DLB (Dispositivo Lógico Borroso) de tipo Mamdani, en los cuales su base de conocimientos está formada por los factores de escala (FE), las funciones de pertenencia (FP) y la base de reglas (BR), se han desarrollado estrategias para el ajuste de estos componentes mediante redes técnicas meta-heurísticas.

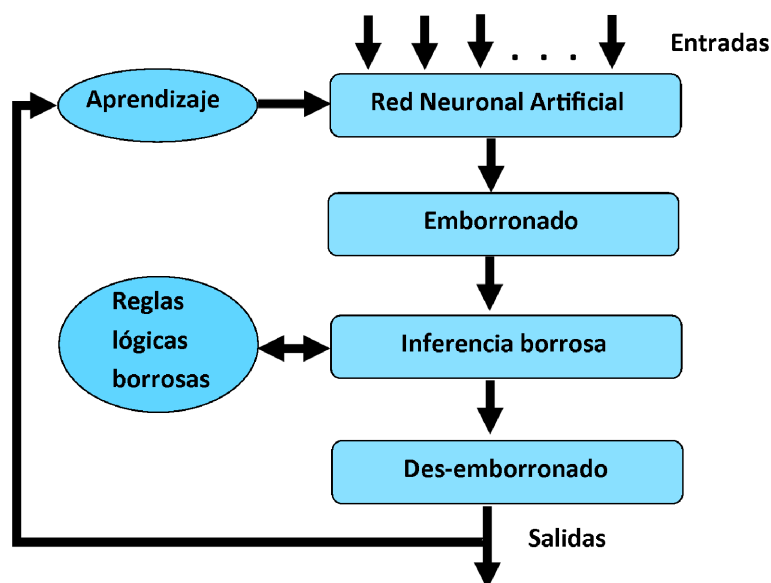


Figura 1.5. Sistema híbrido neuroborroso para modelado de procesos.
(Kumari et al. [76])

Como resultado de la combinación y explotación de las sinergias entre el razonamiento humano de los sistemas borrosos con el aprendizaje y la estructura conexionista de las redes neuronales, nos encontramos ante los comúnmente extendidos **sistemas neuroborrosos** que son, en esencia, sistemas de inferencia borrosa ajustados mediante redes neuronales o a través de sus estrategias de aprendizaje (ver Figura 1.5). Estos sistemas pueden ser de tipo TSK que son aquellos en que su estructura se equipara con las redes neuronales de base radial [77, 78], o de tipo Mamdani. Para este segundo tipo, como ejemplos están el sistema NEFCON [79], desarrollado por Nauck en 1994 para tareas de control y el sistema NEFCLASS [80], propuesto por Nauck y Kruse para ejecutar labores de clasificación.

Por otra parte, uno de los primeros sistemas neuroborrosos conocidos, basado en el modelo de Takagi-Sugeno, es el sistema de inferencia borrosa basado en redes neuronales adaptativas ANFIS (*Adaptive Network based Fuzzy Inference System*) [81]. Estas reglas borrosas se extraen a partir de datos del propio proceso, a través de una estrategia de descomposición, donde las reglas son extraídas en cada nivel de una red neuronal, hasta conseguir la información necesaria global del proceso.

En un trabajo seminal de 1993, Jang [82] propuso este tipo de sistemas, los cuales no son más que redes neuronales artificiales multicapas con alimentación hacia adelante, con la diferencia de que las funciones de activación pueden ser diferentes en cada nodo y además, con la capacidad de poder ser entrenadas de forma híbrida (Ver Figura 1.6).

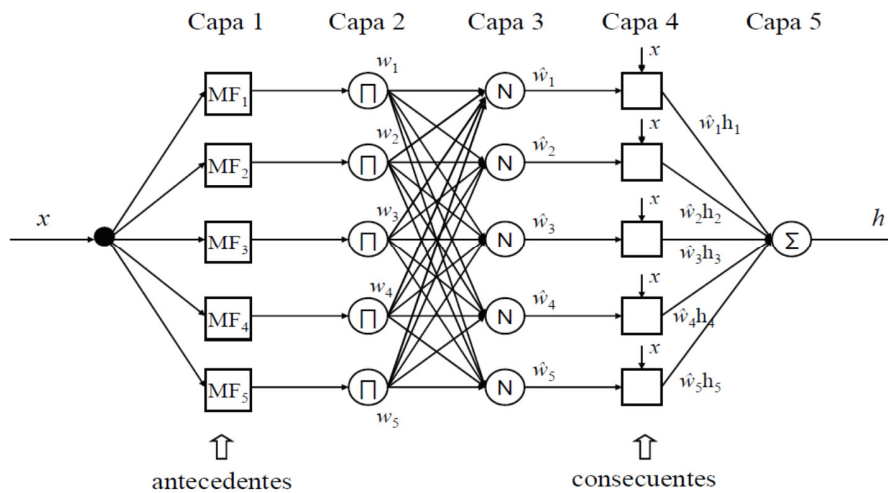


Figura 1.6. Arquitectura ANFIS equivalente.
(Adaptación de Jang, 1993 [82])

En cambio, de la combinación de la lógica borrosa con las técnicas de optimización, un ejemplo clásico de hibridación son los sistemas de inferencia borrosa generados y ajustados mediante algoritmos evolutivos. Para el caso del DLB en tareas de control, una estrategia fácil y práctica en su implementación es utilizar alguna función de coste que evalúe el comportamiento o desempeño del sistema de control a bucle o lazo cerrado. De esta manera a partir de los valores que alcanza la función de coste, empleando estrategias de optimización, puede ajustarse el DLB de forma óptima, ya sea por medio de las funciones de pertenencia o los factores de escala.

A principios de los años 90, se produce una avalancha de trabajos imposibles de ser recogidos todos en un capítulo de este trabajo, en los que se explora las potencialidades del empleo de los algoritmos genéticos para el ajuste de dispositivos lógicos borrosos, principalmente para el control de procesos. Este hecho fue recogido en una publicación en 1996 por Cordon et al. [83], en el cual se relacionan más de 500 publicaciones de este tema. Algunas de las principales contribuciones constituyen por ejemplo, el trabajo de Karr de 1991 [84], uno de los precursores de esta estrategia de hibridación, proponiendo el ajuste de las funciones de pertenencia del DLB mediante algoritmos genéticos. Otro de los trabajos a resaltar es la propuesta de Lee y Takagi, publicada en 1992 [85], en la cual se ajustan las funciones de pertenencia y la base de reglas del DLB de tipo TSK, empleando cromosomas formados por la concatenación de los parámetros de las funciones de pertenencia del antecedente de cada regla y los coeficientes del polinomio del consecuente.

Otra de las propuestas claves, es el trabajo de Bonissone et al. [86] inspirado en el procedimiento de Zheng para el ajuste manual del DLB [87]. Estos autores realizan el ajuste en tres etapas empleando algoritmos genéticos. Primeramente, a partir de una definición de las funciones de pertenencia de forma distribuida en todo el universo de discurso de cada una de

las variables, realizan un ajuste de los factores de escala, tanto de entrada como de salida, causando un efecto “macroscópico” en la base de conocimientos del DLB, ya que los factores de escala definen los rangos de las variables dentro del universo de discurso y por tanto determinan el rango de las reglas, dentro de la base de reglas, que se activarán. Seguidamente, se efectúa un ajuste de las funciones de pertenencia, causando un efecto “mesoscópico” y finalmente, si es necesario un mejor desempeño, se ajusta la base de reglas provocando un efecto “microscópico” en la base de conocimientos del dispositivo lógico borroso.

Tabla 1.1. Sistemas de supervisión inteligente basados en técnicas de AI y sistemas embebidos de procesos complejos.

Técnica y aplicación	Autores
Computación probabilística, Redes Bayesianas. Modelado y monitorización.	Correa et al., 2008 [88]; Flynn y Todd, 2010 [89]; Elliott y Williams, 2006 [90]
Redes neuronales. Modelado y monitorización.	Alippi y Piuri, 1996 [91]; Coit et al., 1998 [92]; Feng et al., 2002 [93]
Redes neuronales. Modelado y monitorización.	Chen y Liao, 2002 [94]; Yu y Xi, 2009 [95]; Gebraeel et al., 2004 [96]; Smith y Eli, 1995 [97]
Lógica borrosa. Modelado y monitorización.	Yoo et al, 2003 [98]; Becker et al., [99]
Sistemas híbridos neuroborrosos. Modelado y monitorización.	Fantoni, 2000 [100]; Wang et al., 2004 [101]; Kothamasu y Huang [102]; Waewsaka et al., 2010 [103]; Kamel et al., 2015 [104]; Zarkogianni et al., 2015 [105]; Dzakpasu et al., 2015 [106]; Azmi, 2015 [107]
Algoritmos evolutivos, hibridación. Modelado y monitorización.	Kim, 1999 [108]; Li et al., 2010 [109]
Máquinas de estado y toma de decisiones. Modelado.	Foukarakis et al., 2014 [110]
Sistema embebido inteligente (ej., RNA, LB, entre otros). Supervisión.	Silva et al., 2015 [111]; King, 1992 [112]
Arquitectura de tiempo real. Supervisión.	Treutterer et al, 2014 [113]; Cantillo et al, 2004 [114]; Viano et al, 2000 [115]

En la Tabla 1.1 se resumen algunos trabajos disponibles en la literatura, en los cuales se aplican varios sistemas de supervisión inteligente basados en técnicas de AI y sistemas embebidos a diferentes procesos complejos.

En este trabajo se hará uso de algunas de las ideas de hibridación propuestas en la literatura y que serán acondicionadas para ser aplicadas en la supervisión inteligente en tiempo real, ya sea de forma directa o mediante estrategias basada en modelos de variables representativas de procesos complejos. De entre toda la amalgama de estrategias estudiadas, se comprobará el desempeño de utilizar algunas de las más comúnmente utilizadas en el modelado de variables representativas de procesos complejos, como, por ejemplo, son las técnicas de regresión neuroborrosa o las estrategias de modelo libre o no paramétrico, así como algún método heurístico o basado en algoritmos evolutivos, pertenecientes a diferentes subclases de técnicas, para el diseño y ajuste óptimo de los parámetros de los sistemas inteligentes. En específico se explorará la viabilidad entre el algoritmo de modelado híbrido incremental y los sistemas neuroborrosos, para la generación de modelos; y el algoritmo de retro-propagación de errores y el algoritmo de temple simulado, para una parametrización óptima de los modelos. Las diferentes estrategias serán utilizadas para la monitorización de procesos de micromecanizado, de los cuales se realizará una breve introducción en la siguiente sección.

1.2 Operaciones de Microfabricación como proceso electromecánico complejo

La Microfabricación se puede definir en realidad como una colección de tecnologías que se utilizan en la fabricación de microdispositivos, 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 [116]. A diferencia de la fabricación tradicional, la microfabricación utiliza, en gran medida, métodos no tradicionales o una miniaturización o modificación de métodos tradicionales, según corresponda, para abordar plenamente las cuestiones relacionadas con la fabricación en el micromundo. Algunas de las características de estos microcomponentes/productos son un tamaño de las características funcionales a nivel micrométrico (hasta 100 μm), tolerancias con alta precisión ($< 1 \mu\text{m}$), buena calidad superficial ($R_a < 0.5$), estructuras complicadas o 3D, uso de una gran variedad de materiales como los cerámicos, aceros duros, aleaciones de titanio, aleaciones de tungsteno, entre otros [117-119].

Existen diferentes formas de clasificar los procesos de Microfabricación. La más extendida clasifica las técnicas de Microfabricación en sistemas de fabricación microelectromecánicos (MEMS, *Micro-Electro-Mechanical Systems*) o en sistemas de fabricación no MEMS. En la actualidad, aunque de una forma menos extendida, se ha ampliado la clasificación de métodos de microfabricación MEMS a ópticos MEMS, radio frecuencia (RF-MEMS), potencia (Power-MEMS) y Bio-MEMS. La fabricación MEMS implica, en gran parte, técnicas tales como: fotolitografía, ataque químico; enchapado; LIGA (*Lithographie*

Galvanoformung Abformung, siglas en alemán); ablación laser; entre otros [120, 121]. Éstos pueden proporcionar componentes de tamaños característicos reducidos en materiales orgánicos e inorgánicos e incluso en formas 3D. Sin embargo, en la últimas dos décadas se han desarrollado una nueva categoría de técnicas de Microfabricación, conocidas como no-MEMS que implica técnicas tales como: EDM, microcorte mecánico, corte por láser / patrón; microestampado, moldeo por microinyección, microextrusión, entre otros. Por otra parte, los procesos de Microfabricación también suelen clasificarse en función del tipo de proceso realizado, diferenciando entre sustractivo, aditivo, deformación del material (*mass containing*) y de unión e híbrido, tal y como ilustra la Figura 1.7:

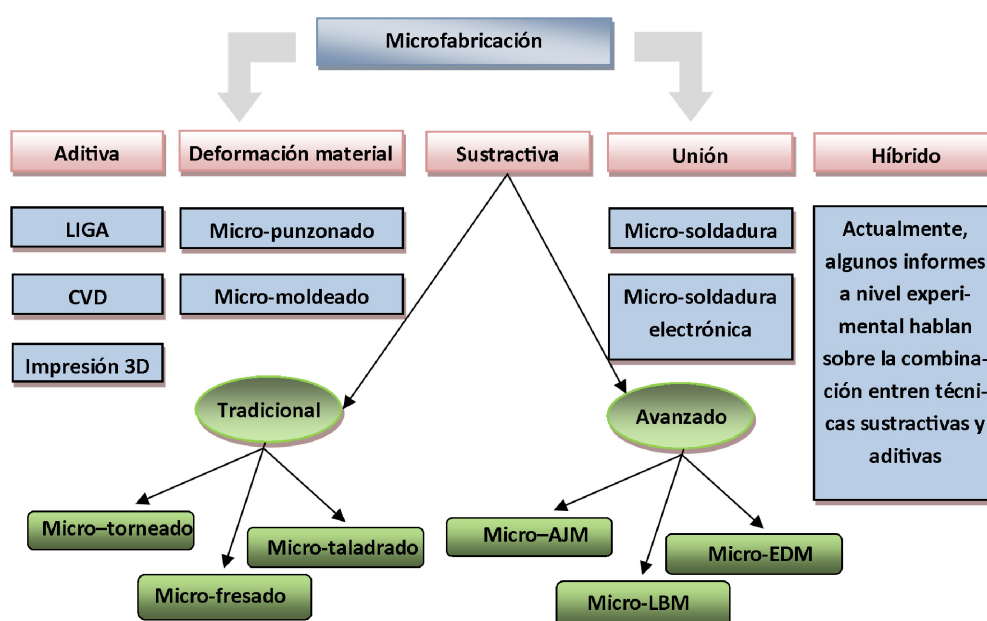


Figura 1.7. Organigrama de las diferentes técnicas de Microfabricación.
(Adaptación de Piljek *et ál* [122])

- **Aditivos**, están asociados a los sistemas microelectro-mecánicos (MEMS). En esta categoría, por citar algunos de los más reportados en la literatura científica, se incluyen la deposición química por vapor (CVD, *Chemical Vapor Deposition*), deposición física por vapor (PVD, *physical vapor deposition*), estereo-litografía, litografía por impresión galvanoplástica (LIGA), entre otros.
- **Deformación del material (*mass containing*)**, se clasifican en dos grandes familias. La primera está relacionada con las tecnologías de microconformado, como son la microforja; microperforación; microrodadura y microextrusión. Uno de los desafíos para la comunidad científica es adaptar y acondicionar a la escala micro, el conocimiento científico y tecnológico que se dispone de las tecnologías de conformado de metal

convencionales. Por otro lado, la segunda está relacionada con las operaciones de microfundición y micro moldeo.

- **Microunión**, ha sido una parte integral de la industria de la microelectrónica, la medicina, la industria aeroespacial y de defensa de microfabricación durante muchas décadas. Pertenecen a este tipo de proceso de fabricación la microsoldadura, microsoldadura electrónica, microsoldadura dura y la unión adhesiva. Estas operaciones de microunión se pueden realizar mediante acoplamiento mecánico, eléctrico o incluso óptico [123].
- **Máquinas híbridas**, son una de las líneas de interés prioritarias para los investigadores y fabricantes de todo el mundo. El nuevo concepto introducido para el desarrollo de máquinas híbridas se centra en utilizar una sola estación de trabajo para la fabricación de microcomponentes. La idea es la reducción o eliminación de un gran número de operaciones de post-montaje que puedan implicar varios esfuerzos en la manipulación y el posicionamiento de alta precisión (ej., aditivo + sustractivo).
- **Microsustractivos o micromecanizados**, se clasifican en dos subclases: **tradicionales y avanzados**. El micromecanizado es la eliminación de material en forma de virutas o restos con tamaños de herramientas en el rango de micras de 1 μm a 999 μm . También, puede ser considerado como un proceso de eliminación de material con ultra precisión, capaz de lograr una exactitud y acabado de varios nanómetros en la microforma [124, 125].

El micromecanizado hace referencia al microcorte mecánico que utiliza dientes de corte con una geometría determinada, llevado a cabo mediante un centro de mecanizado (máquina-herramienta convencional) de alta precisión. Las máquina-herramientas pueden operarse de forma manual (a través de servomecanismos) o de forma automatizada, mediante un control numérico computarizado (CNC). Estas máquinas son capaces de repetir secuencias de órdenes con precisión, pudiendo producir, por tanto, piezas de mayor complejidad. Aunque la fabricación basada en litografiado puede alcanzar una característica de tamaño más reducido, el micromecanizado mecánico tiene muchas ventajas en términos de elección de materiales, precisión relativa y complejidad en la geometría producida. Estas ventajas constituyen, además, una premisa tecnológica necesaria al producir el salto de escalado desde el dominio macro hasta el micro/nano [126, 127].

Entre las operaciones que forman parte de los procesos de micromecanizado tradicionales (ver ejemplos de la Figura 1.8) se encuentran el microtaladrado, microtorneado, microfresado, microlaminado, microrectificado, entre otras; siendo las tres primeras las operaciones con mayor peso en la industria.

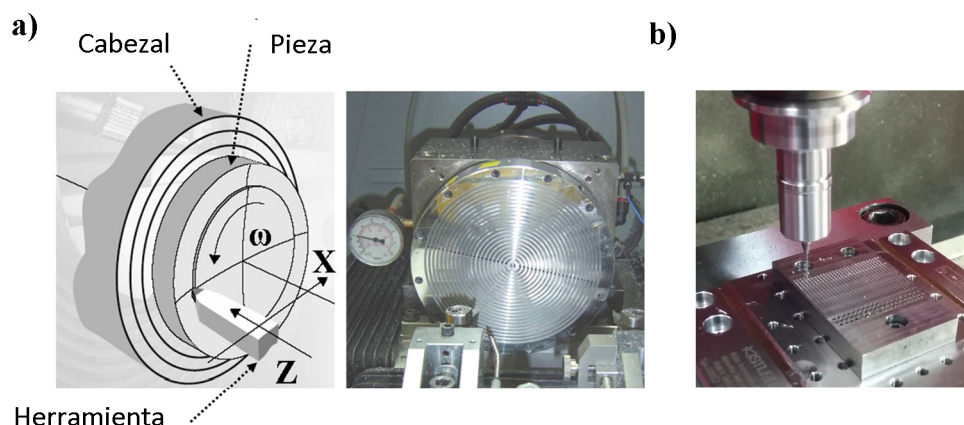


Figura 1.8. Ejemplos de operaciones de micromecanizado tradicional. a) Proceso de microtorneado y b) proceso de microtaladrado.

Por otra parte, el desarrollo de nuevas tecnologías ha traído consigo la implantación en los últimos años de nuevos procesos de micromecanizado, en los cuales el arranque de material se produce de forma no tradicional, empleando energía térmica, mecánica, química, eléctrica o la combinación entre ellas, que vienen a denominarse operaciones de mecanizado avanzado (ver ejemplos de operaciones en la Figura 1.8). Estas operaciones suelen dividirse en cuatro categorías [128], en función del mecanismo de sustracción del material:




Figura 1.9. Ejemplos de operaciones de micromecanizado no convencional. (a) Mecanizado electroquímico. (b) Micromecanizado ultrasónico (Micro USM). (Imágenes adaptadas de [129])

1. Químicas: el mecanismo de arranque se produce por una reacción química o iónica. Ej., el micromecanizado fotoquímico (Micro PCM, *Photochemical micromachining*), conocido también como microfresado químico.

2. Eléctricas o electroquímicas: en estos tipos de procesos, el mecanismo de arranque se produce por una reacción iónica (electrolítica) en la superficie de la pieza de trabajo. Ej., micromecanizado electroquímico (Micro ECM, *Micro Electro-Chemical Machining*).
3. Térmicas: la energía para el arranque de material se proporciona en forma de calor. Entre sus operaciones podemos citar el micromecanizado por electro-erosión (Micro EDM, *Micro Electro-Discharge Machining*), con rayo láser (Micro LBM, *Micro Laser-Beam Machining*), entre otros.
4. Mecánicas: la eliminación de material se produce por erosión, ej., chorro de material abrasivo (Micro AJM, *Abrasive jet machining*), micromecanizado por ultrasonidos (Micro USM, *Micro Ultrasonic Machining*), entre otros.

En vista de la creciente demanda de componentes en la escala micro, las operaciones de micromecanizado en general, y microtaladrado y microfresado en especial, han ido incrementando su importancia en las operaciones de mayor relevancia dentro los procesos de fabricación y ensamblaje de microcomponentes [130, 131]. Estas aplicaciones requieren tecnologías de fabricación que sean capaces de asegurar características de alta precisión y aumentar la productividad en las operaciones de corte con mayores profundidades por pasada con diámetros de herramienta cada vez más pequeños.

Los métodos de mecanizado no tradicionales o avanzados son los más comúnmente utilizados en la realización de operaciones de micromecanizado (ej., láser de electrones, haz láser o electro-descarga) y métodos químicos (ej., pulido electrolítico, mecanizado electro-mecánico) [132]. Sin embargo, la producción de piezas cada vez con mayores requerimientos de profundidad por pasada, mediante operaciones de micromecanizado mecánico, es preferible para una gran variedad de aplicaciones. Esto es debido a los requisitos de alta eficiencia económica y alta productividad que se puede llegar a alcanzar con este tipo de operaciones.

Una de las cuestiones clave de este tipo de procesos es que su complejidad aumenta de forma simultánea a la disminución del diámetro y con el aumento de la profundidad de corte. Esto es causado por la eliminación insuficiente de viruta y la producción de calor, así como problemas relacionados con una lubricación ineficaz, causada por los suministros insuficientes de refrigerante líquido en las áreas necesarias en estas escalas. Debido a estos problemas, el estado de la herramienta se puede deteriorar de manera significativa y en ocasiones incluso puede llegar a provocar la rotura debido a pequeños impactos, fuerzas de flexión o torsión. Por otra parte, en este tipo de operaciones es prácticamente imposible para los operadores expertos supervisar las operaciones de micromecanizado mediante solamente inspección visual o señales audibles, debido a las dimensiones de las herramientas, virutas, rebabas y la cantidad de lubricante que se usa [133, 134].

Por estas razones, junto con la fuerte competencia a nivel internacional en el sector del mecanizado, se hace estrictamente necesario el desarrollo e implementación de sistemas de monitorización y supervisión que mejoren los procesos productivos en todas sus facetas, como pueden ser: incremento de las tasas de arranque del material, disminución de tiempos de parada, mejora de la calidad superficial y dimensional de los componentes fabricados, conservación de las herramientas de corte y durabilidad de las máquinas, entre otras [127]. Además, el operador podrá observar y escuchar el proceso de corte en un proceso de microfabricación tradicional y ser alertado mediante una señal visual o acústica de un mal funcionamiento o fallo de la máquina herramienta. Sin embargo, la complejidad intrínseca de estos procesos hace que esta tarea no resulte nada sencilla. La fuerte interacción en las máquinas debido al movimiento relativo entre la pieza y la herramienta genera problemas como por ejemplo, vibraciones y retemblado, la obtención de formas y de acabados imprecisos, deformaciones de orígenes mecánicos o térmicos, etc [135].

De ello se extrae que debido a la complejidad de la tarea de monitorización en la micro escala se requieren sensores y sistemas sensoriales apropiados. A su vez, existe una tendencia global hacia la utilización y desarrollo de técnicas de fabricación cada vez más rentables basadas en el conocimiento; convirtiéndose también éste en otro nuevo reto. El desarrollo de las ciencias de la computación y las tecnologías de los ordenadores, los dispositivos electromecánicos, los sistemas de medición avanzados, los nuevos materiales, se ha producido de forma simultánea con el empuje, competencia y exigencias en general de la industria de microfabricación. Estos avances han conducido a un incremento en la necesidad de desarrollar e implementar estrategias basadas en la investigación y en la innovación que permitan, a nivel funcional, el aprovechamiento efectivo de la complementariedad y de las sinergias provenientes de diferentes áreas científicas y tecnológicas. Es por ello que los objetivos de este trabajo están encaminados al diseño de estrategias de supervisión y modelado con capacidad de ser embebidas, basadas en **técnicas de Inteligencia Artificial , junto con el diseño e implementación de arquitecturas de tiempo real y sistemas sensoriales, para la monitorización inteligente de procesos de micromecanizado**. Esto será posible gracias al conocimiento generado sobre estos procesos y mediante un método integrador de sistemas de tomas de decisiones, máquinas de estado, diseño de sensores de aplicación específica, hibridación de técnicas de *soft-computing*, técnicas de razonamiento y técnicas de agrupamiento que propiciará potencialidades y sinergias no reportadas anteriormente en el campo de la supervisión inteligente.

1.3 Tiempo real e Inteligencia artificial en la monitorización de procesos de micromecanizado

En la actualidad, una amplia gama de métodos convencionales (llamados así para distinguirlos de las técnicas inteligentes) han sido utilizados para el diseño de sistemas de

monitorización y supervisión. La presentación de la monitorización al usuario puede entregarse de forma directa o ser modificada por algoritmos embebidos que conviertan la información a un formato más conciso y entendible por el operador. En una etapa ulterior, estos algoritmos podrían incorporar módulos de toma de decisiones con capacidades de ayudar en la toma de ciertas medidas correctivas, por si mismas. Otra capacidad más a añadir, sería dotar a la ejecución sistema de cierto determinismo convirtiendo la monitorización del estado del proceso en un sistema de tiempo de real.

En la Tabla 1.2 se resumen algunos trabajos disponibles en la literatura, en los cuales se aplican varios sensores en la monitorización del estado de algunos procesos complejos, la mayoría de ellos en tiempo real. A partir de estas características se pueden dilucidar cuáles podrían ser sus posibles aplicaciones. Sin embargo, los resultados de aplicar estrategias tradicionales a diferentes procesos complejos no han cumplido con las expectativas sino que por el contrario han generado muchas falsas alarmas, ya que requieren de un modelo exacto del proceso, por ejemplo, ecuaciones diferenciales, funciones de transferencia y ecuaciones de estado.

Tabla 1.2. Aplicación de la monitorización directa a diferentes procesos complejos.

Sensor y aplicación	Autores
Sensor de ondas electromagnéticas. Monitorización en tiempo real.	Muradov et al, 2015 [136]; Judd et al, 2005 [137]
SCADA para medición. Monitorización de motor trifásico.	Işık et al, 2016 [138]
Acelerómetro tri-axial (vibraciones). Monitorización del estado.	Er et al., 2016 [139]
Fuerza de corte. Monitorización en tiempo real.	Nouri et al., 2015 [140]
Voltaje, corriente, virtuales. Monitorización en tiempo real.	Caggiano et al., 2015 [141]; Portillo et al, 2009 [142]; Cabanes et al, 2008 [143]

En la actualidad, el funcionamiento deficiente de estos sistemas reclama la atención de la comunidad científica con el fin de superar los problemas relacionados con las falsas alarmas en la supervisión de los procesos de mecanizado.

Entre los métodos destacan los basados en técnicas de Inteligencia Artificial, entre las cuales se destacan la lógica borrosa, las redes neuronales artificiales (RNA), los algoritmos evolutivos y los sistemas híbridos (sistemas neuroborrosos, sistemas neuro-evolutivos, entre otros), han probado ser efectivas en muchas aplicaciones y constituyen la base en esta Tesis

Doctoral para mejorar los esquemas de monitorización disponibles en la actualidad. De todas las técnicas disponibles, los algoritmos basados en las RNA son tal vez los más convenientes para el análisis de información sensorial y la obtención de datos acerca del estado del proceso y de la herramienta. **Las RNA ofrecen un enfoque excepcional para modelar procesos complejos** ya que se caracterizan por **su viabilidad para la implementación por hardware, su habilidad para el funcionamiento en tiempo real y su capacidad para describir procesos con elevada incertidumbre** [144, 145]. Algunos resultados muestran que las redes neuronales artificiales pueden generar modelos más exactos que métodos clásicos tales como los métodos de regresión.

En un primer trabajo publicado en el 2000, Tansel et al., 2000 [146] muestran la construcción y aplicación de modelos neuronales para la monitorización de procesos de micromecanizado (microfresado) de metales, en cuanto a desgaste de herramienta se refiere; mientras que en una segunda parte de esta misma publicación [147], proponen una validación de estos modelos neuronales en materiales no metálicos. Diversas aplicaciones de modelado de procesos de micromecanizado a través de redes neuronales artificiales basadas en relaciones entradas-salidas han sido reportadas en la literatura. Ejemplo de ello constituyen las aplicaciones satisfactorias de las redes neuronales artificiales (RNA) para predecir el número de agujero actual en el microtaladrado a diferentes velocidades del cabezal y avance propuesto por Ranjan y Patra [148]; red neuronal de propagación hacia atrás para identificar el estado del desgaste de la herramienta en base a las vibraciones del cabezal propuesto por Hsieh et al. [149]; la derivación de una red neuronal de función de base radial como base de un modelo no lineal dinámico de un micromáquina de 3kVA [150]. Algunas de éstas técnicas realizan una hibridación con otras técnicas de análisis (ej., estadísticas) a la hora del ajuste de los parámetros. Existen otros trabajos, como el de Zhu et al. [151], donde el modelado neuronal tiene peores prestaciones en comparación con otro tipo de métodos, como puedan ser los estocásticos. A pesar de sus cualidades, las RNA no han sido tan bien acogidas por parte del sector tecnológico e industrial como las técnicas borrosas. A su excelente capacidad de interpolación, se unen ciertas dificultades relacionadas con la poca precisión y exactitud en la extrapolación, lo que conduce a un reentrenamiento forzoso. De ahí que sea necesario un aprendizaje efectivo, que sólo es posible excitando el proceso suficientemente en la identificación y explorando un amplio rango de posibles condiciones de trabajo.

De lo anterior se deduce, por tanto, que la **lógica borrosa** también ha desempeñado un papel muy importante en el modelado y supervisión de procesos de micromecanizado. El modelado basado en la teoría de conjuntos borrosos es usualmente utilizado cuando existe conocimiento subjetivo del proceso u opiniones de operadores expertos, desempeñando un papel fundamental en la definición de funciones objetivo y variables de decisión. Hassan et al. proponen un modelo que sugiere la posibilidad de desarrollar un sistema experto en tiempo real e integrado, haciendo uso de lógica borrosa para monitorizar la erosión de los aceros para

turbo-maquinaria y micromecanizado. Otro modelo borroso es presentado por Ren et al. [152]. En este caso se le añade la potencialidad de agrupamiento sustractivo para la predicción de las fuerzas de corte en un proceso de microfresado [153]. Skrabalak et al. presentan un modelo simplificado basado en reglas borrosas para la estimación del efecto causado por la disolución electroquímica y las descargas eléctricas en la superficie de la pieza en los procesos de μ -ECM y μ -EDM [154].

Por otra parte, en la literatura consultada abundan trabajos basados en lógica borrosa y RNA para el modelado y monitorización de procesos de mecanizado, los llamados sistemas neuroborrosos. Para resolver el problema de la interferencia de ruido para el proceso de identificación de sistemas dinámicos de tiempo variable, como los procesos de micromecanizado, D. Li et al. proponen una red de tipo II neuroborrosa (FNN) con intervalos recurrentes de auto-organización [114]. A través de un método neuroborroso, Malekian et al. fusionan la información de las señales del proceso para determinar si la herramienta está en buen estado o está desgastada [115].

Tabla 1.3. Técnicas de AI en la supervisión de procesos de micromecanizado.

Modelado, Monitorización y Supervisión	Relacionado con	Autores
Modelo ANFIS para micropulido y micromecanizado por electroerosión	Calidad superficial	Suganthi et al., 2013 [155]
Modelo ANFIS para microtorneado	Herramienta y viruta	Palani et al., 2013 [156]
Algoritmo de colonias de abejas artificial para optimización de procesos micromecanizado electro-químico	Herramienta, superficie y viruta	Samanta y Chakraborty, 2011 [157]
RNA de propagación hacia atrás para predicción del proceso de micro electro-erosión.	Tolerancia	Kumar et al., 2014 [158]
Lógica borrosa para la optimización de la respuesta de múltiples procesos en el micromecanizado electroquímico .	Viruta y tolerancia	Manna, 2012 [159]
Sistema borroso-genético para el modelado del proceso de microtaladrado .	Esfuerzo de empuje	Beruvides et al., 2014 [160]
RNA para predecir procesos de microfresado	Rebaba	Zhu et al., 2011 [161]

Para una mayor ilustración de las aplicaciones de las técnicas de AI para la supervisión de procesos de micromecanizado, en la Tabla 1.3 se resumen otras aportaciones recogidas en la literatura y se especifica el proceso de microfabricación en específico y la variable a modelar o monitorizar.

Por otro lado, con un mayor enfoque hacia el tipo de operación de micromecanizado al cual se ha aplicado la técnica y a través de una clasificación de los procesos en operaciones tradicionales y no convencionales, en la Tabla 1.4 también se resumen varias de las propuestas y aportaciones de los últimos años.

A pesar de todas las aplicaciones desarrolladas, el empleo aislado de sistemas borrosos diseñados a partir del conocimiento de operadores expertos, no resulta óptimo para el modelado de los cambios dinámicos subyacentes en cualquier proceso de mecanizado. El aprovechamiento de las sinergias con otras técnicas básicas del *soft-computing*, y por tanto de la AI, permitirán, como ya se ha demostrado por algunas de las aportaciones recogidas en la literatura, el diseño de sistemas inteligentes que aprovechen de forma óptima el conocimiento de estos expertos, que en ocasiones puede carecer de precisión y completitud, y que permitan, además, enfrentar los problemas de complejidad de los procesos de micromecanizado mediante soluciones robustas y de menor coste.

Tabla 1.4. Sistemas inteligentes en la automatización de procesos de micromecanizado.

	Sistemas Inteligentes en la Automatización	Operación	Autores
Micromecanizado no convencional	Algoritmo basado en búsqueda diferencial para optimización del proceso.	Micromecanizado electroquímico	Goswami y Chakraborty, 2014 [162]
	Modelo borroso para la optimización de parámetros	Micromecanizado electroquímico	Venkatesh et al., 2014 [163]
	Modelo borroso para la predicción de la rugosidad superficial	Micro electroerosión (μ-EDM)	Saxena et al., 2014 [164]
	Comparación entre RNA y DoE para el modelado del acabado final del proceso. MLP para el modelado del proceso.	Micromecanizado láser (μ-LBM) Micromecanizado láser (μ-LBM)	Karazi et al., 2009 [165] Teixidor et al., 2015 [166]
Micromecanizado tradicional	Modelo matemático de rugosidad superficial mediante el algoritmo de optimización de colonia de hormigas.	Microfresado	Pansare y Sharma, 2015 [167]
	Modelo borroso del desgaste de la herramienta y emisión acústica.	Microtorneado	Ren et al., 2014 [168]
	RNA para predecir la fuerza de corte.	Microtaladrado	Beruvides et al., 2014 [169]
	Modelo RNA para predecir la rugosidad y las vibraciones en la pieza	Microfresado	Venkata Rao et al., 2015 [170]
Sistema neuroborroso para optimización y monitorización de procesos	Micropulido mecánico	Lipiński y Majewski, 2015 [171]	

A pesar de todas las aplicaciones desarrolladas, el empleo aislado de sistemas borrosos diseñados a partir del conocimiento de operadores expertos, no resulta óptimo para el modelado de los cambios dinámicos subyacentes en cualquier proceso de mecanizado. El aprovechamiento de las sinergias con otras técnicas básicas del *soft-computing*, y por tanto de la AI, permitirán, como ya se ha demostrado por algunas de las aportaciones recogidas en la literatura, el diseño de sistemas inteligentes que aprovechen de forma óptima el conocimiento de estos expertos, que en ocasiones puede carecer de precisión y completitud, y que permitan, además, enfrentar los problemas de complejidad de los procesos de micromecanizado mediante soluciones robustas y de menor coste.

En este sentido, la actividad investigadora, que ha servido como base para el desarrollo de esta Tesis Doctoral, se ha enfocado al desarrollo de estrategias y algoritmos basados en la conjunción de paradigmas de las Ciencias de la Computación y la Inteligencia Artificial y de la Electrónica y Automática. Esta actividad dio sus primeros pasos en el marco de los proyectos de investigación COGNETCON [171] y MICALET [172]. En estos proyectos que han servido como instrumentos para el desarrollo de la investigación recogida en esta Tesis Doctoral, se han diseñado e implementado modelos, sistemas de monitorización y control cognitivo en red, en arquitecturas embebidas distribuidas para la supervisión y optimización de procesos de fabricación complejos y en específico, operaciones de micromecanizado en la macro y microescala, respectivamente.

Estas investigaciones han dado lugar al desarrollo de una arquitectura basada en un servidor de comunicaciones y en un sistema operativo embebido de tiempo real, para incorporar varios sistemas de monitorización integrados en una misma plataforma y con ejecución paralela. Se han diseñado e implementado, también, algoritmos computacionalmente eficientes basados en los paradigmas de la IA para la monitorización, basada o no en modelos experimentales, para ser aplicados a la supervisión inteligente de procesos de microfabricación. En la actualidad, esta actividad investigadora ha continuado en el marco del proyecto de investigación CONMICRO [173], siendo el objetivo principal el desarrollo de un método para el diseño de un sistema de control cognitivo en red, basado en modelos internos, para procesos de micromecanizado.

Otro aspecto de indudable importancia, es la disponibilidad de un laboratorio único en la Comunidad de Madrid y en el CSIC para las investigaciones en el campo de los procesos de fabricación en la micro escala, que está dotado de los dispositivos necesarios que permitirán, sin dudas, llevar a cabo una de las tareas más importantes en la metodología científica: la evaluación experimental. Se cuenta con un centro de Mecanizado Kern Evo de ultra precisión ($\pm 0.5 \mu\text{m}$ y $R_a < 0.1 \mu\text{m}$) equipado con un control numérico Heidenhain iTNC-530.

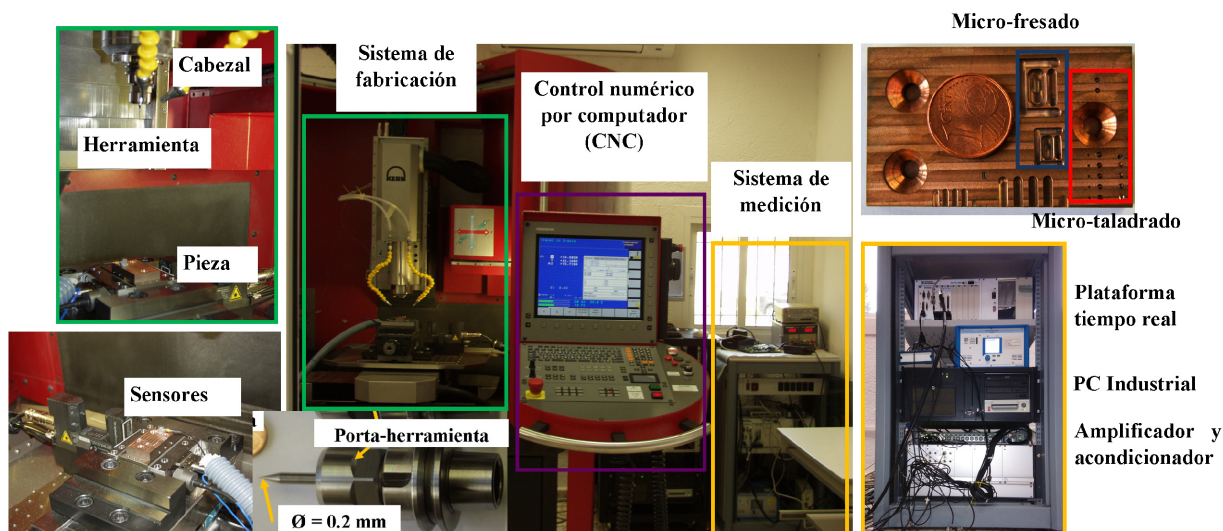


Figura 1.10. Imagen del laboratorio disponible en el Centro de Automática y Robótica (UPM-CSIC) para investigaciones en procesos de microfabricación

Igualmente, se dispone de un sistema de medición (sensores y tarjetas DAQ) tales como sensores de fuerza, aceleración, emisión acústica y tarjetas de digitalizadoras. Todos estos elementos serán descritos con mayor detenimiento en los Capítulos 2 y 7. Debido a la disponibilidad de estas infraestructuras y los equipos de medida, uno de los aspectos novedosos de esta Tesis es, precisamente, la posibilidad de validar experimentalmente los resultados predichos en la fase teórica.

En definitiva, gracias a los conocimientos científicos y técnicos adquiridos en los proyectos citados con anterioridad en los que se ha participado de forma activa, junto a las infraestructuras únicas en la Comunidad de Madrid y el CSIC, se evidenció la necesidad de desarrollar nuevas capacidades en los sistemas de supervisión inteligentes de procesos complejos de fabricación. Es por ello que la actividad investigadora que sustenta el desarrollo de esta Tesis Doctoral, se ha dirigido al desarrollo de métodos computacionalmente eficientes para la monitorización, con capacidad de ser embebidas en arquitecturas de tiempo real, en red, modulares y reconfigurables y, el desarrollo de un servidor de comunicaciones que interactúa con algunas variables del CNC de la máquina-herramienta. Estos métodos se ponen a disposición de sistemas de supervisión a nivel local con capacidades de interactuar con sistemas intermediarios de los que se nutren el resto de arquitecturas a más alto nivel, constituyendo la base para el desarrollo de sistemas distribuidos de control inteligente con capacidades cognitivas a más alto nivel.

1.4 Conclusiones

En este capítulo se ha realizado una revisión del estado de la ciencia y la técnica en los paradigmas elegidos dentro del amplio universo que ponen a nuestra disposición la Teoría

General de Sistemas, la Teoría de Control, las técnicas de Inteligencia Artificial y las Ciencias de la Computación. Se ha prestado especial interés en los paradigmas con una fundamentación teórica simultánea tanto en los Sistemas de Tiempo Real como en el campo de la Inteligencia Artificial (AI), con un enfoque desde la perspectiva de la Electrónica y Automática y la Teoría de Sistemas. El estudio se ha centrado en estrategias susceptibles de ser utilizadas en el modelado y monitorización de procesos físicos, indispensablemente en tiempo real. Por este motivo, la revisión se ha enfocado hacia las técnicas del *soft-computing*, analizando su evolución desde sus inicios hasta las tendencias actuales.

Debido a que las estrategias serán aplicadas a la monitorización de procesos electromecánicos complejos, como es el caso de los procesos de micromecanizado, se ha realizado además, una breve revisión del estado de la técnica de estos procesos. Presentándose de forma breve cómo ha sido su evolución hasta nuestros días y las tendencias actuales en la aplicación de técnicas de AI, desde la perspectiva de la supervisión en tiempo real, para hacer frente a la complejidad de estos procesos y así mejorar su eficiencia.

En el siguiente capítulo se describe la aplicación de métodos de investigación tanto teóricos como experimentales para la extracción de patrones de comportamiento en señales relacionadas con variables representativas de algunos procesos, como es el caso del microtaladrado de alta precisión.

CAPÍTULO 2

SISTEMA SENSORIAL Y PROCESAMIENTO PARA EXTRACCIÓN DE CARACTERÍSTICAS EN PROCESOS COMPLEJOS

En este capítulo se presentan técnicas y métodos computacionalmente eficientes para la búsqueda de patrones de comportamiento que permitan caracterizar los sistemas físicos comunes a una gran variedad de procesos, y a partir de aquí poder emular o simular su comportamiento. La metodología empleada presenta entre sus principales etapas, la configuración de sistemas sensoriales, la elección de las estrategias de medición, procesamiento y acondicionamiento de señales, y el desarrollo de métodos de extracción de patrones y su implementación en una plataforma experimental. A partir de la literatura a la que se ha tenido acceso, también se propone una plataforma multi-sensorial de adquisición de las señales típicas, correspondientes a las diferentes variables representativas en los procesos. Para el indispensable requisito de futura implementación en tiempo real, las técnicas y métodos elegidos deben ser aquellos que conjuguen sencillez, poca carga computacional y que permitan alcanzar unos resultados satisfactorios en términos de eficiencia, robustez, fiabilidad y rendimiento. Con este estudio se pretende generar un conocimiento científico y técnico, y una mejor comprensión de los procesos de microfabricación de componentes de aleaciones especiales.

La estructura de este capítulo comienza con una descripción de métodos y técnicas eficientes para la extracción de patrones de comportamiento en señales (sección 2.1). También, se describen diferentes tipos de sensores y el comportamiento de ciertas variables físicas del proceso, así como diferentes arquitecturas multi-sensoriales para la adquisición de

las señales (sección 2.2). Como resultado, en la sección 2.3, se propone una plataforma multi-sensorial a nivel de laboratorio para llevar a cabo múltiples ensayos.

Por otra parte, como ejemplo de aplicación de la metodología descrita a un proceso específico. El proceso elegido como caso de estudio es la operación de microtaladrado, al que se le aplica una estrategia de extracción de características consistente en dos etapas. Primero, en la sección 2.4, se describe un análisis experimental preliminar para estudiar el comportamiento temporal de la información sensorial obtenida. A continuación, en la sección 2.5 se analizan exhaustivamente las características de las señales con vistas a detectar posibles patrones de comportamiento, ya sean temporales, en frecuencia o en tiempo-frecuencias, y su posible relación con el estado de la herramienta. Posteriormente, en las secciones 2.5 y 2.6 se establecen unas relaciones causa efecto entre la información sensorial y el uso de la herramienta a través de un análisis visual del comportamiento de ciertas técnicas de extracción de rasgos característicos en las señales del proceso. Por último, estos resultados son corroborados experimentalmente en la sección 2.7, a través de una regresión estadística que utiliza unos índices, como son la correlación, R^2 y la capacidad de generalización, con el objetivo de determinar qué técnica de extracción de rasgos podría monitorizar más fielmente el uso de la herramienta.

Las conclusiones de los resultados obtenidos en este capítulo, aparecen en la última sección.

2.1 Métodos de extracción de características en procesos complejos

Es de conocimiento general que una adecuada estrategia de monitorización aplicada a procesos complejos en general y de microfabricación en particular, que esté basada en el análisis de un único comportamiento o evento de una señal determinada, no es factible. Se hace necesario un análisis y procesamiento minucioso y en profundidad de las señales, con el objetivo de detectar u obtener el mayor número posible de eventos o características que puedan dar pistas sobre el comportamiento actual del proceso y poder establecer adecuadas relaciones causa-efecto.

Un esquema lógico de procesamiento de señales es el mostrado en la Figura 2.1. El diagrama está conformado por las siguientes etapas de procesamiento:

- Acondicionamiento y pre-procesamiento, que incluye el filtrado de las señales, conversión A/D y segmentación de las señales. El filtrado también puede realizarse mediante filtros discretos, es decir sobre las señales ya digitalizadas. Esta etapa puede incluir además una transformación de las señales adquiridas al dominio frecuencias o dominio tiempo-frecuencias. Por ejemplo, se podría utilizar, para el primer caso, la transformada rápida de Fourier (FFT) y, para el segundo caso, la transformada de Hilbert-Huang (HHT), la transformada *wavelet* (WT) o la Transformada de Fourier de Tiempo

Reducido (STFT, *Short-Time Fourier Transform*). Con esta última se obtiene el comportamiento espectral de la señal en pequeñas ventanas de tiempo.

- Identificar o extraer de las señales en el dominio temporal o de sus transformadas, determinados patrones de comportamiento que estén vinculados con el estado del proceso.
- Seleccionar los patrones de comportamiento más relevantes de la señal que permitan elaborar estrategias de optimización o de diagnóstico del proceso.

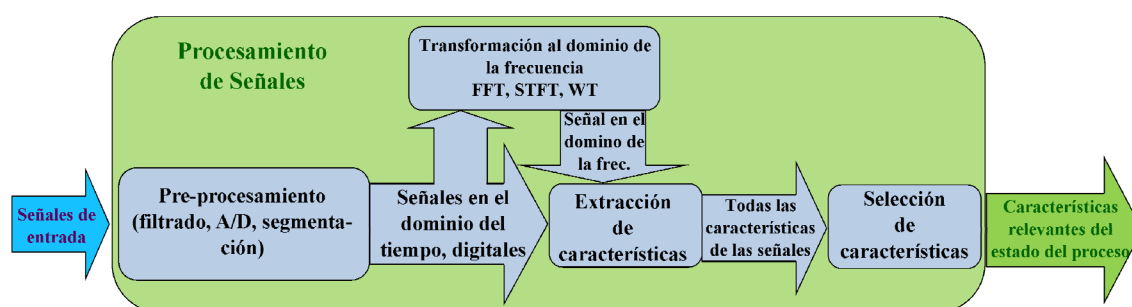


Figura 2.1. Diagrama de una estrategia de procesamiento de señales.
(Adaptación de Teti et al., 2010 [133])

2.2 Acondicionamiento y pre-procesamiento de los datos experimentales

Normalmente, las señales que proporcionan los sensores no suelen conectarse directamente al sistema de adquisición de datos (DAQ). Por lo general, cada señal es pre-procesada por un acondicionador específico para cada sensor. Por ejemplo, la Figura 2.2 muestra un esquema típico de pre-procesamiento de la señal de emisión acústica (EA), en el que se aprecian las diferentes etapas que conforman el proceso de acondicionamiento de la señal. Éste está compuesto por dispositivos electrónicos que operan directamente con la señal analógica, como pueden ser filtros analógicos paso alto (HP) y/o paso bajo (LP), amplificadores de señal, entre otros.

Finalmente, la señal una vez ha sido digitalizada se puede someter también a un procesamiento posterior. Por ejemplo, el filtrado digital de la señal reduce determinadas bandas de frecuencias que no se corresponden directamente con el proceso a monitorizar o permite extraer información vinculada a determinados patrones de comportamiento. Los filtros digitales pueden ser tanto de respuesta finita (FIR) como de respuesta infinita (IIR).

Al aplicar un algoritmo de filtrado digital a las señales medidas, se debe tener en cuenta que las respuestas dinámicas de los filtros causales, afectan tanto a la amplitud de la señal a filtrar como a sus características de fase. Por tanto, el algoritmo de filtrado introduce retrasos de tiempo en la señal filtrada y por supuesto, influirá en el resultado final que se obtenga.

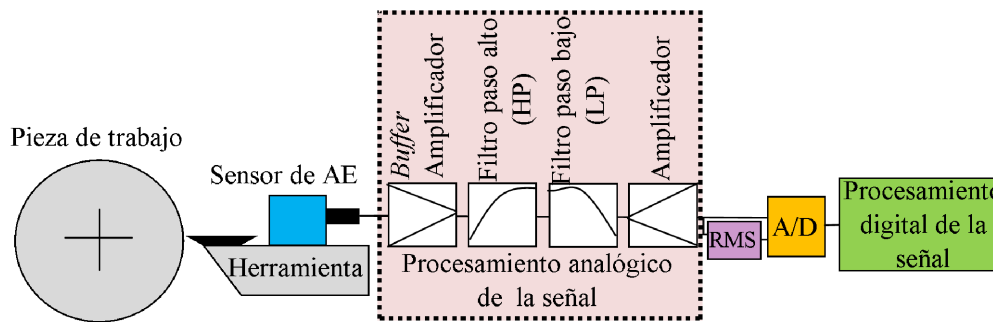


Figura 2.2. Esquema de acondicionador de señal de EA.
(Adaptación de Teti et al., 2010 [133])

El filtrado con fase cero no introduce cambio de fase en la señal que se procesa, sin embargo este tipo de filtro no cumple el principio de causalidad. Por lo tanto, no es posible su implementación en tiempo real aunque sí que puede utilizarse fuera del proceso (“*offline*”) durante el pre-procesamiento de los datos. En la Figura 2.3 se muestra un diagrama del algoritmo de filtrado [174], en el cual a una secuencia de datos que se desea filtrar $x[k]$, se le aplica un filtro causal con una característica de fase arbitraria y respuesta a impulso $h[k]$, obteniéndose la secuencia de datos $g[k]$. A continuación, la nueva secuencia es invertida ($g[-k]$), aplicándose nuevamente el mismo filtro y dando lugar a la secuencia de datos $r[k]$. Por último, esta secuencia se invierte y se obtiene $s[k]$, que constituye la secuencia filtrada pero sin cambio de fase con respecto a $x[k]$.




Figura 2.3. Algoritmo de filtrado con fase cero.

En las ecuaciones (2.1) y (2.2) se describe el algoritmo de filtrado, donde $H(e^{j\omega})$ es la transformada de Fourier de la respuesta al impulso del filtro $h[k]$; $h_1[k]$ representa la respuesta total a impulso del filtro con fase cero; y $H_1(e^{j\omega})$ es su transformada de Fourier.

$$\begin{aligned}
 g[k] &= x[k] \cdot h[k] \\
 r[k] &= g[-k] \cdot h[k]; \quad s[k] = r[-k]; \quad s[k] = x[k] \cdot h_1[k]
 \end{aligned}
 \tag{2.1}$$

$$\begin{aligned} h_1[k] &= h[k] \times h[-k] \\ H_1(e^{j\omega}) &= H(e^{j\omega}) \times H(e^{j\omega}) = |H(e^{j\omega})|^2 \end{aligned} \quad (2.2)$$

Por otra parte, un algoritmo de filtrado muy sencillo pero de gran utilidad para el procesamiento de señales periódicas, es el filtro de respuesta a impulso finita (FIR) de media móvil. El principio de este filtro reside en hallar la media de las muestras de una secuencia dada, $h[k]_{med}$, utilizando un total de muestras igual a la ventana de datos ws . La respuesta a impulso del filtro se describe en la ecuación (2.3).

$$h[k]_{med} = \frac{1}{ws} \sum_{i=0}^{ws-1} h[k-i] \quad (2.3)$$

La aplicación de este filtro a una señal periódica permitiría obtener el valor medio de la señal, su componente de directa o continua, o a muy bajas frecuencias. **Entre los procesos que se encuentran caracterizados por este tipo de señal, se encuentran los procesos de micromecanizado, donde señales de gran relevancia como las fuerzas de corte, poseen componentes periódicas dependientes de la frecuencia de giro del cabezal de la máquina.**

2.2.1 Procesamiento en el dominio del tiempo

Las estrategias más comúnmente empleadas y de mayor efectividad para el procesamiento de señales en el dominio temporal, que permiten identificar posibles patrones de comportamiento, son: su valor efectivo o medio cuadrático (*rms*, *root mean square*), valor medio o promedio, desviación estándar, valores máximos, valores mínimos, amplitud pico-valor, amplitud pico-pico, entre otras.

En el caso del valor medio, este puede determinarse aplicando el filtro de respuesta a impulso finita (FIR, *Finite Impulse Response*) de media móvil, cuya expresión matemática se indica en la ecuación (2.3). Por otra parte, en relación con el valor *rms* de la señal, ésta es una medida estadística de su magnitud y en el caso de señales sinusoidales, constituye su valor eficaz. Puede determinarse tanto en tiempo real como *off-line* de forma similar al valor medio, con la diferencia de que las muestras son elevadas al cuadrado y al promedio de éstas, se les halla su raíz cuadrada de la siguiente manera:

$$h[k]_{rms} = \left\{ \frac{1}{ws} \sum_{i=0}^{ws-1} h[k-i]^2 \right\}^{1/2} \quad (2.4)$$

La aplicación de estas estrategias permitirá realizar un estudio del comportamiento de los patrones temporales de las señales en diferentes etapas del proceso de corte, por ejemplo al inicio, intermedio y fin del corte. Se podrá analizar, además, el comportamiento de estas

magnitudes del dominio del tiempo tanto en regímenes transitorios de las señales como a estado estacionario.

2.2.2 Procesamiento en los dominios de frecuencias y tiempo-frecuencias.

El determinar patrones de comportamiento de las señales en el dominio de frecuencias se basa, inicialmente en la gran mayoría de los casos, en la **Transformada Discreta de Fourier** (DFT, *Discrete Fourier Transform*) aplicada a ventanas de datos. La Transformada Rápida de Fourier (FFT, *Fast Fourier Transform*) es un algoritmo eficiente que permite calcular la DFT y se expresa matemáticamente de la siguiente forma:

$$f_j = \sum_{k=0}^{n-1} x_k e^{-\frac{2\pi i}{n} j k}; \quad j = 0, \dots, n-1 \quad (2.5)$$

donde n es el tamaño de la ventana; x_k es la muestra de la señal en el instante de tiempo k ; y f_j es la componente compleja correspondiente a la frecuencia j .

A partir de la señal en el dominio de frecuencias, puede obtenerse información o coeficientes espectrales como la amplitud y frecuencia de los armónicos dominantes, la potencia de la señal en determinados rangos de frecuencias, la energía de la señal en determinadas bandas de frecuencia, entre otros.

El algoritmo DFT obliga a que su aplicación sea en todo el rango de tiempo durante el que se adquieren las señales vinculadas a los procesos objeto de análisis. Esto implica que todas las componentes de frecuencias sean promediadas, provocando una pérdida de información útil necesaria a la hora de la extracción de las características de las señales. Por tanto, dado el carácter no-estacionario de las señales durante estos procesos, resulta más factible aplicar el algoritmo en pequeños intervalos de tiempo, lo cual es una característica definitoria del algoritmo de **Transformada de Fourier de Tiempo Reducido** (STFT, *Short-Time Fourier Transform*). Es por ello que el análisis y procesamiento de las señales en el dominio tiempo-frecuencias aporta mayor información sobre el comportamiento del proceso de corte que el resto de transformadas de Fourier.

La STFT utiliza una ventana de datos móvil a lo largo del tiempo y permite caracterizar los cambios de las componentes en frecuencia para diferentes intervalos de tiempo. A partir de la STFT pueden obtenerse los coeficientes espectrales mencionados con anterioridad para cada ventana de tiempo y de esta forma analizar su comportamiento a lo largo del tiempo.

Otro de los métodos analíticos para la detección de patrones de comportamiento de las señales, basados en transformadas al dominio tiempo-frecuencias, es la **transformada wavelet o transformada de ondícula** (WT, *Wavelet Transform*). Esta estrategia surge como solución a determinados problemas de resolución en la STFT. Al estar definida la resolución,

tanto en frecuencias como en tiempo, por el ancho de la ventana de datos, la resolución elegida para la transformada no pueden ser tan arbitrariamente grande como se desee (principio de incertidumbre de Heisenberg), lo que resulta ser un gran inconveniente.

La teoría *wavelet* fue desarrollada a finales de los 80 por Mallat [175] y Daubechies [176]. La transformada utiliza ventanas de datos de diferentes longitudes para diferentes bandas de frecuencias. Por ejemplo, las altas frecuencias son analizadas con ventanas más estrechas para una mayor resolución temporal, mientras que para las bandas de bajas frecuencias se utilizan ventanas más amplias para una mejor resolución en frecuencias.

$C(a,b)$, que su definición depende de los índices a y b . Partiendo de un punto de vista intuitivo, la descomposición *wavelet* consiste en calcular un índice de similitud y la *wavelet* localizada en el desplazamiento b y a escala a . Si el índice es grande significa que la similitud es fuerte, en caso contrario significa que ésta es leve. Los índices $C(a,b)$ son denominados coeficientes *wavelets*.

Según la transformada WT de tiempo continuo, los coeficientes se calculan como:

$$C(a,b) = \int_R s(t) \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) dt \quad (2.6)$$

$$a \in R^+ - \{0\}, b \in R$$

donde el sub-espacio de escala a o banda de frecuencia $[1/a, 2/a]$, se genera a partir de la funciones *wavelet* hijas:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (2.7)$$

La WT prácticamente puede reducirse a filtrar la señal empleado filtros paso bajo y paso alto derivados de la *wavelet* y la función de escala. La transformada *wavelet* discreta (DWT) descompone la señal en los coeficientes de escalado y coeficientes *wavelet* mediante convolución de la señal y la respuesta a impulso de los filtros paso bajo y paso alto.

Además de los dos métodos de transformación al espacio tiempo-frecuencias que han sido descritos con anterioridad, la **transformada de Hilbert-Huang** (HHT, *Hilbert-Huang Transform*) constituye uno de los más novedosos y de reciente aplicación a la motorización de procesos. El método tiene su origen en la técnica llamada descomposición empírica de los modos (EMD, *Empirical Mode Decomposition*) propuesta por Huang et al. [177]. Esta técnica descompone cualquier señal en sus denominadas funciones de modos intrínsecos (IMF, *Intrinsic Mode Functions*) que son dependientes de la señal y sirven para reconstruir la señal original. El principio es similar a la transformada de Fourier, cuya diferenciación radica en que la FFT asume la linealidad y el carácter estacionario de la señal, mientras que la

transformada de Hilbert-Huang no presupone nada acerca de la naturaleza de la señal. Por tanto, esto convierte a la HHT en ideal a la hora de trabajar con señales no lineales y no estacionarias como son las procedentes de sensores de fuerza, de emisión acústica o de vibración en procesos de mecanizado.

Un modo intrínseco de la señal representa un modo oscilatorio general simple como contrapartida a la función armónica simple. Por definición, una IMF es cualquier función con el mismo número de extremos que de cruces por cero y con su envolvente simétrica con respecto al cero. En el proceso de obtención de la HHT, el método de descomposición puede utilizar simplemente las envolventes definidas por los máximos y mínimos locales por separado. Una vez son identificados los extremos, todos los máximos locales están conectados mediante una *spline* cúbica como envolvente superior. Este procedimiento se repite para los mínimos locales para generar la envolvente inferior. Las envolventes superiores e inferiores deben cubrir todas las muestras entre ellas. Su valor medio se denota como m_l y la diferencia entre los datos $x(t)$ y m_l , constituye la primera componente h_l :

$$h_1 = x(t) - m_l \quad (2.8)$$

En el siguiente proceso de *sifting* (cernido de la señal), h_l se trata como la señal, obteniéndose lo siguiente:

$$h_1 - m_{11} = h_{11} \quad (2.9)$$

Este procedimiento de *sifting* puede repetirse k veces, hasta que h_{1k} sea una IMF (c_1), es decir, la primera componente IMF de la señal:

$$h_{1(k-1)} - m_{1k} = h_{1k}; \quad c_1 = h_{1k} \quad (2.10)$$

Para comprobar que h_{1k} sea una IMF, deben cumplirse las siguientes condiciones:

- La diferencia entre el número de extremos y cruces por cero de la función debe ser ≤ 1 .
- En cualquier punto, el valor medio de las envolventes generadas por los máximos locales y los mínimos locales debe ser igual a cero.

La primera IMF, c_1 , se sustrae de la señal original s y se obtiene el residuo r_1 :

$$r_1 = s - c_1 \quad (2.11)$$

El residuo constituye la nueva señal y se aplica nuevamente el procedimiento de *sifting*. El proceso de descomposición se detiene finalmente cuando el residuo r_n se convierte en una función monolítica o una función con un único extremo, a partir de la cual no puede extraerse otra IMF.

De esta forma, la señal original es descompuesta hasta n modos empíricos y un residuo:

$$x(t) = \sum_{j=1}^n c_j + r_n \quad (2.12)$$

Otro paso de todo el proceso es aplicar la transformada de Hilbert a las IMFs obtenidas. Cada componente tiene su propia transformada de Hilbert y_i :

$$y_i(t) = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{c_j(\tau)}{t - \tau} d\tau \quad (2.13)$$

Con la transformada Hilbert la señal analítica se define como:

$$\begin{aligned} z(t) &= x(t) + i \cdot y(t) \\ a(t) &= \sqrt{x^2 + y^2}; \quad \theta(t) = \arctan(y/x) \end{aligned} \quad (2.14)$$

donde $a(t)$ es la amplitud instantánea y θ la función fase, calculándose la frecuencia instantánea como:

$$\omega = \frac{d\theta}{dt} \quad (2.15)$$

Una vez aplicada la transformada de Hilbert a cada componente, la información original puede ser expresada como la parte real en la siguiente expresión:

$$x(t) = \Re \left\{ \sum_{j=1}^n a_j(t) \exp \left[i \int \omega_j(t) dt \right] \right\} \quad (2.16)$$

Con el espectro de Hilbert definido, es posible definir también el espectro marginal de la siguiente forma:

$$h(\omega) = \int_0^T H(\omega, t) dt \quad (2.17)$$

El espectro marginal ofrece una medida de la contribución de la amplitud total o la energía de cada valor de frecuencia. Este espectro representa la amplitud acumulada a lo largo de todos los datos. Mayor información sobre la transformada HHT puede encontrarse en los trabajos de Huang et al. [177, 178].

Tanto la STFT, la WT como la HHT han sido aplicadas en trabajos anteriores para monitorizar procesos de mecanizado. Ejemplo de ello constituyen los trabajos de Kalvoda y Hwang [179, 180] en los que se aplican estas estrategias de transformación a señales

provenientes de acelerómetros y de sensores de fuerza, con el objetivo de monitorizar el estado de la herramienta de corte.

La transformación al espacio tiempo-frecuencias de las señales empleadas para monitorizar los procesos, constituirá un paso imprescindible para lidiar con el ruido e incertidumbre implícito en estas señales. Esto permitirá identificar patrones relevantes del comportamiento en estas señales vinculados con el estado de las operaciones y por ende el desarrollo de relaciones causa-efectos.

2.3 Sensores y arquitecturas sensoriales en procesos de microfabricación

De acuerdo a estudios realizados con anterioridad, existen varias variables que aportan información relevante sobre los procesos electromecánicos complejos y, por tanto, susceptibles de ser empleadas en la monitorización y optimización de estos procesos [133]. Estas variables pueden clasificarse de la siguiente forma (ver Figura 2.4):

- Manejadas de forma interna por el control numérico (CNC) de la máquina: corriente, potencia, par, velocidad y posición de los motores que determinan la velocidad de avance y la velocidad de giro.
- Relacionadas con el proceso de corte: fuerzas de corte, par de corte, vibraciones, temperatura, emisión acústica (EA) y deformaciones mecánicas. Estas variables permiten una mejor caracterización de los fenómenos que ocurren durante el arranque de material.

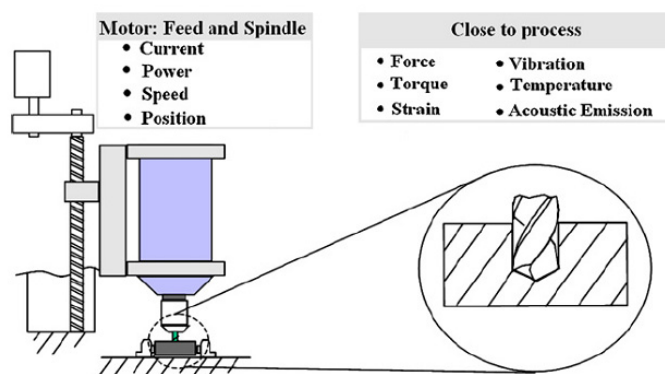


Figura 2.4. Variables que aportan información relevante sobre los procesos de mecanizado. (Teti et al., 2010 [133])

La medición de estas variables mediante sensores y su integración en un sistema de monitorización, permitiría una caracterización de forma indirecta de eventos, fenómenos u otras variables de los procesos de mecanizado, tales como el desgaste de la herramienta de

corte, la rugosidad superficial, acabado superficial, tasa de arranque de material, rotura de la herramienta, entre otros.

Las bases de cualquier sistema de monitorización fiable es, de hecho, un sistema sensorial de bajo coste y eficiente, rápidos métodos de procesamiento de señales y estrategias computacionales de bajo coste capaces de relacionar señales medidas con información relevante sobre el estado del proceso. Una estrategia para integrar múltiples sensores daría lugar a un aumento de las capacidades del sistema para supervisar y controlar los procesos de mecanizado y, en consecuencia, a una mejora de su eficiencia y rendimiento.

La estrategia de integración de múltiples sensores con el objetivo de incrementar las capacidades de los sistemas de monitorización y control de los procesos de mecanizado y, por tanto, mejorar su eficiencia y desempeño, ha sido desarrollada con anterioridad tanto en patentes como en publicaciones científicas. Por ejemplo, en un trabajo desarrollado por Haber et al. [181], se propone la incorporación de múltiples sensores en un sistema de monitorización para la predicción del desgaste de la herramienta de corte. En este trabajo (ver Figura 2.5.a) se utilizan sensores de fuerza, de vibración (acelerómetros) y de emisión acústica, realizando el análisis tanto en el dominio temporal como en el dominio en frecuencias mediante la aplicación de la transformada de Fourier.

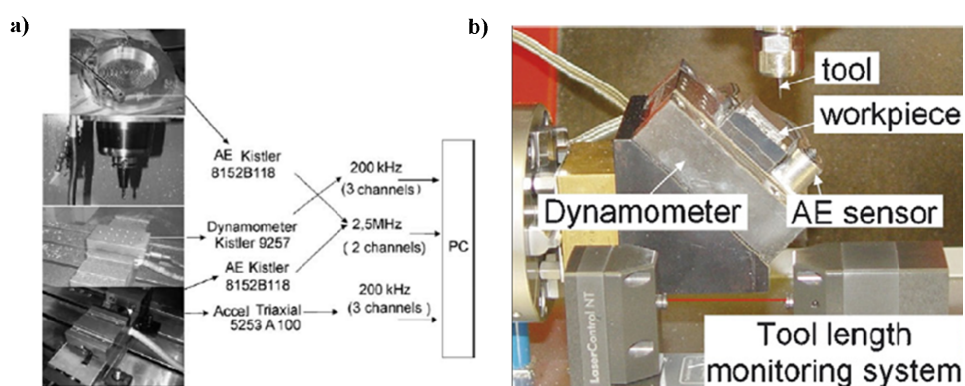


Figura 2.5. Sistema multi-sensorial para la monitorización del desgaste en procesos de: a) mecanizado de alta velocidad (Haber et al., 2004 [181]) y b) microfresado (Jemielniak et al., 2008 [182]).

Un sistema multi-sensorial similar al propuesto (ver Figura 2.5.b) ha sido aplicado al proceso de microfresado con el objetivo de monitorizar el desgaste de la herramienta de corte [182] y alertar sobre posibles roturas [183]. Además, la capacidad de integración sensorial también puede ser de gran utilidad para la detección de vibraciones a altas frecuencias y comportamientos dinámicos no deseados en los procesos de micromecanizado [184].

Por otra parte, Tansel et al., en dos de sus trabajos [185, 186], desarrollaron algunos de los trabajos pioneros vinculados con la monitorización de procesos de micromecanizado a partir

del empleo de varios sensores, principalmente de fuerza. Concretamente, propusieron una estrategia de detección del estado de la herramienta en un estado previo a su rotura aplicada al proceso de microtaladrado [185]. Para ello emplearon un sistema de monitorización multi-sensorial conformado por una plataforma dinamométrica y un sensor de vibraciones láser. Además, relacionado con el proceso de microfresado [186] emplearon una plataforma similar para la monitorización del desgaste de la herramienta y detección de roturas.

Pero la aplicación directa de las estrategias empleadas en el mecanizado en la macro escala se limita en la medida que se reduce el tamaño o área de trabajo. En general, el incremento de requerimientos de precisión de los instrumentos, sensores y accionamientos, demanda de estos una mayor sensibilidad y por tanto, una disminución de la relación señal-ruido. Esto trae como consecuencia que las técnicas de medición y procesamiento hasta ahora con amplia utilidad en la macro y meso escala, se convierten en menos viables desde el punto de vista técnico.

Por el contrario, el uso de múltiples sensores para monitorizar el proceso de microfresado, proporciona robustez y fiabilidad, aunque aumentan los requisitos de coste tanto económico como computacional en el procesamiento de las señales. A pesar que la utilización de múltiples sensores mejora la caracterización e identificación de los procesos, en la literatura a la que se ha tenido acceso se aprecia una tendencia a unificar los esfuerzos hacia la monitorización del estado tanto del proceso como de la herramienta, utilizando un único sensor. Por ejemplo, se han relatado interesantes resultados usando un **sensor de efecto hall** para la medición de la **corriente consumida** por los motores [187, 188]. Sin embargo, no es fácil de establecer cuál de entre todos los sensores disponibles posee como cualidad el equilibrio entre la cantidad de información sensorial, la sensibilidad a altas frecuencias y los costes económicos. La Tabla 2.1 resume diferentes tipos de sensores piezoeléctricos y algunas de las características más importantes, tales como ancho de banda y los principales campos de aplicación.

Tabla 2.1. Sensores piezoeléctricos para sistemas de monitorización [189-191].

Sensor	Variable	A. banda	Aplicación de monitorización
Dinamómetro	Fuerza de corte	< 10 kHz	Carga/Deflexión, rugosidad, desgaste, cinemática-dinámica, temperatura
Acelerómetro	Vibración	< 20 kHz	Rugosidad, daño sub-superficial, desgaste
Emisión Acústica	Vibración	> 100 kHz	Rugosidad, daño sub-superficial, anisotropía del material, desgaste, tolerancia del material

De las variables mencionadas en la tabla anterior y de acuerdo con estudios realizados previamente [192], solo algunas de ellas pueden aportar información de mayor relevancia sobre los procesos de micromecanizado y, además, ser adquiridas en tiempo real, a saber: la fuerza, la vibración y la emisión acústica. Aunque las dos últimas están relacionadas, ya que ambas captan información en forma de vibración, se diferencian en el ancho de banda (valores típicos por debajo de 20 kHz y más de 100 kHz, respectivamente). En este aspecto Lee et al., concluyen que los dinamómetros, los acelerómetros, varios sensores de posición y los sensores de emisión acústica son de gran utilidad en la fabricación en la microescala [193].

Para el caso de las **fuerzas de corte** en el micromecanizado, éstas se miden típicamente empleando dinamómetros con una resolución de sub-milnewtons, capaces de proveer señales de forma simultánea en tres dimensiones y con un ancho de banda típico de hasta 5 kHz. La señal de fuerza varía, principalmente, con la geometría de la pieza a mecanizar, los parámetros de corte empleados, el desgaste de la herramienta de corte y la dureza del material. Además, en el micromecanizado, esta señal es influenciada por la anisotropía de los materiales y el comportamiento cinemático y dinámico de los accionamientos de la máquina-herramienta (Drescher y Dow [194] y Dow et al. [195]). Sin embargo, a pesar de aportar información relevante del proceso, el alto coste de los sensores de fuerza y su instalación, que en ocasiones interfiere físicamente al proceso, han limitado su utilización masiva en la industria [196].

Por el contrario, con relación a la **emisión acústica (EA)**, esta variable es ampliamente utilizada en la industria en sistemas de monitorización con el objetivo de detectar deformaciones plásticas de materiales, formación y crecimiento de grietas, fracturas o fricción. Los sensores de emisión acústica son utilizados, además, en la monitorización de procesos, herramientas y máquinas en operaciones de conformado y corte de metales. Esto lo llevan a cabo detectando vibraciones a altas frecuencias en rangos de hasta 900 kHz. El operar los sensores de EA sobre altos rangos de frecuencia requiere altas frecuencias de muestreo (al menos el doble de la frecuencia más alta) para su procesamiento digital, demandando por tanto grandes recursos de memoria y un alto coste computacional. Esto hace que en muchos casos esta señal solo pueda utilizarse a través de su valor cuadrático medio (*rms*, *root mean square*), permitiendo por tanto que su procesamiento sea más accesible con dispositivos de procesamiento y sistemas de adquisición de menor coste [133].

Son conocidas las afectaciones que producen las vibraciones en el acabado superficial en procesos de micromecanizado, además de las tolerancias en las piezas que se fabrican. De ahí que la emisión acústica (EA) producida por el proceso de arranque de material sea lógicamente una señal utilizada para monitorizar, detectando tanto cambios en la dureza de materiales [197] como en la energía específica de corte [198].

Como es lógico de intuir, la señal de EA es de gran utilidad para caracterizar el estado de desgaste de las herramientas de corte en procesos de micromecanizado [199], encontrándose en la literatura propuestas interesantes como la de Kang et al. [200] para procesos de microfresado y herramientas de 200 μm , y para monitorizar el acabado superficial en la microescala, como es el caso del propio trabajo de Lee et al. [189]. También, Nakao y Dornfeld [201] proponen la incorporación de esta señal en lazos de control del sistema de posicionamiento, con el objetivo de compensar los errores que se producen debido al desgaste de la herramienta de corte y de esta forma reducir el error de forma de la pieza mecanizada.

Por otra parte, con relación a las **vibraciones, su magnitud puede medirse físicamente en forma de desplazamiento que se genera y también como aceleración**, utilizando para ello diferentes tipos de sensores con diversos principios físicos, tales como: los acelerómetros piezoeléctricos, sensores láser de desplazamiento, los sensores capacitivos y los inductivos, entre otros. Las señales de vibración obtenidas de acelerómetros piezoeléctricos tienen muchas características sobresalientes con respecto al resto de señales de vibración provenientes de otros sensores, y por lo tanto deberían ser explorados y estudiados para su integración en un sistema de monitorización en las operaciones de microfresado [202].

Por ejemplo, los **acelerómetros piezoeléctricos**, con una amplia aplicación en la industria en general y en el mecanizado en la macro-escala, se han utilizado muy poco en procesos de micromecanizado tanto a nivel experimental como en aplicaciones industriales. Aunque existen evidencias de que el deslizamiento lineal de los accionamientos de máquinas herramientas desempeñan un papel importante en la aparición de vibraciones, las cuales tienen influencia directa en el acabado superficial y la vida útil de la herramienta [184]. Claramente, esta es una vía a considerar en las investigaciones industriales para mejorar estos procesos mediante la reducción de errores e incrementando la viabilidad económica de estos.

Las principales ventajas de los sensores acelerómetros piezoeléctricos son sus bajos costos de producción, su respuesta de alta velocidad, robustez, flexibilidad, estabilidad, precisión y su mínima interferencia con el proceso de corte [203]. Además es resaltable su versatilidad de funcionamiento, ya que se pueden aplicar sus estructuras piezoeléctricas como sensores o actuadores [204], indiferentemente. Se han publicado unos resultados muy prometedores para los sensores acelerómetros piezoeléctricos en procesos de micromecanizado. Por ejemplo, Del Toro et al. [205] propuso la medición de vibraciones en la nano-escala de las operaciones de microtorneado para estimar la excentricidad en los ejes en dispositivos giratorios de ultra-precisión. Otros estudios han sido enfocados en operaciones de microfresado, con el objetivo de estimar el estado de la herramienta de corte a partir de un análisis en frecuencia de las señales de vibración [149]. Las señales de vibración han proporcionado información relevante para detección rápida del contacto entre herramienta de corte y la pieza de trabajo, como los reportados en otros trabajos [206].

Por otra parte, los sensores **capacitivos e inductivos** han sido mayormente utilizados para monitorizar vibraciones debido a su alta sensibilidad (ej., hasta 0.25 nm) y ancho de banda (ej., hasta 100 kHz). Se han empleado, además, junto a accionamientos piezoeléctricos de alta frecuencia (FTS, *Fast Tool Servo*) para introducir acciones correctivas o de compensación en los sistemas de posicionamiento de procesos de micromecanizado. Por ejemplo, aplicado al proceso de microtorneado, Fawcett, 1990 [207], desarrolla una estrategia para reducir los errores producidos por las vibraciones, mejorando la precisión del sistema de posicionamiento y con ello el acabado superficial con un mínimo de *hardware* añadido.

En propuestas más recientes, se han empleado **sensores láser de desplazamiento**, con el objetivo de monitorizar las vibraciones de la pieza durante operaciones de microfresado. Este trabajo [208] difiere de la propuesta de Fawcett [207] en que se hace vibrar la pieza de trabajo a lazo abierto, a una determinada frecuencia y amplitud. De esta forma se mejora el rendimiento de la máquina y se logran obtener mejores acabados superficiales en las piezas mecanizadas [209].

2.4 Plataforma multi-sensorial para la caracterización de procesos de microfabricación

En base a la literatura consultada y con vistas a poder evaluar y analizar sensores y estrategias de procesamiento en la extracción de patrones de comportamiento en las señales correspondientes a diferentes variables representativas, se diseñó una plataforma experimental que fue instalada en el laboratorio. La plataforma está constituida principalmente por un centro de micromecanizado de alta precisión KERN EVO equipado con un control CNC iTNC 530 de Heidenhain (ver Figura 2.6).




Figura 2.6. Algunos de los elementos de la plataforma multi-sensorial para identificación

Algunas de las características técnicas de este centro de mecanizado son las siguientes: 6 kW de potencia, velocidad de giro máxima del cabezal igual a 50000 rpm, máxima velocidad de avance de la máquina igual a 16 m/min y un par máximo disponible de 1.43 Nm @S1. Se trata, por tanto, de un centro de micromecanizado de muy alta precisión tal y como puede observarse en la Tabla 2.2.

Tabla 2.2. Precisión en el posicionamiento de la Kern Evo UPMC.

Resolución	0.1 μm
Posición de dispersión	$\pm 0.5 \mu\text{m}$
Tolerancia de posicionamiento	$\pm 1.0 \mu\text{m}$
Precisión de la pieza de trabajo (3 ejes)	$\pm 2.0 \mu\text{m}$

Para medir fuerzas durante las operaciones de mecanizado, se utiliza una plataforma dinamométrica *Kistler 9256C1*, instalada en la bancada de la máquina. Las características técnicas más importantes de esta plataforma dinamométrica son: un rango de medición [-250, 250] N en cada eje, frecuencia natural > 5 kHz, linealidad ≤ 0.4 % a escala completa y una sensibilidad de entre 13 y 26 pC/N, según el eje cartesiano de medición. Se utiliza además un amplificador de carga de 8 canales *Kistler 5070A*, para convertir las componentes obtenidas del sensor en la fuerza en los tres ejes cartesianos, F_x , F_y , F_z .

Además de las señales de fuerza y de las variables del CNC, se encuentran instalados sensores para monitorizar otras variables del proceso, como son las vibraciones producidas a frecuencias bajas, medias y muy altas. Por un lado, para las frecuencias de vibración bajas y medias se disponen de 3 acelerómetros piezoeléctricos del tipo PCB piezotronics serie WJT352B, con una sensibilidad de 1015 mV/g y un ancho de banda de 10 KHz; y por otro lado, otros 3 cuyo modelo es Brüel&Kjaer Deltatron 4519-003, con una sensibilidad de 10.58 mV/g y un ancho de banda de 20 kHz. Para estos 6 sensores se utiliza un amplificador / acondicionador Brüel&Kjaer del tipo 2594. La adquisición de estas señales se realiza por medio de una tarjeta DAQ de *National Instruments PCI-6259*.

Por otra parte, la medición de vibraciones a muy alta frecuencia se llevan a cabo mediante dos sensores de emisión acústica (EA), cuyo modelo es 8152B2 de Kistler que llevan implementado un conversor de impedancias para la medición de EA por encima de 50 kHz en estructuras de máquinas. El sensor se acopla a un amplificador EA Piezotron Coupler Type 5125 que genera dos señales. La primera señal se obtiene como resultado del paso de ésta por dos filtros consecutivos de *Butterworth*, paso alto ($f_c = 50$ kHz) y paso bajo ($f_c = 1000$ kHz). La segunda resulta ser el valor *rms* obtenido por cada 1.2 ms a partir de la señal original. La tarjeta digitalizadora de *National Instruments PCI-5912* es la encargada de la captura de estas señales, al ser mucho más potente y con capacidad para poder elegir sus parámetros de ajuste

en base a la velocidad de muestreo o resolución requerida (resolución desde 24 bits a 500 kS/s hasta 16 bits a 15 MS/s).

El sistema DAQ y el procesamiento se complementa con un PC Industrial KISS-4U-760 con un procesador Intel(R) Core(TM) 2 Quad CPU Q9400 de 2.66 - 2.67 GHz y un sistema operativo Windows XP, que incorpora una aplicación software desarrollada en lenguaje gráfico mediante la interfaz *Labview 8.6*. Tanto las señales de fuerza como de aceleración son adquiridas a una frecuencia de muestreo de 50 kHz y la EA a una frecuencia de 1 MHz, mientras que las señales del CNC son muestreadas cada 125 Hz aproximadamente.

Desde el CNC pueden registrarse en un tiempo no determinista las posiciones de la punta de la herramienta en los tres ejes cartesianos y el “*override*”. Esta información que nos suministra el CNC, se encuentra disponible a través de comunicaciones *Ethernet* mediante un protocolo específico proporcionado por el fabricante. Además, otra variable que puede obtenerse del CNC de la máquina son las mediciones on-line de la longitud y el radio de la herramienta mediante un sensor láser. El modelo de sensor es BLUM Laser Control de NT P87.0634 de alta precisión y de luz roja visible, diseñado para herramientas de tamaños superiores a 5 μm .

2.5 Extracción de patrones de comportamiento basados en información sensorial. Caso de estudio, el proceso de microtaladrado

El estudio está enfocado a la aplicación de estas operaciones de mecanizado en materiales para aplicaciones aeronáuticas especiales, como es el caso de las aleaciones de wolframio-cobre. En el estudio se muestran los resultados de un análisis preliminar de los patrones temporales de comportamiento existentes entre una serie de parámetros estadísticos característicos de las señales proporcionadas por tres sensores piezoeléctricos y su relación con el desgaste de la herramienta.

Tabla 2.3. Características de las herramientas.

Diámetro (mm)	Fabricante	Recubrimiento	Referencia
1	Garant	TiAlN	121220 1.0
0.5	Garant	TiAlN	121220 0.5
0.1	Garant	TiAlN 26.57	121220 0.1

Como parte inicial del análisis, se diseñaron un conjunto de experimentos con vistas a estudiar el desgaste en procesos de microtaladrado. En las pruebas se utilizó una aleación de wolframio-cobre ($\text{W}_{72}\text{Cu}_{28}$) como pieza de ensayos y tres herramientas de diferentes diámetros (ver Tabla 2.3).




Figura 2.7. Perfil de la operación de microtaladrado

Tabla 2.4. Condiciones nominales para la operación de microtaladrado.

Diámetro herramienta [mm]	Vel. giro [rpm]	Avance [mm/min]		$a_{p1} = d_1$ [mm]	$a_{p2} = d_2$ [mm]
		f_1	f_2		
1	20.000	440	352	1	3
0.5	40.000	440	352	0.5	1.5
0.1	48.000	530	424	0.1	0.3

Para el estudio de la información sensorial y su relación con el comportamiento dinámico del sistema de accionamiento de la máquina, se aplica un escalón en la velocidad de avance, según se muestra en la Figura 2.7.




Figura 2.8. Detalle del borde de un micro agujero de 0.1 mm de diámetro: (a) primero y (b) último agujero.

Por otro lado, en la Tabla 2.4 se muestran las condiciones nominales de corte para las operaciones de microtaladrado. Para cada herramienta, con las mismas condiciones nominales, se realizaron cinco réplicas del experimento, de tal forma que el estudio de las señales y los patrones de comportamiento que se detecten puedan ser corroborados en diferentes ensayos. Además, la Figura 2.8 ilustra las imágenes ampliadas del primer y último

agujero de 0.1 mm de diámetro. Las imágenes fueron capturadas con un microscopio interferómetro de luz blanca Zygo NewView 600.

2.5.1 Análisis inicial de la respuesta temporal de las señales sensoriales

La plataforma experimental mostrada en la Figura 2.9 fue diseñada para el estudio preliminar de las señales sensoriales. Esto incluye un sensor de fuerzas de corte en los tres ejes, dos sensores de vibración para el eje Y y Z, respectivamente, y un sensor láser para la medición de la variación en longitud y radio de la herramienta. En cada uno de los ensayos se registraron estas seis señales, más la posición de la punta de la herramienta.




Figura 2.9. Posición de los sensores de fuerza y vibración.

En la Figura 2.10, para cada uno de los ensayos con las herramientas de 1 mm, 0.5 mm y 0.1 mm, se muestra el comportamiento de la fuerza bruta en el eje Z y **su valor promedio por cada vuelta de la herramienta respecto a la profundidad del agujero** (ver ecuación (2.3)).

Además, se ilustra el comportamiento de las vibraciones durante las operaciones de microtaladrado, mediante la señal obtenida de los acelerómetros piezoeléctricos ubicados en los ejes Y y Z, y **sus valores medios cuadráticos (*rms*)**. Este último se realizó con una **ventana de datos igual al total de muestras por cada vuelta de la herramienta** (ver ecuación (2.4)). En todos los casos se ha señalado las zonas donde se produce la transición debido al escalón en la velocidad de avance.

Respecto a la **fuerza de corte**, para el caso de la herramienta de 0.5 mm (Figura 2.10.d), existe una zona con un rápido incremento de la fuerza al aproximarse la herramienta a la profundidad máxima predefinida para el experimento (1.5 mm), que se produce debido al comportamiento dinámico de los accionamientos en el eje Z durante el frenado de la máquina y cambio de sentido del movimiento.

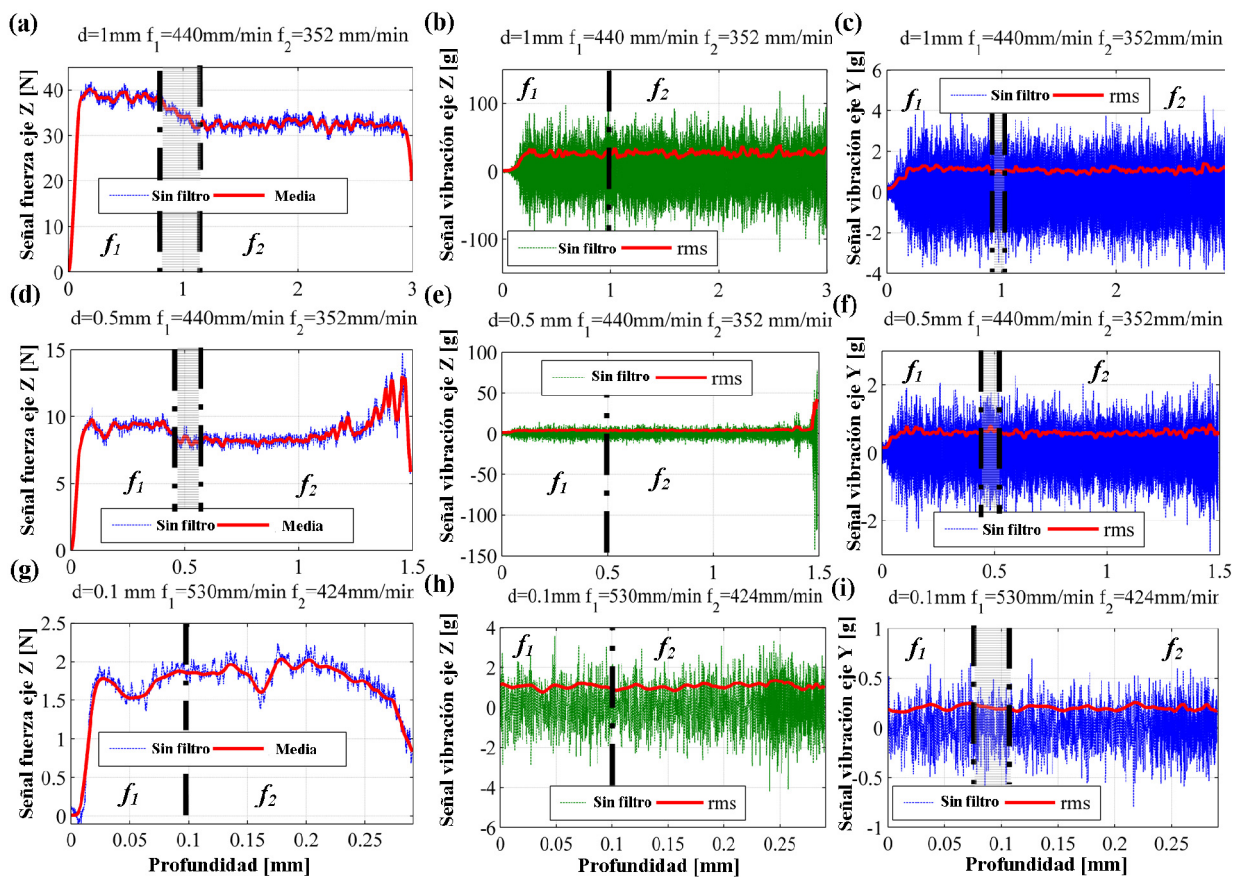


Figura 2.10. a), d) y g) Respuesta temporal de la señal de fuerza de corte en el eje Z. b), c), e), f), h) e i) Respuesta temporal de las señales de los acelerómetros, en los ejes Z e Y, respectivamente.

Por contra, relacionado con los experimentos con la herramienta de 0.1 mm (Figura 2.10.g), al producirse la operación de taladrado a más alta velocidad de avance y al ser la herramienta de menor diámetro, la profundidad que se puede alcanzar con esta herramienta no es suficiente para realizar un análisis exhaustivo, al menos en el dominio del tiempo.

Respecto a **las vibraciones**, en el caso de los experimentos con las herramientas de 1 mm y 0.5 mm, puede apreciarse a simple vista, el incremento de las vibraciones durante la operación de corte. Además, en el caso de la operación con la herramienta de 0.5 mm, se puede observar (ver Figura 2.10.e) el incremento brusco que sufre la señal en el eje Z, tanto la bruta como su valor *rms*, al aproximarse la herramienta a la profundidad máxima del taladro. Este efecto no se aprecia en la señal de vibración en el eje Y (ver Figura 2.10.f). Sin embargo sí se distingue ligeramente una zona de transición (Figura 2.10.c y f) que se corresponde con el cambio de la velocidad de avance en el valor de profundidad indicado para ello.

2.5.2 Evaluación del comportamiento de los parámetros característicos de las señales respecto al uso de la herramienta

La motivación para el desarrollo de este análisis inicial de las señales proporcionada por los sensores piezoeléctricos, se debe a la limitada información obtenida por el sistema de medición láser a la hora de monitorizar el estado de la herramienta en tiempo real. La Tabla 2.5 resume las mediciones del láser para cada herramienta considerada en este estudio. De acuerdo a estas mediciones, no se pudo establecer ni el estado actual de la herramienta, ni siquiera un claro patrón de comportamiento de uso de la misma. De los tres estados que afectan al estado de la herramienta durante su proceso de desgaste, únicamente el desgaste inicial y el desgaste constante están presentes en el experimento. Por el contrario, no se alcanzó el tercer estado (desgaste rápido), debido al número limitado de experimentos realizados.

Tabla 2.5. Valores del desgaste de la herramienta en longitud (Δl).

	$D = 1 \text{ mm}$	$D = 0.5 \text{ mm}$	$D = 0.1 \text{ mm}$
Uso	$\Delta l \text{ [mm]}$	$\Delta l \text{ [mm]}$	$\Delta l \text{ [mm]}$
1	0,0015	0,0046	0,0011
2	-0,0097	0,0046	0,0002
3	-0,0094	0,0058	0,0004
4	-0,0101	0,0042	0,0005
5	-0,0093	0,0034	0,002

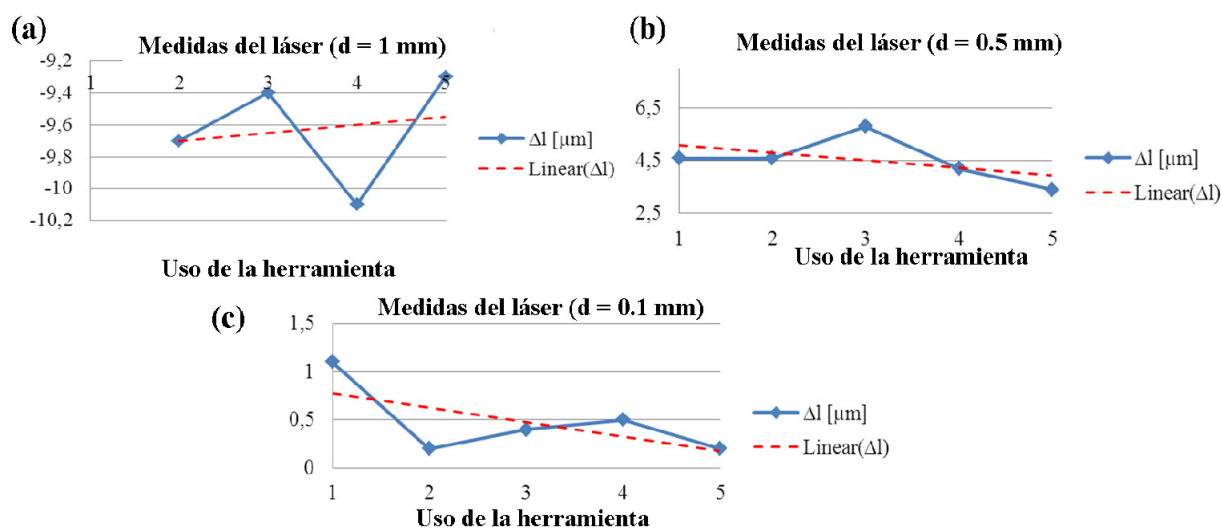


Figura 2.11. Variación de la longitud de la herramienta respecto al uso en base a las mediciones del láser, a) $d = 1 \text{ mm}$, b) $d = 0.5 \text{ mm}$ y c) $d = 0.1 \text{ mm}$.

Las propiedades microestructurales de las aleaciones de tungsteno y cobre que dificultan el proceso de corte, son la principal razón de este comportamiento sensorial inadecuado. Las

propiedades del material producen la adherencia de virutas de tungsteno-cobre en el filo de la herramienta (*built-up-edge*) [210, 211].

2.6 Resultados de la extracción de características de las señales

Como continuación del análisis preliminar, se aplican las técnicas de extracción de características vistas en las secciones anteriores, como son los métodos estadísticos en el dominio del tiempo, o las transformas de Fourier (FFT), *wavelet* (WT) y Hilbert-Huang (HHT) en el dominio de tiempo-frecuencias. **El estudio experimental describe la metamorfosis de las técnicas utilizadas en la escala macro a la escala micro, con el fin de determinar su viabilidad [212-214].**

2.6.1 Dominio del tiempo. Métodos estadísticos

Por tanto, a partir de las técnicas de extracción de características basadas en los parámetros estadísticos en el dominio del tiempo, se calcularon para cada conjunto de datos, después de ser filtrados, el valor efectivo o medio cuadrático (*rms*), valor medio o promedio, desviación estándar, valores máximos, valores mínimos, amplitud pico-valle, amplitud pico-pico, entre otros. Por ejemplo, en la Figura 2.12 se muestra el comportamiento del valor máximo, medio y desviación estándar para la componente de fuerza en el eje Z. Como puede observarse, no hay una tendencia clara en su representación gráfica en relación con el uso de herramienta. De los resultados no puede determinarse un patrón temporal de comportamiento evidente en las señales de vibración en el eje Z. Un comportamiento similar (es decir, no existe una tendencia identificable) también se observó para el resto de señales.

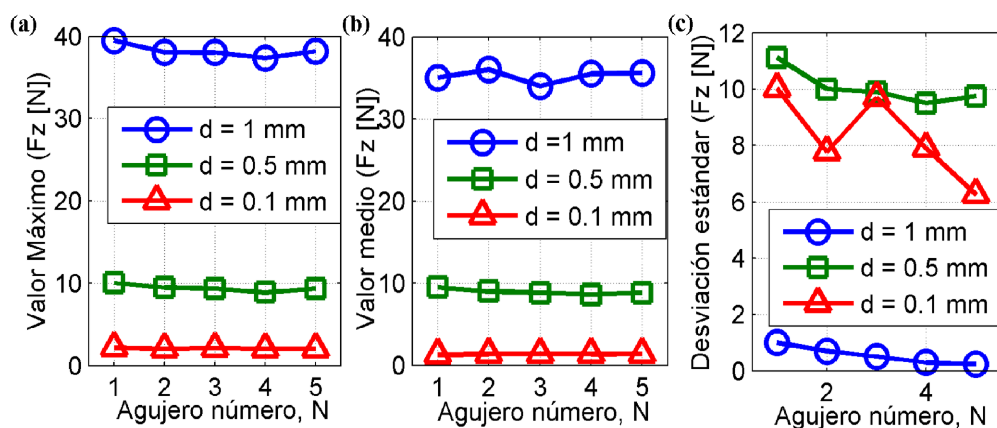


Figura 2.12. Parámetros estadísticos respecto al número de agujeros, para la fuerza en el eje Z con la mayor velocidad de avance. a) $D = 0.1$ mm, b) $D = 0.5$ mm y c) $D = 1$ mm.

2.6.2 Dominio tiempo frecuencias. FFT, WT y HHT

En la Figura 2.13 se muestra los resultados para la componente de vibración en el eje *Y* procesada mediante la **técnica de extracción de características basada en la FFT**.

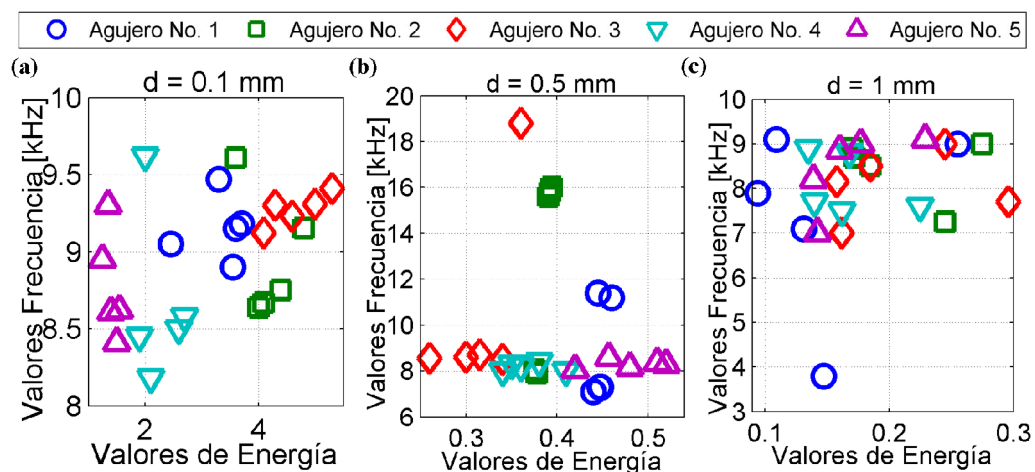


Figura 2.13. Evolución de la energía de la FFT respecto a la frecuencia, para la vibración en el eje *Y* con la menor velocidad de avance. a) $D = 0.1$ mm, b) $D = 0.5$ mm y c) $D = 1$ mm .

En ella, no se observa de forma visual ninguna clara tendencia de los valores de frecuencia respecto a los valores con mayor energía. Igualmente, tampoco se aprecia ninguna relación aparente en las otras dos señales procesadas de una manera similar, vibración en el eje *Y* y *Z*.

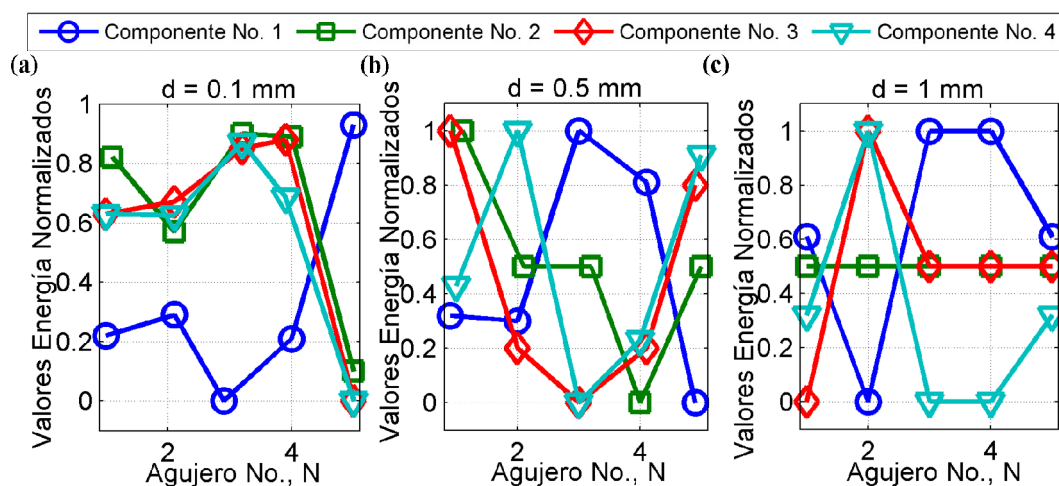


Figura 2.14. Evolución de las componentes de energía de la WT con respecto al número de agujeros, para la fuerza en el eje *Z* con la mayor velocidad de avance. a) $D = 0.1$ mm, b) $D = 0.5$ mm y c) $D = 1$ mm.

Otro enfoque de extracción de características es el basado en la **transformada wavelet**, que presenta como ventaja adicional la posibilidad de filtrar la señal en las diferentes

bandas de frecuencia y separar la frecuencia interesante de la frecuencia de ruido, lo que reduce considerablemente el área para la búsqueda en la etapa subsiguiente. Sin embargo, tampoco existe ninguna tendencia resaltable en la relación con el número de agujeros perforados y la energía de las componentes de la señal, como puede verse en la Figura 2.14. Una posible causa es la escasa información proporcionada por el sensor de vibración debido a la baja relación señal-ruido.

Por último, los resultados de la técnica de extracción de características basadas en la HHT para la componente Z de la vibración se representa en la Figura 2.15.

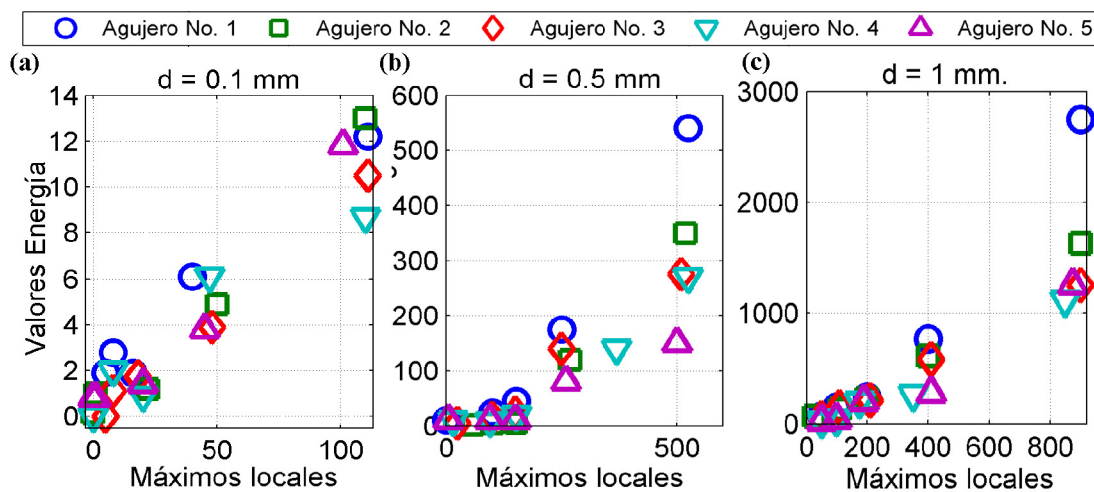


Figura 2.15. Evolución de la energía de la HHT respecto a los máximos locales, para la vibración en el eje Z con la menor velocidad de avance. a) $D = 0.1$ mm, b) $D = 0.5$ mm y c) $D = 1$ mm.

Uno de los resultados más prometedores se observó en el uso de la HHT para la vibración en el eje Z. Existe una tendencia clara a la agrupación, para cada uno de los tamaños de orificio, de los puntos correspondientes a los valores de energía respecto a los máximos locales.

2.7 Resultados del análisis de correlación R^2 y capacidad de generalización

Con el objetivo de corroborar los resultados predichos en el análisis visual preliminar, en esta sección, se presenta la implementación de **cuatro modelos de regresión estadística**, cuya diferencia radica en la **utilización como entradas diferentes técnicas de extracción de características (métodos estadísticos, FFT, WT y HHT), para cada uno de modelos.** La evaluación de estos modelos permite obtener un valor de correlación y una capacidad de generalización por cada variable de entrada con respecto a la salida.

Para cada caso, los parámetros obtenidos a partir de la correspondiente técnica de extracción de características se usaron como entradas de cada uno de los cuatro modelos. Se

usaron como entradas, el valor medio (fuerza) y el valor *rms* (vibración), el valor máximo y la desviación estándar (STD) de cada una de las señales medidas para la técnica estadística en el dominio del tiempo. En cambio, para la técnica de extracción basada en la FFT, las entradas al modelo fueron las energías (E_i) y frecuencias (ν_i) de los cinco valores ($i = 1, \dots, 5$) con mayor energía de cada componente de la transformada. Por otra parte, en la extracción de características basada en la WT, las entradas al modelo son las cuatro componentes ($E_i, i = 1, \dots, 4$) para cada señal medida. Por último, cuando la extracción de características está basada en la HHT, las entradas al modelo son los valores de energía de las cuatro componentes, E_i , y el número de picos, n_i de los cinco más energéticos IMFs. Además, en todos los casos, la velocidad de avance, f , y el diámetro de la herramienta, d , fueron utilizados como entradas. La salida del modelo es el uso de la herramienta, N (número de agujeros realizados con la misma herramienta).

Para el ajuste del modelo, cada señal se dividió en 8 secciones, tal que, se obtuvieron un total de 600 datos de muestra. Estos datos fueron divididos en un conjunto de entrenamiento de 570 elementos y un conjunto de validación de 30 elementos.

$$y^{(P)} = b^T x = [b_0, b_1, \dots, b_n] \cdot \begin{bmatrix} 1 \\ x_1 \\ \vdots \\ x_n \end{bmatrix} \quad (2.18)$$

La regresión lineal múltiple es una técnica para encontrar un ecuación (2.18) que relacione algunas variables de entrada, x , con una salida, y . Los coeficientes, b , se obtienen minimizando la suma cuadrática de la diferencia entre los valores predichos y observados, $y^{(P)}$ e y , para un conjunto de m pares de entrada-salida (2.19), pudiéndose estimar los coeficientes a través de (2.20). El ajuste del modelo de regresión se hizo con MATLAB 2014a *Statistics Toolbox* (versión 9.1).

$$X = \begin{bmatrix} 1 & x_{11} & \cdots & x_{1m} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & x_{n1} & \cdots & x_{nm} \end{bmatrix}; \quad y = \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix}; \quad (2.19)$$

$$b = (X^T X)^{-1} X^T y \quad (2.20)$$

El coeficiente R^2 para el modelo de regresión estadística usando como entradas cada una de las técnicas de extracción de características, se muestra en la Tabla 2.1. Este valor representa la correlación que indica la fuerza y la dirección de una relación lineal y proporcionalidad entre las variables de entrada y salida de un modelo, que generalmente se toma como una medida de la calidad del mismo. Se puede observar a partir de la tabla, que la

calidad en la predicción del modelo de regresión utilizando una técnica en el dominio del tiempo es muy baja. Esto es debido a la alta no linealidad y ruido causado por la naturaleza compleja de los fenómenos de corte en el micromecanizado. En cambio, esta calidad aumenta cuando la entrada es una técnica en el dominio tiempo-frecuencias, siendo el valor más elevado cuando se trata de la transformada wavelet.

Tabla 2.6. Evaluación comparativa (capacidad de generalización vs. correlación) del rendimiento del modelo de regresión.

Extracción de rasgos	Cap. Generalización	Correlación, R^2
Dominio del tiempo	~ 0.0000	0.2134
FFT	~ 0.0000	0.7178
WT	~ 0.0000	0.7451
HHT	~ 0.0000	0.7284

Por otra parte, en la misma tabla también se muestra, para todos los casos, el índice de capacidad de generalización del modelo. Esta capacidad de generalización se determinó utilizando el valor de probabilidad resultante de la comparación entre las medias de los residuos del conjunto de ajuste y validación. Si no hay diferencia estadísticamente significativa entre las dos medias, se puede concluir que este modelo tiene una buena capacidad de generalización. La capacidad de generalización del modelo en todos los casos fue muy pobre. Por tanto, en vista de los resultados obtenidos del valor de capacidad de generalización no es posible determinarse cuál técnica de extracción de características de las señales presenta una mayor relación con el uso de la herramienta (número de agujeros perforados).

2.8 Conclusiones

En este capítulo se han estudiado, analizado y aplicado, técnicas y métodos para extracción de patrones de comportamiento en las señales representativas de las variables típicas de los procesos complejos, como son las técnicas de acondicionamiento y procesamiento de señales (métodos estadísticos en el dominio del tiempo, STFT, HHT, Wavelet, etc.), y estrategias de filtrado digital (media móvil, media cuadrática móvil, paso alto, paso bajo, etc.). A partir de la literatura consultada sobre sensores y sistemas sensoriales, se ha implementado una plataforma de fusión multi-sensorial para la adquisición de señales en un proceso de micromecanizado y así, comprobar el desempeño de estas técnicas y métodos, en un proceso de microtaladrado, a modo de caso de estudio.

En este caso, se ha aplicado una estrategia de dos etapas para monitorizar el nivel de uso de la herramienta de corte. Debido a la insuficiencia de los sistemas de medición láser, a día

de hoy disponibles en el mercado, para monitorizar el estado de la herramienta en línea, se ha priorizado la necesidad de evaluar un sistema sensorial, fuerza en el eje Z y vibración en el eje Y y Z. La aplicación de un filtro de media móvil para la señal de fuerza de corte y del valor cuadrático medio móvil para la vibración proporciona una mejor fiabilidad y una relación señal-ruido notablemente mejorada. De entre las técnicas de extracción bajo análisis, la transformada Wavelet y HHT mostraron el mejor desempeño desde el punto de vista científico y técnico.

Estos resultados se han corroborado matemáticamente mediante la correlación de las diferentes técnicas de extracción de características (métodos estadísticos, FFT, WT, HHT) con el número de agujeros perforados (uso de la herramienta) mediante el uso de regresiones estadísticas (modelos de regresión). La capacidad de generalización revela una relación probabilística entre las entradas y la salida de los modelos que no es significativa. En cambio, el valor del índice de correlación ha sido más alto, sobre todo, utilizando como entradas las técnicas de extracción de características en el dominio del tiempo-frecuencias y en concreto, la de mayor correlación ha resultado ser la WT.

Estos resultados servirán de base para la investigación y el desarrollo de modelos matemáticos que relacionan la condición de la herramienta de corte con las características de la señal de los sensores. Esto, a su vez, conduce al desarrollo de nuevos sistemas de monitorización del desgaste de la herramienta en operaciones de corte a nivel micro y su introducción a nivel industrial.

En siguiente capítulo se profundizará en el conocimiento de las técnicas de AI consideradas en esta Tesis Doctoral para el diseño de modelos experimentales de variables representativas de procesos complejos. Para ello se extraerán del estado del arte algunas ideas conceptuales esenciales. Entre la amalgama de técnicas, se han seleccionado y propuesto dos de las que tienen un consolidado cuerpo de doctrinas e impacto científico y técnico.

CAPÍTULO 3

SELECCIÓN DE ALGORITMOS DE MODELADO DE PROCESOS COMPLEJOS

El mundo real tiende a ser muy complejo e impredecible, y los mecanismos o procesos que generan los datos son muchas veces desconocidos. Cuando almacenamos datos procedentes de mediciones de variables físicas, los sensores no tienen un comportamiento ideal (de precisión finita, ruido, con restricciones de ancho de banda, etc.), de modo que las mediciones no describen fielmente el fenómeno o proceso que está teniendo lugar. Sin embargo, la ingeniería y una gran parte de los métodos para la monitorización, supervisión y control están basados en modelos. De ahí que uno de los desafíos de la ciencia y la técnica es encontrar modelos precisos, robustos y fiables a partir de datos experimentales.

Un modelo constituye una representación abstracta de un cierto aspecto de la realidad. En su estructura intervienen, por una parte, los elementos que caracterizan la realidad modelada y, por otra parte, las relaciones existentes entre ellos. La construcción de modelos revela, a veces, relaciones que no son evidentes a primera vista. Una vez construido el modelo, es posible extraer de él propiedades y características de las relaciones que de otra forma permanecerían ocultas.

En la actualidad se han producido grandes progresos en las técnicas y métodos para el modelado de sistemas complejos y de gran escala. 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 del modelado de un proceso consiste en 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.

En general, uno de los principales inconvenientes a la hora de diseñar y elegir un modelo para un sistema es que se necesita definir a priori la estructura del modelo (modelo paramétrico) antes de realizar cualquier aproximación. Desafortunadamente, en la mayoría de los problemas reales, la definición de la estructura o forma funcional del modelo no es un problema que pueda ser fácilmente resuelto y, cualquier decisión a este respecto, podría influir muy subjetivamente en la naturaleza del problema. Por esta razón, hoy en día se ha despertado un gran interés en la comunidad científica en el desarrollo de técnicas no paramétricas o de modelo libre [215], que se basan en el uso de un modelo genérico simple que se va ajustando iterativamente.

Por otra parte, la gran mayoría de procesos industriales, se caracterizan por contar con pequeñas cantidades de datos experimentales disponibles. Debido a esta restricción y con el objeto de poder interpretar el modelo resultante, las técnicas *black-box approach* son insuficientes y por tanto, hay que considerar técnicas basadas en *grey-box approach* para obtener modelos en los que se combinen el conocimiento de la física de los procesos y de algunas relaciones que rigen el comportamiento. De este modo técnicas de regresión borrosa o neuroborrosas encuentran un nicho claro donde corroborar su efectividad. El modelado borroso ha demostrado una alta capacidad para describir sistemas del mundo real, mantener la transparencia del modelo para hacerlo comprensible al usuario final y una buena capacidad de generalización [216]. Por su parte, el modelado neuroborroso engloba todas las ventajas del modelado borroso, añadiéndole una mayor precisión debido al “ajuste fino” de ciertos parámetros del modelo.

Si bien es cierto que el modelado neuroborroso aporta múltiples ventajas, aún quedan importantes desafíos a la hora de extraer o inferir información a partir de los datos existentes. La técnica por excelencia para la extracción de información es el agrupamiento (*clustering*) y gran parte de los modelos borrosos y neuroborrosos utilizan técnicas de agrupamiento para la creación de las funciones de pertenencia (de entrada y/o salida) que más tarde 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* [217].

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. **En la actualidad, existen una gran cantidad de métodos de**

agrupamiento híbridos en revistas que periódicamente reportan nuevas mejoras y capacidades. Sin embargo, pese a los buenos resultados obtenidos, muchos de estos desarrollos ofrecen prestaciones insuficientes cuando son aplicados a procesos físicos y existen además restricciones de coste computacional, tiempo real, etc.

En este capítulo, por tanto, para el diseño de modelos experimentales de variables representativas de procesos, se han seleccionado de entre la amalgama de técnicas, sólo algunas de las que tienen un consolidado cuerpo de doctrinas e impacto científico y técnico. Esto no significa que no existan otras técnicas que puedan ofrecer resultados similares o mejores, sino que estas se han escogido de antemano precisamente por tener características y tener un buen comportamiento para los problemas considerados en esta Tesis Doctoral. Un estudio masivo de todos los métodos de agrupamiento reportados en la literatura están fuera del alcance de este trabajo, con el que se pretende, precisamente, sentar las bases para explorar nuevos métodos susceptibles de ser aplicados a procesos físicos en la micro y nano escala.

Por un lado, en la sección 3.1, como técnica no paramétrica o de modelo libre, se desarrolla y aplica el algoritmo de modelado híbrido incremental, incluyendo la estrategia de optimización de sus parámetros, a partir del método meta-heurístico de temple simulado (sección 3.2). En la sección 3.3, se explica la aplicación de modelado experimental desarrollada que incluye una interfaz gráfica de fácil manejo por parte de cualquier usuario.

Por otro lado, en esta Tesis se ha seleccionado el estudio de una técnica de regresión neuroborrosa y una técnica de agrupamiento para la creación de las funciones de pertenencia. En definitiva, esta segunda estrategia de modelado se basa en el algoritmo generalizado de agrupamiento borroso *c-Means*. En la sección 3.3 se describe el algoritmo, incluyendo una versión mejorada y generalizada del mismo. También se presenta el procedimiento de generación de las reglas y el método de aprendizaje utilizado que consiste en un algoritmo evolutivo, como es el de retro-propagación de errores (sección 3.5). Igualmente, en la sección 3.6, se presenta el desarrollo de una aplicación con interfaz gráfica para el modelado experimental y estático de sistemas.

Por último, las contribuciones a la ciencia y la técnica alcanzadas en este estudio se presentan en la sección 3.5, a modo de conclusiones.

3.1 Formalización del algoritmo de modelado híbrido incremental, HIM

De entre los distintos métodos para el modelado propuestos en la literatura, se destacan los modelos incrementales propuestos por Pedrycz [218], donde el elemento distintivo del diseño del modelo explota el principio de capacidad incremental. Siguiendo este principio, el modelado debe comenzar por su forma más genérica y por la forma más simple que uno pudiera imaginar. Sin embargo, no es necesario detener el diseño en este paso, ya que si es

necesario, el modelo se refina (ajusta) de forma iterativa mediante la invocación de alguna técnica más refinada (y localizada) para modelar algunas regiones en particular del espacio de entrada. El presente trabajo toma como base este principio, proponiendo el desarrollo de un modelo híbrido incremental. El modelo básico o global tiene que ser lo más simple posible, por lo que las técnicas de regresión lineal se presentan como una solución viable, debido a que son fáciles de desarrollar. Después de construir el modelo básico, los modelos híbridos adicionales necesitan ser refinados con una contraparte incremental como, por ejemplo, el algoritmo de agrupamiento borroso *Fuzzy k-Nearest Neighbors* [219, 220].

3.1.1 Modelo híbrido incremental, HIM

En definitiva, para modelar un proceso complejo esta Tesis Doctoral propone un primer algoritmo que emplea una técnica no paramétrica denominada modelo híbrido incremental que fue desarrollada por Pedrycz y Kwak [218]. Esta estrategia hace uso de 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. Adicionalmente, con el objeto de suavizar las transiciones entre el modelo global y el modelo local, se utiliza una estrategia de suavizado local basada en el algoritmo de agrupamiento borroso descrito por Roh et al. [221].

3.1.2 Modelo global

Cuando no se dispone de un conocimiento previo del sistema a modelar, la utilización de modelos genéricos tales como regresiones lineales o polinómicas, en general, buenas opciones de inicio para representar el comportamiento global del sistema. En nuestro caso en particular, el modelo global del sistema a modelar se obtiene ajustando un polinomio de grado m mediante el algoritmo de mínimos cuadrados. La salida del modelo global tendría, por tanto, la siguiente expresión:

$$\hat{y}_B(x_i) = f_B(x_i, O(x_i)) \quad (3.1)$$

siendo x_i el i -ésimo punto de entrada y $O(x_i)$ el valor de salida del punto x_i .

El procedimiento para la obtención del modelo global consiste en calcular y almacenar los parámetros de la función a ajustar (en nuestro caso el polinomio). La evaluación del algoritmo en un punto objetivo q consiste en evaluar la función en ese punto, con los parámetros obtenidos durante el entrenamiento.

3.1.3 Modelo local

La obtención de modelos locales puede basarse en una amplia gama de técnicas. Con vistas ser coherentes con la propuesta inicial recogida en la literatura y aprovechar al máximo

la potencialidad del método, se ha escogido el *Fuzzy k-Nearest Neighbors* (F- k NN), por su sencillez, facilidad en su interpretación y una buena precisión. De este modo, el procedimiento elegido para la obtención del modelo local en el modelado híbrido incremental es la aproximación *Fuzzy k-Nearest Neighbors* (F- k NN). k NN consiste en promediar el valor de los puntos más cercanos al punto objetivo. El algoritmo k NN asume, por tanto, que puntos cercanos tienen un valor similar. Para calcular la cercanía usaremos la norma euclídea, aunque se pueden utilizar otros métodos de normalización.

El aprendizaje de F- k NN es tedioso, por lo que en esta fase sólo necesitamos almacenar los datos conocidos (puntos de entrada y valores). A la hora de promediar el valor de los puntos más cercanos al punto objetivo q , obtenemos el siguiente conjunto:

$$N_s = \{d_i \in D_i\} \quad (3.2)$$

siendo D_i el conjunto de puntos de entrada para el algoritmo y d_i uno de los k_n vecinos más próximos a q .

La similitud entre los puntos de N_s y q se calcula de la siguiente forma:

$$S(n_i, q) = \begin{cases} 1, & \text{si } \|n_i - q\| = 0 \\ \left[\|n_i - q\|^{\frac{2}{p-1}} \cdot \sum_{j=1}^{k_n} \left(\frac{1}{\|n_j - q\|} \right)^{\frac{2}{p-1}} \right]^{-1} & \text{si } \|n_i - q\| \neq 0 \end{cases} \quad (3.3)$$

donde n_i es el i -ésimo vecino del punto objetivo q , y p es el coeficiente de borrosidad.

Podemos ahora calcular el valor del punto objetivo q utilizando la media de los valores objetivos de los puntos del conjunto N_s ponderada por la similitud S :

$$\hat{r}(q) = \sum_{i=0}^{k_n} S(n_i, q) \cdot r(n_i) \quad (3.4)$$

3.1.4 Modelo incremental

El modelo incremental se encarga de articular los dos modelos descritos anteriormente. El entrenamiento del modelo básico consiste en realizar el entrenamiento de los modelos básico e incremental. Así pues, sea $\hat{y}_b(x)$ la función que evalúa el modelo básico. Entonces podemos calcular el error de la predicción del modelo básico de la siguiente forma:

$$\varepsilon(x) = r(x) - \hat{y}_b(x) \quad (3.5)$$

Estos errores constituyen el conjunto D_i , entrada del modelo local de donde se calculan los vecinos de q utilizando (3.5), y son memorizados en su entrenamiento.

El cálculo del modelo híbrido incremental, en un punto q por parte del modelo incremental se obtiene añadiendo a la salida del modelo básico el término compensatorio calculado por el modelo local siguiendo la ecuación (3.6), es decir:

$$\hat{y}(q) = \hat{y}_B(q) + \hat{r}(q) \quad (3.6)$$

Habitualmente trabajamos con datos cuyas variables tienen universos de discurso muy distintos. Esto hace que tanto el algoritmo global como local trabajen en condiciones extremas en las que se puedan descartar alguna de las variables de entrada y sólo dar peso a la que tenga un dominio más amplio. Por ejemplo, en el modelo local, la selección de vecinos descartará las variables con rangos cortos, pues influyen poco en la norma.

Para evitar este problema, podemos recurrir a la normalización de los datos. Si denotamos por x_i^j la variable j del punto de entrada i , podemos obtener los puntos normalizados de la siguiente forma:

$$z_i^j = \frac{x_i^j - \mu(j)}{\sigma(j)} \quad (3.7)$$

$$\mu(j) = \frac{\sum_{i=0}^n x_i^j}{n} \quad (3.8)$$

$$\sigma(j) = \sqrt{\frac{\sum_{i=0}^n (x_i^j - \mu)^2}{n}} \quad (3.9)$$

donde $\mu(j)$ es la media de la variable j -ésima, $\sigma(j)$ es su desviación típica y n es el número de puntos de entrada.

En las figuras (Figura 3.1 y Figura 3.2) se resumen todos los pasos seguidos para la obtención del modelo incremental. Primeramente se realiza la parte del entrenamiento del modelo a partir de los datos objetivos (Figura 3.1), para posteriormente evaluar el modelo obtenido con los nuevos datos a considerar (Figura 3.2), es decir, calcular el modelo obtenido para los nuevos datos a considerar.

Entrenamiento:

1. Obtención de los parámetros de entrenamiento:
 - (a) Parámetros del modelo global básico (el orden del polinomio m)
 - (b) Parámetros del modelo local (k_n y p , aunque no son necesarios durante el entrenamiento)
 - (c) Datos de entrada y valores de salida (x_i y $O(x_i)$)
2. Normalización de x_i y $O(x_i)$ mediante (3.7)
3. Entrenamiento del modelo global:
 - (a) Cálculo de los coeficientes del polinomio
4. Cálculo de los errores utilizando la ecuación (3.6)
5. Entrenamiento del modelo local utilizando los errores:
 - (a) Memorización de los datos de entrada y los errores correspondientes

Figura 3.1. Pasos seguidos en el entrenamiento del modelo incremental**Evaluación:**

1. Obtención de los puntos de evaluación
2. Normalización de los puntos de evaluación con (3.7), pero con μ y σ del entrenamiento
3. Evaluación del modelo básico en cada punto de evaluación
4. Evaluación del modelo local en cada punto de evaluación con (3.6)
5. Evaluación del modelo incremental en cada punto de evaluación con (3.5)
6. Des-normalización de los datos usando la inversa de (3.7)

Figura 3.2. Pasos seguidos en la evaluación del modelo incremental

3.2 Optimización de los parámetros del modelo híbrido incremental en base al algoritmo de temple simulado

Una de las desventajas del método F- k NN es la elección de los parámetros k_n y p . A esto se une la dificultad del algoritmo HIM para seleccionar el orden del polinomio para el modelo global (m). Esta dificultad es inherente a la parametrización de muchos algoritmos de agrupamiento y abren las puertas a la aplicación de métodos de parametrización óptima basados en Hessianas y en métodos libre de gradiente.

En este trabajo se consideró un método que ya había sido aplicado con éxito anteriormente por su buena y demostrada capacidad de convergencia que es el método del temple simulado. Aunque cualquier otro método puede también aplicado [222]. El temple simulado (SA, *Simulated Annealing*) es un método de búsqueda meta-heurística para la resolución de problemas de optimización global que simula el proceso físico de templado de materiales, el cual consiste en el calentamiento de estos materiales y luego su lento enfriamiento para

aumentar el tamaño de sus cristales y reducir sus defectos, y de esa forma minimizar la energía de todo el sistema.

El método fue propuesto de forma independiente por S. Kirkpatrick, C. D. Gelatt y M. P. Vecchi, del “*IBM Thomas J. Watson Research Center*”, en 1983 [43] y por Vlado Černý, del Instituto de Física y Biofísica de la Universidad de Comenius (Bratislava), en 1985 [42]. El algoritmo es una adaptación del algoritmo de Metropolis-Hastings [223, 224], que es un método de tipo Monte Carlo para generar muestras de estados de un sistema termodinámico.

Básicamente el algoritmo en cada iteración, genera un punto de forma aleatoria y calcula la distancia entre el nuevo punto y el anterior mediante una distribución de probabilidad con una escala que es proporcional a la temperatura. El algoritmo acepta todos los puntos nuevos que reducen el objetivo deseado, pero además, también acepta los puntos que lo incrementan con una cierta probabilidad. Al aceptar los puntos que incrementan el objetivo, el algoritmo evita quedarse atrapado en mínimos locales, y permite una mayor exploración del espacio de búsqueda hacia más posibles soluciones. El algoritmo, según progresa, selecciona una planificación del templado para sistemáticamente disminuir la temperatura. Con la disminución de la temperatura, el algoritmo reduce el espacio de búsqueda hasta converger a un mínimo o máximo, dependiendo de la función de coste [225].

El método de temple simulado consiste principalmente de tres relaciones:

1. $g_T(x)$: Densidad de probabilidad del espacio de estado de D_T parámetros $x = \{x^i; i = 1, \dots, D_T\}$, refiriéndose a T^a , como la temperatura.
2. $h(\Delta E)$: A partir de la variación de la energía, obtenida como la diferencia entre el valor actual y el anterior, calcular la probabilidad de aceptación de una nueva función de coste.
3. $T^a(k)$: Planificación de la “temperatura de templado” T^a en k pasos de tiempo de templado.

La probabilidad de aceptación está basada en la oportunidad de un nuevo estado con “energía” E_{k+1} , relativo al estado previo con “energía” E_k ,

$$h(\Delta E) = \frac{e^{-E_{k+1}/T^a}}{e^{-E_{k+1}/T^a} + e^{-E_k/T^a}} = \frac{1}{1 + e^{\Delta E/T^a}} \approx e^{-\Delta E/T^a} \quad (3.10)$$

siendo $\Delta E = E_{k+1} - E_k$.

La ecuación anterior que no es más que la distribución de Boltzmann, siendo ΔE la diferencia de energía entre los estados consecutivos y el valor de energía en cada instante, se determina mediante la función de coste a minimizar

Considerando el conjunto de estados x , con una energía $e(x)$, un conjunto de distribuciones de probabilidad $p(x)$ y la distribución de energía por estado $d(e(x))$, el algoritmo también puede ser descrito a partir de la energía total E :

$$E = \sum_x p(x)d(e(x)) \quad (3.11)$$

A partir de un estado de referencia x , el valor máximo de entropía SE del sistema puede obtenerse como,

$$SE = -\sum_x p(x) \ln(p(x)/p(\bar{x})) \quad (3.12)$$

El empleo de multiplicadores de Lagrange para limitar la energía al valor medio T^a , conduce a la distribución más probable de Gibbs $G(x)$ normalizada,

$$G(x) = \frac{1}{Z} e^{-H(x)/T^a}; \quad Z = \sum_x e^{-H(x)/T^a} \quad (3.13)$$

donde Z es la función de partición y H es el operador de Hamiltoniano utilizado como función de energía.

Para las distribuciones de los estados (3.12), introducidas anteriormente, y probabilidades de aceptación del tipo como la definida en (3.13), se mantiene el principio de equilibrio del balance detallado. Por ejemplo, dadas las distribuciones de estados consecutivos $G(x_k)$ y $G(x_{k+1})$, aplicando el criterio de aceptación, $h(\Delta E) = h(E_{k+1} - E_k)$, resultan iguales:

$$G(x_k)h(\Delta E(x)) = G(x_{k+1}) \quad (3.14)$$

Lo anterior es suficiente para establecer que todos los estados del sistema pueden ser muestreados. Sin embargo, la planificación del templado interrumpe el equilibrio cada vez que la temperatura cambia, y de esta forma, en el mejor de los casos, esto debe realizarse cuidadosamente y de forma gradual.

Un aspecto importante en el algoritmo de temple simulado, es la selección del rango de los parámetros a ser buscados. En la práctica, el cálculo de sistemas continuos requiere de su discretización, por lo que podemos asumir que el espacio de trabajo puede ser discretizado sin mucha pérdida de información. Existen, además, ciertas restricciones necesarias cuando se utilizan funciones de coste con valores integrales. En varias aplicaciones se suelen utilizar técnicas para reducir el espacio inicial a medida que progresa la búsqueda. Por ejemplo, para muchos sistemas físicos es posible escoger como función de densidad de probabilidad del espacio de estado de los parámetros, la siguiente distribución de Boltzmann [225]:

$$g(\Delta x) = (2\pi T^a)^{-D/2} e^{-\Delta x^2/(2T^a)}; \Delta x = x - x_0 \quad (3.15)$$

tomándose Δx en la práctica como la desviación entre dos estados consecutivos, y siendo además T^a , una medida de las fluctuaciones de la distribución g en el espacio de dimensión D de x . A partir de $g(\Delta x)$, se ha demostrado que basta con obtener un mínimo global de la energía $E(x)$, si selecciona T^a que varíe de la forma:

$$T^a(k) = T_0^a / \ln k \quad (3.16)$$

siendo T_0^a la temperatura inicial y se escoge lo suficientemente grande. Usualmente, también suele realizarse la planificación de la temperatura de forma exponencial [225], es decir:

$$\begin{aligned} T^a(k) &= T_0^a e^{(\xi-1)k} \\ T^a(k+1) &\approx \xi T^a(k) \end{aligned} \quad ; \quad 0 < \xi < 1 \quad (3.17)$$

donde ξ es una constante de reducción cuyos valores típicos se ajustan entre 0.8 y 0.99. Por otra parte, para una variación rápida de la temperatura T^a [222, 225], también se utiliza con frecuencia,

$$T^a(k) = T_0^a / k \quad (3.18)$$

En aplicaciones prácticas del algoritmo, a partir del cálculo de la variación de energía ΔE y a partir de la probabilidad de aceptación $h(\Delta E)$ definida en (3.15), se utilizan criterios de aceptación-rechazo del estado actual, x_k , empleando el algoritmo de Metropolis [223]. Según este criterio, la probabilidad de aceptación se compara con un número R_M entre 0 y 1, generado de forma aleatoria mediante una distribución uniforme, evitando de esta manera que ocurra una convergencia prematura hacia un mínimo local y poder continuar la búsqueda del mínimo global (ver Figura 3.3).




Figura 3.3. Algoritmo de Metrópoli de aceptación-rechazo.

El algoritmo de temple simulado se ejecuta de forma iterativa, generando nuevos estados x que minimicen la energía E del sistema (función objetivo), su ejecución terminará teniendo en cuenta varias condiciones diferentes:

- El nivel de energía E es menor o igual que cierto valor prefijado límite.
- Se ha alcanzado el nivel de tolerancia preconcebido para la variación de energía ΔE .
- Se alcanza un máximo número de iteraciones predeterminadas.
- Se ha sobrepasado el tiempo máximo permitido de ejecución del algoritmo.

En el caso concreto que se considera en esta Tesis Doctoral, el algoritmo de temple simulado comienza su ejecución con valores iniciales de los parámetros del modelo híbrido incremental $K_{HIM} = [m_0, k_0, p_0]$, donde m_0 es el orden inicial del modelo, el número inicial de vecinos es k_0 y p_0 es el valor inicial del coeficiente de borrosidad y se evalúa el índice de comportamiento MAE (error absoluto medio), como función objetivo o de "energía del sistema", mediante las expresiones (3.19) y (3.20):

$$MAE = \frac{1}{N} \sum \frac{|Y - Y'|}{Y} \cdot 100 \quad (3.19)$$

$$K_{HIM} = [m, k, p]_{OPT} = \arg \min(MAE) \quad (3.20)$$

Como paso siguiente en la ejecución del algoritmo, de forma iterativa los parámetros K_{HIM} de modelado actuales son perturbados para generar otro $K_{HIM,NEW}$ y se vuelve a evaluar el índice MAE . El criterio de aceptación o de rechazo está basado en el algoritmo de Metropolis. El algoritmo SA simula, de forma iterativa, el proceso de templado de metales a medida que busca una solución. Se genera una perturbación aleatoria sobre las variables de diseño m, k_n, p

que, a su vez, genera un cambio en la función objetivo, es decir, el índice de comportamiento MAE . Estas perturbaciones dependen de un índice de temperatura, T^a y una tasa de reducción de temperatura ($rdc = [0.5, 0.99]$). En el trabajo de Sun y Lin, 2006, [226], se puede encontrar una descripción detallada de este parámetro de control de la temperatura.

La temperatura disminuye en cada iteración del algoritmo, reduciendo así el tamaño de la perturbación a medida que progresa la búsqueda. Cada conjunto de parámetros del modelo obtenidos por este método se sustituye en las ecuaciones del modelo híbrido incremental y se evalúa la precisión del modelo con cada uno de los datos de entrenamiento. El índice de rendimiento MAE se evalúa comparando las respuestas simuladas con las respuestas deseadas.

Si el índice de rendimiento es menor que el índice de rendimiento anterior, entonces los nuevos parámetros toman el lugar de los parámetros anteriores. En caso contrario, los nuevos parámetros del modelo no se descartan inmediatamente, sino que se someten a un proceso de evaluación de probabilidad donde se calcula la probabilidad P del coste de los nuevos parámetros (MAE_{NEW}) con relación al mejor coste anterior (MAE_{PREV}), utilizando la ecuación de Boltzmann:

$$P = e^{\frac{(MAE_{PREV} - MAE_{NEW})}{T^a}} \quad (3.21)$$

Se compara entonces la probabilidad P con un valor umbral ζ (que es un valor entre 0 y 1 generado mediante una distribución uniforme). Si $P > \zeta$, entonces se aceptan los nuevos parámetros del modelo como si $MAE_{NEW} < MAE_{PREV}$ y se rechazan si $P < \zeta$. Este mecanismo evita una convergencia prematura a un mínimo local y permite acercarse al mínimo global. Después de esta etapa, se reduce el índice de temperatura por medio de una planificación del templeado utilizando la constante de reducción $\zeta = [0.5, 0.99]$.

Todo este proceso se repite hasta que bien el índice de rendimiento MAE haya alcanzado un nivel mínimo aceptable o hasta que el valor de la temperatura haya alcanzado un valor demasiado bajo como para perturbar los parámetros. El objetivo principal es obtener un modelado óptimo de los parámetros que sirvan para conseguir un modelo rápido y preciso a través de la minimización del error medio absoluto (MAE) como índice de rendimiento. El ajuste óptimo de los parámetros de modelado se realiza off-line utilizando el método de temple simulado, obteniéndose un modelo híbrido incremental capaz de representar con muy buena precisión el comportamiento real del proceso.

3.3 Desarrollo de una aplicación de modelado de sistemas complejos basada en el algoritmo híbrido incremental (HIM)

A continuación, en esta sección, se describe la aplicación de modelado desarrollada, la cual incluye una interfaz gráfica. A la hora de implementar el algoritmo, se eligió C como lenguaje y todas las pruebas se realizaron sobre Linux 2.6 y Windows 7.

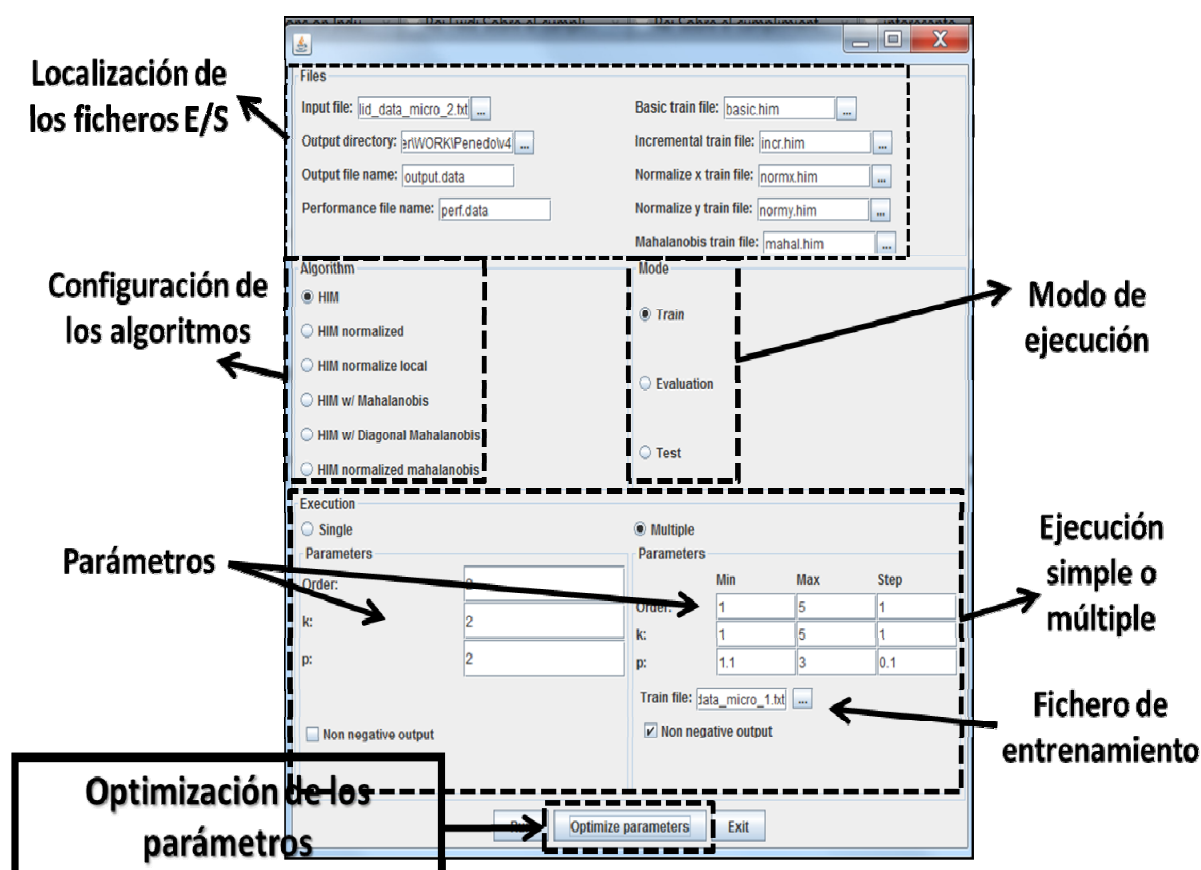


Figura 3.4. Interfaz de la aplicación HIM creada para el modelado de sistemas

La Figura 3.4 muestra la interfaz de usuario desarrollada donde se puede configurar la aplicación. En ella, en la parte superior se destaca el bloque de localización de los ficheros de entrada (datos experimentales) y salida y los de rendimiento. En la mitad izquierda se aprecia el tipo de algoritmo HIM a seleccionar (normalizado, local, Mahalanobis, etc.). En la mitad derecha se selecciona el modo de ejecución (entrenamiento, evaluación o *test*). Por último, en la parte inferior se puede realizar la ejecución simple o múltiple del algoritmo con sus correspondientes valores de los parámetros y, además, se encuentra el botón de configuración de los parámetros. Además, está implementada la opción de optimizar los parámetros mediante el algoritmo de temple simulado.

3.4 Formalización del algoritmo de modelado generalizado de agrupamiento borroso (GFCM)

De entre los métodos de agrupamiento que recoge la literatura, uno de los más estudiados es el algoritmo de agrupamiento borroso *c-means* (FCM) [227]. Este método posee unas características que lo hacen muy atractivo para la extracción de información y el modelado de procesos físicos. FCM y sus diferentes variantes llevan a cabo la tarea de agrupamiento para un conjunto de datos mediante la minimización de una función objetivo sujeta a una serie de restricciones. Por ejemplo, la suma de todos los grados de pertenencia a cada dato en un punto debe ser uno. Debido a su buen funcionamiento, sencillez y amplio conocimiento, multitud de autores se han centrado en mejorar este algoritmo, particularmente estudiando el índice de borrosidad o con el empleo de distintas distancias matemáticas [228],[229] y [230].

En este sentido, Zhu et al. [230] exponen un interesante estudio acerca de las limitaciones que provoca el hecho de fijar un índice de borrosidad $p = 2$ “por defecto”, tal y como se hace actualmente en la mayoría de los algoritmos borrosos. Por ejemplo, Höppner y Klawonn [231] proponen una modificación del algoritmo FCM que consiste en introducir una nueva forma de limitar las particiones borrosas con el fin de mejorar las mismas (IFP-FCM). Sin embargo, esta modificación obliga a situar un índice $p = 2$. Por tal motivo, en el primer trabajo citado en este párrafo [230], los autores propusieron también un algoritmo de agrupamiento que extiende la aproximación FCM *with Improved Fuzzy Partitions* (IFP-FCM) para eliminar la limitación de fijar un valor de $p = 2$. La propuesta, **denominada *Generalized Fuzzy C-Means with Improved Fuzzy Partitions (GIFP-FCM)*** generaliza el uso de IFP-FCM **añadiendo un parámetro α que permite**, según su valor, variar entre el FCM y el IFP-FCM.

A pesar de que la incorporación de este parámetro α presenta muy buenos resultados en clasificación, aún no se han aprovechado las potencialidades que ofrece este nuevo algoritmo de agrupamiento GIFP-FCM para modelar sistemas a través de una regresión borrosa o neuroborrosa. Por tal razón, en este capítulo de la tesis se presenta un algoritmo de agrupamiento *Generalized Fuzzy C-Means with Improved Fuzzy Partitions* (GIFP-FCM) que se aplica a una topología/estructura neuroborrosa que puede ser aplicada al modelado y control de procesos complejos con no linealidades, relaciones entre variables, incertidumbre, etc.

3.4.1 Algoritmo borroso *C-Means* con particiones borrosas mejoradas

El algoritmo de agrupamiento *Fuzzy C-Means* es un resultado de los algoritmos basados en la optimización de una función objetivo básica, que se denominada *C-Means*, en la cual el tipo de agrupamiento se realiza en base a particiones borrosas. Un algoritmo de agrupamiento por particionado es aquel que divide el espacio de datos en partes, denominadas *clusters*, en el

que la asignación de un dato a un *cluster* viene dada por su cercanía al mismo, generalmente, al centro. Por otra parte, un algoritmo por particionado es borroso cuando permite que un dato pueda pertenecer a varios *clusters*, es decir, los *clusters* se pueden superponer parcialmente.

FCM y sus variantes resuelven un problema de optimización no lineal mediante la minimización de la función objetivo (3.22) con una serie de condicionantes o restricciones como, por ejemplo, el que la suma de todos los grados de pertenencia a cada *cluster* en cada punto del espacio de trabajo debe ser igual a la unidad (3.23).

$$J_{FCM} = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m \psi^2(x_j, v_i) \quad (3.22)$$

$$u_{ij} \in [0,1] \quad \text{con} \quad \sum_{i=1}^c u_{ij} = 1 \quad j = 1, 2, \dots, n. \quad (3.23)$$

siendo x_j el punto a procesar, v_i el centro del cluster i , u_{ij} la pertenencia del dato j al cluster i , ψ la distancia a utilizar (euclidea en la mayoría de los casos), p el índice de borrosidad (con $p \geq 1$), c el número total de *clusters* y n el número total de puntos.

Aparentemente este método mejora el problema de la convergencia que tienen otros algoritmos de agrupamiento (ej., algoritmo *K-Means*), pero posee algunas desventajas. La principal desventaja que presenta este método es que para normalizar las probabilidades de que un elemento x_j pertenezca a un *cluster* i depende implícitamente del número de grupos, y si este número se especifica de manera errónea aparecerán graves problemas. Por este motivo, numerosos autores han propuesto modificaciones del mismo (u otros algoritmos) que tratan de solucionar estas desventajas.

Con el fin de mejorar el algoritmo FCM para la regresión de modelos borrosos, el trabajo de Höppner y F. Klawonn [231] elimina la restricción (2) (la suma de las pertenencias en cada punto es igual a la unidad) proponiendo una nueva forma de limitar las funciones de pertenencia. En este trabajo se modifica el algoritmo FCM mejorando las particiones borrosas (IFP-FCM) a través de una modificación en la función objetivo en la que se trabaja con distancias a los prototipos de cada *cluster*, en lugar de distancias al elemento central de cada *cluster* (3.24). Esta modificación recompensa la nitidez de los grados de pertenencia, por lo que esta versión modificada parece ser menos sensible al ruido y a valores atípicos. Sin embargo, el índice de borrosidad p se limita únicamente a dos, a causa de la introducción de las restricciones en la función de pertenencia.

$$J_{IFP-FCM} = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^2 \psi^2(x_j, v_i) - \sum_{j=1}^n a_j \sum_{i=1}^c \left(u_{ij} - \frac{1}{2} \right)^2 \quad (3.24)$$

$$v_i = \frac{\sum_{j=1}^n u_{ij}^2 \cdot x_j}{\sum_{j=1}^n u_{ij}^2} \quad (3.25)$$

$$u_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{\psi^2(x_j, v_i) - a_j}{\psi^2(x_j, v_k) - a_j} \right)} \quad (3.26)$$

$$a_j = \min \left\{ \psi^2(x_j, v_i) - \lambda \mid i \in \{1, 2, \dots, c\} \right\} \quad (3.27)$$

Aunque tanto el algoritmo FCM como el algoritmo IFP-FCM ofrezcan unos resultados de agrupamiento bastante razonables con el índice de borrosidad fijado en $p = 2$, también hay muchos casos que requieren el empleo de un índice de borrosidad diferente para obtener resultados óptimos o cuasi-óptimos. Por esta razón, surge la necesidad de desarrollar algoritmos de agrupamiento (con su correspondiente función objetivo) en los que se pueda generalizar el índice de borrosidad p .

A su vez, otro problema, que vale la pena destacar acerca del uso del agrupamiento IFP-FCM en la regresión de modelos, es cómo elegir adecuadamente el parámetro λ para conseguir aplicar la mayor recompensa posible (3.27). Este parámetro λ es introducido por los autores con el fin de evitar el posible caso de obtención de un grado de pertenencia negativo (consultar [231] para más detalles). Obviamente, el parámetro λ ha de ser positivo ($0, +\infty$) y se puede observar que tiene una influencia importante en la borrosidad de la partición (*fuzziness*) para un conjunto de datos, y que a su vez su valor dependerá del conjunto de datos en cuestión. Sin embargo, Höppner y Klawonn no limitaron el alcance de su valor, ni establecieron ciertas reglas para establecer el mismo.

Con el objetivo de corregir ambos inconvenientes (y sus restricciones asociadas), Zhu et al. desarrollan el *Generalized Fuzzy c-Means algorithm with improved fuzzy partitions* (GFCM) [230] cuya versión extendida y mejorada se presenta en esta Tesis Doctoral.

3.4.2 Algoritmo borroso *c-Means* generalizado con particiones borrosas mejoradas

El algoritmo de agrupamiento borroso generalizado (GIFP-FCM) pretende dar una solución a la lenta convergencia de FCM, a la elección del coeficiente de recompensa λ y a la expansión del coeficiente de borrosidad p (sin limitación). Este algoritmo de agrupamiento mejora el *FCM with Improved Fuzzy partitions* (IFP-FCM), generalizando su uso mediante la adición de un parámetro α que permite, según su valor, variar entre el algoritmo FCM y el IFP-FCM.

Además, el algoritmo GIFP-FCM se diferencia de los algoritmos anteriormente expuestos en que, mediante el empleo del parámetro α y de la re-definición de la función objetivo, incorpora una mejora en el aprendizaje basada en la teoría de aprendizaje competitivo, más concretamente en el aprendizaje competitivo por rival penalizado (RPCL) [232]. A diferencia del enfoque utilizado en [231], en el trabajo de Zhu *et al.* [230] se investiga un enfoque alternativo para reducir la borrosidad de la partición final basado en los principios de RPCL. Con el fin de acelerar la velocidad de convergencia, en términos de la teoría RPCL, se debe reforzar la mayor de las pertenencias, mientras que ha de penalizarse/suprimirse el resto de ellas. Por tanto, se considera un nuevo término de recompensa para la pertenencia a un solo punto de la muestra x_j con el fin de obligar a asignaciones más nítidas (consultar [230] para más detalles). Teniendo en cuenta estas penalizaciones, la función objetivo queda del siguiente modo:

$$J_{GIFP-FCM} = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^2 \psi^2(x_j, v_i) - \sum_{j=1}^n a_j \sum_{i=1}^c u_{ij} (1 - u_{ij}^{p-1}) \quad (3.28)$$

$$a_j = \alpha \cdot \min \{ \psi^2(x_j, v_s) \mid s \in \{1, \dots, c\} \} \quad (3.29)$$

De este modo, se sustituye el parámetro λ por un parámetro α para la recompensa de las pertenencias que introduce las siguientes ventajas: por un parte α se limita a un conjunto mucho más reducido de valores ($\alpha \in [0,1]$) y, por otra parte, con distintos valores de α se puede variar entre las aproximaciones FCM, IFP-FCM, y GIFP-FCM. Con valores de $\alpha=0$ el algoritmo GIFP-FCM resulta ser FCM, mientras que con $p=2$ y α aproximadamente 1 GIFP-FCM tiende a ser IFP-FCM.

En base a la función objetivo (3.28) y las restricciones que impone el parámetro α en (3.29), la pertenencia de cada dato j a cada *cluster* i , así como al centro del *cluster* i , vienen dados en el algoritmo GIFP-FCM por las siguientes ecuaciones:

$$u_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{\psi^2(x_j, v_i) - \alpha \cdot \min_{1 \leq s \leq c} \psi^2(x_j, v_s)}{\psi^2(x_j, v_k) - \alpha \cdot \min_{1 \leq s \leq c} \psi^2(x_j, v_s)} \right)^{\frac{1}{p-1}}} \quad (3.30)$$

$$v_i = \frac{\sum_{j=1}^n u_{ij}^p \cdot x_j}{\sum_{j=1}^n u_{ij}^p} \quad (3.31)$$

donde p es el índice de borrosidad, n es el número total de datos, c es el número de *clusters*, x_j es el dato o muestra j -ésima, u_{ij} es la pertenencia del dato j al *cluster* i , v_i es el centro del *cluster* i y $\psi(\cdot)$ indica la distancia matemática utilizada.

Pese a que el cómputo de las distancias podría hacerse por casi cualquier método, se elige la distancia euclídea frente a otras por su menor sensibilidad al ruido en conjuntos de datos así como por su sencillez computacional que la harán más acorde para posteriores aplicaciones en tiempo real.

En resumen, la ejecución del algoritmo de *clustering* GIFP-FCM queda de la siguiente manera:

- Paso 1:** Se establece el número de *clusters* $c(2 < c < n)$, el umbral ϵ , el índice de borrosidad br , el parámetro α y el máximo de número de iteraciones IT . Se inicializa la partición borrosa $u_{ij}^{(1)}$ y el índice para cada iteración $il = 1$
- Paso 2:** Se calcula los centros de las particiones $v_i^{(il+1)}$ usando la ecuación (2).
- Paso 3:** Se calcula las funciones de pertenencia $u_{ij}^{(il+1)}$ usando la ecuación (1).
- Paso 4:** Si $\|u_{ij}^{(il+1)} - u_{ij}^{(il)}\| < \epsilon$ o el número de iteraciones $il > IT$, entonces se termina el algoritmo devolviendo el resultado del agrupamiento (centros de los *clusters* y matriz de funciones de pertenencia). En caso contrario $il = il + 1$ y volver al **Paso 2**.

Figura 3.5. Descripción del algoritmo de agrupamiento GIFP-FCM.

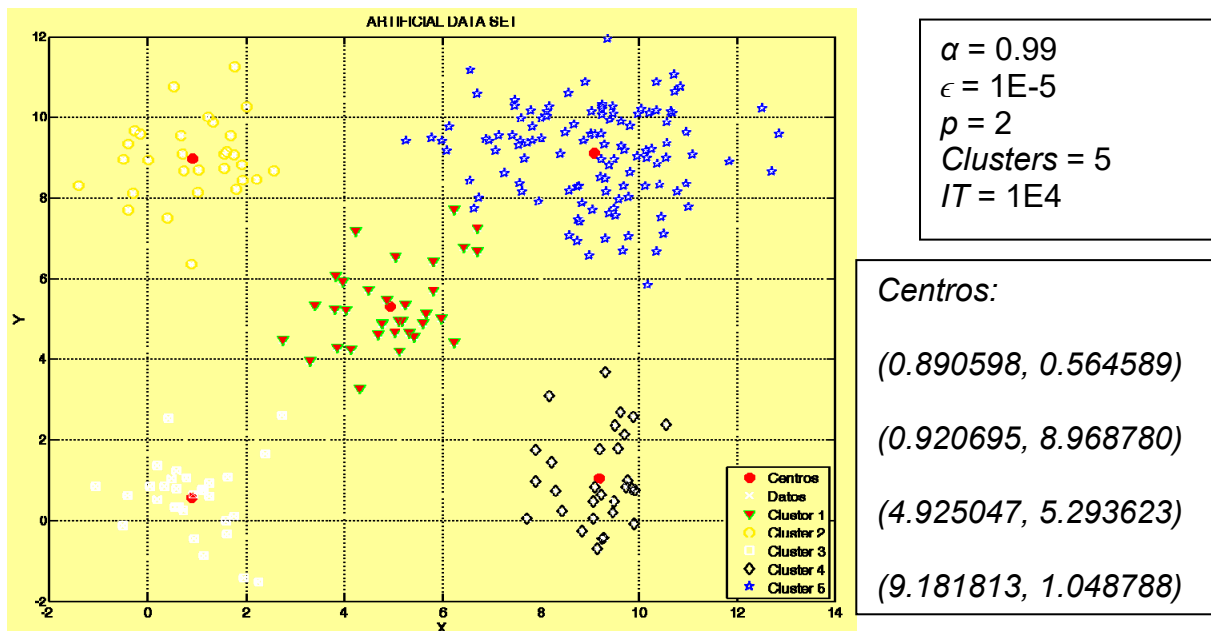


Figura 3.6. Ejecución del algoritmo GFCM implementado, con datos generados artificialmente, y parámetros y resultado de cada agrupamiento (centros).

En la Figura 3.6 se ilustra un ejemplo de la aplicación del algoritmo con datos generados artificialmente. Además, se listan los parámetros utilizados y los resultados de la obtención de los centros de cada agrupamiento borroso.

En base a los experimentos realizados por los autores del trabajo original, así como por los resultados obtenidos en el propio desarrollo de la aplicación basada en este algoritmo, se recomienda el empleo de valores $\alpha \in (0.9, 0.99)$ para obtener, tanto una rápida convergencia como unos buenos resultados de agrupamiento.

3.4.3 Creación de las reglas por medio de un método de inferencia neuroborrosa tipo Mamdani *Neuro-fuzzy System*

Para aprovechar al máximo las ventajas que nos aporta la utilización del algoritmo de agrupamiento borroso *Generalized Fuzzy c-Means with improved fuzzy partitions* (GIFP-FCM) se decide utilizar una regresión o método de inferencia neuroborrosa del tipo Mamdani. En este tipo de sistema neuroborroso nos encontramos con que se utilizan funciones de pertenencia borrosas para determinar tanto los antecedentes como los consecuentes de las reglas *if-then*. Una de las ventajas que tiene este tipo de sistemas neuroborroso es que, si las funciones de pertenencia son derivables, se pueden utilizar algoritmos de aprendizaje supervisado tales como el algoritmo de retro-propagación de errores (*backpropagation*), el cual emplea técnicas de descenso por gradiente con el objeto de optimizar ciertos parámetros del sistema.

Ciertamente, la incorporación del algoritmo de agrupamiento borroso en el sistema de inferencia implica establecer el modo mediante el cual se crean las reglas borrosas. Para ello, en esta tesis se decide adoptar una condición de diseño bastante extendida en los métodos de inferencia neuroborrosos. Ésta establece que el número de reglas del sistema es igual al número de *clusters* obtenidos en el proceso de agrupamiento. Algunos ejemplos que utilizan este principio son [233],[234] o [235]. Así, si consideramos que el sistema tiene c reglas borrosas definidas inicialmente a través del algoritmo de agrupamiento, la i -ésima regla tiene la forma:

Regla i : Si el dato x_j pertenece al cluster i (expresado a través u_{ij}), entonces la salida del sistema y_j es la salida asignada al cluster i (a través de su función de pertenencia Γ_i)

La pertenencia de cada dato al conjunto de funciones que conforman el espacio de entrada, la aporta directamente el algoritmo de agrupamiento borroso GFCM a través de (3.30). Faltaría únicamente por determinar el conjunto de funciones de pertenencia de salida (con un número de funciones igual al número de *clusters* creados). Para facilitar la posterior incorporación de algoritmos de retro-propagación, se eligen funciones de pertenencia de *Gaussiana* a la hora de computar la salida.

$$r_i = \exp \left[-\frac{(y - n_i)^2}{2\delta_i^2} \right] \quad (3.32)$$

Dado que se ha utilizado un algoritmo de agrupamiento borroso, es necesario ponderar la salida asignada a un determinado dato en función de su grado de pertenencia a cada *cluster*.




Figura 3.7. Arquitectura del sistema neuroborroso tipo Mamdani con algoritmo de agrupamiento GIFP-FCM.

En base a este principio, junto a la condición de diseño utilizada y a la estructura neuroborrosa a la que dan lugar ambos conceptos (ver Figura 3.7), se obtiene la fórmula de salida del algoritmo neuroborroso para cada dato:

$$f(x_j) = \frac{\sum_{i=1}^c \frac{n_i}{\delta_i^2} \cdot u_{ij}}{\sum_{i=1}^c \frac{1}{\delta_i^2} \cdot u_{ij}} \quad (3.33)$$

donde x_j es el dato j -ésimo al que se le aplica la función de salida, n_i es el centro de la función de pertenencia correspondiente al consecuente i , δ_i es la anchura de la función de pertenencia correspondiente al consecuente i y u_{ij} es la pertenencia del dato j al *cluster* i . Tal y como se ha comentado anteriormente, este centro y anchura se corresponden al centro y anchura de la función *Gaussiana* (3.32) con el objeto de poder ser derivable la función de salida.

La elección de estas funciones de pertenencia *Gaussianas* de salida (una para cada regla) supone que se deben establecer unos valores iniciales de centro y anchura para cada *cluster* de salida; es decir, de centro y anchura del consecuente de la regla i -ésima. Como punto de partida, se decide inicializar n_i y δ_i de la siguiente forma:

$$n_i(0) = \sum_{k=1}^{l_i} \frac{y_{ki}}{l_i} \quad (3.34)$$

$$\delta_i(0) = \max_{1 \leq k \leq l_i} y_{ki} - \min_{1 \leq k \leq l_i} y_{ki} \quad (3.35)$$

donde y_{ki} es la salida del dato k -ésimo y l_i es el número total de datos, pertenecientes ambos principalmente al *cluster* i .

Dado que esta inicialización puede no ser demasiado buena y con el objetivo de obtener los mejores resultados posibles, se tiene que ejecutar posteriormente un algoritmo de aprendizaje que ajuste, entre otros parámetros, n_i y δ_i hasta lograr minimizar el error que viene dado por la siguiente formula:

$$E(x_j) = \frac{1}{2} (f(x_j) - o_j)^2 \quad (3.36)$$

donde o_j corresponde al valor de salida real para la entrada x_j .

3.5 Aprendizaje del modelo en base al algoritmo de retro-propagación de errores

Una vez obtenido el modelo neuroborroso, y utilizando los datos de entrada-salida de entrenamiento $[x_j, o_j]$, el algoritmo de retro-propagación de errores tratará de minimizar la función objetivo descrita por (3.36).

Para ello, este algoritmo de aprendizaje actualizará los parámetros del modelo a modificar a través de un incremento dado por:

$$h(s+1) = h(s) - \eta \frac{\partial E}{\partial h(s)} \quad (3.37)$$

donde h es el parámetro a actualizar, s es el número de iteración del algoritmo de aprendizaje, η es la tasa de aprendizaje y $\partial E / \partial h(s)$ representa la derivada parcial de la función de error a minimizar con respecto al parámetro a actualizar.

En el caso del modelo neuroborroso tipo Mamdani con algoritmo de clustering GIFF-FCM, los parámetros a actualizar se corresponden con los centros de los *cluster* de entrada, v_i , y salida, n_i , y la anchura de los *clusters* de salida, δ_i . Suponiendo un modelo de Q entradas ($q=1,2,\dots,Q$) y una salida, las fórmulas de actualización quedarían del siguiente modo:

$$n_i(s+1) = n_i(s) - \frac{\eta}{\delta_i^2} \Phi_i(\bar{x}_j) [f_p(\bar{x}_j) - y_j] \quad (3.38)$$

$$\delta_i(s+1) = \delta_i(s) - \frac{2\eta}{\delta_i^3} \Phi_i(\bar{x}_j)[f_p(\bar{x}_j) - y_j][f_p(\bar{x}_j) - n_i(s)] \quad (3.39)$$

$$v_{qi}(s+1) = v_{qi}(s) - \frac{\eta}{\delta_i^2} \Phi_i(\bar{x}_j)[f_p(\bar{x}_j) - y_j][f_p(\bar{x}_j) - n_i(s)] \cdot \frac{[x_{qj} - v_{qi}]}{(\psi^2(\bar{x}_j, \bar{v}_i) - \alpha \min_{1 \leq s \leq c} \psi^2(\bar{x}_j, \bar{v}_s)) \cdot \psi^2(\bar{x}_j, \bar{v}_i)} \cdot \frac{1}{p-1} \quad (3.40)$$

siendo

$$\Phi_i(\bar{x}_j) = \frac{u_{ij}}{\sum_{k=1}^c \frac{1}{\delta_j^2 \cdot u_{kj}}} \quad (3.41)$$

con c igual al número total de *clusters* o reglas borrosas.

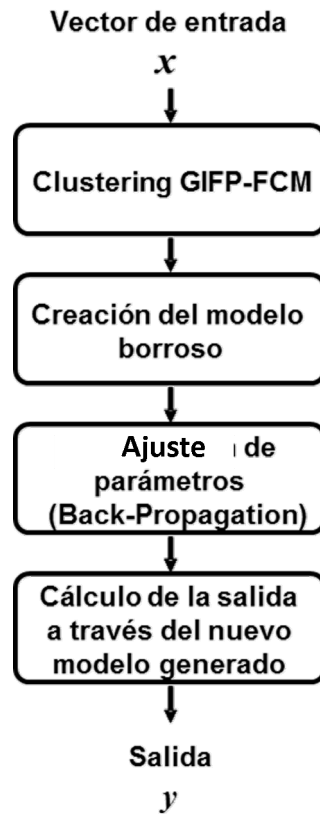


Figura 3.8. Esquema de la retro-propagación de errores.

En la práctica, la utilización del algoritmo de aprendizaje de retro-propagación de errores (*backpropagation*) junto con el algoritmo de agrupamiento borroso GIFP-FCM para la regresión neuroborrosa, se traduce en una implementación sencilla y con una rápida velocidad de convergencia, lo que provoca la eliminación de algunas de las limitaciones a tener en

cuenta en aplicaciones de tiempo real. A modo de pseudocódigo, la Figura 3.8 muestra los pasos que sigue el algoritmo de retro-propagación, el cual utiliza GIFP-FCM.

3.6 Desarrollo de una aplicación de modelado de sistemas complejos basada en el algoritmo GIFP-FCM

En esta sección, al igual que en la sección 3.4, se describe la aplicación de modelado basada en el algoritmo GFCM, cuya interfaz de usuario se muestra en la Figura 3.9. Ésta fue implementada en Java sobre los sistemas operativos Linux 2.6 y Windows 7. En esta interfaz se puede configurar el modo de ejecución (*clustering*, *training*, *evaluation*, *testing* o *find best parameters*), seleccionar el algoritmo, insertar la ruta de los ficheros E/S (entrenamiento, evaluación y test), insertar los parámetros específicos del aprendizaje, entre otros.

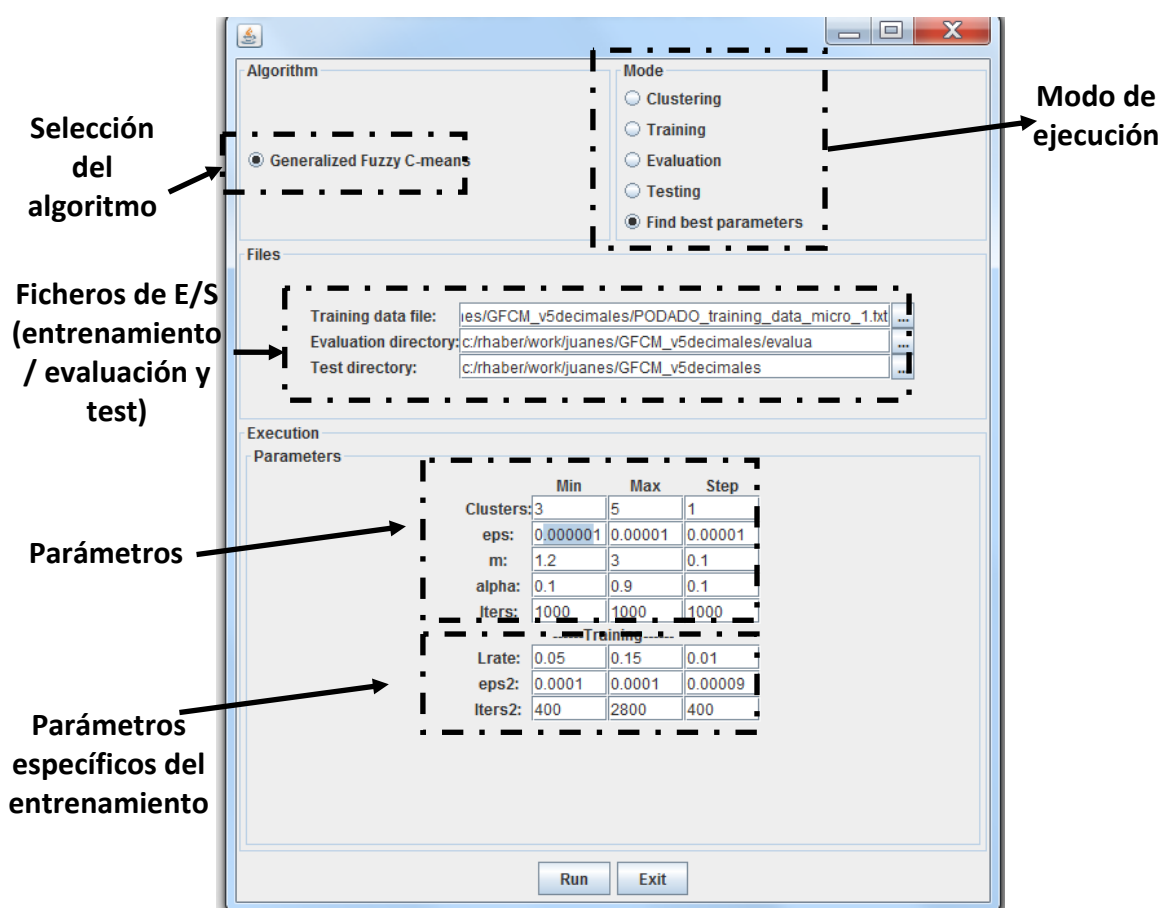


Figura 3.9. Interfaz de usuario del algoritmo GFCM desarrollado.

3.7 Conclusiones

En este capítulo se ha profundizado en el conocimiento de las técnicas de AI consideradas en esta Tesis Doctoral para el diseño de modelos experimentales de variables representativas

de procesos complejos. Entre la amalgama de técnicas, se han seleccionado y propuesto dos que tienen un cuerpo de doctrinas consolidado y un previsible buen impacto científico y técnico. Estas dos técnicas se han acondicionado para ser utilizadas en la monitorización inteligente de procesos complejos, basada en modelos. Por una parte, se han seleccionado las técnicas no paramétricas o de modelado libre debido al interés que despiertan actualmente en la comunidad científica en el modelo de procesos complejos. De entre ellas, la estrategia elegida es el modelado híbrido incremental (HIM). También, se ha tratado una técnica de optimización con vistas a la parametrización óptima del algoritmo de modelado basada en el temple simulado.

Como primera propuesta de modelado se han expuesto las ideas conceptuales y básicas de una de las estrategias de modelado libre o no paramétrico, por ejemplo, el algoritmo de modelado híbrido incremental (HIM). Esta elección se debe a que en la actualidad esta técnica ha despertado gran interés en la comunidad científica y técnica en la modelización de procesos, en casos donde no se conoce la estructura inicial del modelo (modelo no paramétrico) y que presentan un alto grado de incertidumbre. Esta técnica utiliza 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 esta Tesis Doctoral, como caso particular, se ha elegido como modelo global el ajuste de un polinomio de grado m mediante el algoritmo de mínimos cuadrados. En cambio, como modelo local, y con el objetivo de suavizar las transiciones entre el modelo global y el modelo local, se utiliza una estrategia de suavizado local basada en el algoritmo de agrupamiento borroso F-kNN (*Fuzzy k-Nearest Neighbors*). Seguidamente, se ha realizado un acercamiento científico a un método de optimización estocástico y libre de gradiente, para su aplicación en el ajuste óptimo de los parámetros del modelo. El estudio se ha centrado en un método libre de gradiente, como es el caso del algoritmo de temple simulado.

Como segunda propuesta de modelado se ha considerado una técnica de regresión borrosa o neuroborrosa que es considerada usualmente para obtener modelos de aquellos procesos caracterizados por disponer de pequeñas cantidades de datos experimentales (ej., los procesos de fabricación). Debido a que el modelado borroso presenta importantes desafíos a la hora de extraer o inferir información a partir de los datos existentes, esta propuesta ha sido complementada con una técnica de agrupamiento o *clustering*, como es el algoritmo generalizado de agrupamiento borroso c-Means con particiones borrosas mejoradas, GIFP-FCM, que generaliza el uso de IFP-FCM, añadiendo un parámetro α que permite, según su valor, variar entre el FCM y el IFP-FCM. A pesar de que la incorporación de este parámetro presenta 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 una regresión borrosa o neuroborrosa. Por tal razón, la contribución en esta Tesis Doctoral ha sido la incorporación del algoritmo de agrupamiento GIFP-FCM a una estructura

neuroborrosa con el fin de modelar procesos complejos con no-linealidades, relaciones entre variables, incertidumbre, etc. Por último, los parámetros del modelo fueron sintonizados mediante un algoritmo evolutivo, como es el algoritmo de retro-propagación de errores.

Además, se han desarrollado dos aplicaciones sencillas específicas para el modelado de procesos. Estos dos programas constituyen herramientas útiles para el modelado ya que están basadas en dos técnicas muy novedosas. La aplicación y evaluación de estos algoritmos se presentan en el Capítulo 6, específicamente para la estimación del acabado superficial en procesos de micromecanizado.

En el siguiente capítulo se abordará una metodología de caracterización experimental computacionalmente eficiente de procesos complejos. Como caso de estudio, ésta será aplicada al contacto entre la herramienta de corte y la pieza de trabajo en operaciones de micromecanizado.

CAPÍTULO 4

CARACTERIZACIÓN EXPERIMENTAL DE PROCESOS FÍSICOS. APLICACIÓN AL PROCESO DE MICROFABRICACIÓN

El presente capítulo se ha centrado en el desarrollo de una metodología para la caracterización experimental de procesos complejos y su implementación en un proceso computacionalmente eficiente. Como caso de estudio, ésta ha sido aplicada al estudio de la interacción dinámica entre la herramienta de corte y la pieza de trabajo en operaciones de micromecanizado. Debido a las grandes restricciones de tiempo de procesamiento y de cómputo que serán detalladas más adelante, el punto de partida para el análisis es la utilización de la variable resistividad eléctrica, que involucra al contacto punta de la herramienta y el material. Los resultados aquí obtenidos y que serán descritos en este capítulo, pueden ser aplicados a todas aquellas operaciones o procesos de fabricación, en la micro y meso escala, de arranque o eliminación de materiales conductores. En primer lugar, se ha realizado un análisis de los modelos teóricos del mecanismo de corte en operaciones de fresado, con el fin de obtener una caracterización matemática de la zona de contacto de la punta de la herramienta / material. En segundo lugar, los resultados de los análisis teóricos han sido corroborados experimentalmente. A priori, se presupone que los resultados de esta investigación servirán como base para el desarrollo de un método tecnológico de alta precisión de monitorización en tiempo real de procesos complejos y en específico, de la interacción herramienta-pieza de trabajo y detección del corte en operaciones de micro mecanizado. El análisis teórico se centra principalmente en las operaciones de corte y en los intervalos de tiempo de corte en los que el contacto de la herramienta material es intermitente.

En este sentido, la caracterización de la interacción dinámica entre el husillo, la herramienta y la pieza (STP), para la monitorización de estos procesos, es en la actualidad un campo importante de investigación. Diversas investigaciones actualmente están dirigidas hacia el objetivo de generar modelos teóricos STP en operaciones de mecanizado y ofrecer caracterizaciones matemáticas para predecir las fuerzas de corte y otros efectos relacionados (ej., formación de virutas, rebabas) [236-238]. Hay, sin embargo, muchos menos estudios, cuando el enfoque cambia de la macro a la microescala.

Del mismo modo, hay estudios que proponen técnicas para determinar el estado del contacto herramienta-pieza a partir de la información proporcionada por los sensores basados en el principio físico de piezoelectricidad. Estos trabajos han sido ampliamente utilizados para la monitorización de STP (es decir, sensores de diferentes tipos tales como acelerómetros, emisión acústica, la fuerza de corte, infrarrojos, etc.) [206, 239-242]. Por otro lado, cuando es difícil, costoso económica o computacionalmente el uso de sensores para la medición de las variables físicas, algunos autores predicen o estiman las señales características del proceso de fabricación (ej., fuerzas de corte) a partir de modelos matemáticos que describen la interacción herramienta / pieza de trabajo, de modo que estos modelos pueden posteriormente ser utilizados, ya sea para la supervisión o control de operaciones de fabricación [243-246].

Todos estos métodos esbozados anteriormente son muy válidos cuando no hay restricciones en el tiempo de respuesta, ni en el coste o limitaciones en el espacio de trabajo. Por lo tanto, el uso de otros sensores y técnicas, e incluso su diseño e implementación [247], se hace estrictamente necesario.

Es importante destacar que numerosos trabajos se centran en materiales metálicos conductores, debido a que estos materiales son los más utilizados en las operaciones de fabricación por arranque de material tanto en la macro como en la microescala. De este modo, se puede obtener la resistencia del contacto eléctrico filo de la herramienta y el material conductor, resultante del paso de una corriente alterna a través del sistema formado por la impedancia STP (Z_{STP}). Este principio básico se ha utilizado en un trabajo previo [183], en el que se investigaron varios métodos para detectar la rotura de la herramienta. El mismo principio ha sido aplicado en la investigación anterior para referenciar la posición de la punta de la herramienta [248, 249] para determinar el origen de coordenadas en la pieza que se va a fabricar. Esta información es insuficiente para una adecuada caracterización del contacto STP. Por consiguiente, es necesario establecer el comportamiento dinámico o la evolución temporal de STP, a partir de las mediciones de (Z_{STP}) durante las operaciones de microfabricación y así, poder tomar decisiones relacionadas con el estado del proceso.

Este capítulo está organizado de la manera que se describe a continuación. En primer lugar, la sección 4.1 presenta los fundamentos teóricos de la resistencia de contacto y el área de contacto; mientras que la sección 4.2 describe el procedimiento de caracterización

experimental propiamente dicho, a partir de la obtención en tiempo real de los valores del tiempo de contacto y la distancia recorrida por la herramienta. Para corroborar la metodología implementada, en la sección 4.3 se resumen los resultados experimentales que se expresan en términos de error relativo entre los valores teóricos y los obtenidos experimentalmente. Para finalizar, se muestran en la sección 4.4, algunas conclusiones sobre los resultados de este trabajo.


4.1 Fundamentación teórica de la resistencia de contacto en operaciones de fabricación

La resistividad eléctrica, también conocida como resistencia específica de un material, constituye una medida del grado de oposición de un material al paso de la corriente eléctrica. Una baja resistividad indica que el material permite fácilmente el paso de cargas eléctricas a través de él.

A partir de la magnitud E ($V m^{-1}$) de un campo eléctrico que se aplica a un material y la densidad de corriente J ($A m^{-2}$) que circula por el material, la resistividad estática ρ (Ωm) del material y su valor inverso o conductividad eléctrica σ , se determinan como:

$$\rho = \frac{E}{J}; \sigma = \rho^{-1} \quad (4.1)$$

A partir de la resistividad de los materiales y según la geometría de estos, se puede determinar el valor total de la resistencia eléctrica R (Ω) que ofrece el material al paso de la corriente. Por ejemplo, para el caso de una pieza conformada por un solo material resistivo con un área A de sección transversal uniforme (ver Figura 4.1) y una longitud ℓ ; su resistencia eléctrica, y el inverso de esta o conductancia eléctrica G , se determinan según la ecuación (4.2).



$$R = \rho \frac{\ell}{A}; G = R^{-1} \quad (4.2)$$

Figura 4.1. Pieza de material resistivo y ecuación de su resistencia eléctrica.

En operaciones de fabricación de componentes en materiales conductores, si se aplica un campo eléctrico al conjunto herramienta-pieza, se produce una resistencia eléctrica en los

puntos de contacto (resistencia de contacto). Esta resistencia de contacto, también llamada resistencia de difusión [250], está causada debido a que la corriente que se genera debido al campo eléctrico aplicado, circula desde una amplia sección, como es el caso de la sección transversal de la pieza, hacia un área muy reducida como el área de contacto entre la herramienta y el material. La resistencia que se produce durante las operaciones de corte R_c , depende principalmente, tanto de la resistividad eléctrica del material de la pieza ρ_p , de la resistividad del material del cual está conformada la herramienta ρ_t y del área de contacto A_c , es decir:

$$R_c = f(\rho_p, \rho_t, A_c) \quad (4.3)$$

Para una **caracterización adecuada del área de contacto** entre la herramienta de corte y el material, es necesario realizar un estudio del modelo geométrico a lo largo del filo de corte helicoidal de las herramientas. El modelo geométrico del filo de corte requiere de un análisis del modelo cinemático y dinámico que describe de forma teórica el proceso de fabricación. La posición de un punto de contacto P_0 en el filo de corte se caracteriza a partir de un sistema de coordenadas, del ángulo de la hélice y su distancia angular, según describen Del Toro et al. y Engin y Altintas, en sus respectivos trabajos [251, 252].

El diferencial del área de contacto en el punto P_0 se calcula a partir de la longitud de la viruta en contacto con el filo de corte y la longitud infinitesimal del filo en el punto de contacto dS , la cual se determina de forma general según la propuesta de Engin y Altintas [252]. Esto hace que el área de contacto dependa de las condiciones de corte, del material de trabajo, de la geometría de la herramienta, y del material y tipo de refrigerante que se emplea durante las operaciones de corte (Imani et al. [253]). Según este trabajo, la longitud de contacto con la viruta puede variar desde 2 y 3 veces el espesor de la viruta h , dependiendo de las condiciones de operación. Dado que la longitud de contacto de la viruta es mayor que el espesor de la viruta sin cortar, podemos definir un coeficiente de proporcionalidad o de “deformación” K_{def} , tal que el diferencial del área de contacto se puede determinar según la siguiente ecuación:

$$dA(\phi_j, z) = K_{def} h(\phi_j, z) dS ; K_{def} \geq 1 \quad (4.4)$$

Siendo N_f el número total de dientes, el **área de contacto entre la herramienta y el material**, en cada instante de tiempo, y su valor medio por cada vuelta de la herramienta, se **calculan** integrando a lo largo de todo el filo y sumando el valor para cada diente que se encuentre insertado, es decir:

$$A_T = \sum_{j=1}^{N_f} A_{Tj} = \sum_{j=1}^{N_f} \int_{z_1}^{z_2} dA(\phi_j, z) = K_{def} \sum_{j=1}^{N_f} \int_{z_1}^{z_2} h(\phi_j, z) \frac{dS}{dz} dz \quad (4.5)$$

$$A_{TM} = \frac{\Omega}{2\pi} \int_{t_0}^{t_0+2\pi/\Omega} A_T dt \quad (4.6)$$

En la ecuación (4.6) debido a la intermitencia en el proceso de corte, el cálculo de la integral (área total para cada labio A_{Tj}) se realiza solo para los puntos de contacto que se encuentran insertados dentro del material. En los instantes de tiempo en que la herramienta no ha alcanzado la máxima profundidad radial de corte a_e , la integral a lo largo de todo el filo es válida si se cumple que $\phi_{st} \leq \phi_j \leq \phi_{ex}$, de otra forma A_{Tj} se considera nula para ese labio. ϕ_{st} y ϕ_{ex} son los ángulos de inmersión radial de entrada y salida a la pieza, respectivamente. Más adelante se harán algunas observaciones acerca de estos ángulos. Una vez alcanzado el valor de a_e , el cálculo de la integral sigue siendo válido, pero solo para aquellas zonas del filo de la herramienta que se encuentren insertadas dentro del material.

En la ecuación (4.5), z_1 y z_2 son los límites de integración de la zona de contacto en cada momento del corte y pueden calcularse a partir del modelo geométrico generalizado de la fresa. d_z es el diferencial de la profundidad axial de corte. Los ángulos ϕ_{st} y ϕ_{ex} determinan el comportamiento dinámico del área de contacto, ya que definen el **tiempo de contacto**, t_c , en que el área de contacto es distinta de 0 en cada periodo de rotación de la herramienta. El tiempo t_c depende también de la velocidad del cabezal Ω :

$$t_c = f(\phi_{ex}, \phi_{st}, \Omega) \quad (4.7)$$

Los ángulos de inmersión radial de entrada y salida, ϕ_{st} y ϕ_{ex} , se determinan a partir de la profundidad radial de corte a_e y dependen del tipo de operación de fresado, ya sea con perfil de ranura o de contorno. Tradicionalmente estos ángulos son considerados constantes durante la operación de corte si a_e no varía. Si se considera que la herramienta antes de comenzar el corte no se ha insertada aún en la pieza, a medida que vaya avanzando y comienza el corte, el valor de la profundidad radial de corte prefijada será alcanzado en un instante de tiempo determinado por la velocidad de avance f y el diámetro de herramienta D . Esto hace que ϕ_{st} y ϕ_{ex} sean variables en el tiempo (véase la Figura 4.2).

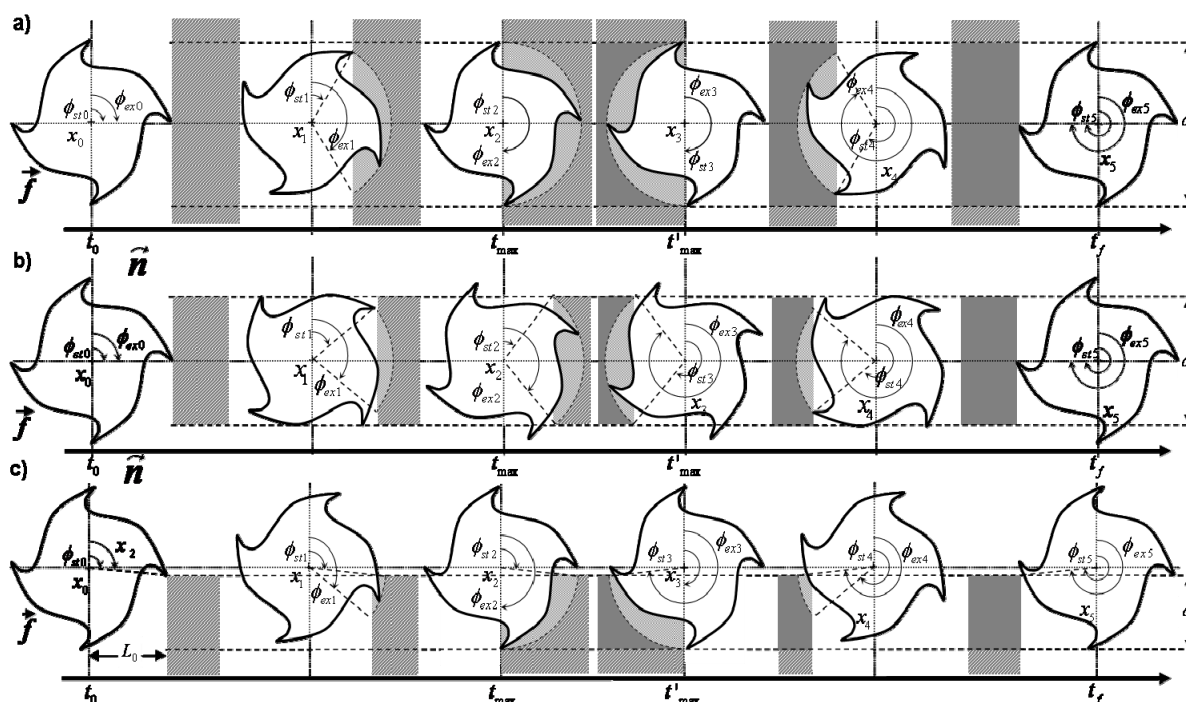


Figura 4.2. ϕ_{st} y ϕ_{ex} para diferentes posiciones de la herramienta con respecto a la pieza. a) Operación de ranura. b) Operación de planeo. c) Operación de contorno.

Consideraremos que en la operación de fresado la pieza de trabajo se mueve en dirección contraria a la herramienta y que, antes de iniciar el corte, la distancia entre el extremo de la herramienta y el borde de la pieza, a la profundidad radial de corte inicial, es nula (Figura 4.2). Se determinarán las ecuaciones teóricas para los ángulos ϕ_{st} y ϕ_{ex} , durante las operaciones con perfil de ranura, planeo y contorno.

En ambas operaciones, existen tres intervalos de tiempo, que están delimitadas por cuatro instantes de tiempo, que determinan los valores de estos ángulos: un tiempo inicial t_0 , un tiempo t_{max} , dentro del cual se alcanza la máxima profundidad radial determinada durante la entrada de la herramienta en el material, un tiempo t'_{max} , en el que la herramienta comienza a salir del material, y un tiempo t_f , a partir del cual la herramienta ha salido del material.

Durante el intervalo de tiempo $t_0 \leq t \leq t_{max}$ debe producirse un incremento del valor medio del área de contacto, A_{TM} , para cada vuelta de la herramienta (ver ecuación (4.6)). En el intervalo $t_{max} \leq t \leq t'_{max}$, el valor medio del área de contacto, en condiciones teóricas, debe permanecer prácticamente constante. Finalmente, durante el intervalo $t_{max} \leq t \leq t_f$, se debe producir un decremento del valor medio del área de contacto. El comportamiento real de área de contacto se verá afectado por la dinámica del corte (vibraciones, etc.) y por las irregularidades de la superficie del material que se mecaniza, los cuales no son objeto de análisis en esta Tesis Doctoral.

4.1.1 Operaciones de fresado plano y ranura

Las ecuaciones resultantes para estas dos operaciones son las mismas, la ranura es un caso especial de fresado plano, en el que la profundidad radial de corte máxima o deseada es el diámetro de la herramienta $a_e = D$ (ver Figura 4.2.a). En la operación de fresado plano sólo se considerará el caso de que no exista excentricidad entre la herramienta y la pieza, cuando la profundidad radial de corte sea menor que el diámetro de la herramienta ($a_e < D$) (ver Figura 4.2.b). El tiempo t_{max} en que la herramienta alcanza la profundidad de corte prefijada se determina mediante la siguiente ecuación:

$$t_{max} = \frac{60}{f} \frac{D - \sqrt{D^2 - a_e^2}}{2} + t_0; \quad \left[\frac{s \min^{-1}}{mm \min^{-1}} mm \right] \quad (4.8)$$

Habiendo determinado t_{max} , se pueden plantear las ecuaciones para el cálculo en cada instante de tiempo de los ángulos de corte de inmersión radial de entrada y salida.

$$\phi_{st}(t) = \begin{cases} \frac{\pi}{2} - \arccos\left(1 - \frac{2f}{60D}(t - t_0)\right), & t_0 \leq t \leq t_{max} \\ \arccos\left(\frac{a_e}{D}\right), & t_{max} \leq t \leq t'_{max} \\ \frac{3\pi}{2} - \arccos\left(\frac{2f}{60D}(t - t'_{max})\right), & t'_{max} \leq t \leq t_f \end{cases} \quad (4.9)$$

$$\phi_{ext}(t) = \begin{cases} \frac{\pi}{2} - \arccos\left(1 - \frac{2f}{60D}(t - t_0)\right), & t_0 \leq t \leq t'_{max} \\ \pi - \arccos\left(\frac{a_e}{D}\right), & t_{max} \leq t \leq t'_{max} \\ \frac{3\pi}{2} - \arccos\left(\frac{2f}{60D}(t - t'_{max})\right), & t'_{max} \leq t \leq t_f \end{cases} \quad (4.10)$$

4.1.2 Operaciones de fresado de contorno

Para esta operación se debe determinar primeramente la distancia inicial L_0 entre el centro de la herramienta y el borde de la pieza, en el momento justo antes del comienzo de la inserción de la herramienta en la pieza (ver Figura 4.2.c).

$$L_0 = \sqrt{D a_e - a_e^2} \quad (4.11)$$

A partir de la distancia L_0 se puede determinar el tiempo t_{max} en que la herramienta alcanza la profundidad radial de corte prefijada.

$$t_{\max} = \frac{60L_0}{f} + t_0; \left[\frac{s \min^{-1}}{mm \min^{-1}} mm \right] \quad (4.12)$$

Conociendo L_0 y t_{\max} , se pueden establecer las ecuaciones para el cálculo, en cada instante de tiempo, de los ángulos de inmersión radial de inicio y fin de corte.

$$\phi_{st}(t) = \begin{cases} \pi - \arccos\left(1 - \frac{2a_e}{D}\right), & t_0 \leq t \leq t'_{\max} \\ \pi + \arcsin\left(\frac{2f}{60D}(t - t'_{\max})\right), & t'_{\max} \leq t < t_f \end{cases} \quad (4.13)$$

$$\phi_{ext}(t) = \begin{cases} \pi - \arcsin\left(\frac{2}{D}(L_0) - f(t - t_0) / 60\right), & t_0 \leq t < t_{\max} \\ \pi, & t_{\max} \leq t < t'_{\max} \\ \pi + \arccos\left(1 - \frac{2a_e}{D}\right), & t'_{\max} \leq t < t_f \end{cases} \quad (4.14)$$

En este tipo de operación de corte, el ángulo de inicio de corte ϕ_{st} permanece constante durante toda la operación hasta alcanzar el instante de tiempo t'_{\max} , siempre que la profundidad radial de corte prefijada a_e no varíe. De forma general, para ambas operaciones y cumpliendo la condición de que la diferencia entre los ángulos de entrada y salida sea menor que el paso angular entre dientes de la herramienta ϕ_p , el tiempo de contacto t_c puede calcularse mediante la ecuación (4.15). Este planteamiento es válido para los intervalos de tiempo $t_0 \leq t \leq t_{\max}$ y $t'_{\max} \leq t \leq t_f$. En caso contrario, para cada filo y vuelta de la herramienta, este tiempo dependerá de la continuidad del contacto herramienta-material.

$$t_c = (\phi_{ex} - \phi_{st}) / \Omega, \quad (\phi_{ex} - \phi_{st}) < \phi_p \quad (4.15)$$

4.2 Propuesta de un método de caracterización experimental. Aplicación al proceso de microfresado

En línea con los objetivos, el siguiente paso se centra en el diseño experimental apropiado para obtener los datos adecuados y proponer una configuración del sistema de medición del ancho del pulso de la señal objeto de estudio, con el fin de corroborar los resultados del análisis teórico realizado en la sección anterior.

4.2.1 Configuración del sistema de medición del tiempo de contacto

En la siguiente sección, se describe la plataforma de medición experimental propuesta para la captura de t_c en tiempo real, con el objetivo de validar las predicciones teóricas hechas en el estudio previo sobre el tiempo de contacto (t_c).

La Figura 4.3.a muestra un circuito equivalente de una plataforma experimental formada por un interruptor en serie con una impedancia igual a Z_{STP} . También se puede apreciar que la resistencia de salida, R_{in} , está conectada a la pieza de trabajo, mientras que el polo negativo de la fuente de alimentación CA (tierra del circuito eléctrico) está conectado a la parte estática del cabezal. Por lo tanto, existe una caída de tensión de voltaje por el efecto provocado por el paso de la corriente CA sobre la resistencia de contacto, la cuál será capturada y almacenada.

Como parte del procedimiento, se filtra y se rectifica la señal $V_{Z,STP}$ para producir una señal de DC mediante un filtro paso bajo (LP) con frecuencia de corte de 300 Hz. En el diseño propuesto (Figura 4.3.b), se convierte la señal analógica mediante un comparador de nivel en una señal digital, a partir de la cual **se calcula el ancho de pulso en términos de tiempo** con un contador digital programable integrado en la tarjeta de adquisición de datos NI PXI-6259, insertada en una de las ranuras modulares presentes en la plataforma de tiempo real de National Instruments.

Las señales digitales fueron adquiridas, mediante la detección de los flancos tanto de subida como de bajada, para prevenir posibles sobrecargas computacionales debido a la monitorización continua con una frecuencia de muestreo fija. El proceso de adquisición fue configurado con el objetivo de detectar transiciones en el nivel de las señales con un mínimo tiempo de muestreo de $250\mu\text{s}$ y un tiempo de espera máximo por flanco de 3 segundos, en una plataforma de tiempo real con un controlador embebido NI PXI-8187.




Figura 4.3. a) Circuito equivalente del principio de operación de medición de esparcimiento. b) Plataforma experimental de medición.

4.2.2 Diseño del protocolo experimental

En este diseño experimental se utilizaron diferentes diámetros de herramienta (D) y diferentes profundidades radiales (a_e) para la misma herramienta. La Tabla 4.1 detalla las condiciones de operación de un sub-conjunto de pruebas experimentales realizadas para su posterior análisis. Por otra parte, se puso un mayor énfasis en operaciones de microfresado debido a la influencia de la profundidad en el comportamiento dinámico de la zona de contacto.

Tabla 4.1. Condiciones de operación del diseño experimental.

D [mm]	N	n [rpm]	f [mm/min]	a_n [mm]	a_{e1} [mm]	a_{e2} [mm]	a_{e3} [mm]
0.2	2	44500	440	0.2	0.1	0.05	0.025
0.5	2	45000	200	0.5	0.25	0.125	0.0625
1	2	40000	200	1	0.5	0.25	0.125

Se utilizó un perfil de velocidad de avance con cambios porcentuales ($f_{n1} = 0.8 f_n$, $f_{n2} = f_n$ y $f_{n3} = 1.2 f_n$) en base al valor nominal inicial (f_n). En otras palabras, se utilizaron tres pasos de avance que cambian de acuerdo con la Figura 4.4.a, en cada sección de la operación de

microfresado de ranuras. La Figura 4.4.b ilustra una ranura realizada en un perfil escalonado con canales transversales de 3 mm, separados 1,5 mm y a una profundidad de 1 mm. Por otra parte, la pieza de ensayo en el desarrollo experimental fue una aleación de cobre-tungsteno (W78Cu22) común en aeronaves y componentes electrónicos.

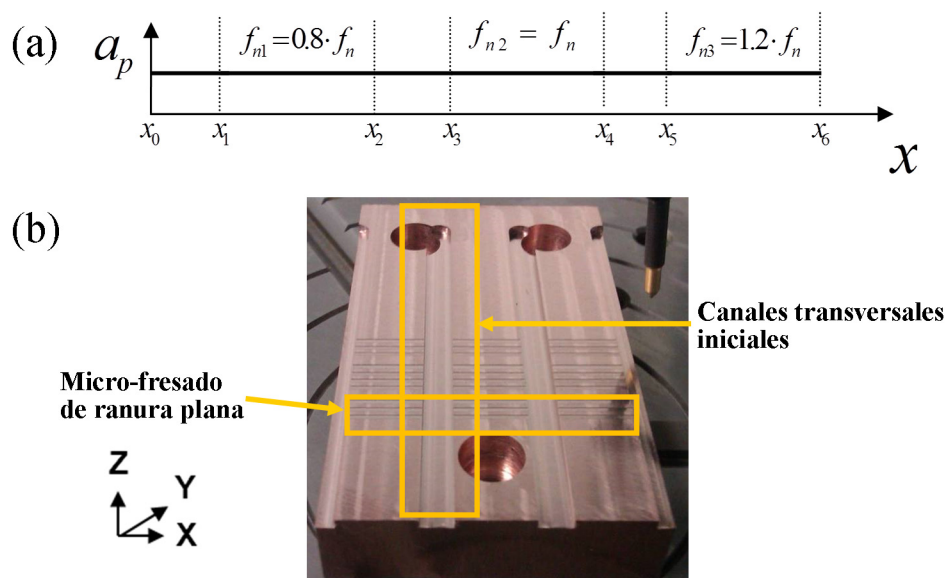


Figura 4.4. Diseño experimental del perfil de microfresado. a) Valores de f_n en función de la posición en el eje X. c) Imagen de la probeta de ensayos siguiendo una operación con perfil de ranura plana.

La Figura 4.5 ilustra el comportamiento de tres señales digitales obtenidas desde la plataforma experimental: una señal a partir de un filtro con una frecuencia de corte alta y una constante de tiempo baja (DIF), una señal que se corresponde al ancho de pulso de DIF (FIW) y una señal que se corresponde al ancho de pulso filtrado (FIW-m), mediante un filtro paso bajo de primer orden con una frecuencia de corte igual al 10% de la frecuencia de rotación (40 Hz). La señal de ancho de pulso y el valor filtrado, se normalizan con respecto a una vuelta de la herramienta (1.33 ms), siendo limitado a un rango de entre 0 y 3 veces este valor. En ambas señales, "1" significa que hay contacto entre la herramienta y el material, y "0" hace referencia a que no hay contacto. Esto se aprecia claramente en las regiones que se corresponden con los intervalos de entrada y salida del material que se representan en la Figura 4.5.b y c. En el primer caso, hay un incremento en el valor medio de la señal digital de ancho de pulso (FIW-m), lo que indica un incremento en el tiempo de contacto. Este efecto, sin embargo, se invierte durante la salida de la herramienta del material.

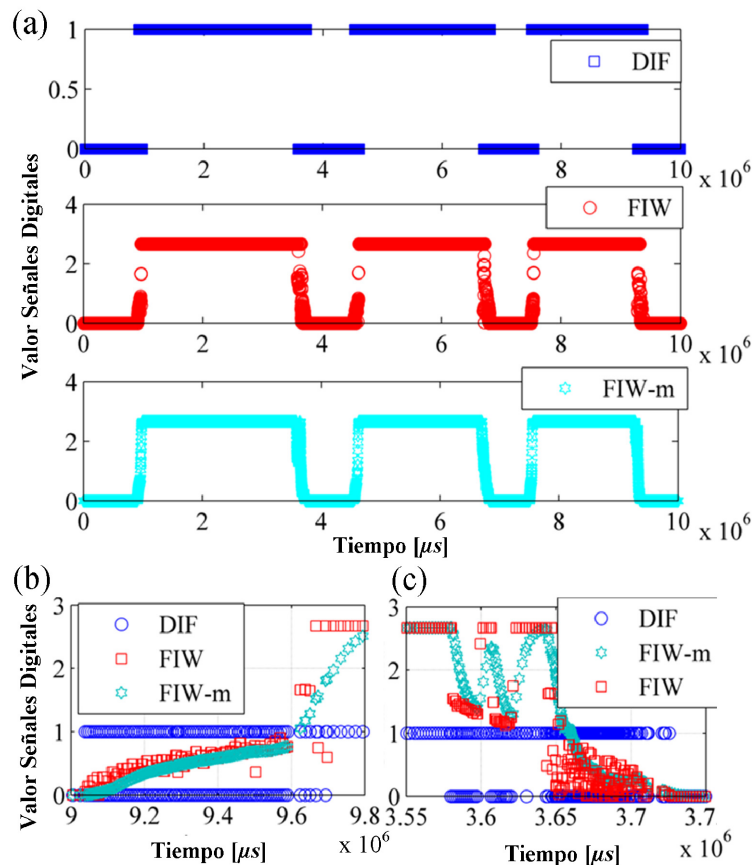


Figura 4.5. Señales digitales procedentes de las mediciones en la plataforma experimental durante una operación de microfresado de ranura, $N_f = 2$, $D = 0.5$ mm, $n = 45000$ rpm y $f = 200$ mm/min.

De la misma forma, la Figura 4.6 muestra el comportamiento de las mismas señales pero durante una operación de contorno usando las mismas condiciones de corte, exceptuando la profundidad radial que en este caso es igual a 0.25 mm (50% del diámetro de la herramienta). Como se puede apreciar, la señal digital muestra un comportamiento discontinuo en el contacto herramienta-pieza durante esta operación. Sin embargo, el comportamiento del valor medio del ancho de pulso es similar al caso de la operación de fresado durante los intervalos de entrada y salida de la herramienta del material.

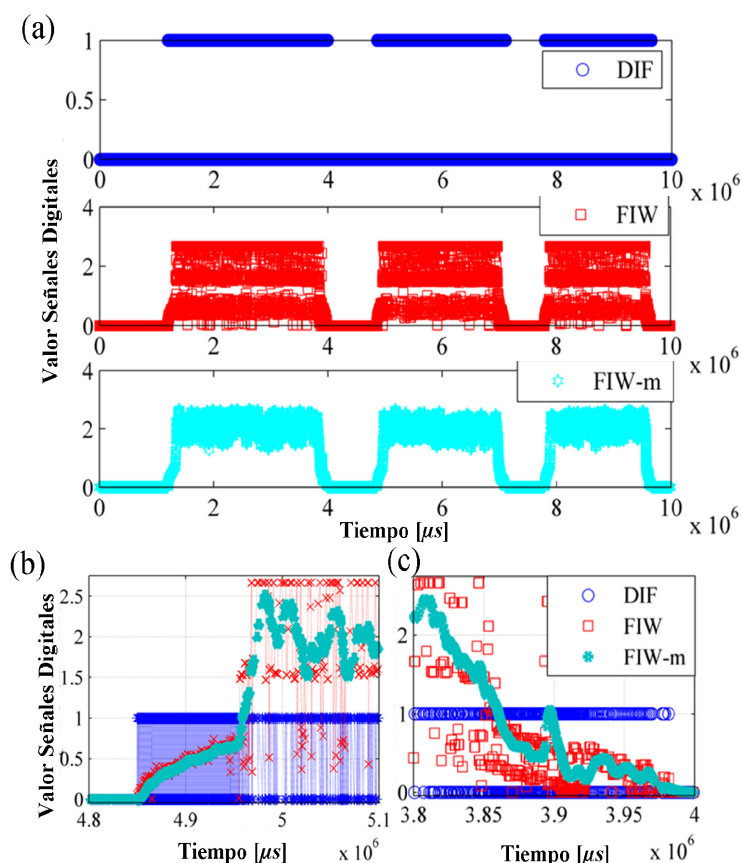


Figura 4.6. Comportamiento de la señal digital durante una operación de contorno, a) a través de todo el perfil de la pieza de trabajo, b) durante la entra en la pieza, y c) el intervalo de tiempo durante la salida del material.

4.2.3 Tiempo en el contacto filo de la herramienta - material

En esta sección, se pretende corroborar experimentalmente la relación existente entre el voltaje que es generado por el paso de una corriente eléctrica a través de la resistencia de contacto ($V_{Z,STP}$) y el tiempo de contacto (t_c). Con el objetivo de obtener información sobre el estado de la iteración herramienta-pieza, la medición de la frecuencia de esta señal de voltaje proporcionará el valor del tiempo de contacto en cada instante de tiempo.

Con vistas a obtener una distribución adecuada de los valores que alcanza esta variable, estos valores han sido limitados entre el mínimo tiempo de muestreo ($250 \mu s$) y un 90% de su valor máximo, durante toda la operación de corte. Además, el rango de datos se divide en 50 intervalos equidistantes. La Figura 4.7 ilustra los histogramas de diferentes distribuciones de las mediciones del tiempo de contacto, obtenidas durante una operación de microfresado de ranura y otra de contorno. El ancho de pulso o tiempo de contacto se normalizó con respecto a la velocidad del cabezal (una vuelta de la herramienta).

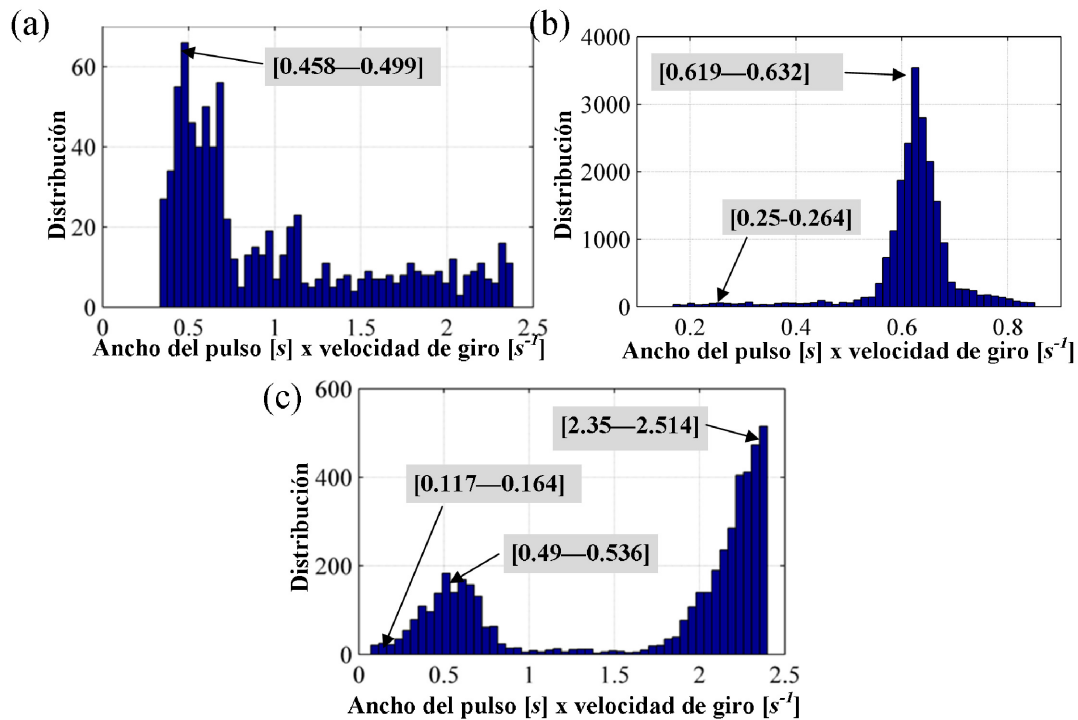


Figura 4.7. Histogramas sobre la distribución de las mediciones de los valores del tiempo de contacto, $N_f=2$, $D=0.5\text{ mm}$, $n=45000\text{ rpm}$ y $f=200\text{ mm/min}$. a) Operación de ranura, $a_e=D=0.2\text{ mm}$, y de contorno, b) $a_e=D/2=0.1\text{ mm}$ y (c) $a_e=D/8=0.0625\text{ mm}$.

En el caso de una operación de microfresado (Figura 4.7.a), el valor máximo de la distribución es obtenido en el rango de datos [0.458 - 0.499], es decir, una duración aproximada de $\frac{1}{2}$ vuelta de la herramienta. Este resultado es el esperado para este tipo de herramienta (ver ecuaciones (4.9) y (4.10)). Esto es debido a que las señales digitales, DIS y DIF, solo varían en las etapas de entrada y salida de la herramienta del material.

Para operaciones de contorno (Figura 4.7.b y c), se identifican varios puntos. En la Figura 4.7.b, $a_e=D/2$, se destaca el valor máximo de la distribución dentro del intervalo [0.619 - 0.632] (sobre $\frac{2}{3}$ de una vuelta de la herramienta) y el valor pico que está dentro del rango [0.25 - 0.264]. Este valor se corresponde con el valor medio de la señal a través de las etapas de transición (herramienta entrando y saliendo) y el primer valor está relacionado con el valor medio del resto de la operación de corte.

Por otra parte, se ven tres puntos relevantes para la operación de contorno con $a_e=D/8$ (Figura 4.7.c): entrada y salida del material [0.117 - 0.164], $\frac{1}{2}$ de una vuelta de la herramienta [0.49 - 0.536] y $\frac{5}{2}$ de una vuelta de la herramienta [2.35 - 2.514].

En el caso de la operación de contorneado (Figura 4.7.b), si calculamos el valor máximo que alcanza el tiempo de contacto (durante las regiones de entrada y salida del material) a partir de las ecuaciones que definen los ángulos de entrada y salida de la herramienta, ecuaciones (4.13), (4.14) y (4.15), obtenemos que el tiempo de contacto es un 25 % del

período de rotación de la herramienta. Como podemos apreciar, este valor se sitúa dentro del rango determinado experimentalmente [0.25 - 0.264]. Es decir, si se asume que $a_e = 0.1$ mm, $D = 0.5$ mm, y el tiempo es igual a t_{max} y t'_{max} ; se obtiene:

$$\phi_{ex} - \phi_{st} = \arccos(1 - 2a_e/D) = \arccos(0) = \pi / 2 \quad (4.16)$$

$$t_c = (\phi_{ex} - \phi_{st}) / (2\pi n) = 0.25 / n \quad (4.17)$$

4.3 Resultados de la comparación entre la caracterización teórica y experimental del tiempo de contacto. Mínimo error relativo

Siguiendo con la metodología descrita, se procedió a la obtención del error relativo entre el resultado final del cálculo del tiempo teórico ($t_{c,teórico}$) y el experimental ($t_{c,ex,borde}$). En todos los casos se determinó el mínimo error relativo ($Error_{r,t_c}$) (ver ecuación (4.18)) para diferentes valores de área de contacto a_e , con diferentes diámetro de herramienta (D), tal y como se lista en la Tabla 2.4.

$$|Error_{r,t_c}(\text{Mín})| = \left| \frac{t_{c,ex,borde}(\text{Mín}) - t_{c,teórico}}{t_{c,teórico}} \right| \quad (4.18)$$

Tabla 4.2. Mínimo error relativo entre los valores teóricos y los valores experimentales de t_c .

D [mm]	a_e [mm]	$t_{c,teórico}$	$t_{c,ex,borde}$ [μ s]		$Error_{r,t_c}$ [%]
			Min	Máx	
0.2	0.1000	337.079	344	375	2.053
	0.0500	224.719	207	212	5.660
	0.0250	155.092	130	149	3.928
0.5	0.2500	333.333	320	360	4.000
	0.5000	666.667	467	481	27.850
	0.2500	333.333	240	279	16.300
	0.0625	153.369	80	120	21.757
1	0.0625	153.369	120	160	4.324
	1.0000	750.000	755	797	0.667
	1.0000	750.000	612	656	12.533
	0.5000	375.000	319	342	8.800
Error Relativo Medio [%]					9.807

Por un lado, el valor de $t_{c,teórico}$ es obtenido mediante (4.15), de la forma que se explica en (4.16) y (4.17). Por otro lado, $t_{c,ex,borde}$ es determinado por el valor absoluto de la diferencia entre los dos bordes de los intervalos de la distribución a la que pertenece el valor $t_{c,teórico}$.

Obviamente, resultan dos diferencias correspondientes a los dos bordes del intervalo, apareciendo una diferencia menor, $t_{c,ex,borde}$ (Mín), y una mayor ($t_{c,ex,borde}$ (Máx), valores que se muestran también en la tabla. Por último, el mínimo error relativo se calcula según:

Por lo tanto, realizando el análisis durante toda la ranura de la operación de microfresado (sin tener en cuenta las diferentes secciones de la ranura, ilustradas en las Figura 4.4.b), se observa como resultado final en la tabla un error relativo medio de un 9.807%. Además, fueron validadas las predicciones teóricas hechas al principio de este estudio concerniente a la influencia entre el área de contacto (a_e) y el tiempo del contacto filo de la herramienta-material (t_c).

En ciertas operaciones de corte, la velocidad de alimentación puede ser modificada en diferentes secciones de material, pero por lo general estos cambios no se producen repentinamente. La duración de las transiciones puede ser expresada en términos de distancia cubierta durante el tiempo de inmersión de la punta de la herramienta en la pieza de trabajo, d_c , con el fin de evitar la influencia de la velocidad de avance, en detrimento de la expresión en términos de tiempo (t_c). La ecuación (4.19) representa la forma de calcular la distancia recorrida d_c a partir de los valores de t_c y velocidad de avance (f_n).

$$d_c = t_c \cdot f_n \quad (4.19)$$

Aplicando esta ecuación, se produjo una reducción en el error relativo para las distintas secciones de la ranura. Estos errores fueron 8,33%, 0,263% y 3,612% para la primera, segunda y tercera ranura, respectivamente y un valor medio de 4.07 %. En resumen, se puede observar que el error relativo promedio entre el grupo experimental y los valores teóricos son más pequeños en relación a los cambios en la velocidad de avance, cuando se introdujo el concepto de la distancia recorrida.

4.4 Conclusiones

En este capítulo se ha propuesto una metodología de caracterización experimental computacionalmente eficiente para procesos complejos en la micro escala, específicamente de fabricación. Este método está dirigido hacia la caracterización del contacto entre la herramienta de corte y la pieza, y abarca diferentes etapas anteriormente descritas. Se basa en la medición directa de los anchos de los pulsos de las señales digitales (contador digital hardware), provenientes del voltaje generado por la circulación de una corriente eléctrica de excitación a través de un material que sea conductor de la electricidad (resistencia de contacto). Como caso de estudio, ésta ha sido aplicada a la caracterización de la interacción dinámica entre la herramienta de corte y la pieza de trabajo en operaciones de micromecanizado. La propuesta se ha sustentado en el estudio y **análisis de la resistividad eléctrica del contacto entre la punta de la herramienta y el material**. Estos resultados son

aplicables y se pueden extender a todos aquellos procesos que involucren el contacto de materiales eléctricos, y muy especialmente a los procesos de fabricación por arranque de material. A continuación se describen cada uno de los resultados que se han alcanzado en este capítulo.

En primer lugar, se ha realizado un análisis de los modelos teóricos del mecanismo de corte en operaciones de fresado, a fin de obtener una caracterización matemática de la zona de contacto punta de la herramienta / material. En segundo lugar, en este trabajo también se ha proporcionado un análisis teórico del comportamiento dinámico de los ángulos de inmersión radial de entrada y salida a lo largo de los bordes de la herramienta y su relación con el comportamiento dinámico de la zona de contacto. Este análisis teórico se centra principalmente en los intervalos de la operación de corte donde el tiempo de contacto es intermitente.

En tercer lugar, los resultados de los análisis teóricos han sido corroborados experimentalmente. La comparación entre los resultados teóricos y experimentales confirman que mediante la medición directa de los anchos de pulso de las señales digitales se obtiene el valor del tiempo de inmersión de la punta de la herramienta / borde del material o tiempo de contacto con un error promedio de menos de un 10%. Como mejora de este resultado, debido a que la velocidad de avance en ciertas operaciones de corte se puede modificar en diferentes secciones de material, aunque estos cambios no sean generalmente bruscos; la duración de las transiciones puede ser expresada en términos de distancia recorrida durante el tiempo de inmersión de la herramienta en el material, con el fin de evitar la influencia de la velocidad de avance. En este caso, se ha reducido el error, entre los valores teóricos y los experimentales, un 4,284%.

Por último, los resultados de esta investigación permitirán el desarrollo de un método tecnológico de alta precisión de monitorización en tiempo real de la interacción herramienta-pieza de trabajo y detección de corte en operaciones de microfabricación.

La evidencia de esta prometedora línea de investigación será el diseño de un sensor de conductividad para la monitorización del estado de corte que será descrito en el siguiente capítulo.

CAPÍTULO 5

SENSOR INTELIGENTE Y ALGORITMOS DE DETECCIÓN DEL ESTADO DEL PROCESO

En el Capítulo 2 se concluyó que el diseño y desarrollo de nuevos sistemas de supervisión en tiempo real de procesos complejos requerirá en buena medida de la aplicación de nuevos principios y sistemas sensoriales y de medición, y que, además, se debe prestar especial atención a la **investigación y desarrollo de nuevos sensores**. Esta Tesis recoge la investigación realizada en este aspecto crucial mediante el desarrollo e integración de un sensor que detecte el contacto eléctrico herramienta-pieza, con el objetivo de incrementar las capacidades de los sistemas de monitorización y supervisión de los procesos y, por tanto, mejorar su eficiencia y funcionamiento. Como ya se comentó en el Capítulo 4, esta estrategia ya ha sido abordada con anterioridad, tanto en patentes como en publicaciones científicas, aunque se ha descubierto que se necesita abrir nuevas líneas de investigación en este sentido, dado el carácter parcial e incompleto de los resultados mostrados en estos trabajos.

Por un lado, en este capítulo se describe el diseño de un sistema sensorial para una supervisión con alta precisión y en tiempo real de la interacción herramienta-pieza de trabajo y la detección de corte en procesos de fabricación en la micro escala. Este sistema está basado en un sensor de conductancia (sección 5.1), que se diseña en este capítulo, y en un procedimiento sencillo y computacionalmente eficiente para detectar el estado actual del contacto dinámico del filo de la herramienta y el borde del material. Los resultados son aplicables a las operaciones de fabricación, y en especial de mecanizado, **en materiales conductores**. El principio de funcionamiento en el que se basa este sensor ha ocupado una sección entera en el Capítulo 4, definiendo conceptos como la resistencia de contacto, área de contacto, tiempo de contacto, entre otros. Cabe destacar que este principio consiste en la

medición de la caída del voltaje producido por el paso de una corriente alterna a través de la impedancia formada por la interacción del husillo, herramienta y pieza de trabajo.

Por otro lado, se propone el diseño e implementación de un sistema de toma de decisiones para la monitorización en tiempo real del estado actual de la interacción herramienta / pieza y la rotura de la herramienta en operaciones de microfabricación. Este sistema consta de un sistema embebido para detectar el estado actual de este contacto dinámico (sección 5.2) y otro algoritmo, también embebido, para la detección de roturas de la herramienta (sección 5.3). Este sistema está compuesto por un conjunto de reglas basadas en el conocimiento experto del sistema y una máquina de estado finito con el fin de supervisar el estado del proceso.

La eficacia del sistema formado por la integración del sensor de conductividad y los dos algoritmos embebidos se presenta en la sección 5.4 y es objeto de una validación inicial en la sección 5.5. Sin embargo, en el Capítulo 7, esta eficacia será verificada más exhaustivamente en una evaluación más completa en tiempo real, junto al resto de módulos de la plataforma en varias operaciones de microfabricación.

5.1 Diseño hardware del sensor de conductancia. Especificaciones y configuración.

Con el fin de proporcionar información útil sobre el estado del corte, se hace necesario precisar las especificaciones de diseño, los requisitos de precisión, rangos de voltaje y corriente de excitación, etc. Para ello, y con vistas a obtener la configuración apropiada de estos valores, se realizaron algunas operaciones de microfresado de ranuras.




Figura 5.1. Circuito equivalente del principio de funcionamiento del sensor de conductancia.

En la Figura 5.1 se muestra el circuito equivalente utilizado para la generación y medición de las señales. En el lado izquierdo del circuito, se ilustra un circuito que consta de una fuente de alimentación de CA en serie con una resistencia (R_I). En pasos posteriores, la caída de tensión captada por el sensor será rectificada y filtrada. Además, debe tenerse en cuenta que la salida de la resistencia R_I está unida a la pieza; mientras que la parte estática del husillo está conectado al circuito eléctrico de tierra.

5.1.1 Especificaciones, extracción de características y filtrado

Como primer paso para el diseño hardware del sensor, se realizaron a una serie de experimentos donde se midió el voltaje a través del conjunto pieza-cabezal utilizado dos configuraciones del filtro $C_2 = 220$ nF ($f_c = 0.7$ Hz) y $C_3 = 470$ pF ($f_c = 338.9$ Hz). La Figura 5.2 representa la caída de voltaje eléctrica (V_{STP}) entre el husillo y la pieza de trabajo cuando existe contacto mecánico entre la herramienta y la pieza. La señal V_{STP} se rectificó y se filtró de forma independiente para la obtención de las señales $V_{STP,slow}$, obtenida a partir del filtro de frecuencia de corte más baja o “señal más rápida”, y $V_{STP,fast}$, obtenida a partir del filtro de frecuencia de corte más alta o “señal más lenta”. A partir de la representación temporal de estas dos señales, se pudieron apreciar tres regiones muy bien diferenciadas en dos situaciones diferentes del estado de la inserción de la herramienta en la pieza, que son la región de entrada (Figura 5.2.a) y la de salida (Figura 5.2.b):

- Región en la que no existe el corte (**Región 1**).

No existe contacto eléctrico alguno entre la herramienta y la pieza de trabajo.




Figura 5.2. Características extraídas de las señales ($V_{STP,slow}$ y $V_{STP,fast}$) sobre el estado de corte en una operación de microfresado. (a) Entrando y (b) Saliendo.

- *Región de corte con inserción total de la herramienta en la pieza (Región 2).*

La herramienta está completamente insertada en la pieza a una profundidad radial (a_e) igual al diámetro de la herramienta. Existe un contacto total que no se ve afectado por el número de dientes de la herramienta (N_f) ni por la velocidad del cabezal (n), debido a la geometría de la herramienta. La punta de la herramienta de corte está siempre en contacto eléctrico con el material durante el corte, si se mantiene en las condiciones de corte un a_e igual al diámetro de la herramienta (D).

- *Regiones de transición: entrada (Región 3) y salida (Región 4).*

Estas regiones se corresponden al momento en que la herramienta entra o se retira del material. Existe un contacto parcial e intermitente relacionado con N_f y n . Como es evidente, el contacto es intermitente dependiendo de la posición de los dientes de la herramienta con respecto a la pieza.

En vista de estos resultados, no es posible determinar de forma automática cada una de las regiones de corte a partir de una única señal. Por ello, como una sola señal no garantizaba la fiabilidad y robustez del sistema, se seleccionaron ambas señales como entradas del sensor.

5.1.2 Configuración e implementación del sensor de conductancia

En el diseño propuesto (Figura 5.3.a), las dos señales analógicas, $V_{STP, fast}$ y $V_{STP, slow}$, respectivamente, son convertidas por los comparadores de nivel con histéresis en señales digitales (DIS, *Digital In Fast*, y DIF, *Digital In Slow*), que son manipuladas por varias operaciones lógicas en un bloque de procesamiento digital de señales (DSP, *Digital-Signal-Processing*).

Como parte del procesamiento digital de la señal (Figura 5.3.b), y a partir de la caracterización experimental de procesos propuesta en el Capítulo 4, se ha desarrollado un sistema para **calcular el ancho de los pulsos** digitales de la entrada **DIF** (variable **FIW**), mediante un contador digital. Se ha obtenido, además, su valor medio a través de un filtro pasa-bajos de primer orden y frecuencia de corte igual al **10% de la frecuencia de giro** (variable **FIW - m**).

En la ecuación (5.1), se describe la expresión para calcular la nueva variable, donde: $V_{in}(k)$ es la muestra en el instante actual k de la variable de entrada (en este caso **FIW**); $V_o(k)$ es la señal filtrada **FIW - m**; $V_o(k - 1)$ es su valor en el instante de tiempo anterior; τ es el inverso de la frecuencia de corte del filtro; y ΔT es el tiempo entre muestras de la variable de entrada.

$$V_o(k) = \frac{(\tau/\Delta T)V_o(k-1) + V_{in}(k)}{(\tau/\Delta T) + 1} \quad (5.1)$$

En el Capítulo 4, quedó demostrado que la medición de esta señal coincide con el tiempo del contacto entre la herramienta y el material. El análisis de los estados de corte fue la base para el diseño del prototipo de sensor de conductividad.

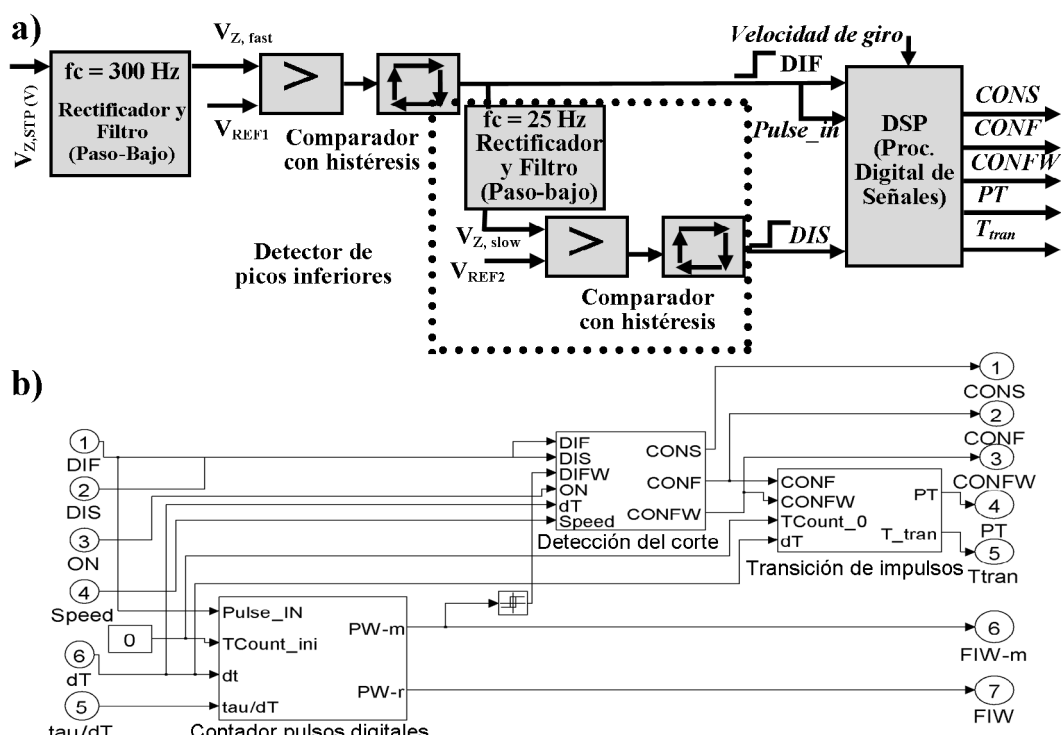


Figura 5.3. Diagrama de bloques del sensor de conductividad inteligente propuesto. a) Generalidades b) Detalle del bloque DSP.

5.1.3 Caracterización del proceso de corte

En el análisis realizado sobre el comportamiento de las señales digitales en diferentes operaciones de corte, se ha podido apreciar que es posible caracterizar las diferentes etapas o estados del contacto herramienta-material. Inicialmente, como se aprecia en la Figura 5.4, se pueden definir **dos estados básicos o estacionarios** que se denominan “**CORTANDO**” y “**NO CORTANDO**”. Estos estados se definen, a partir de las dos señales digitales de voltaje elegidas, de la siguiente forma:

$$\begin{aligned} & \text{Si } (DIF = 1) \text{ ó } (DIS = 0) \text{ entonces } (\text{Estado} = \text{CORTANDO}) \\ & \text{En caso contrario } (\text{Estado} = \text{NO CORTANDO}) \end{aligned} \quad (5.2)$$

Pero como ya se ha comprobado del análisis teórico y experimental del comportamiento dinámico del contacto herramienta-material, es posible definir dos **etapas de transición** entre los dos estados definidos, que se dominarán: **ENTRANDO** (entrada al material) y **SALIENDO** (salida del material). Estos estados se pueden observar más claramente en

operaciones de ranura, en la cual, la señal digital *DIF* partiendo de un nivel lógico inicial “0”, comienza a cambiar de nivel de forma intermitente durante la etapa *ENTRANDO*. Por otra parte, durante el estado de transición *SALIENDO*, la misma señal se comporta de la misma forma, pero partiendo del nivel lógico “1”. Por otro lado, debido al origen de la señal *DIS*, esta solo alcanza el nivel lógico “1” cuando el contacto herramienta-pieza es continuo, por lo que se mantiene en el nivel lógico “0” durante estos estados de transición.




Figura 5.4. Estados del proceso corte en operaciones de micro fresado: una ranura plana.

De acuerdo con ello, es posible describir los estados definidos de acuerdo con la Tabla 5.1. Además de los antecedentes de las reglas descritos en la tabla anterior, a partir del comportamiento de la duración del contacto según la señal *DIF*, o lo que es equivalente, a partir del comportamiento del valor medio del ancho de los pulsos de esta señal (*FIW-m*) durante los estados de transición y su influencia en el estado, podemos realizar el siguiente planteamiento:

$$\begin{aligned}
 & \text{Si } (FIW - m > \text{Valor umbral}) \text{ entonces } (\text{Estado} = \text{CORTANDO}) \\
 & \text{Si } (FIW - m = 0) \text{ ó } (FIW - m < \text{Valor mínimo}) \\
 & \text{entonces } (\text{Estado} = \text{NO CORTANDO})
 \end{aligned}
 \tag{5.3}$$

El planteamiento de esta reglas puede ser de gran utilidad, ya que permitiría confirmar o retener los estados estacionarios y, además, en el caso de operaciones donde el contacto es discontinuo (ej., operación de contorneado), puede ser tenida en cuenta para **diferenciar las regiones de transición de los estados estacionarios** del contacto herramienta-pieza. Este análisis se realiza en el **módulo de detección del corte**, representado en la Figura 5.3.b.

Tabla 5.1. Estados de las operaciones de corte, antecedentes y descripción.

Estado (consecuente)	Antecedentes	Descripción
<i>NO CORTANDO</i>	Si ($DIF = 0$) y ($DIS = 0$)	Estado estacionario , no existe contacto herramienta-pieza de trabajo.
<i>CORTANDO</i>	Si ($DIF = 1$) ó ($DIS = 1$)	Estado estacionario , existe contacto herramienta-pieza, si ambas señales están en el nivel lógico “1”, significa que el contacto es continuo.
<i>ENTRANDO</i>	Si (<i>Estado anterior = NO CORTANDO</i>) y ($DIS = 0$) y ($DIF = \text{cambia de forma intermitente}$)	Estado transitorio , la señal digital <i>DIF</i> partiendo de un nivel lógico inicial “0”, comienza a cambiar de nivel de forma intermitente, mientras la señal <i>DIS</i> permanece en el nivel lógico “0”.
<i>SALIENDO</i>	Si (<i>Estado anterior = CORTANDO</i>) y ($DIS = 0$) y ($DIF = \text{cambia de forma intermitente}$)	Estado transitorio , la señal digital <i>DIF</i> partiendo de un nivel lógico inicial “1”, comienza a cambiar de nivel de forma intermitente, mientras la señal <i>DIS</i> permanece en el nivel lógico “0”.

5.2 Diseño de un algoritmo computacionalmente eficiente para la detección del estado del proceso de corte.

A partir de la definición de los estados del contacto herramienta-material y de los antecedentes que dan lugar a su definición, es posible diseñar un procedimiento y método computacional mediante el cual se pueda monitorizar la operación de corte. Este algoritmo permitirá, además, detectar posibles fallos o anomalías durante las operaciones de micromecanizado.

Para determinar el estado del proceso es necesario verificar los antecedentes que le darán lugar. Para ello se impone el desarrollo de estrategias o funciones de procesamiento digital que permitan caracterizar el comportamiento de las señales digitales. Según los antecedentes establecidos, el procesamiento debe ser capaz de determinar:

- Nivel actual de las señales digitales: niveles lógicos “1” (“ON”) y “0” (“OFF”).
- Cambios en los niveles de las señales digitales: flanco de subida \uparrow o de bajada \downarrow .
- Intervalos de intermitencia en el nivel de las señales.
- Duración de los pulsos de la señal **DIF**.

- Valores de umbral de la duración de los pulsos de esta señal que permitan discernir entre los estados de transición y los estados estacionarios: valor de umbral para el estado **CORTANDO** y valor mínimo para el estado **NO CORTANDO**.

Como paso inicial del procesamiento digital, a partir de cada señal de entrada se obtiene una nueva **señal digital “filtrada”**, que **elimina los cambios intermitentes de las señales originales**. Se interpreta como “**intermitente**” los cambios de nivel que se producen a frecuencias similares a la frecuencia de giro de la herramienta, o bien dentro de un intervalo de tiempo proporcional a un número determinado de vueltas consecutivas de la herramienta.

Para este tipo de filtrado una solución aceptable es una función que simule un circuito digital monoestable con re-disparo. La duración de la salida cuando está activada puede ser, además, de gran utilidad para determinar la duración de los intervalos de intermitencia de la señal digital de entrada. Denominaremos a las señales filtradas obtenidas de las entradas digitales como **DFM** (*Digital Fast Monostable*) y **DSM** (*Digital Slow Monostable*).

Para implementar la regla descrita en (5.2), se ha generado una nueva señal denominada **DIFW** (*Digital In Fast Width*). Esta se obtiene empleando un comparador con histéresis aplicado a la variable **FIW - m**, en el que se ajusta un valor de umbral (**inicialmente 60%** del período de rotación de la herramienta) para determinar el nivel lógico “1” y un valor mínimo (**inicialmente 40%** del período de rotación de la herramienta) para establecer el nivel “0”. A la nueva señal digital también se le ha aplicado la función de filtrado de tipo monoestable con re-disparo para evitar cambios de nivel no deseados (señal denominada **DFWM**, *Digital Fast Width Monostable*).

A partir de las señales obtenidas mediante el procesamiento digital (DFM, DSM, DIFW y DFWM) y las entradas digitales provenientes del sensor diseñado, se construyen los antecedentes de las reglas definidas en (5.2) y (5.3), y la Tabla 5.1, aplicando una serie de operadores lógicos (ecuación (5.4)). Estas operaciones lógicas devuelven como resultado una variable lógica que se mantiene en el nivel “1” durante todo el contacto herramienta-pieza, incluyendo las regiones de transición (CONF, *Cut ON Fast*). Además, éstas devuelven otras variables (CONS, *Cut ON Slow*, y CONFW, *Cut ON Fast Width*), también lógicas, que se mantienen en el nivel lógico “1”, solamente durante el estado estacionario CORTANDO.

$$\begin{aligned}CONF &= (DIF) \text{ OR } (DFM) \text{ OR } (CONS) \\CONS &= (DIS) \text{ OR } (DSM) \\CONFW &= (DIFW) \text{ OR } (DFWM)\end{aligned}\tag{5.4}$$

En la Figura 5.5 se muestra un ejemplo del comportamiento temporal de estas variables lógicas. Se han utilizado como señales digitales de entrada, las obtenidas en la operación de microfresado de ranura, mencionado con anterioridad. En las gráficas también se muestran las

señales filtradas (salidas de las funciones monoestables con re-disparo) **DFM** y **DSM**. Para su obtención, se han ajustado las funciones correspondientes con un tiempo mínimo de activación para cada salida igual a **5 veces el periodo de rotación de la herramienta**. Se describe además el comportamiento temporal de las variables lógicas **CONF** y **CONS** durante los 4 estados definidos en toda la operación de corte. Esta última, en este caso de operación de ranura, presenta un comportamiento muy similar al de la variable **CONFW**.

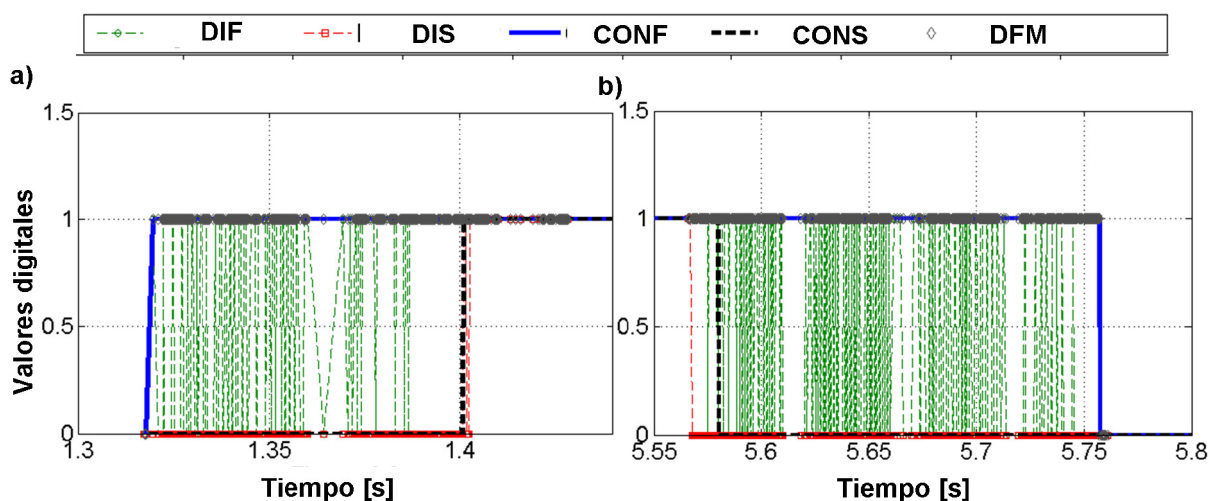



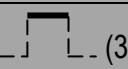






Figura 5.5. Comportamiento de las señales digitales, de entrada y procesadas, durante una operación de ranura, $N_f = 2$, $D = 0.4$ mm, $n = 24000$ rpm, $f = 100$ mm/min, $a_p = 0.1$ mm y $a_e = 0.4$ mm, a) entrada de la herramienta al material y b) salida del material.

A partir de las variables lógicas obtenidas y su estado, caracterizado por su nivel lógico (“0” ó “1”) y transiciones (flanco de subida \uparrow o de bajada \downarrow), se puede establecer de forma preliminar el estado del proceso de corte en cada instante de tiempo. En la siguiente tabla (Tabla 5.2) se describe un conjunto de reglas que definen el estado actual del proceso de corte a partir del estado de las variables lógicas **CONFW** y **CONF**.

Las reglas se definen, por ejemplo, de la siguiente forma: Si (**CONFW** = “0”) y (**CONF** = “0”) entonces (Estado del corte = **NO CORTANDO**). Para algunas de las combinaciones de los estados de las variables de entrada a la tabla, no existe un estado asociado como los ya definidos con anterioridad para el proceso de corte. Esto se debe a que si el comportamiento de las variables no es el esperado (estado **SEÑAL**) o el consecuente de la regla no es único, el resultado final dependerá de los estados anteriores (estado **TRANSICION**). El primero de estos dos nuevos estados definidos puede ser de gran utilidad en un sistema de monitorización para indicar un comportamiento no esperado tanto en el procesamiento digital, como en las señales digitales que provee el sensor desarrollado.

Tabla 5.2. Reglas que establecen el estado del contacto herramienta-pieza.

		CONFW			
		 (0)	 (1)	 (2)	 (3)
CONF	 (0)	NO CORTANDO	CORTANDO	NO CORTANDO	CORTANDO
	 (1)	ENTRANDO	CORTANDO	SEÑAL	CORTANDO
	 (2)	NO CORTANDO	CORTANDO	NO CORTANDO	CORTANDO
	 (3)	TRANSICION	CORTANDO	SALIENDO	CORTANDO

Finalmente, en el caso que el consecuente de la regla sea el estado **TRANSICION**, a partir del estado anterior del contacto herramienta-pieza, podemos determinar el estado actual como:

- Si (Estado preliminar = TRANSICION) y (Estado anterior = ENTRANDO)
Entonces (Estado del corte = ENTRANDO)*
- Si (Estado preliminar = TRANSICION) y (Estado anterior = ENTRANDO) (5.5)
Entonces (Estado del corte = ENTRANDO)*
- Si (Estado preliminar = TRANSICION) y (Estado anterior = SALIENDO)
Entonces (Estado del corte = SALIENDO)*

5.3 Diseño de un procedimiento para la detección de interrupciones en el proceso de corte

A partir de la estrategia desarrollada para la detección de los estados del proceso, se puede desarrollar un algoritmo que permite la monitorización en tiempo real y la detección de interrupciones en el proceso de corte, por ejemplo a causa de roturas de la herramienta.

Como se ha podido comprobar en los experimentos realizados sobre el comportamiento del contacto herramienta-pieza, existen etapas de transición entre los estados de corte y no corte en las operaciones de microfresado. Estas etapas de transición pueden ser de vital importancia para monitorizar el proceso de corte y detectar situaciones imprevistas y de gran repercusión negativa (costes, averías en husillo, defectos en piezas, etc.) como es el caso de rotura de la herramienta. Si se produce un cambio abrupto del estado de la operación, por ejemplo de CORTANDO a NO CORTANDO, sin estado de transición o, de existir, ésta tiene una duración muy pequeña, entonces se puede determinar que se ha producido una rotura de la herramienta. Para comprobar esta afirmación, en la Figura 5.6, se puede observar el

comportamiento de una de las señales analógicas ($V_{Z,MH,FAST}$) que también provee el sensor diseñado.

En la operación que se muestra, la herramienta de corte sufre una rotura durante el estado CORTANDO de la operación de corte y se produce un cambio abrupto hacia el estado NO CORTANDO, sin intermitencia en el corte durante la salida del material. Como se puede apreciar, el tiempo de transición (T_{tran}) durante la entrada al material (T_{in}), igual a 20 milisegundos, es al menos unas 10 veces mayor que el tiempo de salida (T_{out}).




Figura 5.6. Comportamiento de la señal analógica $V_{Z,MH,FAST}$ durante una operación de microfresado de ranura, $N_f = 2$, $D = 0.2$ mm, $n = 40000$ rpm, $f = 96$ mm /min, $a_p = 0.05$ mm y $a_e = 0.2$ mm, a) entrada de la herramienta al material y b) rotura y salida abrupta del material.

El experimento que se muestra en la Figura 5.6 constituye una evidencia experimental del comportamiento dinámico del contacto herramienta-pieza en presencia de roturas de la herramienta. Esto da lugar a realizar un estudio sobre la relación entre los intervalos de duración de los estados transitorios de ENTRADA y SALIDA y de esta manera establecer reglas que ayuden en la toma de decisiones sobre el estado del corte durante las operaciones de microfresado.



Figura 5.7. Diagrama del comportamiento esperado de las señales digitales durante los estados del proceso de corte.

Una forma muy sencilla de delimitar los estados transitorios es realizando operaciones lógicas sobre las variables digitales CONFW y CONF. Dado que la variable CONF debe permanecer en el nivel lógico “1” durante toda la operación de corte (comportamiento esperado en operaciones de ranuras), mientras que la variable CONFW debe alcanzar este nivel solamente durante el estado CORTANDO; entonces al realizar una operación de suma lógica exclusiva (XOR) se obtendría una nueva variable (**PT, Pulse Transition**) que en el nivel lógico “1” indica que estamos en presencia de un estado de transición (ver Figura 5.7). Es decir:

$$PT = CONF \text{ XOR } CONFW \quad (5.6)$$

A partir de la variable lógica PT se puede determinar de manera muy sencilla el tiempo de duración de cada estado de transición, empleando un contador digital. Mediante la comparación entre los tiempos de transición (T_{tran}) de los estados de ENTRADA (T_{in}) y de SALIDA (T_{out}), se pueden establecer reglas que ayuden en la toma de decisiones acerca de una posible terminación abrupta del corte en las operaciones de microfresado (estado del corte **INTERRUMPIDO**).

Con el objetivo de definir estas reglas se han obtenido los tiempos de transición de entrada y salida en diferentes operaciones de microfresado, específicamente en operaciones de ranura. Estos tiempos se muestran en la siguiente tabla (Tabla 5.3), donde $N_f = 2$ y $a_e = D$ y donde la fila resaltada corresponde a la rotura de la herramienta.

Tabla 5.3. Tiempos de transición en operaciones de ranuras, $N_f = 2$ y $a_e = D$.

Tiempos de transición		Parámetros de corte			
T_{in} (s)	T_{out} (s)	f (mm/min)	n (min^{-1})	a_p (mm)	D (mm)
0.097	0.188	100	24000	0.10	0.4
0.103	0.183	100	24000	0.10	0.4
0.102	0.178	100	24000	0.10	0.4
0.020	0.045	400	24000	0.10	0.4
0.022	0.045	400	24000	0.10	0.4
0.020	0.043	400	24000	0.10	0.4
0.020	0.002*	96	40000	0.05	0.2
0.118	0.121	100	45000	0.02	0.2
0.035	0.129	100	45000	0.02	0.2
0.040	0.121	100	45000	0.02	0.2

*Rotura de la herramienta

Como puede apreciarse el tiempo T_{out} , por lo general, es mayor que el tiempo T_{in} correspondiente, excepto en el caso que se produzca la rotura de la herramienta. Aunque este comportamiento no es generalizable debido a que en los datos mostrados, la velocidad de

avance permanece constante durante toda la operación. Se da el caso que en determinadas operaciones de corte, la velocidad puede variar en ciertos tramos del material, pero normalmente los cambios no se producen de forma abrupta. Para evitar la influencia de la velocidad de avance, la duración de las transiciones se puede expresar en términos de distancia recorrida por la herramienta.

A partir de la relación T_{out} vs. T_{in} , se puede detectar la terminación abrupta del estado CORTANDO. Analizando los valores de estos tiempos de transición y en dependencia del estado del proceso de corte, podemos establecer la siguiente regla: **si el estado del corte preliminar es SALIENDO y T_{out} es menor que un valor porcentual β_{break} de T_{in} , entonces el estado de corte ha sido INTERRUMPIDO.**

Tabla 5.4. Toma de decisiones sobre el estado del corte y la herramienta a partir del estado anterior y el estado preliminar establecido mediante el procesamiento de señales.

Estado anterior	Estado preliminar	Operación y estado final
	<i>CORTANDO</i>	$T_{in} = T_{tran}(k)$ *El tiempo de entrada al material es igual al tiempo del estado transitorio actual.
<i>ENTRANDO</i>	<i>NO CORTANDO</i>	Si $T_{tran}(k) > T_{tran}(k-1)$ entonces Estado del corte = <i>INTERRUMPIDO</i> *Si el tiempo de duración del estado transitorio actual es mayor que el tiempo de salida o transitorio anterior, entonces el corte se ha interrumpido abruptamente. El estado transitorio anterior sirve como referencia para hacer la comparación. Inicialmente este valor es cero.
	<i>TRANSICION</i>	Estado del corte = <i>ENTRANDO</i> *Se mantiene el estado anterior.
<i>SALIENDO</i>	<i>NO CORTANDO</i>	$T_{out} = T_{tran}(k)$ Si $T_{out} < \beta_{break} T_{in}$ entonces Estado del corte = <i>INTERRUMPIDO</i> *El tiempo de salida al material es igual al tiempo del estado transitorio actual. Si este valor es menor que un valor porcentual β_{break} del tiempo de entrada al material, entonces el corte ha sido interrumpido de forma abrupta.
	<i>TRANSICION</i>	Estado del corte = <i>SALIENDO</i> *Se mantiene el estado anterior.
<i>CORTANDO</i>	<i>NO CORTANDO</i>	$T_{tran}(k) = 0$ Si $T_{in} < T_{tran}(k-1)$ entonces Estado del corte = <i>INTERRUMPIDO</i> *Se inicializa a cero el tiempo del estado transitorio. Si el tiempo de entrada al material es menor que el tiempo del estado transitorio anterior, entonces el corte ha sido interrumpido de forma abrupta. El estado transitorio anterior sirve como referencia para hacer la comparación.
<i>NO CORTANDO</i>	<i>CORTANDO</i>	$T_{tran}(k) = 0$ *Se inicializa a cero el tiempo del estado transitorio.
<i>INTERRUMPIDO</i>	<i>NO CORTANDO</i>	Estado del corte = <i>INTERRUMPIDO</i> *Si se ha detectado la interrupción abrupta del corte, se mantiene el estado de corte interrumpido.

La Tabla 5.4 muestra la toma de decisiones sobre el estado del corte y la herramienta a partir del estado anterior y el estado preliminar establecido mediante el procesamiento de señales. Esta tabla presenta un conjunto de reglas y operaciones para detectar la rotura de la herramienta. Las reglas se establecen a partir del estado preliminar del corte (ver Tabla 5.2 de estados, ecuación (5.5)) y el estado anterior del corte. Principalmente, se realiza una toma de decisión acerca de la transición entre los estados ENTRANDO, SALIENDO y CORTANDO, hacia el estado preliminar NO CORTANDO.

5.4 Integración del sistema sensorial y el sistema de toma de decisiones

En esta sección se presenta una visión general del sensor inteligente de conductividad integrado en un sistema de monitorización. En la Figura 5.8 está representada la instalación completa de todo el sistema de medición y adquisición, y la interacción con el sensor, con el fin de supervisar las operaciones de corte. La plataforma de monitorización está compuesta por los siguientes dispositivos:

- El **sensor inteligente de conductancia** tiene dos partes bien diferenciadas: un módulo de excitación y un módulo de medición. La parte de excitación suministra una corriente alterna a través de la impedancia formada por la interacción cabezal-herramienta-pieza, y la parte de medición captura el valor de la caída de voltaje en esta impedancia.
- Las señales digitales acondicionadas procedentes del sensor fueron unidas físicamente a la parte digital de una **caja de conexiones** BNC-2110.
- Una **tarjeta de adquisición** NI PXI-6259 fue empleada para capturar las señales digitales procedentes del sensor y realizar la medición del ancho de pulsos, mediante un contador digital configurable integrado en la propia tarjeta.
- Un **sistema embebido** formado por una plataforma de tiempo real NI PXI 1050, que integra la propia tarjeta de adquisición y una unidad de procesamiento NI PXI-8187 que ejecuta los algoritmos de detección del corte, a partir de las señales digitales procesadas.




Figura 5.8. Resumen del sistema sensorial incluido en el sistema de monitorización en tiempo real.

En la Figura 5.8, también se ilustran las bornes de la parte de excitación del sensor conectadas al cabezal y a la pieza de una máquina-herramienta. La máquina usada es un centro de micromecanizado de alta precisión Kern Evo, equipado con un control numérico por computador iTNC530. Este centro fue utilizado para llevar a cabo los ensayos experimentales de monitorización de operaciones de microfabricación.

5.5 Resultados experimentales

Se realizaron ensayos industriales de operaciones de microfresado en componentes típicos de aleaciones aeroespaciales (ej., tungsteno-cobre, W78Cu22), para evaluar el rendimiento y la eficacia del sistema sensorial en la monitorización de procesos. Estas pruebas proporcionaron información relevante y un índice de rendimiento del sistema en la detección de los estados del proceso de corte y rotura de la herramienta en operaciones de microfresado.




Figura 5.9. Montaje de la pieza sobre una plataforma que actúa como aislamiento electromecánico. a) Diagrama y (b) fotografía.

Los ensayos experimentales se realizaron utilizando herramientas con diferentes diámetros y condiciones nominales de operación. La colocación de la pieza de trabajo y el conector 2 del sensor de conductancia se muestra en la Figura 5.9.a. El aislamiento eléctrico necesario entre la pieza y la carcasa de la máquina para que el sensor funcione correctamente también se aprecia en esta figura.

De acuerdo con el perfil de la operación de corte en la pieza de trabajo, en la Figura 5.10 se describe el comportamiento esperado de la variable de salida del algoritmo, ante una operación de microfresado de ranura con un perfil de pieza, como el mostrado en la Figura 5.9.b. Éstos pueden ser comparados con los valores reales obtenidos en tiempo real en pruebas de validación y así, obtenerse un porcentaje de exactitud en la determinación de los estados del corte. La variable de salida del algoritmo presenta un nuevo valor cada 250 μ s.




Figura 5.10. Esquema del comportamiento esperado de la variable de salida del algoritmo de detección del estado de corte.

La Figura 5.11 muestra las variables de salida del algoritmo ("estado del corte"), como resultado de tres ensayos concretos de operaciones de micro fresado.




Figura 5.11. Estado del corte durante operaciones de micro fresado con $D = 200 \mu\text{m}$, $N_f = 2$, $n = 45000$ rpm, $a_e = 200 \mu\text{m}$ y $a_p = 200 \mu\text{m}$, a) $f = 50$ mm/min, b) $f = 100$ mm/min y c) $f = 200$ mm/min.

Del análisis, se concluye que el comportamiento del sistema ha mostrado muy buenos resultados con aproximadamente un 90% de precisión en la detección de los estados del proceso, utilizando el modo de muestreo cada $250 \mu\text{s}$. Este grado de éxito durante los estados de transición se puede mejorar mediante el ajuste de los parámetros de configuración del algoritmo de detección. En contraste, la Figura 5.11.a y b muestran posibles errores relacionados con el efecto de las vibraciones en los estados de transición que cambian entre los estados de "SALIENDO" a "NO CORTANDO" o de "ENTRANDO" a "CORTANDO". Las causas principales son debidas a la vibración de la herramienta de corte al entrar o salir del material, los cuales provocan cambios bruscos en el área del contacto de corte. Por último, en la Figura 5.11.c, el sistema produjo un estado "INTERRUMPIDO", como consecuencia de una rotura de la herramienta.

En el Capítulo 7 se llevará a cabo una validación experimental mucho más exhaustiva del sensor inteligente y algoritmos de detección del estado del proceso, integrado en la arquitectura de tiempo real. Todo este sistema será ejecutado en paralelo junto a un módulo de estimación *on-line* de la rugosidad superficial durante operaciones de microfresado.

5.6 Conclusiones

En este capítulo se ha presentado el diseño e implementación de un sensor inteligente de conductividad para la monitorización del estado de un proceso complejo. En este caso, se ha aplicado en la detección de los diferentes estados del proceso de microfabricación, en los que los sensores tradicionales y los operadores de las máquinas son ineficaces. Los resultados de esta investigación experimental han demostrado que el sensor de conductancia es la mejor

opción para supervisar el estado del corte y detección de roturas de la herramienta en la microfabricación mecánica por arranque de material (micromecanizado), cuando se requiere utilizar la mínima información sensorial posible y métodos de cómputos sencillos y eficientes. El sensor mide la conductancia de la caída de voltaje generada en la resistencia eléctrica debido al contacto dinámico de la herramienta con la pieza de trabajo. Esto implica que los resultados de este estudio son aplicables a los procesos de micromecanizado de materiales conductores.

Además, se ha corroborado que este sensor cumple los requisitos de robustez, fiabilidad, bajo coste y alta velocidad de respuesta debido a que aprovecha las características de alta velocidad de la conductividad eléctrica, el uso de circuitos mixtos electrónicos (analógicos-digitales) y un post-procesamiento con una electrónica digital simple.

Como continuación de este capítulo, las señales proporcionadas por este sensor han sido utilizadas como entradas a un sistema embebido, diseñado para el sistema de ayuda a la toma de decisiones, que está basado en un conjunto de reglas y una máquina de estados finitos para la detección del estado del corte y de la rotura de la herramienta. Debido a ello, se ha confirmado que utilizar como entradas a los algoritmos embebidos, las señales obtenidas del sensor de conductancia es la mejor opción para supervisar el estado del proceso de fabricación.

Del análisis experimental extraído del comportamiento del sistema se ha concluido que el comportamiento del sistema ofrece muy buenos resultados con aproximadamente un 90% de precisión en la detección de los estados del proceso. Estos resultados han sido obtenidos al utilizar el modo de muestreo continuo cada 250 μ s. Dicha validación será ampliada de una manera más exhaustiva en el Capítulo 7.

En el siguiente capítulo, los dos algoritmos desarrollados basados en técnicas de AI propuestos en el Capítulo 3 serán aplicados para el diseño e implementación de modelos de estimación de variables representativas del proceso de microfabricación. En específico, se ha considerado la estimación de la rugosidad superficial on-line en el proceso de microfresado de alta precisión, como caso real de proceso electro-mecánico complejo.

CAPÍTULO 6

MODELADO REPRESENTATIVO DE CIERTAS VARIABLES DEL PROCESO. RUGOSIDAD SUPERFICIAL

En este capítulo se mostrarán la aplicación y los beneficios de las técnicas de modelado, optimizaciones de parámetros y aprendizaje analizadas en el Capítulo 3, en el campo de los procesos de microfabricación, específicamente el microfresado. Estos procesos involucran maquinaria y materiales muy costosos así como operadores expertos altamente cualificados. De ahí que cualquier modelo que sea capaz de describir de forma eficiente los procesos físicos que tienen lugar en la micro escala, 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.

Por ejemplo, las características del microfresado como proceso electromecánico complejo limitan el uso de las herramientas matemáticas clásicas para su modelado. En el Capítulo 3 se demostró que si las técnicas clásicas no son viables, no se dispone de un modelo matemático exacto o éste es muy complejo de ser obtenido y ajustado por el alto número de variables y parámetros que lo hacen computacionalmente ineficiente y el conjunto de datos experimentales es escaso, **la técnica de modelado híbrido incremental (HIM) y la técnica de agrupamiento borroso generalizado *C-means* (GFCM) han mostrado su eficacia previamente y pueden ser muy útiles como se mostrará en este capítulo.** Estas dos técnicas propuestas **no son únicas dentro de la gran amalgama de técnicas clásicas y de inteligencia artificial disponibles en la actualidad, pero son contemporáneas.** Mediante la

aplicación de estos métodos, se pretende superar algunas limitaciones relacionadas con el conocimiento exacto de las no linealidades del proceso y las dificultades asociadas a la representación cuasi-lineal o lineal de un proceso no lineal.

En este capítulo se contribuye fundamentalmente con modelos para la estimación en proceso (on-line) de una variable representativa del proceso de microfabricación, como es la rugosidad superficial, a partir de la mínima información sensorial posible, utilizando para ello dos modelos experimentales basados en los algoritmos HIM y GFCM.

Este capítulo se estructura de la manera que se describe a continuación. Inicialmente, en la sección 6.1 se explican las motivaciones que han llevado al desarrollo de este trabajo. Con tal fin, en la sección 6.2 se hace necesario que se establezcan unas relaciones causa-efecto entre la información sensorial, el estado del proceso de micromecanizado y la calidad dimensional y superficial (rugosidad superficial). Se ha establecido la rugosidad superficial y específicamente la R_a como el criterio de mayor importancia, aunque también se ha considerado la R_q . A continuación, en la sección 6.3 se prepara la base de datos de entrenamiento y validación de los modelos, a partir de una serie de ensayos experimentales de microfresado. Las relaciones anteriormente mencionadas fueron formalizadas a través de dos tipos de modelos (sección 6.4), los cuáles serán comparados con el objetivo de determinar cuál de ellos será embebido definitivamente en el sistema de tiempo real (sección 6.5), cuya implementación será descrita en el Capítulo 7.

6.1 Necesidad de modelos predictivos de la calidad superficial

La rugosidad o acabado superficial de un componente o pieza es **una de las características más importantes para conocer la calidad de la microfabricación**, constituyendo un indicador final de la efectividad del proceso de fabricación llevado a cabo. El procedimiento empleado para la medición de la rugosidad superficial puede convertirse en un elemento diferenciador no solo desde el punto de vista científico-técnico sino también en lo que a competitividad y eficiencia de las empresas se refiere, ya que influye en criterios tales como el rendimiento y la productividad de las estrategias de fabricación utilizadas.

Actualmente, es posible conseguir de modos relativamente sencillos una medida precisa de la rugosidad de piezas mecanizadas a escala macro. Sin embargo, esta precisión y sencillez se reduce a medida que disminuye la escala dimensional a la que se trabaja, llegando a ser crítica en la escala micro y la escala nano. En otras palabras, la determinación del acabado de piezas pequeñas a escala micro es bastante más difícil, siendo especialmente problemática cuando los requerimientos de rugosidad se encuentran entre 0,3 nm y 7,0 nm. (Gillespie, 2008 [254]). Nótese que el ajuste y acabado de micropiezas puede afectar a la calidad y funcionamiento a más alto nivel.

Actualmente, los procedimientos con mayor arraigo en la industria para medir de forma precisa la rugosidad superficial de fabricación se llevan a cabo en los departamentos de control de calidad en tareas de post-procesado, es decir, una vez concluidas las operaciones de fabricación, influyendo por tanto de forma decisiva en el tiempo total de fabricación de la pieza [255]. Para ello, normalmente se utilizan los denominados perfilómetros o rugosímetros (Figura 6.1), que pueden ser unos dispositivos sin contacto o con contacto. Estos últimos están dotados de una aguja que toca la superficie cuya rugosidad se desea medir. Las altas variaciones de la superficie son medidas moviendo la aguja (o la superficie). Los movimientos de la aguja se convierten en señales eléctricas que luego son amplificadas, digitalizadas e introducidas al ordenador para posteriormente ser analizadas.



Figura 6.1. Posicionamiento y medición de la rugosidad superficial en una pieza mecanizada.

En el caso de la escala micro, la cabeza del palpador y la aguja son versiones a escala reducida de los perfilómetros de contacto tradicionales. Sin embargo, a diferencia del método de contacto tradicional, la medición se registra cuando se presenta un cambio en el movimiento constante del microsensor (amortiguado). Actualmente se dispone de agujas de tamaños extraordinariamente pequeños, como por ejemplo de 0.125 mm de diámetro y 10 mm de largo. Cuando la punta se acerca al objeto a medir, su micromovimiento es amortiguado por la proximidad a la superficie de la pieza. Este cambio de paso de umbral en el micromovimiento se registra como un punto de medición.

Un inconveniente de la medición de la rugosidad en piezas en la escala micro con perfilómetros está relacionado con el posicionamiento de la micropieza para inspeccionarla con el perfilómetro. Debido al tamaño tan reducido de las piezas es difícil ver físicamente, debajo de la cabeza del palpador, la posición de la pieza a medir para alinear el movimiento de la aguja con la pieza. Se necesita un sistema de pre-posicionado, usando soportes, calzas, agujeros o algún sistema que permita situar la pieza bajo la cabeza del palpador. En definitiva, se trata de tareas muy laboriosas y engorrosas.

Para solucionar este problema se han desarrollado métodos para medir la calidad “en-proceso”. Algunos son métodos físicos que involucran sistemas libres de contacto, de procedimiento óptico, con láser, ultrasonidos, ente otros. Por ejemplo, **a partir de las señales de vibración**, Abouelatta y Madl [256] desarrollaron un método de predicción de la rugosidad superficial en el torneado sobre la base de parámetros de corte y el análisis FFT de estas señales. Salgado et al. [257] también usaron el análisis singular del espectro para descomponer la señal de vibración para la predicción en proceso de la rugosidad superficial en el torneado. Sin abandonar la vibración, Song et al. [258] investigaron a través del análisis de series temporales la utilidad para la predicción en tiempo real de la rugosidad superficial de estas señales, medidas durante las operaciones de corte. Sin embargo, otra posible señal a correlacionar con la rugosidad superficial, la cual también mide vibraciones, es la de emisión acústica (EA). Guo y Ammula [259] investigaron la sensibilidad de una amplia gama de parámetros de la señal de EA en el acabado superficial y en el desgaste de la herramienta: el valor *rms* de la EA y la frecuencia tienen una buena correlación y por tanto pueden ser utilizados para monitorizar la integridad de la superficie.

Por el contrario, si las variables analizadas son parámetros de corte, se pueden destacar trabajos como el de Rawat y Attia [260]. Ellos investigaron el efecto de la velocidad de corte y velocidad de avance sobre las características de calidad de los agujeros taladrados en materiales compuestos de fibra de carbono (delaminación, errores geométricos, acabado de la superficie) mediante el registro de las fuerzas de corte con un dinamómetro y la inserción de dos termopares tipo K dentro de la broca. **Estos tipos de sistemas de medición directa en proceso han sido probados y validados en ambientes de laboratorio que se alejan bastante de lo normal en cualquier taller.**

Otra posible solución consiste en modelizar el comportamiento de la rugosidad superficial a partir de otras variables asociadas al proceso. El modelo de esa variable asociada al proceso podría llegar a obtenerse de forma matemática, a través de técnicas clásicas o a partir de técnicas basadas en Inteligencia Artificial.

Por un lado, si el modelo es matemático exacto, se pueden citar trabajos como el de Jie Yi et al. [261], en el cual se desarrolla un modelo matemático para predecir la rugosidad superficial en un proceso de microfresado basado en el método de respuesta de superficie (*Response Surface Method*, RSM). El diseño experimental propuesto está basado en un diseño central compuesto circunscrito (*Central Composite Circumscribed*, CCC) para la reducción del número de ensayos experimentales. De ese estudio se concluye que al aumentar la velocidad de avance y disminuir la velocidad del cabezal, se incrementa la rugosidad superficial. Las variables de entrada son la velocidad del cabezal, velocidad de avance, profundidad de corte, mientras que la salida es la rugosidad superficial. Zhang et al. [262] también aplican un modelo matemático para una evaluación on-line de la superficie, a partir de la tasa de arranque de viruta producida en el corte y del desgaste de la herramienta.

Por su parte, a partir de una técnica clásica como es la regresión estadística, Bandapalli et al. [263] desarrollan un modelo de regresión lineal, cuyos resultados arrojan que a altas velocidades de giro del cabezal, baja profundidad de corte y baja velocidad de avance, se asegura la alta calidad de la rugosidad superficial, en el microfresado. Otro modelo de regresión, fue desarrollado por Chang et al. [264] para la predicción en proceso de la rugosidad superficial sobre la base de la señal de desplazamiento del movimiento del husillo

En cambio, si la opción escogida son técnicas basadas en Inteligencia Artificial, en la literatura se encuentran diferentes trabajos. Por ejemplo, Azouzi y Guillot [265] 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, utilizando redes neuronales y una fusión sensorial. También, en base a una red neuronal, Huang y Chen [266] utilizan un enfoque estadístico para correlacionar la rugosidad superficial y la fuerza de corte en las operaciones de fresado. Con el mismo objetivo, pero en este caso utilizando un modelo adaptativo de inferencia neuroborrosa (ANFIS), Palani et al. [156] estiman la rugosidad a partir de las entradas velocidad de corte, velocidad de avance y profundidad de corte, en el proceso de microtorneado. Por su parte, Chavoshi et al. [267], comparan varios modelos de predicción de la rugosidad usando, para cada uno de ellos: perceptrón multicapa (*multilayer perceptron*, MLP), pre-alimentación generalizada (*generalized feed forward*, GFF), red neuronal modular (*modular neural network*, MNN) y sistema de inferencia borrosa co-activo (*co-active neuro-fuzzy inference system*, CANFIS) en un proceso de microfresado plano. Las variables de entrada son la velocidad de corte, velocidad de avance, profundidad de corte. Los autores de este trabajo concluyen que los mejores resultados se obtienen al aplicar CANFIS.

Por todo ello, en este capítulo se decide diseñar un modelo de estimación de la rugosidad superficial on-line, basado en técnicas de inteligencia artificial, con el objetivo de monitorizar el proceso, realizar recomendaciones inteligentes, o realizar acciones correctivas en el mismo, si los valores no se sitúan en los rangos deseados. Asimismo, la salida del modelo es la rugosidad superficial en tiempo real y por tanto, en el caso que se desee, se podría cerrar el bucle mediante un controlador que ajuste los parámetros de forma automática.

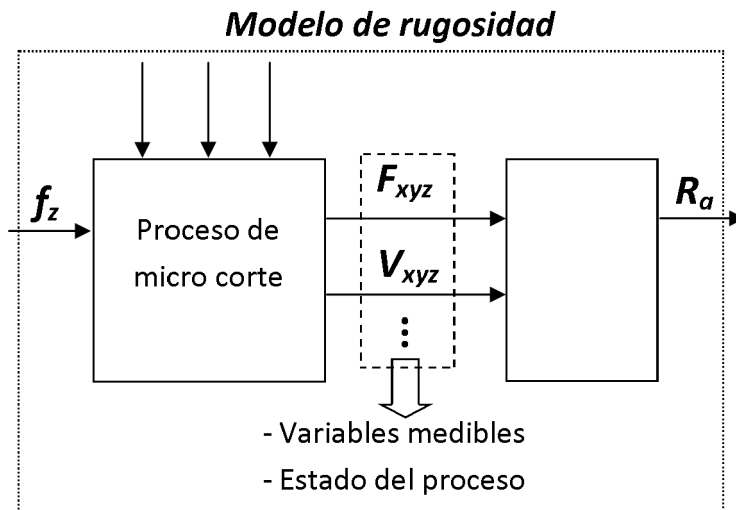


Figura 6.2. Diagrama del proceso a modelar, y las variables de entrada y salida

El proceso de corte informa sobre el estado del proceso a partir de una serie de fenómenos o variables físicas medibles (ej., fuerzas de corte, vibraciones, etc.) que afectan al acabado superficial de la pieza. La magnitud de las variables físicas que representan estos fenómenos depende, entre otras muchas causas, de las condiciones de operación (velocidad de avance, velocidad del cabezal, etc.), las características de la herramienta (por ejemplo, número de dientes), o la unificación de ambas (por ejemplo, avance por diente, f_z). Se ha necesario, por tanto, determinar que parámetros de corte y variables medibles se deben utilizar en la estimación de la rugosidad superficial.

6.2 Elección de variables representativas del proceso de micromecanizado

La rugosidad superficial y específicamente la R_a es uno de los indicadores industriales más utilizado para evaluar la calidad superficial. La R_a se define como:

$$R_a = \frac{1}{n} \sum_{i=1}^n |y_i| \quad (6.1)$$

La rugosidad se expresa normalmente en micras, o en nuestro caso en nanómetros, y se define como la media aritmética de los valores absolutos de los puntos con distancia y_i con respecto a la línea media del perfil de rugosidad medido.

Sin embargo en la literatura no están claros cuales son las variables que mayor influencia tienen en la rugosidad superficial al menos en la escala micro. Por ello, se ha llevado a cabo un estudio experimental de las diferentes variables implicadas en el proceso de mecanizado para determinar cuáles de ellas son las más adecuadas para predecir la rugosidad de la pieza en tiempo real. Los resultados del estudio experimental permiten concluir que las variaciones

en la rugosidad superficial con la velocidad de corte tienen diferentes comportamientos para diferentes valores de avance por diente.




Figura 6.3. Comportamiento de la rugosidad superficial ante la variación en el avance por diente.
(Adaptación de Sooraj y Mathew, 2011 [268]).

Además, en general un aumento en la velocidad de corte conduce a una reducción en la rugosidad. Esto se produce fundamentalmente por los siguientes motivos:

1. El mecanismo de rugosidad de la superficie a bajas velocidades de corte incluye no sólo las consideraciones geométricas, sino también los efectos del espesor de la viruta mínimo, la recuperación elástica, y la acción de arrastre.
2. El aumento de la tasa de desgaste a bajas velocidades dará lugar a una tensión no uniforme sobre la herramienta y a una rápida propagación del desgaste, que afectará significativamente las características de la superficie.
3. El efecto de la microestructura de la pieza de trabajo, cuando el espesor de la viruta es en el orden o menor que el promedio tamaño de grano.
4. La tasa de aumento de la tensión superficial debido al efecto de tamaño y el efecto de flujo de plástico (similar al arrastre) que depende de la combinación pieza-herramienta.

Las observaciones experimentales revelaron que la interacción de la velocidad de corte y la carga de viruta (avance por diente) es un criterio fundamental para decidir la rugosidad de microcanales en operaciones de microfresado. Las observaciones experimentales mostraron también que los niveles de avance por diente y la interacción de la velocidad de corte y carga de viruta son factores cruciales en la operación de microfresado. La variación drástica de la presión específica de corte y las fuerzas de corte a menores avances por diente, indica claramente el efecto del espesor mínimo de viruta en el micromecanizado. Por tanto, **una de las variables elegidas para la estimación de la rugosidad superficial ha sido el avance por**

diente, señal que puede obtenerse a partir de las señales internas de la máquina herramienta, a través del control numérico por computador abierto.

Sin embargo, tal y como recoge la literatura, una sola variable es insuficiente para hacer una buena predicción de la rugosidad superficial en tiempo real. Es necesario utilizar otra variable medida que sea capaz de reflejar de forma sistemática y en tiempo real la influencia de otras variables y de las propias no linealidades y perturbaciones tales como el *run-out*, la geometría de la herramienta y el efecto del tamaño con vistas a capturar de forma más realista el mecanismo de eliminación de material en la escala micro y su influencia en la rugosidad.

De todas las variables analizadas la que ofrece mejor relación señal ruido y cuyo coste del sensor es más económico es la **señal de vibración procedente de un acelerómetro**. Ciertamente se trata de un sensor relativamente poco invasivo al proceso, robusto y cuyo coste y procesamiento de señales no es tan costoso, como ocurre con los sensores de emisión acústica, ni tan invasivos como los sensores de fuerza.

En definitiva, en la presente Tesis Doctoral las variables utilizadas para modelar y caracterizar el acabado superficial son la velocidad cuadrática de avance por diente y la vibración media cuadrática en el eje Z de la máquina.

6.3 Diseño experimental inicial. Base de datos para el modelado

Se realizaron más de 200 experimentos con el objetivo de estudiar y analizar el comportamiento de las variables en procesos de microtaladrado y microfresado. A modo de ejemplo, se pueden mencionar los experimentos realizados en Wolframio (WCu), utilizando fresas y brocas de 0,2 mm, 0,5 mm, 1 mm y 1,8 mm de diámetro, que permiten estudiar una zona muy amplia y potencialmente muy importantes desde el punto de vista comercial y de la eficiencia de los procesos de micromecanizado. Se analizó un rango de velocidades de giro entre las 8000 rpm y las 45000 rpm, y se midieron acabados superficiales desde los 70 nm hasta los 500nm.

La Figura 6.4.a muestra el montaje experimental empleado para la adquisición y procesamiento de datos. En la Figura 6.4.b se observa el acelerómetro piezoeléctrico instalado en la mordaza o mecanismo de sujeción de la pieza para medir la vibración en el eje Z. La señal analógica del sensor inteligente de conductancia es adquirida mediante tarjetas de adquisición y se procesa mediante un programa de adquisición y procesamiento situado en un dispositivo de cómputo de alto rendimiento.

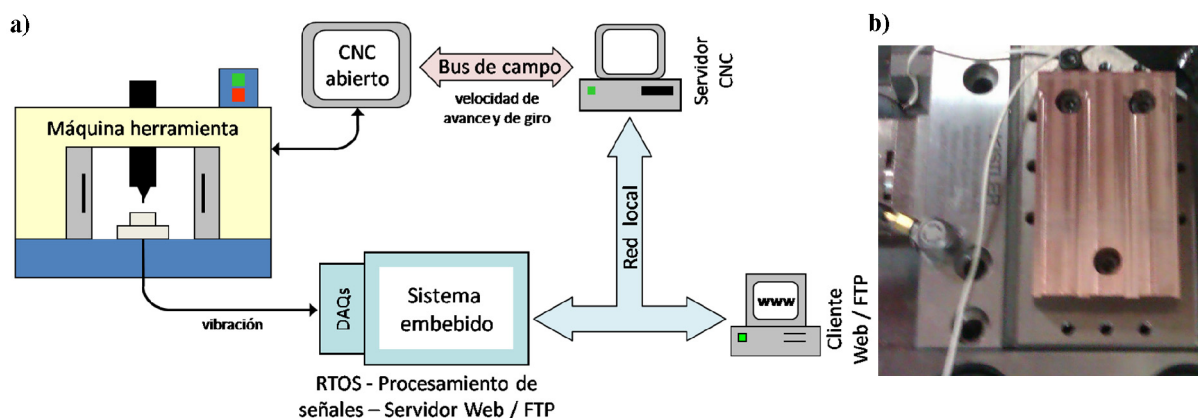


Figura 6.4. a) Sistema de adquisición y procesamiento. b) Instalación del acelerómetro en la pieza a fabricar.

El diseño experimental utilizó un valor nominal de avance (f_{nm}) para cada herramienta: f_{n1} , $f_{n2} = 2 f_{n1}$ y $f_{n3} = 3 f_{n1}$. Además, en cada sección de la ranura se utilizaron tres escalones de avance que variaban porcentualmente según la Figura 6.5.




Figura 6.5. Perfil del diseño experimental con cambios en la velocidad de avance.

Los cambios en la velocidad de avance se produjeron durante la realización de operaciones de microfresado sobre un perfil de pieza con un tamaño de 50 x 30 x 8 mm. A lo largo del eje Y, ésta pieza se dividió en tres secciones o canales transversales de 7 mm con una profundidad de 1 mm y cada canal se separó 3 mm del anterior. A modo de clarificación, en la Figura 6.5 se ilustra el diseño del perfil del protocolo experimental.

A continuación, se describe el pre-procesamiento llevado a cabo sobre las señales de vibración para su posterior utilización en la estimación del acabado superficial. Hay que tener en cuenta que los pasos seguidos en la estrategia de procesamiento y acondicionamiento de los datos experimentales para el entrenamiento y evaluación de los modelos, se implementará a posteriori en el sistema embebido para su ejecución en tiempo real. Por tanto, no se podrán incluir técnicas que conlleven mucha carga computacional que demore el tiempo de ejecución de los demás ciclos del sistema. Se elegirá la estrategia más simple posible que genere unos resultados mínimamente satisfactorios.

Como paso inicial, se elimina el *offset* o componente de continua mediante un filtro paso alto a muy baja frecuencia, para que no elimine información relevante contenida en el resto de frecuencias. También, se eliminan las componentes en frecuencias por encima de la

sensibilidad del sensor. Como resultado, se diseña un filtro IIR digital tipo “*Butterworth*” de 6º orden con $f_c = 100$ Hz y $f_s = 50$ kHz, cuyos coeficientes son los mostrados en la ecuación (6.2).

$$Y(z) = \frac{0.028 + 0.053z^{-1} + 0.071z^2 + 0.053z^{-3} + 0.028z^{-4}}{1 - 2.026z^{-1} + 2.148z^{-2} + 1.159z^{-3} + 0.279z^{-4}} \quad (6.2)$$

Con el fin de convertir el filtro diseñado en parametrizable, adaptativo y más preciso, se decide que la frecuencia de corte dependa de la mitad de la frecuencia giro. Esta decisión se debe a que los armónicos con más información también son múltiplos de la frecuencia de giro y de la frecuencia de paso por diente (el doble de la frecuencia de giro). Los coeficientes del filtro relativos a una misma frecuencia de giro, se calculan en el proceso de inicialización del sistema, junto al resto de variables, según la siguiente ecuación:

$$f_{c,HP} = \frac{n}{2 \cdot 60} \text{ [Hz]} \quad (6.3)$$

Como se ha podido comprobar en estudios previos, el valor *rms* de la señal de vibración es un parámetro altamente relacionado con la rugosidad superficial; y por tanto, fue el procesamiento elegido a la hora de preparar la señal de vibración como datos de entrenamiento en los algoritmos de modelado. En la Figura 6.6, se observa esquematizada esta metodología de preparación de los datos experimentales.




Figura 6.6. Esquema de las zonas que se toman el valor *rms* total para cada velocidad de avance en cada sección de la ranura completa.

En definitiva, se calculará el valor *rms*, ecuación (6.4), del conjunto de datos de vibración filtrados por cada una de la tres subsecciones (X_0 , X_1 , X_2 y X_3) con variación porcentual de la velocidad de avance. Cabe resaltar que para una operación completa de microfresado de ranura se dispone de nueve subsecciones (X_0, \dots, X_n).

$$Ac_{Z,rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (6.4)$$

A cada subsección X_n , se le eliminarán el conjunto de datos correspondientes a los instantes de tiempo en los que la herramienta no está insertada totalmente en el material ($+R$, $-R$). En otras palabras, debido al estado de la inserción de la herramienta en la pieza, no se utilizará para el cálculo del valor *rms*, los datos de vibración correspondientes a una región que se corresponda con instantes de tiempo al principio ($X_n - R$) y final de cada subsección ($X_n + R$). Con ello, se intenta aislar los datos afectados por la respuesta dinámica de la maquina a las variaciones en la velocidad de avance.




Figura 6.7. Rugosidad superficial en un perfil ranura con una herramienta de diámetro 1000 μm , a) perfil de rugosidad completo, b) perfil de rugosidad en la primera sección de la ranura y c) perfil de rugosidad en tres regiones de la sección seleccionada.

Por último, para completar la base de datos experimental, solo falta describir el método usado para la obtención de la variable de salida del modelo. La rugosidad superficial fue medida post-proceso mediante un perfilómetro de precisión. El modelo utilizado es el *Form Talysurf PGi* (Figura 6.1), el cual posee una resolución desde 0.8 nm hasta 3.2 nm para todos los rangos de medición (4, 8, 12.5 mm). Como ejemplo, la Figura 6.7 representa el comportamiento de la rugosidad superficial en uno de los perfiles de ranura realizado por una

de las operaciones de microfresado con una herramienta de 1000 μ m de diámetro, a una velocidad de giro de 40000 rpm, 100 mm/min de avance y una profundidad axial de 100 μ m, correspondiente al conjunto de experimentos iniciales. En la Figura 6.7.a se muestran los escalones en la profundidad de corte de la pieza en todo el perfil de ranura medido, desde un punto de vista lateral. También, se resaltan las zonas de donde se desea extraer los valores de rugosidad. Además, en la Figura 6.7.b se puede apreciar el comportamiento de la rugosidad de acuerdo con la salida que proporciona el perfilómetro correspondiente a las zonas de la sección remarcadas en la figura anterior. Se concluye que es necesario llevar a cabo un procesamiento para eliminar la deriva por imprecisiones. Finalmente en la Figura 6.7.c se ilustra el comportamiento de la rugosidad superficial en las regiones analizadas que se corresponden con las marcadas en la figura superior. A partir de estos valores se determina el valor de R_a , tal y como se ha descrito en (6.1). En este caso, el valor de la rugosidad superficial, R_a , para estas regiones, según el mismo orden en el que aparecen en la figura, ha sido de 228.49 nm, 181.83 nm y 178.89 nm.

6.4 Generación del modelo representativo del proceso de microfabricación

En este primer paso, se obtienen los modelos representativos del proceso de microfabricación que permite estimar la rugosidad superficial a partir de datos del avance por diente y de la vibración de la máquina en el eje Z. El avance por diente se define como la distancia que avanza cada diente de la herramienta con relación a la pieza por cada vuelta que realiza. Esta información se obtiene a partir de la velocidad de avance de la máquina, su velocidad de giro y la información geométrica de la herramienta, que normalmente se encuentran disponibles internamente en la máquina, específicamente en su controlador. Por otro lado, la vibración de la máquina en el eje Z se mide utilizando un acelerómetro instalado en la pieza.

Específicamente, **los modelos tienen como salida la rugosidad superficial media absoluta (R_a)**, expresada en nanómetros (nm), y **como entradas el valor cuadrático del avance por diente (f_z)² normalizado con relación al radio de la herramienta (r)**, ambos expresados en nanómetros (nm), y **la vibración media cuadrática en el eje Z (A_{crms}) normalizada con relación a su valor máximo (A_{cmax})** durante una ventana temporal. Matemáticamente, se puede representar como:

$$R_a = f\left(\frac{f_z^2}{r}, \frac{A_{crms}}{A_{cmax}}\right) \quad (6.5)$$

La Tabla 6.1 muestra el conjunto de 21 datos obtenidos experimentalmente que se han utilizado en este ejemplo para llevar a cabo el ajuste de los dos modelos utilizados en esta

Tesis Doctoral. Se presentan en esta tabla no sólo los datos de avance por diente, vibración en el eje Z y rugosidad superficial, sino también un gran número de datos auxiliares.

Tabla 6.1. Los datos utilizados para obtener los diferentes modelos.

PosY [mm]	PosX [mm]	f [mm/min]	n [1/min]	fz [um]	r [mm]	Accel_rms [g]	Accel_max [g]	Ra [nm]	Rq [nm]	Rv [nm]	Rp [nm]	Muestras / Intervalo
12	8,25	80	45000	0,88889	0,25	0,0262	0,10257	102,75	134,44	-657,52	297,88	7333
12	25,917	100	45000	1,1111	0,25	0,028317	0,15561	91,362	120,85	-849,45	279,26	7333
13	13,583	120	45000	1,3333	0,25	0,050049	0,19443	95,604	148,18	-1635	285,08	7333
18	15,917	200	45000	2,2222	0,25	0,014867	0,085213	88,538	136,29	-1513,5	255,97	7333
18	28,25	160	45000	1,7778	0,25	0,016169	0,099085	81,747	122,62	-844,75	238,91	7333
21	23,583	360	45000	4	0,25	0,011993	0,054595	156,96	225,07	-1345,6	506,88	7333
22	25,917	300	45000	3,3333	0,25	0,012071	0,057455	148,45	213,53	-1556	373,91	7333
20	8	80	40000	1	0,50	1,3386	5,6295	178,89	226,37	-924,07	862,73	5333
20	15,667	100	40000	1,25	0,50	2,2783	6,2525	167,59	212,65	-990,41	630,99	5333
20	23,333	120	40000	1,5	0,50	0,95401	3,2482	171,03	217,4	-936,59	494,49	5333
23,5	13,333	240	40000	3	0,50	1,3564	3,8861	249,49	308,83	-1217,8	880,4	5333
23,5	18	160	40000	2	0,50	1,3838	3,9785	237,64	300,21	-1069	795,96	5333
30	23,333	360	40000	4,5	0,50	0,1164	0,24094	295,01	373,28	-1884,9	818,45	5333
31,5	5,6666	300	40000	3,75	0,50	0,10185	0,29414	226,29	287,24	-1251,4	918,73	5333
14,5	27,6	80	15000	2,6667	0,90	1,2441	1,9268	337,62	430,38	-1344,9	1089,5	2133
17	5,2667	100	15000	3,3333	0,90	1,077	1,6353	325,4	441,53	-1350,8	2645,2	2133
17	17,6	80	15000	2,6667	0,90	1,0435	1,6196	316,3	391,07	-1008,2	1042,7	2133
17	22,933	120	15000	4	0,90	1,1453	1,6907	392,32	488,63	-1251,5	1546,7	2133
33,5	7,6	40	15000	1,3333	0,90	0,09464	0,22397	288,62	359,42	-1202,9	1172,4	2133
33,5	15,267	50	15000	1,6667	0,90	0,093389	0,228	294,8	357,55	-844,93	1169,8	2133
33,5	22,933	60	15000	2	0,90	0,093431	0,22928	287,54	353,84	-999,87	845,74	2133

En la fase de entrenamiento o ajuste y validación del proceso de modelado de la rugosidad superficial, R_a , se obtienen una serie de cifras de mérito o índices de comportamiento que reflejan la calidad, rendimiento, eficacia y precisión del propio modelo. A continuación se definen los índices de comportamiento usados en esta Tesis Doctoral para el estudio comparativo de ambos modelos, HIM y GFCM:

$$SSE = \sum_{i=1}^{Nm} (R_a - R_a')^2 (i) \quad (6.6)$$

$$NSSE = \sqrt{\frac{SSE}{2 \cdot Nm}} \quad (6.7)$$

$$FPE = \frac{NSSE(N + p)}{N - p} \quad (6.8)$$

$$ENV = \frac{2 \cdot N \cdot NSSE}{N - p} \quad (6.9)$$

$$MRE = \frac{1}{Nm} \sum_{i=1}^N \frac{|R_a - R_a'|}{R_a} (i) \quad (6.10)$$

donde **SSE** (*Sum of Squared Errors*) es la **suma de errores cuadráticos**, **NSSE** (*Noise of Sum of Squared Errors*) es el error de predicción o **ruido en el suma de errores cuadráticos**, **FPE** (*Final Prediction Error*) es el **error de predicción final**, **ENV** (*Estimated Noise Variance*) es la **varianza estimada de ruido** y **MRE** (*Mean Relative Error*) es el **error relativo medio**. En estas ecuaciones, Nm es el número de total de muestras modeladas, p es el número de parámetros del modelo y R_a y R_a' son los valores de rugosidad superficial de la observación y la predicción i -ésima, respectivamente.

Los índices de comportamiento descritos anteriormente fueron aplicados en el modelado tanto con el algoritmo HIM como GFCM. Además, específicamente se utilizaron otros, como por ejemplo el **número de casos (data points) con un error $\geq 10\%$** , para el caso de HIM. En cambio para GFCM se añaden **MSE** (*Mean Squared Error*) que el **error cuadrático medio** y **SNSE** (*Sum of Normalized Squared Error*) que es la **suma de errores normalizados al cuadrado**.

$$MSE = \frac{1}{Nm} \sum_{i=1}^{Nm} (R_a - R_a')^2 (i) \quad (6.11)$$

$$SNSE = \sum_{i=1}^{Nm} \left(\frac{R_a - R_a'}{R_a} \right)^2 (i) \quad (6.12)$$

6.4.1 Obtención de un modelo híbrido incremental (HIM)

En primer lugar se procedió a la aplicación del algoritmo de modelado híbrido incremental, desarrollado en la sección 3.3 del Capítulo 3. La configuración utilizada se muestra en la Figura 6.8. **Una de las motivaciones tenidas en cuenta para aplicar esta estrategia de modelado fue la necesidad de hacer frente a comportamientos con no-linealidades y variantes en el tiempo con procedimientos de bajo coste computacional.**

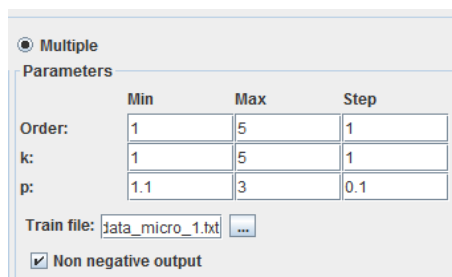


Figura 6.8. Configuración en la interfaz de usuario de los parámetros utilizados en el entrenamiento del HIM

Empleando el conjunto de 21 muestras (Tabla 6.1) como datos de partida (*data_micro_1.txt*), el modelo híbrido incremental correspondiente, queda ajustado de la siguiente forma: **orden del modelo, $m = 1$, número de vecinos, $k_n = 8$, coeficiente de borrosidad, $p = 2.712$** . Los resultados entregan, después de la aplicación del algoritmo unos resultados muy prometedores (Tabla 6.2).

Tabla 6.2. Criterios de error en la fase de entrenamiento de HIM

Índices de desempeño	[%]
Suma de errores cuadráticos (SSE)	0.0000
Ruido en la suma de errores cuadráticos (SNSE)	0.3000
Error de predicción final (FPE)	0.3000
Varianza estimada de ruido (ENV)	0.5000
Error relativo medio (MRE)	0.2000
<i>Data points</i> con un error $\geq 10\%$	0.0000




Figura 6.9. Representación gráfica obtenida durante el aprendizaje y obtención del modelo HIM

Aunque con la configuración obtenida **el error fue prácticamente cero**, la aplicación de este algoritmo en tiempo real no es sencilla y se requiere una validación rigurosa, ya que estos resultados con HIM pueden no ser concluyentes como podrá verse más adelante en los resultados de la validación del sistema. La Figura 6.9 muestra los valores de la rugosidad superficial estimados cuando se introducen en el modelo obtenido los propios datos de la Tabla 6.1, empleados para calcularlo. Evidentemente, el resultado es que los valores reales y estimados coinciden casi al 100%.

6.4.2 Obtención del modelo por agrupamiento borroso GFCM

En segundo lugar, el algoritmo de modelado GIFP-FCM aplicado fue el desarrollado en la sección 3.4 del Capítulo 3. Como primer paso del proceso de obtención del modelo, se realiza el *clustering* de los datos experimentales para, posteriormente, iniciar el proceso de aprendizaje del modelo. Los resultados obtenidos fueron como consecuencia de utilizar una configuración de los parámetros como se lista en la Tabla 6.3.

Tabla 6.3. Configuración de los parámetros utilizada en el entrenamiento de GFCM.

Número de grupos	6
Umbral 1	2.0E-5
Índice de borrosidad	1.2
Parámetro α	0.9
Número de iteraciones 2	1000
Tasa de aprendizaje	0.056
Umbral 2	1.0E-4
Número de iteraciones 2	400

Los resultados obtenidos durante el aprendizaje del modelo se resumen en la Tabla 6.4:

Tabla 6.4. Criterios de error obtenidos en el aprendizaje de GFCM

Índices de desempeño	
Suma de errores cuadráticos (<i>SSE</i>)	16935.318293
Ruido en la suma de errores cuadráticos (<i>NSSE</i>)	20.080385
Error de predicción final (<i>FPE</i>)	36.144693
Varianza estimada de ruido (<i>ENV</i>)	56.25078
Error relativo medio (<i>MRE</i>) en %	9.071994
Suma normalizada de errores cuadráticos (<i>SNSE</i>) en %	190.511880
Error cuadrático medio (<i>MSE</i>) en %	15.764212

Es importante señalar que el error medio absoluto es de un 9% y por tanto, mucho más alto que el obtenido con HIM (0.2%). Se hace necesario validar el algoritmo en ensayos experimentales con otras condiciones de operación para comprobar su robustez y precisión. Estos resultados de validación finales que se desarrollan en las subsecciones 6.5.1 y 6.5.2 corroborarán la viabilidad o no de los predictores de la rugosidad superficial basados en HIM y GFCM.

A continuación, en la Figura 6.10 se presenta una gráfica del comportamiento de la predicción/estimación hecha por el modelo GFCM en el proceso de aprendizaje. Como se aprecia visualmente, el modelo GFCM sigue con bastante precisión el comportamiento de la rugosidad real medida mediante el perfilómetro.




Figura 6.10. Rugosidad superficial real (azul) frente a rugosidad estimada (rojo) basada en el modelo GFCM.

6.5 Evaluación de los modelos de estimación de la rugosidad superficial on-line

El primer paso en la validación fue aplicar el algoritmo desarrollado en la subsección 6.2.1 (modelo híbrido HIM) que estima la rugosidad superficial, utilizando dos entradas: el avance por diente normalizado con respecto al diámetro de la herramienta de corte y la señal de vibración normalizada con respecto al valor máximo en la sección de material considerada.

Una vez calculados ambos modelos de estimación de la rugosidad superficial, únicamente es necesario introducir datos de la velocidad cuadrática de avance por diente de la herramienta y datos o valores cuadráticos medios de vibración en el eje Z de la herramienta obtenidos en tiempo real durante un proceso de micromecanizado para obtener la rugosidad superficial instantánea en ese momento.

6.5.1 Validación del modelo de estimación en base al algoritmo HIM.

El funcionamiento adecuado del sistema en tiempo real es muy importante y, por lo tanto, una evaluación de la estrategia de modelado propuesta se convierte en una necesidad. Por razones de espacio, de entre todos los ajustes y evaluaciones posibles, la validación se realiza mediante 96 ejecuciones con datos no conocidos de antemano y que no han sido utilizados en la fase de entrenamiento.

Después del ajuste óptimo sobre la base del algoritmo de temple simulado, los mejores resultados se obtuvieron con un polinomio de orden primero, un vecino $k_n = 1$ y un coeficiente de borrosidad $p = 1,262833$. En la Figura 6.11 se muestran las diferentes iteraciones obtenidas debido a la optimización con todos los valores parciales y el resultado final obtenido




Figura 6.11. Aplicación del algoritmo de temple simulado a la optimización de los parámetros (m, k_n, p) de HIM.

Tabla 6.5. Criterios de error obtenidos en la validación de HIM

Índices de desempeño	
Suma de errores cuadráticos (SSE) en %	52912.438834
Ruido en la suma de errores cuadráticos (NSSE) en %	16.600772
Error de predicción final (FPE) en %	16.950262
Varianza estimada de ruido (ENV) en %	33.551033
Error relativo medio (MRE) en %	16.705646
Data points con error $\geq 10.00000\%$	51

Sin embargo, se hace necesario hacer una validación más exhaustiva que incluya 6 cifras de mérito cuyos resultados se resumen en la Tabla 6.5. Tal y como se observa el modelo estima bastante bien la rugosidad aunque el error relativo medio fuese de un (17%), valor muy superior al obtenido durante el aprendizaje y la obtención del modelo (0.2%). En la misma tabla aparecen otras cifras de mérito que son muy importantes, tales como, el número

de casos con un error superior al 10% (51 casos de 96 analizados), el error final de predicción (*FPE*) del 16.95%, la varianza estimada de ruido (*ENV*) de un 33.55% entre otros.

Asimismo, la Figura 6.12 representa la rugosidad superficial prevista y real en cada ejecución. El modelo predice adecuadamente la rugosidad superficial, a pesar que se observa un alto grado de dispersión entre los puntos correspondientes a los valores reales y estimados.




Figura 6.12. Representación gráfica obtenida durante la evaluación del modelo de HIM

6.5.2 Validación del modelo de estimación en base al algoritmo GFCM

Con el objetivo de validar de una forma más realista el modelo generado, se ha incluido también la evaluación de otra técnica como es GFCM y así, poder realizar un estudio comparativo con HIM. De este modo, no solo a partir de los criterios de error que se han utilizado, sino también de los resultados comparativos de aplicar técnicas en el estado del arte, permitirán obtener conclusiones verdaderamente útiles acerca de la funcionalidad del sistema. La configuración de parámetros utilizados para validar el modelo de rugosidad superficial son los mismos que se obtuvieron en el aprendizaje (ver Tabla 6.3).

Tabla 6.6. Criterios de error obtenidos en la validación de GFCM

Índices de desempeño	
Suma de errores cuadráticos (<i>SSE</i>)	193454.346331
Ruido en la suma de errores cuadráticos (<i>NSSE</i>)	31.742318
Error de predicción final (<i>FPE</i>)	35.974627
Varianza estimada de ruido (<i>ENV</i>)	67.716944
Error relativo medio (<i>MRE</i>) en %	15.084170
Suma de errores normalizados cuadráticos (<i>SNSE</i>) en %	1448.080358
Error cuadrático medio (<i>MSE</i>) en %	20.87557

De la misma forma a como se procedió con el modelo HIM, en este caso se hace necesario hacer una validación más exhaustiva del modelo GFCM que incluya 6 cifras de mérito cuyos resultados se resumen en la Tabla 6.6. Tal y como se observa **el modelo estima bastante bien la rugosidad con un error medio del 15%, menor que el obtenido con HIM, y comparable al obtenido durante el aprendizaje y la obtención del modelo actual (9%).**

Además, en la tabla anterior aparecen otras cifras de mérito que son muy importantes, tales como, el número de casos con un error superior al 10% (40 casos de 100 analizados), el error final de predicción (*FPE*) del 35%, la varianza estimada de ruido (*ENV*) de un 67% entre otros.

Finalmente, la Figura 6.13 representa la rugosidad superficial prevista y real en cada ejecución. El modelo predice adecuadamente la rugosidad superficial, a pesar que se observa un alto grado de dispersión entre los puntos correspondientes a los valores reales y estimados.




Figura 6.13. Vista ampliada de la respuesta del modelo GFCM con respecto a la rugosidad real medida con el perfilómetro.

6.5.3 Estudio comparativo

Como último paso de la evaluación de los modelos, en la Tabla 6.7 se muestran de forma resumida los errores que se han obtenido en la validación de HIM y GFCM. Tal y como se observa, ambos modelos predicen con buena precisión la rugosidad superficial, teniendo en cuenta la naturaleza (ensayos industriales) del estudio realizado. El modelo HIM presenta un error relativo medio de un 16.71%, algo mayor que el obtenido con GFCM que es de un 15.08%. En cambio, si se presta especial atención al error de predicción final, las tornas

cambian. En este caso, es el modelo HIM (16.95%) quien presenta un error menor respecto a GFCM (35.97%).

Tabla 6.7. Resultados comparativos de ambos modelos, HIM y GFCM

Índices de desempeño	HIM	GFCM
Suma de errores cuadráticos (<i>SSE</i>)	52912.44	193454.35
Ruido en la suma de errores cuadráticos (<i>NSSE</i>)	16.60	31.74
Error de predicción final (<i>FPE</i>)	16.95	35.97
Varianza estimada de ruido (<i>ENV</i>)	33.55	67.72
Error relativo medio (<i>MRE</i>) en %	16.71	15.08

La comparación de los criterios de error anteriores no nos permiten dilucidar cual modelo presenta mejores prestaciones, con el objetivo de tomar la decisión sobre cuál de ellos será el elegido para su implementación embebida y posterior incorporación a la plataforma software. Por tanto, **se decide implementar ambos modelos, pero es GFCM el que presenta unas mejores prestaciones para un funcionamiento eficiente y adecuado en tiempo real, debido a su mayor facilidad de implementación e integración en la plataforma, para un funcionamiento eficiente y adecuado en tiempo real. Esta es la principal razón que nos ha llevado a embeber el modelo de GFC en la plataforma.** A continuación se representa el comportamiento de este modelo al introducirle nuevas muestras como datos experimentales correspondientes a diferentes operaciones de microfresado.

La Figura 6.14.a muestra este ejemplo de predicción de la rugosidad superficial llevado a cabo en proceso. Se han representado los valores de rugosidad estimados y los reales, los cuales son medidos con posterioridad con un perfilómetro. Como se aprecia visualmente, el método de monitorización empleado sigue con bastante precisión el comportamiento de la rugosidad real en la mayoría de los casos. Para comprobarlo, la Figura 6.14.b representa el comportamiento del error en la estimación de la rugosidad de la Figura 6.14.a, **observándose que el error medio absoluto entre todas las pruebas realizadas es de un 10.9%.**

Existen algunos factores que pueden explicar esta notable diferencia, entre el valor de error obtenido en la fase de validación del modelo GFCM y el del ejemplo de predicción con nuevas muestras. Una de ellas, está relacionada con la sensibilidad del sensor de vibración que puede no ser suficiente para hacer frente a la escala nano-métrica de la rugosidad superficial. El segundo problema está relacionado con los experimentos realizados con diferentes condiciones de corte, y diferentes horarios de trabajo (ej., la influencia de la temperatura sobre la rugosidad superficial). Desde el punto de vista industrial, esta precisión es suficiente porque el cien por ciento de los componentes aeronáuticos debe ser verificado de todas formas. Por tanto, queda demostrado que el modelo GFCM puede estimar la rugosidad

superficial con suficiente exactitud y precisión para poder proporcionar recomendaciones inteligentes sobre la calidad del proceso de micromecanizado y a posteriori, poder realizarse nuevas medidas correctivas en el control de la calidad.

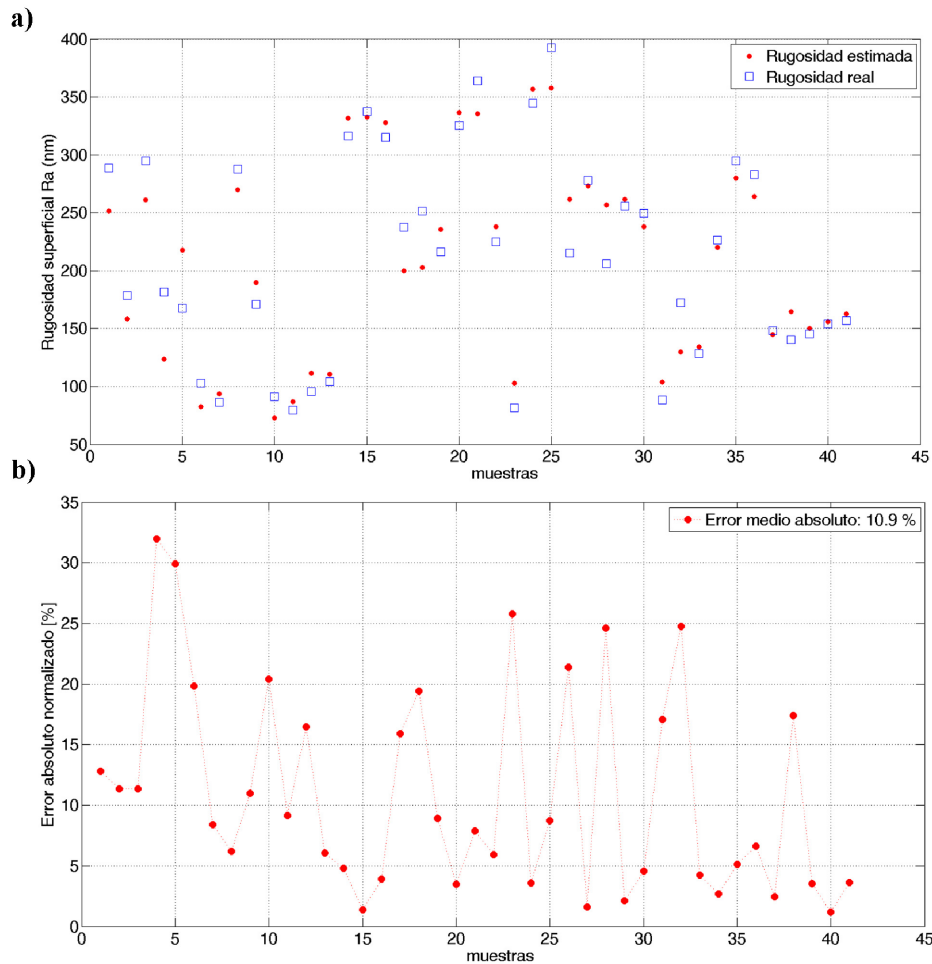


Figura 6.14. a) Comportamiento de la rugosidad real frente a la estimada (validación en proceso). b) Comportamiento del error en proceso durante las operaciones de microfresado.

6.6 Conclusiones

En este capítulo, a partir del análisis sistémico y de la determinación de la mínima cantidad de variables para estimar la **rugosidad superficial media absoluta (R_a)**, se han escogido dos variables de entrada: **el valor cuadrático del avance por diente (f_z)² normalizado con relación al radio de la herramienta (r)**, ambos expresados en nanómetros (nm), y **la vibración media cuadrática en el eje Z ($A_{c_{rms}}$) normalizada con relación a su valor máximo ($A_{c_{max}}$)** durante una ventana temporal, para modelar esta variable representativa del proceso de microfabricación.

Para tal fin, se han considerado dos ejemplos de algoritmos de modelado para la estimación de la rugosidad on-line en procesos de micromecanizado. Estos dos algoritmos constituyen una herramienta imprescindible para el modelado y están basadas en dos técnicas muy novedosas, a saber: **el modelado híbrido incremental (HIM)** y **el modelado por agrupamiento borroso generalizado (GFCM)**.

Estos modelos han sido evaluados experimentalmente por medio de cifras de mérito tales como la suma de errores cuadráticos (*SSE*), ruido en la suma de errores cuadráticos (*NSSE*), error de predicción final (*FPE*), error relativo medio (*MRE*), varianza estimada de ruido (*ENV*), entre otros. Tal y como se observa, ambos modelos predicen con bastante exactitud la rugosidad superficial. En cambio, el modelo HIM presenta un error medio de un 16.71%, algo mayor que el obtenido con GFCM que es de un 15.08 %. La comparación de estos criterios de error no han podido ser considerados una razón poderosa para decantarnos por uno u otro modelo a la hora de que uno de ellos sea el elegido para ser embebido en la plataforma. Por tanto, debido a que GFCM es el que ha presentado unas mejores prestaciones para un funcionamiento adecuado en tiempo real y nos ha resultado más fácil su implementación e integración, **se ha decidido que el modelo a embeber en la arquitectura de tiempo real sea GFCM**, cuya implementación se llevará a cabo en el siguiente capítulo.

Igualmente se han obtenido importantes conclusiones acerca de la utilidad del método desarrollado en esta Tesis doctoral como etapa previa a un método de fabricación industrial. Se han incluido, básicamente en este capítulo, los resultados de tareas parciales de validación y optimización final de la estimación de la rugosidad superficial en tiempo real, clave para el control de calidad on-line y la disminución del tiempo total para producir la primera pieza correctamente.

Los resultados descritos anteriormente han estado precedidos por una experimentación que ha abarcado cientos de ensayos en los que se ha establecido la rugosidad superficial y específicamente la R_a como el criterio de mayor importancia.

La contribución fundamental obtenida en este capítulo ha sido que a partir de la mínima información sensorial posible (señal de aceleración) y de la mínima cantidad de información sobre las condiciones de corte (avance por diente) se pueda estimar la rugosidad superficial on-line. Este resultado científico y técnico, supone un salto cualitativo importante sin precedentes en la investigación industrial en el campo de la microfabricación.

En el siguiente capítulo se presentará la plataforma de alto rendimiento en tiempo real, en red, modular y reconfigurable. Además se describirán todos y cada uno de sus módulos embebidos. Por último, se validará todo el sistema a nivel de laboratorio y en un proceso industrial real.

CAPÍTULO 7

ARQUITECTURA Y SISTEMA EMBEBIDO PARA SUPERVISIÓN DE PROCESOS

En este capítulo se describe la arquitectura de tiempo real, en red, modular y reconfigurable para la supervisión inteligente de procesos complejos, y específicamente del proceso de microfabricación ampliamente tratado en esta Tesis y de gran importancia científica por los retos que lleva asociado, pero también de gran repercusión económica y social. La arquitectura diseñada tiene la capacidad de aceptar diferentes módulos embebidos para cada una de las estrategias de supervisión que se deseen implementar. El diseño demuestra su modularidad mediante dos procedimientos de acondicionamiento de los diferentes módulos para su aplicación a todos y cada uno de los procesos industriales objetos de monitorización. En este capítulo, en concreto, el sistema de supervisión se aplica al proceso de microfresado de alta precisión. Específicamente, en esta Tesis Doctoral, a través de ambos procedimientos descritos en capítulos anteriores, se implementa un módulo de estimación de variables representativas del proceso de microfresado, como es la rugosidad superficial. Además, se implementa un algoritmo embebido de detección del estado del proceso de microfresado y de ayuda al proceso de toma de decisiones.

A continuación, se describen todos los elementos de la arquitectura desarrollados en el marco de esta Tesis doctoral (Figura 7.1). La distribución y organización de la arquitectura final ha tenido en cuenta los resultados y recomendaciones de los estudios, diseños, experimentaciones, y desarrollos llevados a cabo en todos los capítulos anteriores para un funcionamiento preciso, robusto, con baja carga computacional, alto tiempo de respuesta y eficiente de la misma.

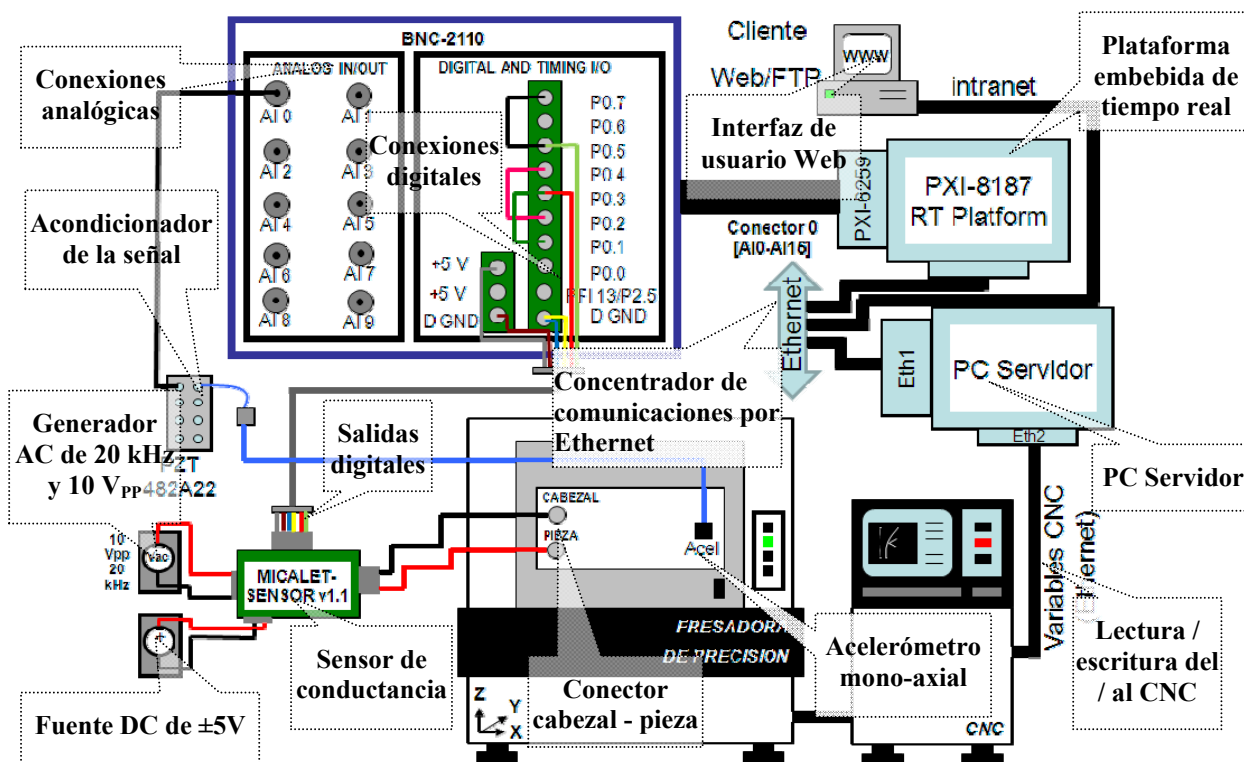


Figura 7.1. Diagrama de la arquitectura hardware del sistema de monitorización inteligente en tiempo real.

El capítulo se divide en siete secciones. La sección 7.1 presenta, a nivel *hardware*, la configuración de la arquitectura y cada uno de los elementos que la conforman: plataforma de tiempo real, sensores y sistema de adquisición, y el servidor de comunicaciones TCP/IP. A continuación, en la sección 7.2 se detallan cada uno de los componentes del sistema de monitorización a nivel *software*. Además, se muestra la interacción con el resto de elementos que conforman el sistema, como son: el programa principal de la aplicación de monitorización, la aplicación del servidor TCP, los sensores de vibración y conductividad, y el sistema de adquisición de señales.

Finalmente, en la siguiente sección 7.3 se valida todo el conjunto en la supervisión de procesos de micromecanizado, específicamente en operaciones de microfresado. Por tanto, se evalúa en el laboratorio el comportamiento en tiempo real del subsistema que estima la rugosidad superficial y el subsistema dedicado a la detección del estado del corte. Asimismo, en la sección 7.4 este sistema será aplicado y validado en la supervisión de un método de fabricación industrial de componentes aeroespaciales.

A modo de conclusiones, en la sección 7.5 se presenta un resumen de los resultados obtenidos en este capítulo.

7.1 Arquitectura hardware para el sistema inteligente embebido. Conexión al centro de micromecanizado.

La arquitectura hardware del sistema de monitorización está equipada con los siguientes dispositivos, tal y como se representa en la Figura 7.2:

- Un PC industrial conectado a la intranet de la máquina herramienta vía *Ethernet* es el encargado de ejecutar los programas de monitorización en tiempo real. Se trata de una plataforma comercial de última generación, a saber la **plataforma de *National Instrument* PXI-1050 con procesador PXI-8187**.
- Una **tarjeta de adquisición de datos PXI-6259** es la encargada de convertir las señales analógicas de los sensores en señales digitales.
- Esta tarjeta se conecta, mediante las entradas analógicas, con el **acondicionador de señales PZT482A22** que es el encargado de preparar las señales del **acelerómetro mono-axial modelo Bruel&Kjaer 4519-003**.
- El medio físico de unión de la salida de los alimentadores y adaptadores de los sensores; es mediante la **caja de conexiones BNC-2110**.
- Un centro de micromecanizado de alta precisión Kern EVO, que está equipado con un control numérico por computador (CNC) iTNC530 de Heidenhain
- Los dos sensores recomendados para cumplir con el criterio de mínima información sensorial posible: **el sensor de vibración para el eje Z (Capítulos 2 y 6)** y **el sensor de conductancia (Capítulos 4 y 5)**.

A continuación se detallan las especificaciones de los tres elementos principales *hardware* que conforman el sistema de monitorización. Por una parte, se detallan las especificaciones de la plataforma de tiempo real de *National Instruments*, incluyendo todos los módulos insertables que dispone. Por otra parte se describen los sensores principales recomendados, así como los sistemas de medición para la monitorización inteligente de las operaciones de micromecanizado. Además, asociado al sistema de adquisición se presenta el servidor de comunicaciones TCP/IP que obtiene las variables internas manejadas por el CNC y las pone a disposición de los clientes que quieran acceder a ellas.

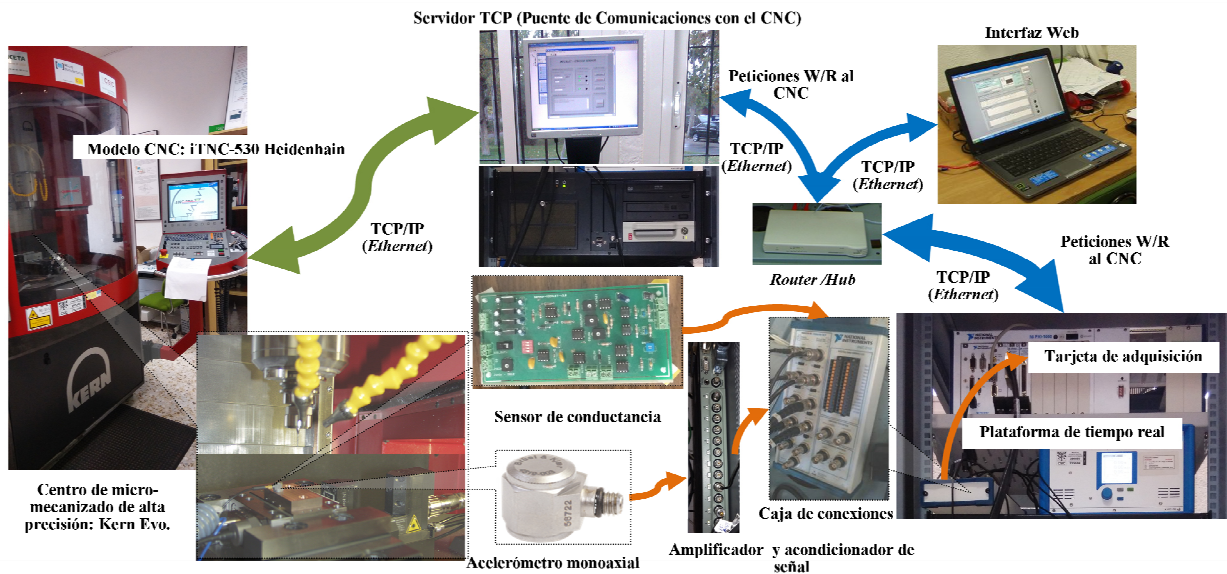


Figura 7.2. Visión global del sistema de monitorización inteligente de tiempo real desarrollado.

7.1.1 Plataforma NI PXI de tiempo real. Portabilidad y conectividad.

La plataforma PXI de *National Instrument*, está compuesta básicamente de tres componentes: el chasis, el controlador y los módulos periféricos. El chasis está provisto de un embalaje modular de gran dureza para el sistema. Este contiene el *backplane* PXI de alto rendimiento, el cual contiene el bus PCI y los buses para tareas de sincronización. Mediante el empleo de los buses de sincronización es posible desarrollar sistemas para aplicaciones que requieran un alto nivel de sincronismo. El controlador PXI-8187 se instala en una ranura específica del chasis para él (1ra ranura). Entre las posibles capacidades del controlador, se pueden destacar; la posibilidad de ser controlado remotamente desde un ordenador de mesa, una estación de trabajo, un servidor o un ordenador portátil; además de ser un controlador embebido de un rendimiento muy alto con un sistema operativo, ya sea *Windows 2000/XP* o un sistema operativo en tiempo real como *LabView Real-Time 8.1*, que es el empleado actualmente en esta Tesis doctoral para el desarrollo del sistema de monitorización inteligente.

En las ranuras disponibles para los módulos periféricos es posible instalar tarjetas para entradas y salidas analógicas, interfaces de comunicación, entradas y salidas digitales, de procesamiento de señales, para adquisición de imágenes, de control de movimiento, como fuentes de suministro, temporizadores, etc. Para tal fin, dispone de 7 ranuras para módulos PXI.



Figura 7.3. Vista general de la plataforma PXI y sus componentes principales.

En la Figura 7.3, se muestra la plataforma de adquisición PXI-1050 equipada con el procesador de tiempo real de *National Instrument* PXI-8187. Se trata de una **plataforma abierta** con **estructura modular**, basada en una arquitectura de ordenadores para la medición y el control. Tiene un gran ancho de banda y una latencia muy pequeña y además **admite varias tarjetas de entrada / salida** y comunicaciones tipo *Ethernet*. PXI son las siglas de *PCI eXtensions for Instrumentation*. El PXI-8187 no es más que un controlador de alto rendimiento con un procesador PENTIUM 4 *embedded*. Estas características le añaden una gran capacidad de **portabilidad y conectividad**.

7.1.2 Sensores y sistema de adquisición

En esta subsección se describen los dos sensores recomendados en los **Capítulos 2, 5 y 6** para la monitorización inteligente de operaciones de Microfabricación (acelerómetro mono-axial en el eje *Z* y el sensor inteligente de conductancia) y el sistema de adquisición de las señales de las variables físicas del proceso (tarjetas de adquisición y controlador embebido de tiempo real). En la Figura 7.4.a se describen detalles sobre la instalación física que se realizó, el sistema de medición, acondicionamiento y adquisición de señales; además de la disposición final de los componentes empleados. La conexión de los pines de la tarjeta PXI-6259 a las salidas digitales de la placa PCB del sensor de conductancia y al acondicionador de señal del acelerómetro (PZT482A22), se produce mediante la caja de conexiones BNC-2110 (ver también Figura 7.1).

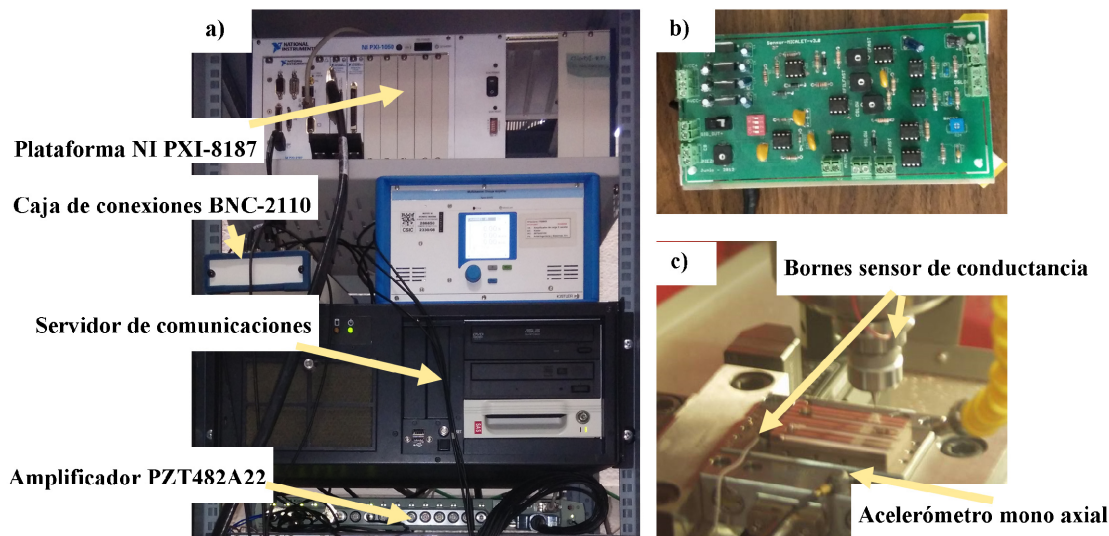


Figura 7.4. a) Detalle de la instalación del equipo de medida y acondicionamiento de señal. b) Detalle del sensor de conductancia; y c) bornes del sensor de conductancia (en cabezal y pieza) y acelerómetro.

La colocación de los sensores utilizados dentro del sistema de monitorización es de vital importancia para un correcto funcionamiento del resto de módulos que componen el sistema. En el caso del sensor de conductancia, los electrodos positivo y negativo están conectados a la parte estática del cabezal de la máquina (polo negativo o masa), y el polo positivo va unido a la pieza (ver Figura 7.4.c).

La adquisición de estas señales digitales (DIF y DIS) se realiza mediante la **detección** de los **flancos de subida** y de **bajada**, previniendo de esta forma una posible sobrecarga computacional del prototipo, debido a una monitorización continua con una frecuencia fija de muestreo en este hilo o bucle de ejecución. Por tanto, este ciclo “despertará” cada vez que exista un flanco positivo o negativo en las señales digitales. Este modo de adquisición no permite seguir muestreando las entradas digitales, mientras no se perciba un flanco de subida o bajada. Estas conexiones facilitaron la incorporación y adaptación al programa principal de los módulos de detección del estado del proceso y de rotura de la herramienta que fueron desarrollados previamente.

Las tareas de adquisición se configuraron en *Labview*, de tal forma que se detectan los flancos provenientes de las entradas digitales **P0.5**, **P0.3** y **P0.2** de la tarjeta de adquisición PXI-6259, con un **tiempo de espera máximo** para la detección de los flancos de **3 segundos** (ver plano general de conexiones en la Figura 7.1). Las dos primeras entradas están conectadas a las dos señales digitales que provee el sensor de conductancia. Además, para lograr un funcionamiento eficiente del hilo, estas dos señales están puenteadas a las entradas digitales **P0.7** y **P0.1**, respectivamente, y de esta forma se realiza una correcta adquisición.

Por último, la tercera entrada digital **P0.2** está conectada a la salida digital **P0.4**, la cual es utilizada durante los estados transitorios de la operación de corte. Durante estos estados, se

genera un tren de pulsos digitales con un periodo de **250 μ s** que se envía hacia la salida digital **P0.4**. Esto permite **determinar con precisión los cambios que se producen entre los diferentes estados de la operación de corte**.

En cambio, el acelerómetro *Bruel&Kjaer 4519-003* (Figura 7.4.c) se colocó sobre la pieza, existiendo entre la misma y el propio sensor un aislamiento eléctrico, aunque evitando que este aislamiento también fuese mecánico. Si así fuera, éste aislamiento amortiguaría las señales de vibración que se pretenden medir, alterando considerablemente la información útil extraíble de las mismas.

Tal y como se ha mencionado con anterioridad, se utilizó la tarjeta PXI-6259, la cual es una tarjeta de adquisición de datos multifunción de alta velocidad. Posee 4 salidas y 32 entradas analógicas de 16 bit de resolución, con una frecuencia de adquisición de hasta 2.8 MS/s; contando además con 48 E/S digitales y con contadores digitales de 32 bits. La situación de esta tarjeta dentro de las ranuras habilitadas en la plataforma PXI, se observa en la Figura 7.5.




Figura 7.5. Plataforma PXI instalada y los módulos adquisición que la componen.

7.1.3 Servidor de comunicaciones TCP/IP para peticiones de acceso R/W al CNC de la máquina.

Aunque la aplicación de comunicaciones TCP/IP no pueda ser considerada un sensor en sí misma, podría ser incluida en esta sección. En cierta medida, esto se debe a que forma parte del sistema de medición de las variables internas necesarias que proporciona la propia máquina herramienta (posiciones *X*, *Y*, *Z*, avance estimado, retraso entre dos accesos consecutivos, etc.) a través del control numérico por computador (CNC).

Para el acceso de lectura/escritura a las variables internas del CNC, se utilizó un PC en modo servidor. Se trata de un PC industrial KISS-4U-760 con un procesador Intel(R) Core(TM) 2 Quad CPU Q9400 de 2.66 - 2.67 GHz y sistema operativo *Windows XP* (ver Figura 7.4.a). Éste funciona como puente de comunicaciones o sistema intermediario entre la plataforma de tiempo real PXI-8187 y el propio control numérico. Con este fin, se desarrolló una aplicación en *LabVIEW 8.1* que interactúa con el cliente (plataforma NI-PXI), siguiendo un protocolo específico definido en esta Tesis doctoral. La inclusión de este servidor en la

arquitectura está motivada por cuestiones de software propietario y debido a las incompatibilidades que existen entre las bibliotecas suministradas por el fabricante del CNC y el sistema operativo de tiempo real de *National Instruments RT 8.1*.

Tabla 7.1. Protocolo diseñado para las comunicaciones TCP/IP (Cliente - Servidor).

Operación de lectura del CNC	
Cliente	Servidor
Ordena Leer <ul style="list-style-type: none"> • Escribir cadena: 'R'00 	Esperando ...
Espera ...	Lee por TCP/IP <ul style="list-style-type: none"> • Si 'R' → Lee del CNC • Escribe tamaño del arreglo (N) + Datos
Lee por TCP/IP <ul style="list-style-type: none"> • 1º: 2 bytes (valor N) • 2º: N bytes de datos 	-----
Operación de escritura en el CNC	
Cliente	Servidor
Escribir por TCP <ul style="list-style-type: none"> • Escribir cadena: 'W'+(N)+Valor 	Esperando ...
-----	Lee por TCP/IP <ul style="list-style-type: none"> • Si 'W' → Lee N (tamaño) bytes • Escribe en el CNC

Como parte del procedimiento, el cliente envía peticiones de lectura o escritura al PC servidor, y éste, a su vez, se las realiza al CNC. Posteriormente, será el propio CNC quien envíe una respuesta, a través del PC servidor, con la información solicitada previamente. La Figura 7.6 ilustra una sección del código que se desarrolló en *LabVIEW*, donde se encuentra el bucle de ejecución principal del programa servidor, que cumple con las especificaciones del protocolo definido en la Tabla 7.1.

Por una parte, está la función de lectura TCP/IP, 'R', que activa el proceso de obtención de los valores de las variables internas disponibles del CNC. A continuación, el servidor prepara un arreglo que incluya el tamaño de los datos leídos del CNC en número de bytes, *N*, más los propios datos convertidos a cadena de caracteres, y se lo envía al cliente.

Por otra parte, está la función de escritura TCP/IP. Ésta se activa cuando el servidor lee del puerto de comunicaciones el carácter 'W' (previamente enviada desde el cliente). Después, el

servidor decodifica la cadena para obtener la orden de escritura que se enviará al control numérico de la máquina.

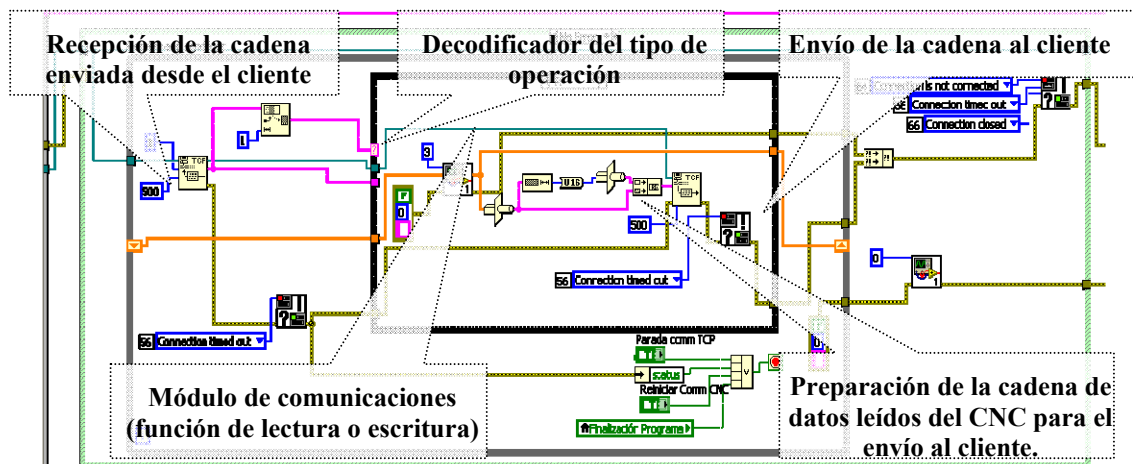


Figura 7.6. Sección del código correspondiente al programa principal del servidor TCP/IP.

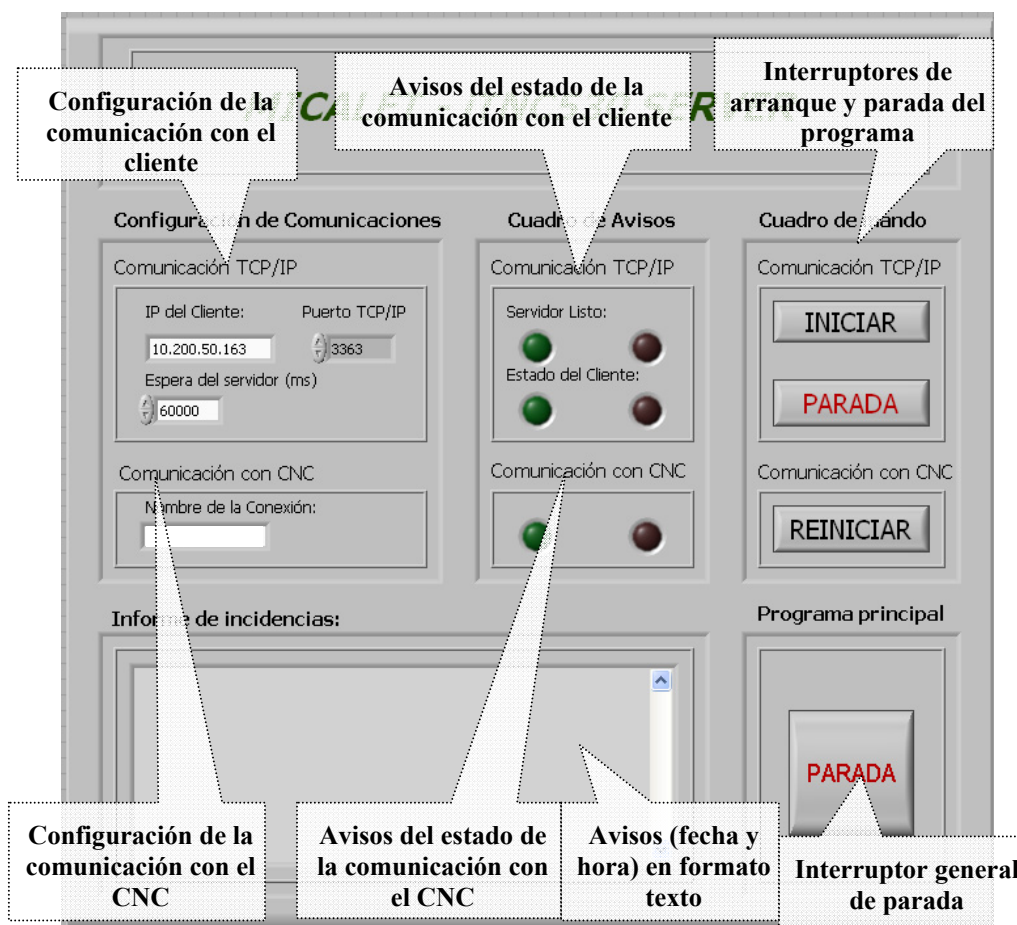


Figura 7.7. Interfaz de usuario del servidor de datos del CNC.

Cabe destacar que el módulo de comunicaciones es independiente del protocolo específico de comunicación con el CNC utilizado y simplemente maneja las funciones básicas de lectura y escritura de datos, accediendo a las librerías que suministre el fabricante del control numérico.

Esta aplicación que hace de servidor de comunicaciones entre el cliente y el CNC de la máquina puede configurarse como un servicio que arranque junto al sistema operativo. A pesar de ello, se desarrolló un panel frontal que hace de interfaz hombre máquina entre el CNC y el operario, con el objetivo de poder identificar posibles problemas de tráfico de datos en la red, alertas, avisos, pérdida de señales, etc. En la Figura 7.7, se representa una captura de esta interfaz de usuario.

7.2 Implementación software del sistema embebido para monitorización inteligente

Para la realización del sistema, se ha desarrollado una aplicación mediante el entorno gráfico *LabVIEW*® y en lenguaje *C* de alto nivel. En el entorno gráfico se ha implementado el programa principal, que incluye: la interfaz de usuario, la captura de la señales provenientes de los sensores a través de la tarjeta de adquisición PXI-6259, el procesamiento de estos datos para alimentar los módulos de toma de decisiones y estimación, y demás tareas asociadas. Los módulos para la toma de decisiones sobre el estado del proceso y para la estimación de la rugosidad superficial, han sido desarrollados en lenguaje *C* (ver descripción en la subsección 7.3.3).

El programa principal fue organizado en una estructura apilada en marcos (*frames*). Cada marco contiene un grupo funcional de acciones, y los marcos se ejecutan sucesivamente en un orden predefinido. Tras la última ejecución, el sistema vuelve a la primera. De esta forma, la aplicación se ejecuta de forma continua, permitiendo monitorizar largas operaciones de micromecanizado. Según el flujo de datos del programa principal (ver Figura 7.8), se realizan las siguientes operaciones:

- Inicialmente, el sistema procesa un **archivo de configuración “*inicia.ini*”** que contiene: valores de referencia de la operación de corte, información del sistema de adquisición y parámetros de funcionamiento de los algoritmos de monitorización, entre otros.
- Seguidamente, el usuario puede inspeccionar y cambiar algunos de los parámetros de la monitorización, como su duración máxima, nombre asignado a la operación de corte a realizar, etc.
- A continuación, el programa configura las tareas de adquisición de las señales provenientes de los sensores: reserva de memoria para intercambiar información entre

las diversas partes del sistema, inicialización de los módulos y las variables necesarias y, por último, espera la orden del usuario para comenzar la monitorización del proceso.

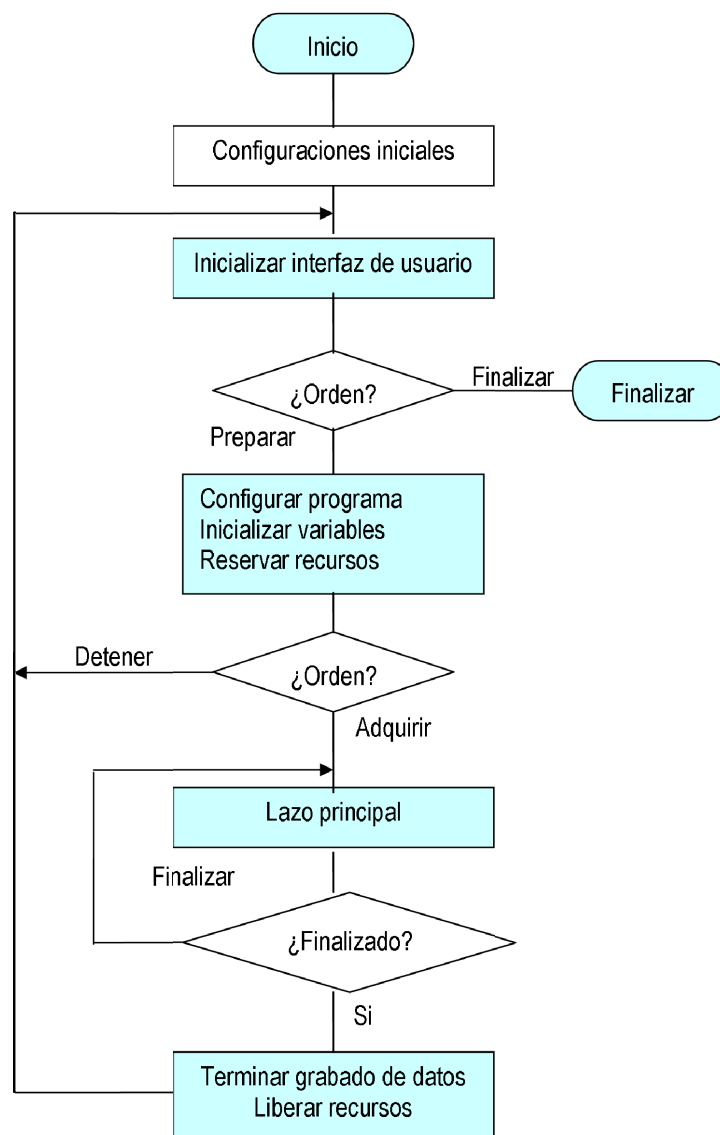


Figura 7.8. Diagrama de flujos del programa principal del sistema de monitorización.

El núcleo principal de funcionamiento del programa consiste en una serie de bucles o hilos de ejecución que se ejecutan en paralelo. Cada bucle realiza una función distinta, con una frecuencia de reloj asociada acorde con las operaciones que realiza. La información entre bucles se transmite mediante pilas FIFO (*First In First Out*, primero en entrar, primero en salir). Esta tecnología de transferencia de datos entre hilos de ejecución, permite acceder dentro de un bucle a la información generada en otro, sin pérdida de información y de forma determinista.

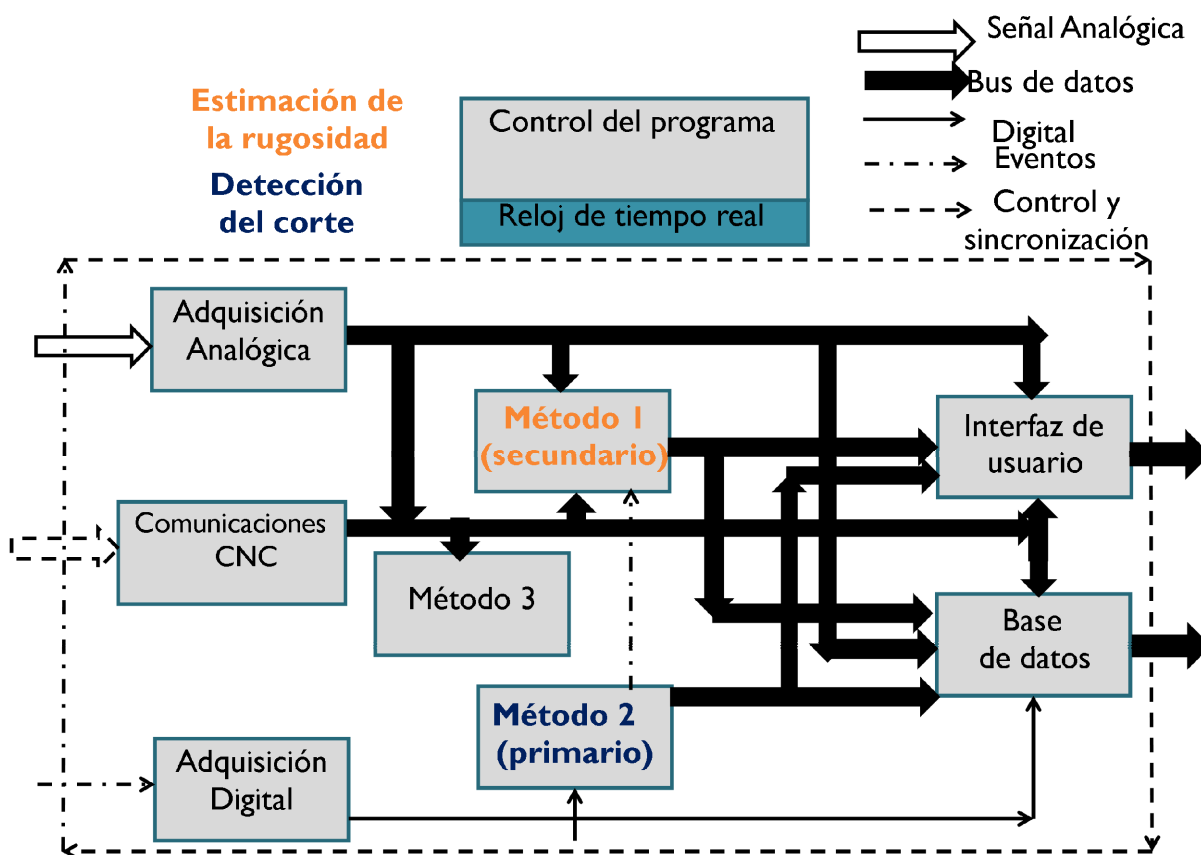


Figura 7.9. Hilos de ejecución en paralelo del lazo principal

En la Figura 7.9 se muestra la tarea principal de monitorización, el cual constituye el núcleo principal de funcionamiento del programa y consiste en una serie de bucles o hilos de ejecución en paralelo. Los diferentes hilos están interconectados, ya sea, mediante buses de datos, señales digitales, eventos y señales de control y sincronización. Existe un hilo encargado del control de programa y sincronización del resto de hilos, el cual incluye el reloj de tiempo real. En la parte izquierda, nos encontramos con los hilos de entrada que realizan la adquisición y captura de datos, tanto de las señales digitales como analógicas. En la parte central, nos encontramos con los métodos, los cuales en algunos casos su activación puede depender de un evento enviado desde otro método. En el caso particular desarrollado en esta Tesis, los métodos que están embebidos en la plataforma software son el de estimación de la rugosidad superficial y el de detección del corte. Por último, en la parte final del diagrama están los hilos de salida, interfaz de usuario y base de datos, que de alguna u otra manera presentan la información al usuario.

Tabla 7.2. Cuadro de tiempos de los hilos de ejecución

Hilo de ejecución	No. Prioridad	Tiempo de ciclo (x=50 μ s)
Detección del estado del corte	1500	5x
Lectura señales vibración	100	100x
Estimación de la rugosidad	100	1000x
Refresco de pantalla	50	10000x
Almacenar en disco	25	1000x
Finalizar monitorización	100	20000x
Comunicación con servidor CNC	100	300x

En la Tabla 7.2 se relacionan los distintos hilos de ejecución del programa principal. Se detalla su prioridad relativa, así como el tiempo de ejecución del ciclo. La prioridad la utiliza el sistema operativo cuando hay conflictos, para decidir qué hilo se ejecuta primero y cual queda en espera de continuar su ejecución. Los tiempos de ciclo están referidos a una base de tiempos global. En el prototipo esa **base de tiempos es de 50 microsegundos** y por tanto, los tiempos de la tabla son múltiplos de esta base de tiempos. A continuación se relacionan los hilos de ejecución del programa principal:

- **Bucle de adquisición y procesamiento de las señales digitales provenientes del sensor de conductancia.** Se capturan y procesan con el objetivo de alimentar a los módulos de detección del corte y rotura de la herramienta. La información obtenida se transmite a las pilas correspondientes para su uso en otros lazos. El reloj de este lazo es el de mayor frecuencia, ya que debe procesar la información proveniente del sensor a gran velocidad para la detección en tiempo real del estado del corte.
- **Bucle de adquisición de las señales analógicas provenientes de los sensores del proceso.** Este lazo se ejecuta a una velocidad sincronizada con la frecuencia de muestreo y el tamaño de los paquetes, ambos **configurados en el archivo “config.ini”**. Este bucle se encarga de poner en las pilas correspondientes la información proveniente de la tarjeta de adquisición.
- **Ciclo de procesamiento de las señales analógicas:** Esta señal va a la entrada del modelo de predicción de la rugosidad superficial. La medición recibida de la señal de vibración se filtra, se calcula la media y el máximo valor absoluto de una ventana de datos, y esos valores son enviados al módulo de predicción de rugosidad.
- **Ciclo de actualización de datos en la interfaz de usuario:** Esta actualización se realiza pocas veces por segundo al ser un proceso lento y no necesitarse actualizaciones a velocidades mayores. No se trata de información crítica, sino solamente de información que se muestra al usuario.

- **Ciclo para almacenamiento en disco de la información de los sensores, las entradas y salidas del modelo:** Dado que el acceso a disco es un proceso costoso computacionalmente, este ciclo se realiza a baja frecuencia y se van almacenando unos pocos datos cada vez que se le asigna tiempo de ejecución. Cuando el proceso finalice, se guardarán todos los datos todavía no almacenados.
- **Bucle de control del tiempo máximo para monitorizar las operaciones de corte:** Un simple ciclo controla, una vez por segundo, si el tiempo máximo de monitorización ha transcurrido, o si el usuario ha ordenado detener el programa. En ambos casos, este ciclo envía la orden de parar a todos los demás ciclos.

El sistema de monitorización incorpora una funcionalidad más, que consiste en la adquisición, ilustración y almacenamiento de información sobre la posición de los ejes de la máquina para cada estado de la operación de corte. Este módulo necesita un servidor en red conectado a la máquina. La disponibilidad de esta opción depende del CNC de la máquina a la que esté conectado el sistema, y la existencia de una biblioteca con instrucciones de acceso de E/S que haga de interfaz para la comunicación con dicho CNC.

Una vez terminada la monitorización de la operación de corte, la siguiente etapa del programa se encarga de almacenar en disco la información que permanece en las pilas FIFO. Se almacena, además, en un archivo de salida el informe de incidencias y la configuración previa. Finalmente, libera los recursos que ya no son necesarios, y vuelve a la etapa inicial, esperando una nueva orden del usuario.

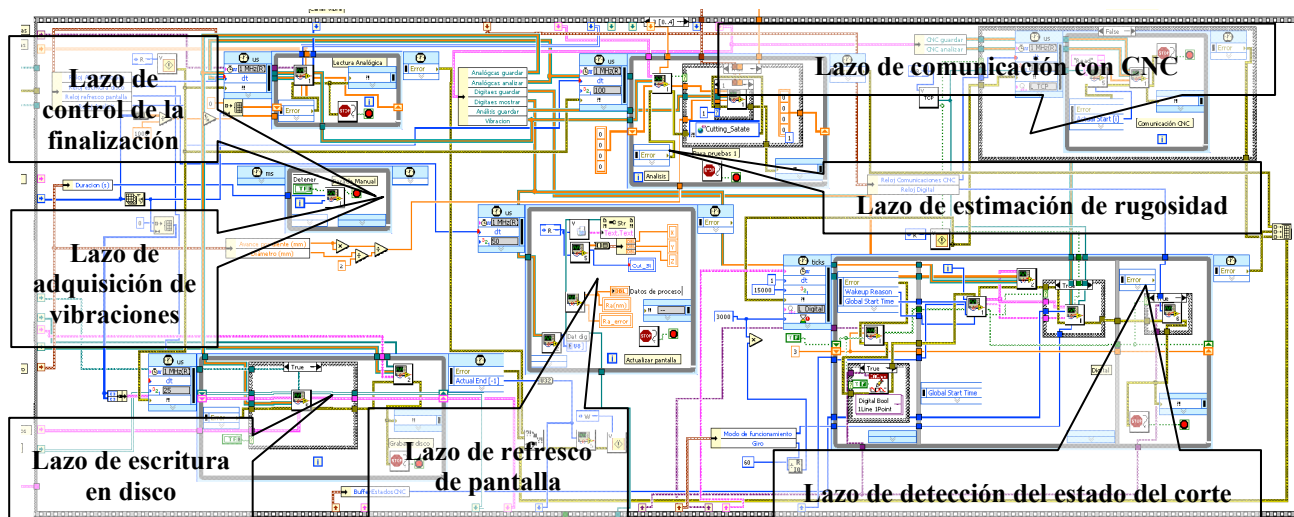


Figura 7.10. Sección del código en Labview del núcleo principal de la aplicación.

7.2.1 Procesamiento de las señales de vibración

La tarjeta PXI-6259 almacena temporalmente los datos recibidos en un buffer hardware. El ciclo mostrado lee los datos de dicho buffer y les aplica la ganancia de los sensores, para convertir los datos de tensión (en voltios) a datos en m/s^2 . Posteriormente, transfiere la información a dos pilas FIFO, poniéndolos a disposición de otros hilos del programa. Una de las pilas de datos va hacia el hilo de ejecución en el que se ejecuta el módulo de estimación de la rugosidad. La otra es empleada para almacenar los datos adquiridos en bruto en el disco duro. En la Figura 7.11 se muestra el diagrama de la sección de la aplicación que se desarrolló dedicada a la adquisición de las señales de vibración.

Por otro lado, en la Figura 7.12 se muestra la parte del programa que se encarga de procesar los datos de vibración provenientes del bucle descrito anteriormente. La señal de vibración se filtra mediante un **filtro de respuesta a impulso infinita (IIR) de Butterworth, pasa-banda de orden 6 y cuyas frecuencias de corte son 100 y 20 kHz**. Los coeficientes del filtro se calculan en la etapa de configuración inicial de la aplicación y se almacenan en memoria.

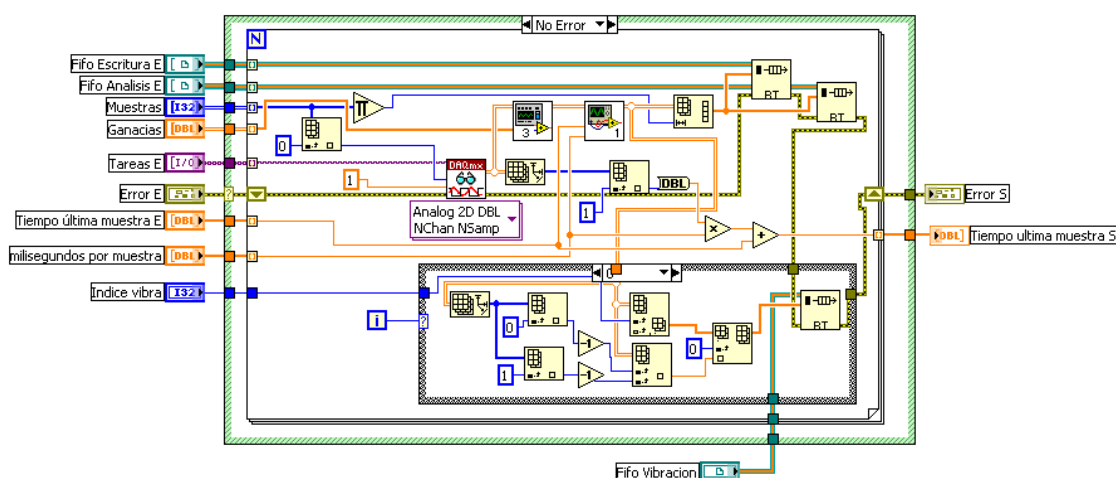


Figura 7.11. Código desarrollado para la adquisición de señales analógicas.

Por un lado, del intervalo de datos analizados de la señal filtrada se obtiene el **valor máximo absoluto** y por otro, se obtiene el **valor cuadrático medio (*rms*)**. Este intervalo se elige en **función de la velocidad de giro del cabezal**. En este caso, **el número de muestras del intervalo es el correspondiente a 10 vueltas del cabezal**. Este parámetro, así como los del filtro, son modificables en el **archivo de inicialización, "inicia.ini"**. Para normalizar el valor *rms* del intervalo, éste se divide entre el máximo (en valor absoluto). El cociente resultante es **una de las entradas del módulo de estimación de la rugosidad**.

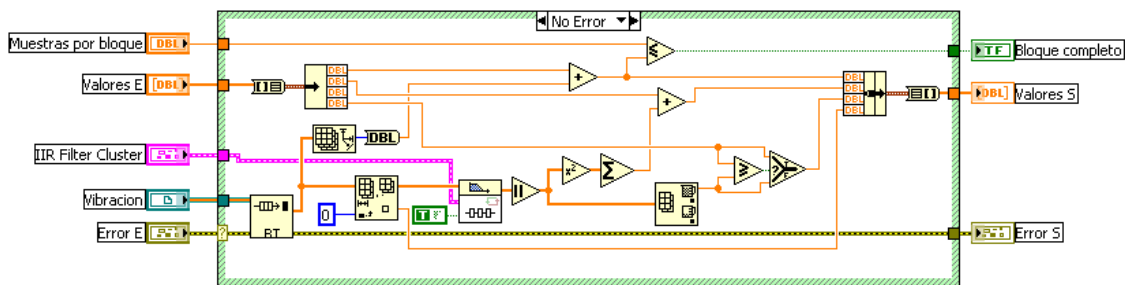


Figura 7.12. Filtrado de señal de vibración: filtro IIR de Butterworth, pasa-banda, orden 6 y frecuencias de corte de 100 Hz a 20 kHz.

7.2.2 Cliente de comunicaciones TCP/IP para peticiones W/R con el PC servidor

En la sección 7.2.3 se ha realizado la descripción de una aplicación desarrollada en un PC industrial que actúa como servidor de comunicaciones TCP/IP entre un cliente y el CNC de la máquina-herramienta. A continuación, lo que se describe, es precisamente este proceso de comunicación pero desde el punto de vista del cliente que fue también diseñado acorde al protocolo listado en la Tabla 7.1. De esta tabla, se extrae que el cliente cuando desee realizar una petición de lectura, debe ordenársela al servidor mediante la generación de una cadena, 'R'00. Seguidamente queda en espera hasta que tiene en su puerto de comunicaciones la respuesta del servidor en forma de datos. Estos datos tienen que ser decodificados para su interpretación.

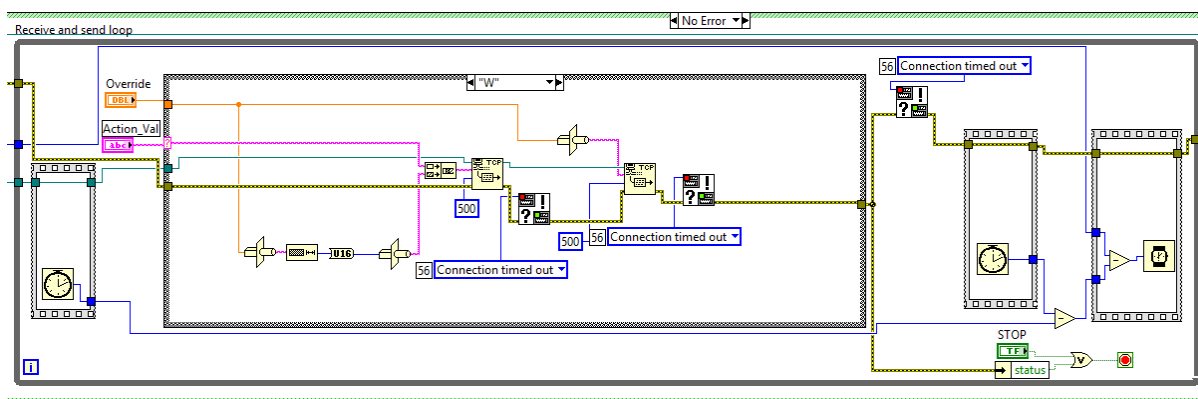


Figura 7.13. Sección del código implementado correspondiente al programa principal (bucle de ejecución continua).

Por otro lado, si lo que se pretende es una escritura, el cliente debe ordenársela al servidor, mediante la formación de una cadena del tipo 'W'+ tamaño del dato + dato. Este ejemplo es el que se ilustra en la Figura 7.13.

Cabe resaltar que el cliente, en el proceso de inicialización general del programa general, se conecta al servidor y permanece conectado hasta la finalización total de la ejecución del programa. En caso de pérdida de las comunicaciones, automáticamente intentará su restablecimiento.

7.2.3 Descripción de los módulos embebidos del sistema inteligente

Los algoritmos para monitorizar las operaciones de corte, la detección de roturas y predicción de la rugosidad superficial, introducidos con anterioridad en los **Capítulos 5 y 6**, han sido desarrollados en lenguaje *C* y también en *Labview*. Su implementación computacional eficiente permite embeber los modelos estimativos y el sistema de toma de decisiones en la arquitectura de tiempo real, convirtiéndola, además, en un **sistema embebido de supervisión inteligente de tiempo real de operaciones de micromecanizado**.

Las funciones que implementan los algoritmos inteligentes han sido encapsuladas en bibliotecas de vínculos dinámicos (DLL, *Dynamic Link Libraries*). En la Tabla 7.3 se describen, de forma resumida, las funciones desarrolladas y embebidas en el sistema de monitorización.

Tabla 7.3. Listado de funciones que componen las bibliotecas definidas para los dos módulos embebidos.

Biblioteca DLL	Función	Descripción
GFCM_dll.dll	<i>EvaluatePoint</i>	Función que calcula la salida del modelo, a partir de un conjunto de datos de entrada.
	<i>LoadTrainData</i>	Función que carga en una estructura de datos, los parámetros del modelo de rugosidad entrenado mediante el algoritmo GFCM.
	<i>GetLastError</i>	En caso de que se produzca algún error durante la ejecución de la funciones <i>EvaluatePoint</i> y <i>LoadTrainData</i> , la llamada a esta función devuelve un mensaje con detalles sobre el error producido.
	<i>DestroyData</i>	Limpia la memoria de datos reservada durante la llamada a la función <i>LoadTrainData</i> .
control_rt_dll.dll	<i>DetCutMonitor</i>	Función para monitorizar operaciones de microfresado. Detección de los estados del proceso de corte a partir de entradas digitales y detectar roturas de la herramienta de corte.
	<i>InitVars</i>	Función para ajustar los parámetros necesarios para el funcionamiento del algoritmo, antes de su ejecución.

A) Módulo para la monitorización del corte y detección de roturas en el proceso de micromecanizado.

La monitorización de los estados del proceso de corte y detección de roturas de la herramienta, constituye uno de los hilos de ejecución del sistema de monitorización (ver Figura 7.10). Conocidos los requisitos de alta precisión en la monitorización de las operaciones de corte, esta tarea se configura para que posea la mayor prioridad dentro de todo el sistema (ver subsección 7.1.2).

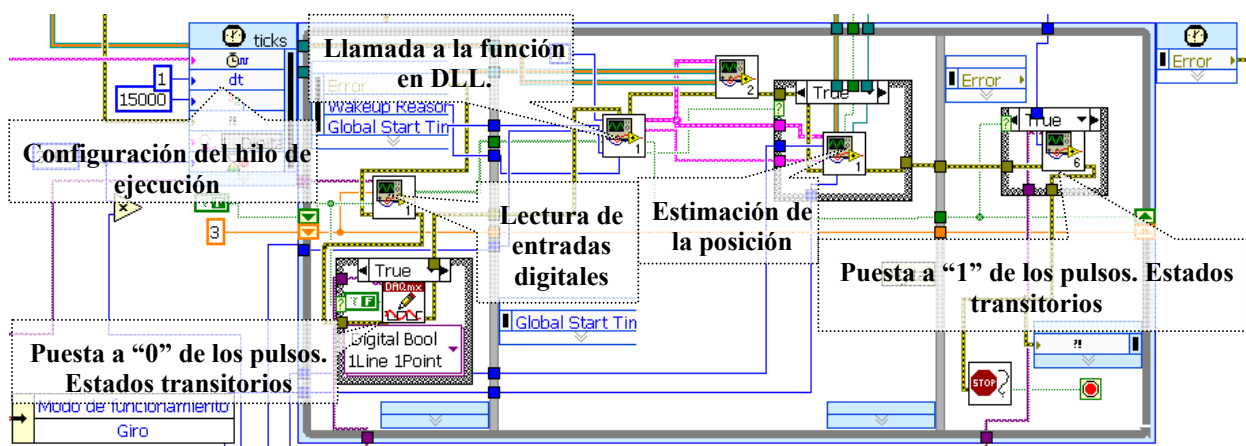


Figura 7.14. Bucle de adquisición, procesamiento de las señales digitales provenientes del sensor de conductancia, monitorización del estado del corte y detección de roturas.

Asimismo, esto permite **determinar con precisión los cambios que se producen entre los diferentes estados de la operación de corte**. En la Figura 7.14 se muestra el código desarrollado en *Labview*, en el que se implementa el hilo de ejecución para la monitorización de los estados del corte y detección de roturas. Dentro de él, se encuentra la subrutina donde se implementa la llamada a la función “*DetCutMonitor*”, que se encuentra encapsulada dentro de la biblioteca de vínculos dinámicos “*control_rt_dll.dll*”.

Según la arquitectura propuesta y debido a que es posible acceder a las variables internas del controlador numérico (CNC) de la máquina herramienta, el algoritmo implementado en *Labview* ofrece la posibilidad de estimar la posición en que se producen los cambios de estado de las operaciones de corte. Esto permite, por ejemplo, conocer con precisión dónde se produce el contacto herramienta-pieza o la rotura de la herramienta.

La estimación de la posición para cada estado, $[x, y, z]_k$, se calcula mediante una extrapolación a partir del instante de tiempo en que se produce el cambio de estado (T_k) y la información de la posición que se obtiene del CNC en n instantes de tiempo anteriores, es decir:

$$\begin{aligned}
 [x \ y \ z]_k &= \frac{\Delta[x \ y \ z]_k}{\Delta T_k} (T_k - T_{k-1}) + [x \ y \ z]_{k-1} \\
 \Delta[x \ y \ z]_k &= \frac{1}{n} \sum_{i=k-n-1}^{k-1} ([x \ y \ z]_i - [x \ y \ z]_{i-1}) \\
 \Delta T_k &= \frac{1}{n} \sum_{i=k-n-1}^{k-1} (T_i - T_{i-1})
 \end{aligned}
 \tag{7.1}$$

Como parte de la monitorización del estado del proceso de corte, se desarrolló también una función de *Labview* que realiza el cálculo de la media de los valores diferenciales del vector de posición, $\Delta[x, y, z]_k$, y de sus instantes de tiempo correspondientes, ΔT_k . A partir de esta información ($[x, y, z]_{k-1}$) y del valor anterior de posición leída del CNC, T_{k-1} , se implementó otra función que realiza la extrapolación lineal para obtener el valor actual de posición.

B) Módulo para la predicción de la rugosidad superficial.

Otro de los bucles o hilos de ejecución que compone el sistema de monitorización, es el módulo para la predicción de la rugosidad superficial en operaciones de microfresado. Durante este bucle, se calculan las entradas definidas para el modelo de rugosidad (ver **Capítulo 6**) y se realiza la llamada a la función embebida en la biblioteca DLL *GFCM_dll.dll*. Los parámetros del modelo son previamente cargados, antes del comienzo de la monitorización de las operaciones de corte mediante la función “*LoadTrainData*”.

En la Figura 7.15 puede observarse la sección del código en *Labview* en el que hace la llamada a la función embebida “*EvaluatePoint*” para la estimación de la rugosidad superficial. Cabe denotar que la estimación de la rugosidad solo se realiza durante el estado **CORTANDO**, determinado por el algoritmo de monitorización de los estados de la operación de corte. De esta forma se garantiza que **la estimación del modelo se realiza solamente durante el contacto herramienta-pieza**.

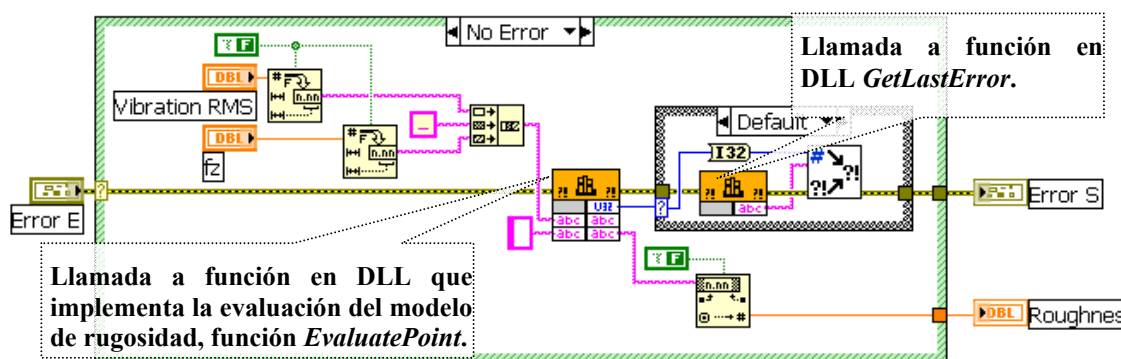


Figura 7.15. Sección del código en *Labview* donde se incrusta la llamada a la función de estimación de la rugosidad superficial. Llamada a la función “*EvaluatePoint*” en DLL.

A partir del valor estimado por el modelo de rugosidad, se calcula el error en la estimación según el error porcentual medio obtenido durante el entrenamiento del modelo de rugosidad. Este dato forma parte de la configuración del prototipo de monitorización. Tanto el valor estimado, como el error en la estimación se muestran en la interfaz de usuario del sistema y se almacenan en disco por si fuese necesario un posterior análisis.

7.2.4 Interfaz hombre-máquina o usuario. Descripción del funcionamiento.

En esta subsección se realiza una descripción de la interfaz gráfica de usuario del prototipo del sistema de monitorización inteligente desarrollado. Por una parte se describen los parámetros de entrada a la aplicación que el usuario debe introducir, para obtener unos resultados satisfactorios; y, por otra parte, la visualización de los resultados de la aplicación provenientes de los módulos de adquisición, monitorización del estado del proceso de corte y detección de roturas, y del algoritmo de estimación de la rugosidad superficial.

La aplicación es una interfaz web que está embebida en la plataforma PXI de alto rendimiento, permitiendo, de esta forma, que se pueda monitorizar el estado de las operaciones de corte, desde cualquier punto de acceso a la intranet de la planta de fabricación.

A. Parámetros del usuario.

La aplicación desarrollada para el prototipo tiene una serie de opciones de configuración. Todas estas opciones están en un archivo de texto llamado “*micalet.ini*” que el programa lee durante la etapa de configuración inicial. En este archivo se almacenan los siguientes datos:

- Datos de configuración del sistema de adquisición de las señales analógicas, como son la frecuencia de muestreo y la ganancia de los sensores de vibración.
- Parámetros de configuración de los modelos.
- Frecuencias de los relojes internos del sistema.
- Dimensiones de las pilas FIFO a emplear.
- Parámetros de la monitorización que dependen de las condiciones del proceso.

Estos parámetros asociados con el proceso se muestran por pantalla en la interfaz de usuario (ver Figura 7.16). El usuario puede entonces modificar los valores que desee, antes de poner en marcha el sistema de monitorización. Además la interfaz de usuario está conformada, para su correcto funcionamiento, por una serie de indicadores y controles.

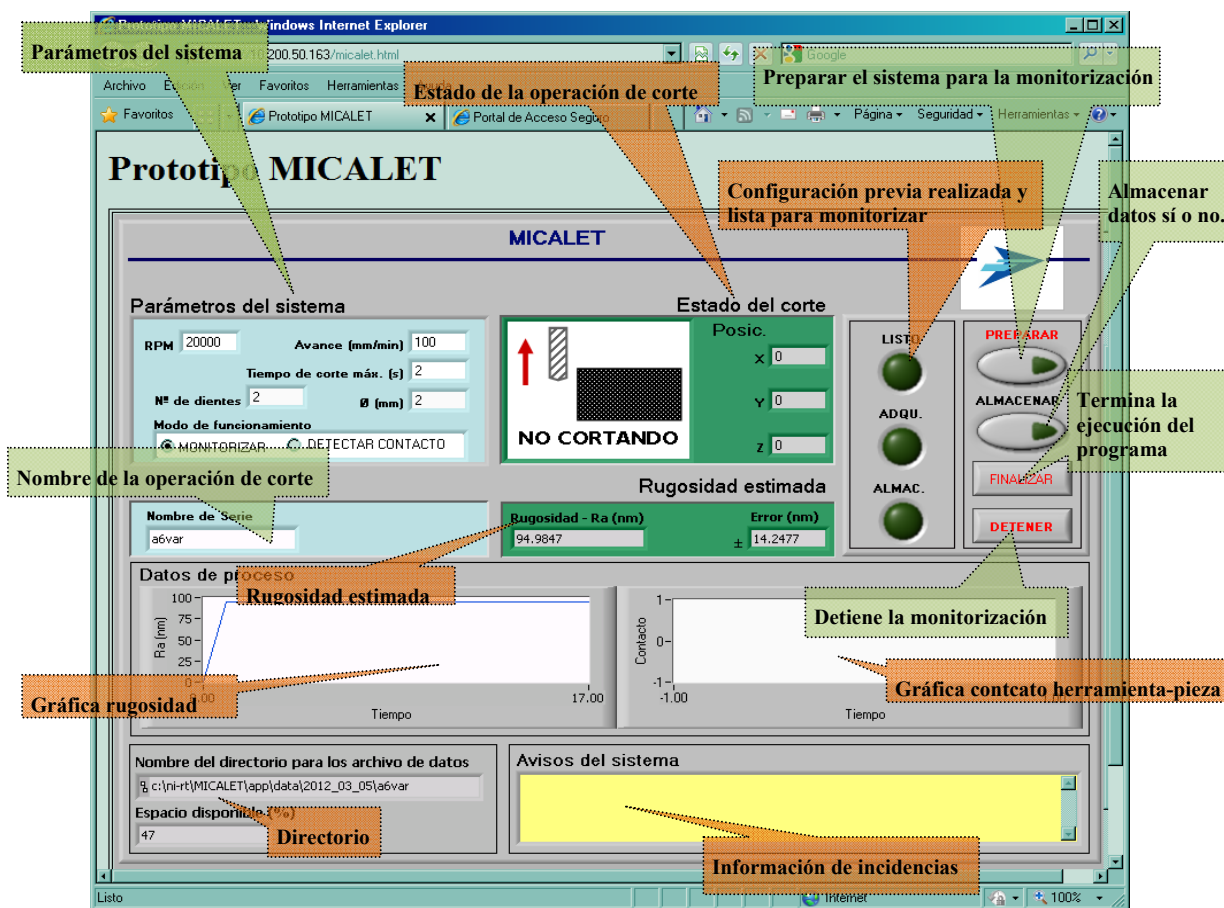


Figura 7.16. Interfaz de usuario del prototipo desarrollado.

Varios de estos campos que son modificables por el usuario en la interfaz, inicialmente pueden contener valores que son leídos de un archivo de configuración de inicialización de todo el sistema. El archivo de configuración “*inicia.ini*” contiene toda la información de configuración necesaria para el funcionamiento del programa. Es un archivo de texto plano, modificable con un editor de textos. En caso de modificar valores, se debe respetar la estructura interna de dicho archivo.

B. Visualización y salida gráfica del programa.

La pantalla de la interfaz de usuario muestra, en indicadores, una serie de información sobre el proceso y las salidas de los módulos de monitorización. Esta información se va actualizando continuamente, según el parámetro de tiempo ajustado para el bucle de refresco (actualmente 0.5 segundos). A continuación se describen los indicadores de la interfaz gráfica de usuario:

Tabla 7.4. Archivos de informe y almacenamiento de salida del sistema de monitorización.

Nombre de archivo	Descripción
<i>Info.txt</i>	Informe sobre la operación de corte monitorizada
<i>Digital.txt</i>	Almacena las entradas y salidas, durante toda la operación de corte, del módulo de monitorización inteligente de las operaciones de corte.
<i>Roughness.txt</i>	Entradas y salidas durante toda la operación de corte del algoritmo de estimación de la rugosidad superficial.
<i>Vibracion_XXXX.txt</i>	Datos en bruto de la señal de vibración.
<i>Var_CNC.txt</i>	Almacena las variables internas del control numérico, durante toda la operación de corte.

Además del archivo “*Info.txt*” (ver Tabla 7.4) el sistema guarda información de las entradas y salidas de los módulos de detección del corte en el archivo “*Digital.txt*” y de estimación de la rugosidad en el archivo “*Roughness.txt*”. Si la opción de almacenar datos sin filtrar está activa, también se guardan los datos (generados a **50000 KS/s**) provenientes del sensor de vibración en el archivo “*Vibracion_XXXX.txt*”. Todos los archivos generados son de texto sin formato.

Si está disponible un servidor TCP que proporcione información proveniente del CNC sobre la posición de los ejes de la máquina, ésta información se almacena en un archivo llamado “*Var_CNC.txt*”, de estructura similar a los anteriores, que contiene seis columnas. La primera es el tiempo en milisegundos. Las columnas segunda, tercera y cuarta contienen la posición de los ejes X, Y y Z de la máquina, en las unidades y referencia del CNC. La quinta columna contiene el avance de los ejes, mientras que la última el intervalo de tiempo entre dos datos consecutivos, medido por el servidor.

7.3 Ensayos de evaluación de supervisión inteligente de procesos de microfresado, a nivel de laboratorio

En esta sección se describen los resultados más importantes que se han obtenido acerca de la utilidad de la arquitectura y las estrategias de supervisión inteligente desarrolladas en esta Tesis Doctoral, como etapa previa a un método transferible a escala industrial. Se han incluido, básicamente, los resultados finales de validación y optimización final de los tres pilares principales del sistema de supervisión inteligente: la detección del contacto herramienta-pieza de trabajo, imprescindible para referenciar la pieza (ceros) de una forma rápida y eficiente; la detección de la rotura, esencial para disminuir los tiempos de parada y mejorar la eficiencia del micromecanizado mecánico y; la estimación de la rugosidad

superficial en tiempo real, clave para el control de calidad on-line y la disminución del tiempo total para producir la primera pieza correctamente.

Además de la validación, se debe demostrar la **capacidad** que tiene la arquitectura de **integrar y controlar en tiempo real y simultáneamente en paralelo los diferentes módulos que la componen**. En este trabajo los algoritmos embebidos e integrados en cada módulo están diseñados para un proceso de microfabricación en específico, como es el proceso de microfresado. Sin embargo, esta arquitectura está diseñada para su utilización en cualquier tipo de proceso complejo, ya que está dotada de un alto grado de **reconfiguración y versatilidad**.

Tabla 7.5. Condiciones nominales de operación para los ensayos de evaluación.

<i>Caso no.</i>	<i>D [mm]</i>	<i>f [mm /min]</i>	<i>s [rev / min]</i>	<i>ae [mm]</i>	<i>a_p [mm]</i>
1	0.2	440	44500	0.2	0.025
2				0.1	
3				0.067	
4				0.05	
5				0.025	
6					
7					
8	0.5	200	45000	0.5	0.0625
9				0.25	
10					
11				0.0625	
12					
13					
14					
15	1	200	40000		0.125
16				1	
17				0.5	
18					
19	1.8	100	15000	1.8	0.3
20				0.9	
21				0.6	
22					

7.3.1 Diseño experimental

Con el objetivo de evaluar el desempeño y la efectividad del sistema de monitorización inteligente, se han desarrollado 22 ensayos de laboratorio con operaciones de microfresado de ranuras, empleadas en la fabricación de componentes aeroespaciales en aleaciones de tungsteno. Estos ensayos han permitido evaluar los resultados de los algoritmos para la

monitorización de los estados del proceso de corte, detección de roturas de la herramienta y estimación de la rugosidad superficial.

Los ensayos se han realizado con herramientas de diferentes diámetros y diferentes condiciones nominales en operaciones de microfresado de ranuras en una aleación de tungsteno-cobre con composición $W_{78}Cu_{22}$. En la Tabla 7.5 se describen los parámetros de corte empleados para los ensayos de evaluación del prototipo del sistema de monitorización inteligente, donde: D es el diámetro de la herramienta; N_f es el número de dientes de la herramienta; n es la velocidad de giro; f es la velocidad de avance; y a_e y a_p son las profundidades radial y axial empleadas, respectivamente.

7.3.2 Monitorización del estado de la operación de corte y detección de interrupciones

La aplicación de monitorización genera por cada ensayo realizado, un archivo de información y errores “*Info.txt*”, en el que se describen los resultados del algoritmo de monitorización del estado del corte y detección de interrupciones durante las operaciones de microfresado de ranuras. En la Figura 7.17 se muestra el archivo correspondiente a una operación de microfresado de ranura con una herramienta de 200 μm de diámetro, 44500 rev / min de velocidad de giro y 440 mm / min de velocidad de avance (Caso no. 3). Los resultados del algoritmo se muestran a modo de eventos cada vez que cambia el estado, almacenando la posición en la que se alcanza el nuevo estado.

```
Experimento realizado el día 15 del 12 del 2015 a las 11:18:02
11:18:04 - ESTADO DEL CORTE, ENTRANDO
11:18:04 - Tiempo (us) = 2053770; Posición estimada:{X = 1.3985 Y = 13.2000 Z = -0.0201}
11:18:04 - ESTADO DEL CORTE, CORTANDO
11:18:04 - Tiempo (us) = 2105325; Posición estimada:{X = 1.4502 Y = 13.2000 Z = -0.0198}
11:18:12 - ESTADO DEL CORTE, SALIENDO
11:18:12 - Tiempo (us) = 10849076; Posición estimada:{X = 8.5022 Y = 13.1999 Z = -0.0200}
11:18:13 - ESTADO DEL CORTE, NO CORTANDO
11:18:13 - Tiempo (us) = 10989620; Posición estimada:{X = 8.5955 Y = 13.2000 Z = -0.0201}
11:18:16 - ESTADO DEL CORTE, ENTRANDO
11:18:16 - Tiempo (us) = 14444533; Posición estimada: {X = 11.3938 Y = 13.2000 Z = -0.0199}
11:18:16 - ESTADO DEL CORTE, CORTANDO
11:18:16 - Tiempo (us) = 14486348; Posición estimada: {X = 11.4341 Y = 13.2000 Z = -0.0199}
11:18:25 - ESTADO DEL CORTE, SALIENDO
11:18:25 - Tiempo (us) = 23260325; Posición estimada: {X = 18.5123 Y = 13.2000 Z = -0.0200}
11:18:25 - ESTADO DEL CORTE, NO CORTANDO
11:18:25 - Tiempo (us) = 23391821; Posición estimada: {X = 18.6002 Y = 13.2000 Z = -0.0200}
11:18:28 - ESTADO DEL CORTE, ENTRANDO
11:18:28 - Tiempo (us) = 26837856; Posición estimada: {X = 21.3899 Y = 13.2000 Z = -0.0199}
11:18:29 - ESTADO DEL CORTE, CORTANDO
11:18:29 - Tiempo (us) = 26888351; Posición estimada: {X = 21.4423 Y = 13.2000 Z = -0.0199}
11:18:37 - ESTADO DEL CORTE, SALIENDO
11:18:37 - Tiempo (us) = 35630576; Posición estimada: {X = 28.4954 Y = 13.2000 Z = -0.0200}
11:18:37 - ESTADO DEL CORTE, NO CORTANDO
11:18:37 - Tiempo (us) = 35798824; Posición estimada: {X = 28.6079 Y = 13.1999 Z = -0.0200}
```

Figura 7.17. Ejemplo de un archivo de información y errores de una operación de microfresado de ranuras (Caso no. 3).

En el archivo “*Digital.txt*” de salida del sistema, se almacena el comportamiento del algoritmo de toma de decisiones sobre el estado de la operación de corte. Este archivo almacena el comportamiento temporal durante toda la operación de corte de este módulo del sistema de monitorización inteligente. En este archivo, los estados se almacenan con un valor numérico, siendo: NO CORTANDO = 0, CORTANDO = 1, ENTRANDO = 2, SALIENDO = 3 e INTERRUMPIDO = 4.

A continuación, en la Figura 7.18 se describe el comportamiento del estado del corte detectado por el sistema de monitorización, durante toda la operación de microfresado, para 6 de los 22 casos usados durante el estudio de validación.

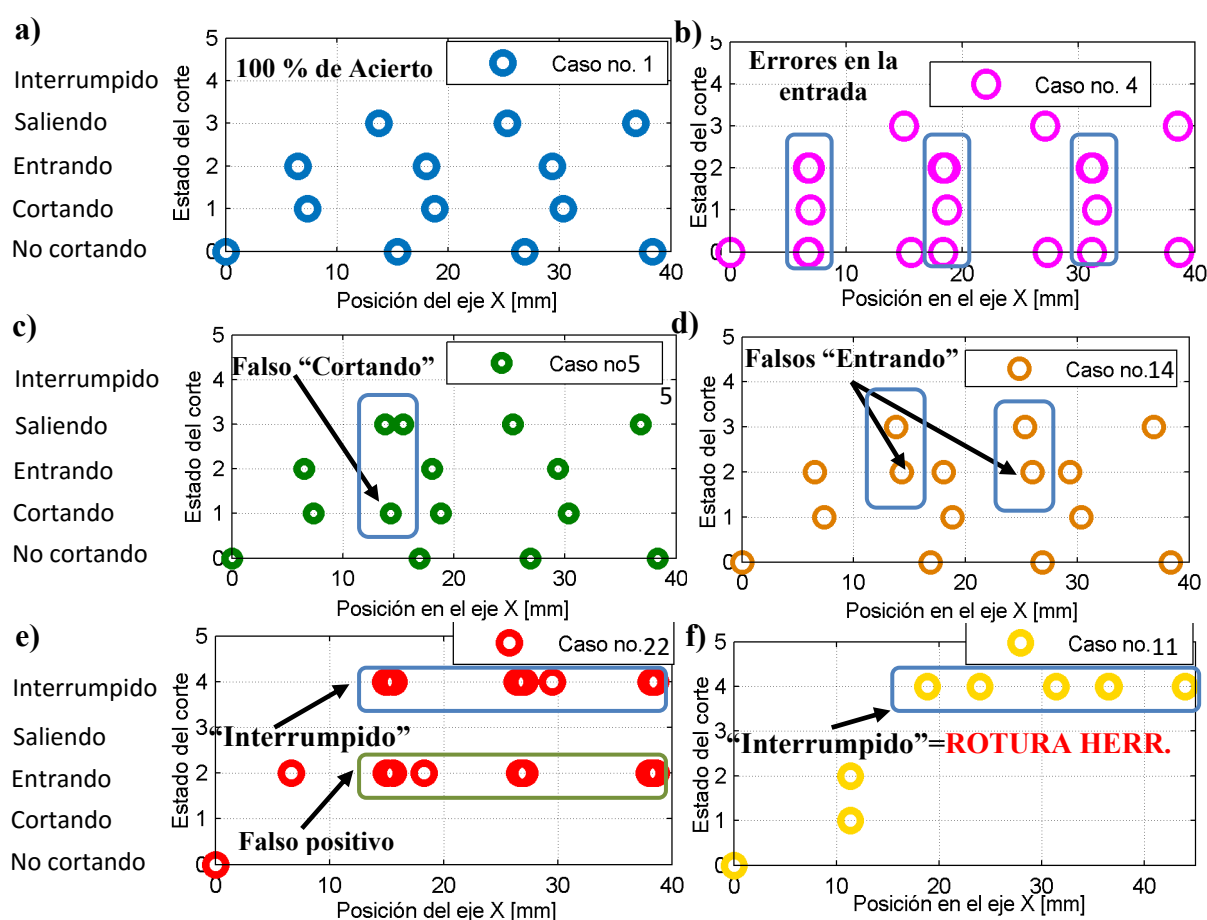


Figura 7.18. Estado del corte durante operaciones de microfresado: a) Caso no. 1, b) Caso no. 4, c) Caso no. 5, d) Caso no. 14, e) Caso no. 22 y f) Caso no. 11.

El comportamiento de los estados en la Figura 7.18.a, correspondiente al Caso no. 1, es un claro ejemplo de una detección perfecta de los estados (tasa de acierto del 100%). En cambio, en ocasiones el sistema puede dar como resultado falsas detecciones, como ocurre en la Figura 7.18.c y d. En la primera se produce un falso CORTANDO durante el proceso de

salida de la herramienta del material, mientras que en la segunda hay dos falsos ENTRANDO, igualmente en la etapa de salida de la herramienta del material. Sin embargo, en la Figura 7.18.b se producen tres errores en el estado ENTRANDO. Como se demostrará numéricamente un poco más adelante los dos momentos de transición ENTRADA / SALIDA son los más críticos y susceptibles de sufrir falsas detecciones y positivos.

Por último, en los Casos no. 22 y no. 11 (Figura 7.18.e y f, respectivamente), el sistema detectó el estado INTERRUMPIDO. En el primer caso, esta detección resultó ser un **falso positivo**, es decir, en realidad el estado en ese instante de tiempo debió de ser NO CORTANDO. Este error se debe a las vibraciones que sufre la herramienta durante la salida del material, lo cual provoca una reducción del área de corte y por consiguiente, variaciones en la resistencia de contacto. En cambio, el segundo caso de detección del estado INTERRUMPIDO fue correcto, ya que a posteriori se comprobó que se había producido realmente la rotura de la herramienta.

Sin embargo, a pesar de las posibles falsas detecciones, en el resto de casos analizados, el comportamiento del sistema ha resultado muy satisfactorio, con un **nivel de acierto de un 87%**, en los cambios de estados de la herramienta-material. La mayoría de los fallos del algoritmo tienen lugar en la entrada al material, donde el estado del corte conmuta de ENTRANDO a NO CORTANDO o de ENTRANDO a CORTANDO (ver Figura 7.19.b). Esto se debe a las vibraciones de la herramienta durante la transición en la entrada al material. Este grado de acierto durante los estados de transición es mejorable, reajustando los parámetros de configuración del algoritmo de monitorización. Por la misma circunstancia, también puede observarse que el segundo estado más crítico es la salida del material, conmutando de SALIENDO a ENTRANDO o de SALIENDO a NO CORTANDO.

Por otra parte, a partir de la Figura 7.19.a se concluye que el valor de la profundidad radial influye negativamente sobre la tasa de acierto, detectándose tasas del 70% en valores de a_e por debajo de 0.25 mm. Este resultado concuerda con las conclusiones del Capítulo 4, en el cual se relaciona inversamente la profundidad radial (directamente relacionada con el área de contacto) con la resistencia de contacto, es decir, a medida que aumenta esta profundidad, disminuye la resistencia asociada. Dicha resistencia es el principio de funcionamiento del sensor inteligente de conductancia diseñado y por consiguiente, de los algoritmos de detección del estado del proceso, ya que las señales que proporciona este sensor son utilizadas como entradas en los algoritmos.




Figura 7.19. Diagrama de barras para la tasa de acierto de todos los ensayos respecto a: a) profundidad radial, a_e , b) estados del corte y c) velocidad de avance.

Finalmente, de la Figura 7.19.c es posible deducir otro resultado lógico a partir de los valores de velocidad de avance de los diferentes ensayos realizados. A medida que este valor aumenta, el acierto va progresivamente disminuyendo. Este resultado también está relacionado con una de las conclusiones del Capítulo 4, en la cual se determinó que la precisión en la obtención del tiempo de contacto, medible mediante un contador digital de pulsos, se ve afectado por el valor de la velocidad de avance. Esta medición del tiempo de contacto también forma parte del principio de funcionamiento del sensor inteligente de conductancia. En este caso, se determinó que la variable medible fuese la distancia recorrida durante el tiempo de contacto, término que incluye en su cálculo el valor de velocidad de avance en cada instante de tiempo.

7.3.3 Estimación de la rugosidad superficial. Viabilidad de integración

En esta sección la principal cuestión consiste en evaluar en tiempo real el comportamiento del subsistema que estima la rugosidad superficial y que ha sido descrito con anterioridad en el Capítulo 5 (modelado de la rugosidad superficial) y en la sección 7.2.3 (módulo para la predicción de la rugosidad superficial).

Tal y como se comentó con anterioridad, es muy importante el comportamiento adecuado del sistema en tiempo real y para ello hay que hacer una evaluación de la viabilidad de integración de un módulo dedicado a realizar la estimación on-line de la rugosidad, en paralelo a la ejecución de otros módulos, como los algoritmos de detección del estado. De todos los ajustes y evaluaciones realizados por cuestiones de espacio, elegimos la validación del sistema ante las mismas 22 situaciones diferentes no conocidas de antemano por el sistema durante la generación de los modelos de rugosidad en la fase de entrenamiento. Estas situaciones son las mismas que se utilizaron en la sección anterior (Tabla 7.5). La forma de presentar el sistema de monitorización la estimación de la rugosidad puede ser de dos formas diferentes:

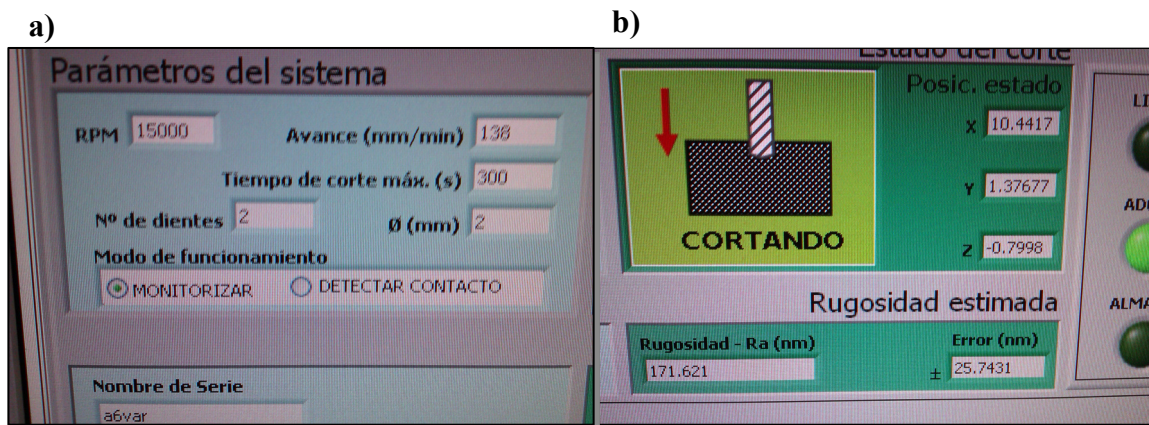


Figura 7.20. Secciones de la interfaz de usuario del sistema de monitorización inteligente durante una operación de ranura, herramienta de 1800 μm de diámetro, a) sección “Parámetros del sistema” y b) sección de resultados de los algoritmos, “Estado del corte” y “Rugosidad estimada”.

En primer lugar, el resultado de la estimación on-line puede presentarse mientras se lleva a cabo la propia operación de microfresado, simplemente mediante la observación de la interfaz de usuario del programa en tiempo de ejecución. La Figura 7.19 muestra una captura de la interfaz gráfica de usuario del sistema desarrollado. Las imágenes se corresponden a una ranura realizada con una herramienta de 1800 μm de diámetro, a una velocidad de giro de 15000 rev / min, 138 mm / min de avance y una profundidad axial de 200 μm . La Figura 7.19.a describe la entrada de parámetros del sistema o condiciones de operación y la Figura 7.19.b muestra los resultados del sistema de monitorización inteligente, según las condiciones de operación seleccionadas.

En segundo lugar, el resultado de la estimación de la rugosidad por el sistema puede ser almacenado en un archivo en el disco duro. Este archivo “**Roughness.txt**” tiene una estructura similar al archivo “**Digital.txt**”, pero con **cinco columnas**. La **primera** es el tiempo, medido en milisegundos. Las siguientes columnas son las **entradas al módulo de**

estimación de la rugosidad. Consecutivamente, estas entradas son la **vibración**, consistente en el **valor *rms* normalizado** según el **valor absoluto máximo de la señal filtrada** en el intervalo considerado, y la **entrada de avance**, consistente en el **avance por diente al cuadrado dividido por el radio de la herramienta**, todo ello en nanómetros. La cuarta columna es la salida del modelo, la rugosidad estimada, mientras que la quinta es el error de esa estimación (respecto a la propia estimación).

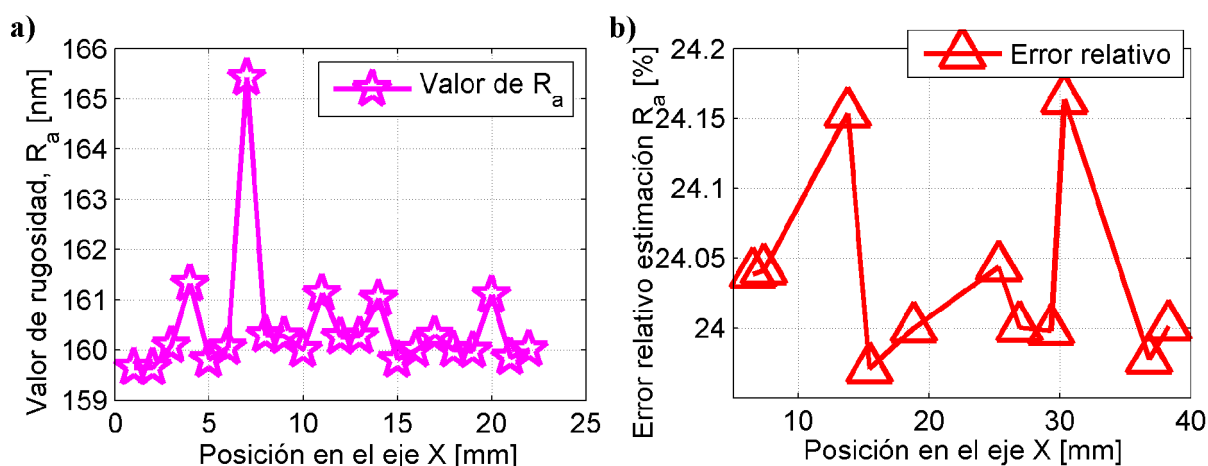


Figura 7.21. Resultado de la estimación de la rugosidad superficial para el Caso no. 18, durante una operación de microfresado de ranura. a) Valor de R_a estimado para toda la operación y, b) su correspondiente error relativo obtenido en la estimación.

A partir del análisis de los 22 archivos “**Roughness.txt**”, se ha podido extraer un valor de **rugosidad superficial media de 160,4797 con un error en la estimación del 24,07%**. En la Figura 7.21.a se muestra el resultado del archivo de “**Roughness.txt**”, correspondiente al Caso no. 18. En cambio, en la Figura 7.21.b se representa el error de esa estimación (respecto a la propia estimación).

Por tanto, **se puede determinar que la arquitectura de tiempo real, modular, en red y reconfigurable es capaz de estimar on-line la rugosidad superficial, en paralelo a la ejecución de otros módulos de tiempo real, como son los algoritmos de detección del estado.**

7.4 Ensayos de evaluación de supervisión inteligente de procesos de microfresado, a nivel industrial

Como etapa final de esta Tesis Doctoral, el sistema de supervisión inteligente ha sido aplicado a un método de fabricación industrial. La evaluación de las estrategias de supervisión, embebidas en la plataforma de tiempo real, modular, en red y reconfigurable, se realizó durante la fabricación de una pieza compleja correspondiente a una parte de algún

componente aeroespacial. El material de esta pieza, al igual que en todos los ensayos llevados a cabo en este trabajo, es una aleación de tungsteno-cobre (W22Cu78).

El sistema de monitorización inteligente fue trasladado a la sede de la empresa MECAES (Mecanizados Escribano), situada en Alcalá de Henares. En la Figura 7.22.a se muestra el montaje del sistema de monitorización en un centro de mecanizado Mori SEIKI Dura Vertical 5060 con un modelo de CNC MSX-504 III, perteneciente a la empresa MECAES.




Figura 7.22. a) Vista del montaje y configuración en la máquina Mori SEIKI, b) su cabezal y mordaza, c) pieza a mecanizar y sensor de vibración en el eje Z y d) pieza mecanizada con uno de los bornes del sensor de conductancia.

El proceso de fabricación de esta pieza incluye la realización de diferentes operaciones de microfresado (ranura, planeo, contorno, entre otros) de forma continua. En la Figura 7.23 se ilustra el acabado final de la pieza de trabajo como resultado del proceso de micromecanizado. A simple vista puede observarse la complejidad de las operaciones que se realizaron para obtener perfiles de ranura, contorno, islas, planeado, cajera, entre otros.




Figura 7.23. Resultado final de la realización de las operaciones en la pieza

En el cabezal y la pieza de trabajo se situaron los bornes del sensor de conductancia (Figura 7.22.b); mientras que el acelerómetro mono-axial se situó sobre la mordaza de la máquina herramienta (Figura 7.22.c). En la Figura 7.22.d se observa la conexión del borne del sensor de conductancia en la pieza de trabajo, la cual se encuentra aislada eléctricamente del resto de la máquina.

Inicialmente, se procedió a configurar y ajustar los parámetros del sistema de monitorización para la nueva máquina y proceso en específico al que se iban a aplicar las estrategias de supervisión inteligente. Una vez ajustado todo, se procedió a comprobar el correcto funcionamiento de los sensores y de todo el sistema. **Cabe resaltar que en esta máquina no se pudo tener acceso a las variables internas del CNC y por tanto, no se pudieron obtener los valores de velocidad de avance y posición en tiempo real. Como consecuencia, en la interfaz gráfica no aparecen actualizaciones en los valores de posición cada vez que se produzca un cambio de estado en el proceso.**

Finalmente, se inició el proceso de monitorización del estado del corte en tiempo real y estimación de la rugosidad superficial on-line. Se realizaron cuatro ensayos industriales de fabricación de la pieza compleja (Caso no.1, Caso no. 2, Caso no. 3 y Caso no. 4). Para las cuatro operaciones de fabricación de esta pieza se utilizó una herramienta de dos dientes y un diámetro de 1 mm, con unas condiciones de corte que fueron una velocidad de giro de 10000 rev / min, una velocidad de avance de 300 mm / min y una profundidad axial y radial variable, en función de la zona de la pieza que se estuviese mecanizando en ese instante de tiempo. La duración total de la operación estuvo entorno a los 200 segundos.

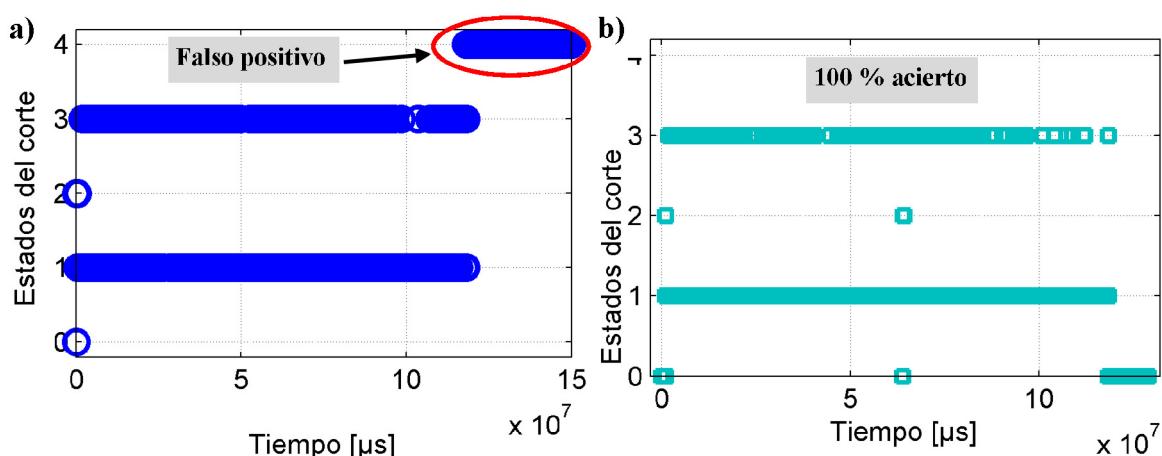


Figura 7.24. Detección de los estados del corte, durante la fabricación industrial de la pieza compleja. a) Caso. no. 1 y b) Caso no. 2.

En la Figura 7.24 se representan dos de los cuatro resultados en la detección del estado del proceso llevados a cabo en la industria MECAES. Se puede apreciar en la Figura 7.24.a como,

justo antes de finalizar la operación de microfresado, se detecta un estado INTERRUMPIDO. En este caso se trata de un falso positivo debido a que no se produjo ninguna rotura de la herramienta. En cambio, la Figura 7.24.b refleja una detección perfecta de los estados del corte en un proceso completo de fabricación de la pieza. En general, **el sistema determinó bastante bien los estados del corte para el método de fabricación industrial, presentando una tasa de acierto final del 90%**.

Los resultados en **la estimación de la rugosidad superficial** muestran que el sistema de monitorización es capaz de estimar on-line la R_a con unos resultados muy satisfactorios. En la Figura 7.25.a se muestra el resultado del archivo de “Roughness.txt”, correspondiente al Caso no. 3, donde se puede observar una predicción en el **valor de R_a de 202,4394 nm** de media, durante todo el proceso de fabricación de la pieza. En cambio, en la Figura 7.25.b se representa el error de esa estimación (respecto a la propia estimación). Se aprecia un **error medio en la predicción de R_a del 30,72%**. Este error se debe a que el modelo de rugosidad sólo ha dispuesto de una de sus entradas en tiempo real, la vibración en el eje Z. Por el contrario, el avance se ha introducido de forma manual y ha permanecido constante a 300 mm /min durante todo el ensayo. El motivo es que en esta máquina y específicamente, en este CNC no se ha podido tener acceso a la velocidad de avance en tiempo real.




Figura 7.25. Resultado de la estimación de la rugosidad superficial para el Caso no. 3 de ensayo de fabricación industrial de la pieza. a) Valor de R_a estimado para toda la operación y, b) su correspondiente error relativo obtenido en la estimación.

7.5 Conclusiones

En este capítulo se han integrado todas las estrategias de supervisión inteligente desarrolladas en esta Tesis Doctoral para ser evaluadas en tiempo real. Todos estos métodos han sido embebidos en una plataforma de tiempo real, modular, en red y reconfigurable. A lo largo del desarrollo de este capítulo, se han presentado todos los componentes que conforman el prototipo del sistema de monitorización inteligente implementado. El sistema está conformado principalmente por los siguientes componentes: un sistema sensorial, un sistema de medición en red, un sistema de adquisición, algoritmos de procesamiento digital, algoritmos embebidos que implementan procesos de toma de decisiones y una máquina de estados finitos, algoritmos embebidos basados en técnicas de inteligencia artificial y una aplicación web embebida en una plataforma de alto rendimiento.

Se ha demostrado que la portabilidad y modularidad de esta arquitectura se sustenta en dos procedimientos de acondicionamiento de sus estrategias al proceso que se desee supervisar. En esta Tesis doctoral, el sistema ha sido aplicado al proceso de microfresado de alta precisión. Por tanto, en nuestro caso particular, las dos estrategias desarrolladas se han dedicado a la monitorización de las operaciones de corte y detección de roturas, y a predecir la rugosidad superficial. Estos procedimientos han sido introducidos con anterioridad en los Capítulos 4 y 5, donde se hace referencia al módulo de detección de estado del proceso de corte, y en los Capítulos 3 y 6, donde se hace referencia al módulo dedicado a la predicción de la rugosidad superficial. Su implementación computacional eficiente ha permitido embeber los modelos estimativos y el sistema de toma de decisiones en la plataforma de tiempo real. Todo esto ha convertido a la arquitectura en un sistema embebido de supervisión inteligente en tiempo real, en red, modular y reconfigurable de operaciones de micromecanizado.

Como parte de la metodología científica de este capítulo, todas las estrategias embebidas desarrolladas han sido validadas en una plataforma experimental de tiempo real. Para ello, se han realizado ensayos en operaciones de micromecanizado para evaluar el desempeño del sistema desarrollado. Esta evaluación se ha realizado a partir de cifras de mérito que comparan las estimaciones o decisiones del sistema de monitorización y el comportamiento real de la operación de corte.

En primer lugar, como paso previo a la aplicación del sistema a un método de fabricación industrial, se ha validado el sistema en el laboratorio ante 22 ensayos de laboratorio con operaciones de microfresado de ranuras, empleadas en la fabricación de componentes aeroespaciales en aleaciones de tungsteno. En estos ensayos se ha concluido que el resultado ha sido muy satisfactorio, con un nivel de acierto de un 87%, en los cambios de estado correspondientes al contacto entre la herramienta y el material. Sin embargo, se han obtenido falsas detecciones en el resto de casos analizados, la mayoría de ellos en las dos regiones de transición (entrada o salida de la herramienta del material). Este grado de acierto durante los

estados de transición es mejorable, reajustando los parámetros de configuración del algoritmo de monitorización.

En segundo lugar, los resultados en la estimación de la rugosidad superficial presentan un valor de rugosidad superficial de 160,4797 nm de media, con un error en la estimación del 24,07%. Se ha demostrado que el sistema desarrollado es capaz de estimar on-line la rugosidad superficial, en paralelo a la ejecución de otros módulos de tiempo real, como son los algoritmos de detección del estado del corte.

Como etapa final de este capítulo, el sistema de supervisión inteligente ha sido aplicado a un método de fabricación industrial. La evaluación de las estrategias de supervisión, embebidas en la plataforma de tiempo real, modular, en red y reconfigurable, se ha realizado durante la fabricación de una pieza compleja correspondiente a una parte de algún componente aeroespacial. En este caso, los resultados concluyen que se han determinado bastante bien los estados del corte y detección de interrupciones para el método de fabricación industrial con una tasa de acierto del 90%. En cambio, para la estimación de la rugosidad superficial se ha podido observar una predicción en el valor de R_a de 202,4394 nm de media, durante todo el proceso de fabricación de la pieza, presentando un error medio del 30,7%. Este error ha aumentado considerablemente respecto al obtenido en los ensayos a nivel de laboratorio, debido a que en esta máquina y específicamente, en este CNC no se ha podido tener acceso a la velocidad de avance en tiempo real.

Los resultados obtenidos en este capítulo constituyen la base para el desarrollo de nuevos sistemas de supervisión inteligente a nivel distribuido, que incorporen estrategias de competitividad, para ser utilizados en el modelado, monitorización y control de procesos físicos complejos, con un comportamiento dinámico inherentemente no lineal y variantes en el tiempo.

CONCLUSIONES

Esta Tesis Doctoral basada en una metodología científica en la que interactúan métodos de investigación teórica y experimental, trata el diseño, desarrollo e implementación de una arquitectura e inteligencia computacional embebida para la supervisión de procesos, y el caso real de un proceso de Microfabricación. El método propuesto está basado en técnicas de Inteligencia Artificial (AI) y ha conducido al diseño e implementación de un sistema embebido en una plataforma de tiempo real, modular, en red y reconfigurable, para la monitorización inteligente de sistemas complejos. Este trabajo tiene un carácter multidisciplinar e interdisciplinar ya que se abordan desafíos científicos y técnicos en diferentes áreas de conocimiento y tópicos desde la ingeniería mecánica y la microfabricación hasta la Electrónica, la Automática y la ingeniería de Control. Las estrategias de supervisión propuestas

Las estrategias de supervisión propuestas han tenido en los sistemas informáticos y en las Ciencias de Computación e Inteligencia Artificial, la base de la que nos hemos podido nutrir para articular una solución embebida y computacionalmente eficiente, con un funcionamiento adecuado en tiempo real. Este éxito se ha conseguido al haber abordado una amplia gama de técnicas y estrategias de procesamiento y filtrado de señales y extracción de patrones de comportamiento, diseño de un sensor, hasta la aplicación de métodos contemporáneos para el modelado híbrido y el agrupamiento borroso.

La capacidad de reconfiguración y portabilidad de esta arquitectura se ha sustentado sobre dos procedimientos de acondicionamiento, de los diferentes módulos, al proceso que se desee supervisar. Estos procedimientos, cuyos resultados serán brevemente resumidos en párrafos posteriores, tienen una precisión dependiente de los diferentes modelos y algoritmos embebidos e integrados en la arquitectura. En esta Tesis doctoral, el caso real de aplicación ha sido el proceso de microfresado de alta precisión, un proceso de microfabricación que tiene un

gran impacto en el siglo XXI en la producción de bienes y servicios y en la mejora de la calidad de vida.

Como paso inicial, se ha realizado una revisión del estado de la ciencia y la técnica en los paradigmas elegidos dentro del amplio universo que ponen a nuestra disposición la Teoría General de Sistemas, la Teoría de Control, las técnicas de Inteligencia Artificial y las Ciencias de la Computación. Se ha prestado especial atención a los paradigmas con una fundamentación teórica en la conjunción de los sistemas de Tiempo Real e Inteligencia Artificial (AI), con un enfoque desde la perspectiva de la Automática y la Teoría de Sistemas. El estudio se ha centrado en estrategias susceptibles de ser utilizadas en el modelado y monitorización en tiempo real de procesos físicos. En este sentido, la revisión se ha enfocado hacia las técnicas del *soft-computing*, analizando su evolución desde sus inicios hasta las tendencias actuales. Esto permitió no solo conocer la evolución de estas técnicas sino identificar algunas con mayor para ser embebidas de modo que se dote a la arquitectura de las capacidades necesarias cualitativamente superiores con vistas a asegurar mejores prestaciones en las nuevas generaciones de sistemas de monitorización y supervisión de procesos físicos complejos.

Debido al carácter multidisciplinar, interdisciplinar y heterogéneo resaltable en esta Tesis Doctoral, el estado del arte se ha encajado enfocado con vistas a poder generar contribuciones científicas y técnicas en todos y cada uno de los campos de aplicación, áreas de conocimiento y tópicos que conforman esta Tesis, sin haber llegado a entrar con gran profundidad en ninguno de ellos, ya que esto desde el punto de vista temporal se hubiese convertido en irrealizable e inalcanzable en el marco de la Tesis Doctoral.

Esto motiva que se haya optado en darle relevancia en esta revisión al desarrollo de métodos computacionalmente eficientes para la supervisión inteligente de procesos en tiempo real. Se profundiza en el estado de la ciencia y la técnica en conjunción de los temas tratados, de modo que ha permitido articular todas las contribuciones e interrelaciones entre las diferentes áreas de conocimiento que se tratan en esta Tesis Doctoral. Precisamente, es la ingeniería informática y específicamente, los sistemas informáticos, las ciencias de la computación (específicamente, la inteligencia computacional) y los sistemas embebidos de tiempo real los aglutinantes ya catalizadores de este trabajo.

Los resultados más destacados que se han obtenido en la Tesis Doctoral se presentan brevemente a continuación.

Para alcanzar el objetivo principal de esta Tesis Doctoral únicamente nos hemos basado en la abstracción de los diferentes retos científicos y técnicos en la conjunción de las diferentes áreas de conocimiento presentes en esta Tesis Doctoral. Como ya se ha comentado anteriormente, el área de conocimiento que actúa como eje central de esta Tesis y sobre el que giran el resto de contribuciones (Sistemas Embebidos y Tiempo Real, Electrónica,

Automática e ingeniería de Control, Mecánica y procesos de Fabricación) es la ingeniería Informática. La conciliación de estas diferentes áreas a través de la Informática es la materialización de esta disertación, cuyo último fin ha sido dar soluciones a problemas inherentes a los procesos físicos complejos en el ámbito de la Mecánica y los procesos de Fabricación en la micro escala.

En el campo de las arquitecturas, los sistemas informáticos de tiempo real y las Ciencias de la Computación, el logro más destacado ha sido el diseño e implementación de una plataforma para la monitorización y supervisión de un proceso físico complejo. Esta plataforma está basado en un sistema propietario comercial (National Instruments) y en un sistemas de medición, procesamiento y toma de decisiones formado por módulos embebidos que han sido descritos en esta Tesis y que serán brevemente resumidos en este capítulo. Esta plataforma que incluye procedimientos de comunicaciones basado en Ethernet han permitido estudiar y conocer fenómenos físicos que ocurren en la micro y meso escala, y de este modo acercarnos a las restricciones y desafíos de los sistemas de procesamiento y cómputo para abordar los nuevos retos científicos y tecnológicos de los procesos físicos complejos que tienen lugar en la micro escala. Ciertamente, el disponer de una máquina única en el CSIC y en la Comunidad de Madrid, ha permitido evaluar experimentalmente la plataforma y conocer el alcance real de los métodos desarrollados para un sector de gran importancia económica.

En el ámbito de la ingeniería de sistemas y la Automática, y específicamente, relacionado con los sistemas de medición y el procesamiento de señales, un resultado científico ha sido el estudio y análisis de técnicas y métodos para la extracción de patrones de comportamiento a partir de las señales representativas en variables típicas de procesos físicos complejos, y específicamente el proceso de microfabricación. De este modo, se han tratado y analizado diferentes técnicas de acondicionamiento y procesamiento de señales tales como métodos estadísticos en el dominio del tiempo, STFT, HHT, Wavelet, etc., y diferentes estrategias de filtrado digital (media móvil, media cuadrática móvil, paso-alto, paso-bajo, etc.). A partir de la literatura consultada sobre sensores y sistemas sensoriales, se ha desarrollado e implementado una plataforma de medición multi-sensorial para la adquisición de señales en un proceso de microfabricación y así, comprobar el desempeño de estas técnicas y métodos, en un proceso de microtaladrado, a modo de caso de estudio. Esta plataforma es única en España y en el CSIC.

La contribución aquí ha sido el desarrollo de una estrategia de dos etapas para monitorizar el grado de uso de la herramienta de corte. **Se ha minimizado la cantidad de sensores necesaria a tales efectos. El sistema sensorial está formado por un sensor de fuerza en el eje Z y dos de vibración en los ejes Y y Z.** La aplicación de un **filtro de media móvil para la señal de fuerza de corte y del valor cuadrático medio móvil para la vibración** proporciona una mejor fiabilidad y una relación señal-ruido notablemente buena. De entre las técnicas de extracción bajo análisis, la transformada de Wavelet (WT) y la transformada de

Hilbert-Huang (HHT) mostraron el mejor desempeño desde el punto de vista científico y técnico.

Estos resultados se han corroborado matemáticamente mediante la correlación de las diferentes técnicas de extracción de características con el número de agujeros perforados (uso de la herramienta) y mediante el uso de regresiones estadísticas (modelos de regresión). La capacidad de generalización revela una relación probabilística entre las entradas y la salida de los modelos que no es significativa. En cambio, el valor del índice de correlación ha sido más alto, sobre todo, utilizando como entradas las técnicas de extracción de características en el dominio del tiempo-frecuencias y en concreto, la de mayor correlación ha resultado ser la WT. **Con este estudio se ha generado un conocimiento científico y técnico importante, y se ha contribuido a una mejor comprensión de los procesos de microfabricación de componentes de aleaciones especiales. Sin embargo, la aportación más importante de este resultado ha sido la inclusión en las especificaciones del futuro diseño e implementación de la arquitectura de tiempo real, un sub-módulo de adquisición, procesamiento y registro de las señales del proceso.**

A continuación se esbozan los logros más relevantes en cada uno de los dos procedimientos que se han incluido en la arquitectura de tiempo real, en red, modular y reconfigurable para la monitorización y supervisión.

El primer procedimiento **se ha centrado en una metodología para la caracterización experimental en tiempo real de procesos complejos.** Como caso de estudio, ésta ha sido aplicada a la interacción dinámica entre la herramienta de corte y la pieza de trabajo en operaciones de microfabricación. **Todo ello, sobre un análisis basado en la resistividad eléctrica en el contacto entre la punta de la herramienta de corte y el material. Estos resultados son aplicables a una gran variedad de procesos de fabricación por arranque viruta o eliminación mecánica de material en materiales conductores.** En primer lugar, se ha realizado un análisis de los modelos teóricos del mecanismo de corte en operaciones de fresado, por ser este el caso general más complejo, con el fin de obtener una caracterización matemática de la zona de contacto punta de la herramienta y el material. En segundo lugar, los resultados de los análisis teóricos han sido corroborados a través de su comparación con los resultados del análisis experimental. Los resultados de esta investigación han servido como base para el desarrollo de un método tecnológico (patente) de alta precisión para la monitorización en tiempo real de procesos físicos complejos y en particular, para detección de la zona corte en operaciones de microfabricación.

Así, la evidencia de esta prometedora línea de investigación se materializa mediante el desarrollo de un sensor inteligente de conductividad para la detección de los estados en un proceso físico complejo, y en particular el caso del proceso de microfabricación. Los resultados de esta investigación experimental han demostrado que el sensor de conductancia

es una opción viable científica y técnicamente para supervisar el estado de corte y la detección de roturas de la herramienta en operaciones de micromecanizado, cuando se requiere utilizar la mínima información sensorial posible y los menores requisitos computacionales. El sensor mide la conductancia de la caída de voltaje generada por el paso de una corriente de autoexcitación a través de la resistencia eléctrica del contacto dinámico herramienta / pieza de trabajo. **Las señales** proporcionadas por este sensor **han sido utilizadas como entradas a un método embebido**, diseñado para el proceso de ayuda a la toma de decisiones, que está **basado en un conjunto de reglas y en una máquina de estados finitos** para la detección del estado del corte y rotura de la herramienta en procesos de micromecanizado.

Este primer procedimiento es el resultado natural fruto de la necesidad del diseño e implementación, dentro de la arquitectura de tiempo real, de uno de los módulos más importantes con vistas a la monitorización del estado del proceso objeto de monitorización.

Un **segundo procedimiento** se ha desarrollado a partir del sistema sensorial, en el que se ha profundizado en el conocimiento de las técnicas de Inteligencia Artificial consideradas en esta Tesis Doctoral **para el diseño de modelos experimentales de variables representativas en procesos físicos complejos**. Para ello se han considerado a partir del estado del arte algunas ideas y conceptos esenciales. Entre la amalgama de técnicas, se han **seleccionado y propuesto dos** de las que tienen un consolidado cuerpo de doctrinas y un reconocido impacto científico y técnico en el modelado de procesos físicos.

Como primera propuesta de modelo, en esta Tesis Doctoral se han expuesto las ideas conceptuales y básicas de una **estrategia de modelado libre o no paramétrico, conocido como algoritmo de modelado híbrido incremental (HIM)**. Esta elección se debe a que en la actualidad esta técnica ha despertado gran interés en la comunidad científica y técnica para el modelado de procesos físicos complejos, en casos donde no se dispone o conoce la estructura del modelo (modelo no paramétrico) y que presentan un alto grado de incertidumbre. 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 esta Tesis Doctoral, 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, y con el objetivo de suavizar las transiciones entre el modelo global y el modelo local, se utiliza una estrategia de suavizado local basada en el algoritmo de agrupamiento borroso F-kNN (*Fuzzy k-Nearest Neighbors*)**. Seguidamente, se ha realizado un acercamiento científico a un método de optimización estocástico y libre de gradiente, para su aplicación en el ajuste óptimo de los parámetros del modelo. El estudio se ha centrado en un método de inspiración física, como es el caso del **algoritmo de temple simulado**.

Como segunda propuesta de modelado se ha **considerado una técnica de regresión borrosa o neuroborrosa que es considerada usualmente para obtener modelos de aquellos procesos caracterizados por disponer de pequeñas cantidades de datos experimentales** (ej., los procesos de fabricación). Debido a que el modelado borroso presenta importantes desafíos a la hora de extraer o inferir información a partir de los datos existentes, esta propuesta ha sido complementada con una técnica **de agrupamiento o *clustering*, como es el algoritmo generalizado de agrupamiento borroso *c-Means* con particiones borrosas mejoradas (GIFP-FCM), que generaliza el uso de IFP-FCM, añadiendo un parámetro α que permite, según su valor, adoptar diferentes comportamiento entre el FCM y el IFP-FCM**. A pesar de que la incorporación de este parámetro 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 una regresión borrosa o neuroborrosa. **Por tal razón, la contribución en esta Tesis Doctoral ha sido la incorporación del algoritmo de agrupamiento GIFP-FCM a una estructura neuroborrosa con el fin de modelar procesos complejos con no-linealidades, relaciones entre variables, incertidumbre, etc.** Por último, los parámetros del modelo fueron ajustados mediante un **algoritmo de retro-propagación de errores**.

Como continuación, estos dos métodos y modelos desarrollados basados en técnicas de AI propuestos en esta Tesis Doctoral han sido aplicados para el diseño e implementación de modelos de estimación de variables representativas del proceso de microfabricación. **En específico se ha considerado la estimación, en proceso, de la rugosidad superficial en el proceso de microfresado de alta precisión, como caso real de un proceso físico complejo**. Los resultados descritos anteriormente han estado precedidos por una experimentación que ha abarcado cientos de ensayos en los que se ha establecido la rugosidad superficial, y específicamente la R_a , como el criterio esencial y de mayor importancia para evaluar la calidad superficial de lotes de piezas mecanizadas. En esta Tesis se han hecho dos propuestas y se ha realizado un estudio comparativo entre ellas. Fruto de esta comparación se decidió embeber o empotrar el modelo obtenido en la segunda propuesta (GIFP-FCM) en el módulo de la arquitectura de tiempo real para a la estimación on-line de la rugosidad superficial, con vistas a su ensayo industrial.

Este segundo procedimiento ha añadido en las especificaciones de diseño e implementación de la arquitectura de tiempo real un módulo para la supervisión basada en modelos de variables representativas de los procesos.

Finalmente, a partir de todas las aportaciones en las especificaciones de diseño e implantación de los diferentes módulos que forman la arquitectura e inteligencia computacional embebida para la supervisión de procesos, se ha decidido la integración de los siguientes componentes modulares: un sistema sensorial, un sistema de medición en red, un sistema de adquisición, algoritmos de procesamiento digital, algoritmos embebidos que

implementan procesos de toma de decisiones y una máquina de estados finitos, algoritmos embebidos basados en técnicas de inteligencia artificial y una aplicación web embebida en una plataforma de alto rendimiento.

Como ya se ha mencionado anteriormente, los dos procedimientos se unifican mediante la integración de los módulos resultantes en una plataforma de tiempo real, modular, en red y reconfigurable. A continuación, se presentan de forma resumida los resultados finales obtenidos en los dos procedimientos de obtención de dos de los módulos más importantes dentro de la arquitectura: el de detección en tiempo real del estado del corte y toma de decisiones, y el de estimación on-line de la rugosidad superficial en un proceso de micromecanizado.

Resultados finales sobre el procedimiento de obtención del módulo de detección en tiempo real del estado del corte y la toma de decisiones

Como metodología computacional eficiente de caracterización experimental se **ha implementado una plataforma de medición directa de los anchos de los pulsos de las señales digitales (contador digital hardware)**, provenientes del voltaje generado por la circulación de una corriente eléctrica de auto-excitación a través de un sistema complejo que sea conductor de la electricidad (resistencia de contacto). La estrategia ha sido aplicada al sistema formado por la interacción cabezal-herramienta-pieza. **El desempeño de la estrategia de caracterización ha sido corroborado experimentalmente mediante la comparación entre los resultados teóricos calculados y los valores experimentales obtenidos en la plataforma de medición durante operaciones de microfresado.**

Estos resultados confirman que mediante la medición directa de los anchos de pulso de las señales digitales se obtiene el valor del tiempo de inmersión de la punta de la herramienta / borde del material o tiempo de contacto con un error promedio de menos de un 10%. Como mejora de este resultado, se ha propuesto que **la duración de las transiciones pueda ser expresada en términos de distancia recorrida durante el tiempo de inmersión herramienta / material, con el fin de evitar la influencia de la velocidad de avance.** En este caso, se ha reducido el error, entre los valores teóricos y los valores experimentales, un **4,284%**.

Los resultados de esta investigación se han plasmado en una **evidencia física de esta prometedora línea de investigación. Se trata del diseño e implementación de un sensor inteligente de conductividad** para la monitorización del estado de corte en tiempo real de procesos de fabricación. Se ha corroborado que este sensor cumple fielmente **los criterios de robustez, fiabilidad, bajo coste y alta velocidad de respuesta** debido a que **aprovecha las características de alta velocidad de la conductividad eléctrica, el uso de circuitos mixtos electrónicos (analógicos-digitales) y un post-procesamiento con una electrónica digital**

simple. Se ha confirmado, además, que utilizar como entradas, a los algoritmos embebidos, las señales obtenidas del sensor de conductancia es la mejor opción para supervisar el estado del proceso de fabricación.

Del análisis experimental extraído del comportamiento del sistema **se ha concluido que el comportamiento del sistema ha mostrado muy buenos resultados con aproximadamente un 90% de precisión en la detección de los estados del proceso. Estos resultados han sido obtenidos al utilizar el modo de muestreo continuo cada 250 μ s.**

Comentarios finales sobre el procedimiento de estimación on-line de la rugosidad superficial

En el caso del procedimiento de estimación on-line de la rugosidad superficial, a partir del análisis sistémico y de la determinación de la mínima cantidad de variables para estimar **la rugosidad superficial media absoluta (R_a)**, se han escogido dos variables de entrada: **el valor cuadrático del avance por diente (f_z)² normalizado con relación al radio de la herramienta (r)**, ambos expresados en nanómetros (nm), y **la vibración media cuadrática en el eje Z (A_{crms}) normalizada con relación a su valor máximo (A_{max})** durante una ventana temporal, para modelar esta variable representativa del proceso de microfabricación.

Para tal fin, **se han considerado dos ejemplos de algoritmos de modelado para la estimación de la rugosidad on-line** en procesos de micromecanizado. Estos dos algoritmos constituyen una herramienta imprescindible para el modelado y están basadas en dos técnicas muy novedosas, a saber: **el modelado híbrido incremental (HIM) y el modelado por agrupamiento borroso generalizado (GFCM).**

Para cada uno de los algoritmos de modelado utilizados se ha seguido la misma metodología de diseño que consta básicamente de las siguientes etapas:

1. Obtención de los modelos

En este primer paso, se obtienen los dos modelos representativos del proceso de mecanizado, para cada máquina que se desee caracterizar, que permite obtener la rugosidad superficial (salida del modelo) a partir de datos del avance por diente y de la vibración de la máquina en el eje Z (las dos entradas al modelo).

2. Evaluación de los modelos

2.1 Adquirir datos de la velocidad cuadrática de avance por diente de la herramienta y datos de la vibración en el eje Z de la herramienta durante una ventana temporal cuya duración es proporcional al periodo de rotación de la herramienta, preferentemente 10 veces dicho periodo de rotación.

- 2.2 Calcular el valor medio cuadrático de los datos de vibración en el eje Z durante dicha ventana temporal y normalizarlo con relación al valor máximo de la vibración dentro de la misma ventana de datos.
- 2.3 Normalizar los datos de la velocidad cuadrática de avance por diente con relación al radio de la herramienta.
- 2.4 Introducir los valores normalizados de la velocidad cuadrática de avance por diente y los valores cuadráticos medios de vibración en el eje Z de la herramienta en los modelos para obtener la rugosidad superficial instantánea. Preferentemente, antes de comenzar la adquisición de datos se detecta el inicio efectivo del mecanizado teniendo en cuenta el momento en que la herramienta contacta con la pieza, utilizando la conductividad del conjunto máquina-herramienta-pieza.

Estos algoritmos cuyas bases matemáticas han sido ampliamente descritas, han sido aplicados a la predicción on-line de la rugosidad superficial con unos **resultados prácticos** en el diseño **realmente muy alentadores**, corroborados con ensayos masivos en la fase final de validación. **Estos modelos han sido evaluados experimentalmente por medio de cifras de mérito tales como la suma de errores cuadráticos (*SSE*), suma de errores normalizados cuadráticos (*NSSE*), error de predicción final (*FPE*), error relativo medio (*MRE*), varianza estimada de ruido (*ENV*),** entre otros. Tal y como se observa, ambos modelos predicen con bastante exactitud la rugosidad superficial. En cambio, el modelo HIM presenta un error medio de un 16.71%, algo mayor que el obtenido con GFCM que es de un 15.08 %.

Las cifras de mérito han corroborado que el diseño, desarrollo e implementación de estrategias de supervisión de procesos, cuyos métodos estén basados en técnicas de Inteligencia Artificial (AI), y que hayan sido embebidas en una plataforma de tiempo real, modular, en red y reconfigurable, para la monitorización inteligente de sistemas complejos, puedan ser efectivas para hacer frente a la complejidad intrínseca de procesos físicos, como es el caso de los procesos de microfabricación estudiados en esta Tesis Doctoral, y conducen, por tanto, a una mejoría sustancial de su funcionamiento y eficiencia.

Desde el punto de vista técnico, la contribución fundamental de esta Tesis Doctoral es que a partir de la mínima información sensorial posible (señal de aceleración y señales del sensor de conductancia) y de la mínima cantidad de información sobre las condiciones de corte (avance por diente), se ha podido detectar en tiempo real, y de forma simultánea y en paralelo, el estado de la herramienta de corte y estimar la rugosidad superficial on-line. Este resultado técnico, supone un salto cualitativo importante sin precedentes en la investigación industrial en el campo de la microfabricación, y por tanto un resultado destacado desde la perspectiva de la ingeniería mecánica y de fabricación.

Como parte del proceso de evaluación final, todas las estrategias embebidas desarrolladas han sido validadas rigurosamente en una plataforma experimental de tiempo real, mediante una ejecución simultánea y en paralelo de todos los módulos que componen la arquitectura final. Para ello, se han realizado ensayos en operaciones de micromecanizado para evaluar el desempeño del sistema desarrollado. Esta evaluación se ha realizado a partir de cifras de mérito que comparan las estimaciones o decisiones del sistema de monitorización y el comportamiento real de la operación de corte.

Por una parte, se ha obtenido **un nivel de acierto de un 87%**, en la detección de los cambios de estados de la herramienta-material por el algoritmo basado en reglas y en una máquina de estados finitos. **Sin embargo, se han obtenido falsas detecciones** en el resto de casos analizados, **la mayoría de ellos en las dos regiones de transición** (entrada o salida de la herramienta del material). **Esto se debe a las vibraciones de la herramienta durante la transición en la entrada al material.** Este grado de acierto durante los estados de transición es mejorable, reajustando los parámetros de configuración del algoritmo de monitorización.

Por otra parte, se ha obtenido **un valor de rugosidad superficial de 160,4797 nm de media, con un error en la estimación del 24,07%.**

Como etapa final de este capítulo, el sistema de supervisión inteligente ha sido aplicado a un método de fabricación industrial. La evaluación de las estrategias de supervisión, embebidas en la plataforma de tiempo real, modular, en red y reconfigurable, se ha realizado **durante la fabricación de una pieza compleja correspondiente a un componente aeroespacial que se desarrolla en la empresa MECAES (Mecanizados Escribano S.L.).** En este caso, los resultados concluyen **que se han sido altamente positivos en la determinación de los estados del corte y la detección de interrupciones para el método de fabricación industrial con una tasa de acierto del 90%.** En cambio, para la estimación de la rugosidad superficial se ha podido observar una predicción en el valor de R_a de 202,4394 nm de media, durante todo el proceso de fabricación de la pieza, presentando un error medio del 30,7%.

Los dos procedimientos computacionales, sus metodologías y estrategias, desde el punto de vista científico y técnico, son otras de las aportaciones de este trabajo. De forma resumida, las contribuciones científico-técnicas realizadas en esta Tesis Doctoral han sido:

1. El análisis de diferentes tipos de sensores, estrategias de procesamiento y metodologías de extracción de patrones de comportamiento de las señales representativas en procesos de microfabricación. Estudio particular del proceso de microtaladrado.

2. **El diseño e implementación de una metodología de caracterización experimental en tiempo real, que consiste en la medición directa de los anchos de los pulsos de las señales digitales (contador digital hardware), provenientes del voltaje generado por la circulación de una corriente eléctrica de auto-excitación a través de un sistema complejo que sea conductor de la electricidad (resistencia de contacto). Aplicación a la caracterización del área de contacto entre la punta de la herramienta de corte y la pieza en operaciones de microfresado.**
3. **Desarrollo de un sensor de conductancia que detecte el contacto eléctrico herramienta–pieza de trabajo, en materiales conductores, el cual ha incrementado las capacidades de los sistemas de monitorización en tiempo real en procesos de mecanizado.**
4. **El diseño e implementación de un algoritmo embebido computacionalmente eficiente basado en un conjunto de reglas y máquinas de estado para la monitorización del estado de los procesos y detección de interrupciones. Estudio del caso particular de detección del estado del corte y roturas de la herramienta en procesos de micromecanizado.**
5. **Se ha diseñado e implementado dos algoritmos de modelado basados en técnicas de Inteligencia Artificial (i.e., modelado híbrido incremental HIM y algoritmo de agrupamiento borroso generalizado GFCM) para el modelado de variables representativas de procesos de alta complejidad. Así, también se han aplicado técnicas de optimización y ajuste de los parámetros de los modelos (ej., temple simulado y retro-propagación de errores). Como caso de estudio, se ha elegido como variable representativa del proceso de micromecanizado, la rugosidad superficial.**
6. **El desarrollo de un estudio comparativo entre las dos técnicas de modelado de la rugosidad superficial on-line en procesos de micromecanizado. Además, el algoritmo ganador ha sido embebido para ser ejecutado en tiempo real y de forma simultánea y en paralelo con el resto de módulos de la arquitectura.**
7. **Se ha diseñado e implementado una arquitectura de tiempo real, modular, en red y reconfigurable. Ésta contiene un sistema embebido de tiempo real, sensores, sistema de adquisición de señales, sistema intermediario, cliente web, entre otros.**
8. **Se ha aplicado la arquitectura de tiempo real al proceso complejo de Microfabricación. Las variables representativas a monitorizar han sido el estado del proceso de corte, la herramienta de corte y la rugosidad superficial on-line.**

Lista de publicaciones

Algunas de las contribuciones científicas y técnicas realizadas durante toda la etapa de investigación de esta Tesis Doctoral, han sido puestas a consideración por la comunidad científica en diferentes publicaciones realizadas, ya sea en artículos de revistas indexadas (SCI, *Science Citation Index*), actas de congresos científicos o en patentes solicitadas, las cuales se relacionan a continuación.

Publicaciones científicas:

- G. Beruvides , R. Quiza, R. del Toro, **F. Castaño**, R. E. Haber, "Correlation of the Holes Quality with the Force Signals in a Microdrilling Process of a Sintered Tungsten-Copper Alloy", *International Journal of Precision Engineering and Manufacturing*, vol. 15, Issue 9, pp 1801-1808, September 2014.
- G. Beruvides, R Quiza, M. Rivas, **F. Castaño**, and R. E. Haber, "On-line detection of run out in microdrilling of tungsten and titanium alloys", *The International Journal of Advanced Manufacturing Technology*, vol. 74, Issue 9, pp 1567-1575, October 2014.
- **F. Castaño**, R. M. Del Toro, R. E. Haber, and G. Beruvides, " Conductance sensing for monitoring micromechanical machining of conductive materials," *Sensors and Actuators A: Physical*, vol. 232, pp. 163-171, August 2015.
- G. Beruvides, **F. Castaño**, R. Quiza, and R. E. Haber, "Surface Roughness Monitoring and Optimization for Micro-milling Processes of Tungsten-copper Alloys", *Mesaurement (Journal of the International Measurement Confederation)*, Vol. 86, pp. 246 – 252, 2016.
- **F. Castaño**, R. M. del Toro, and R. E. Haber, "Characterization of tool–workpiece contact during the micromachining of conductive materials", *Mechanical Systems and Signal Processing*, (ENVIADO), 2016.

Artículos en actas de congresos:

- **F. Castano**, G. Torelli, R. Pérez-Aloe, and J. M. Carrillo, “Low-voltage rail-to-rail bulk-driven CMFB network with improved gain and bandwidth”, in *Proc. of 2014 17th IEEE International Conference on Electronics, Circuits, and Systems (ICECS)*, Atenas, Grecia, 2010, pp. 207-210.
- G. Beruvides, R. Quiza, M. Rivas, **F. Castaño**, and R. E. Haber, “A Fuzzy-Genetic System to Predict the Cutting Force in Microdrilling Processes”, in *Proc. of 2014 IEEE 40th Annual Conference on Industrial Electronics Society (IECON)*, 2014, Dallas, USA, pp. 34-37.

-
- G. Beruvides, **F. Castano**, R.E. Haber, R. Quiza, and M. Rivas, "Intelligent Models for Predicting the Thrust Force and Perpendicular Vibrations in Microdrilling Processes", in *Proc. of 2014 IEEE 26th International Conference on Tools with Artificial Intelligence (ICTAI)*, Lymasol, Chipre, 2014, pp. 506-511.
 - G. Beruvides, **F. Castano**, R.E. Haber R. Quiza, and R. Haber, "Artificial intelligence-based modelling and optimization of microdrilling processes", in *Proc. of 2014 IEEE Symposium on Computational Intelligence for Engineering Solutions (CIES)*, Orlando, USA, 2014, pp. 54-59.
 - **F. Castano**, R.E. Haber, R. M. Del Toro, and G. Beruvides, " Application of hybrid incremental modelling strategy for surface roughness estimation in micromachining processes", in *Proc. of 2014 IEEE Symposium on Computational Intelligence for Engineering Solutions (CIES)*, Orlando, USA, 2014, pp. 49-53.
 - **F. Castano**, R. E. Haber, R. M. del Toro, and G. Beruvides, "Conductance sensor for micromachining. A case study on monitoring tool-workpiece contact", in *Proc. of 2015 IEEE International Conference on Industrial Technology (ICIT)*, Sevilla, España, 2015, pp. 1422-1426.
 - G. Beruvides, C. Juanes, R. E. Haber, and **F. Castano**, "A self-learning strategy for artificial cognitive control systems", in *Proc. of 2015 13th IEEE International Conference on Industrial Informatics (INDIN)*, Cambridge, UK, 2015, pp. 1180-1185.
 - **F. Castaño**, R. M. Del Toro, R. E. Haber, and G. Beruvides, "Monitoring tool usage on the basis of sensory information in microdrilling operations", in *Proc. of 2016 IEEE International Conference on Industrial Technology (ICIT)*, Taipei, Taiwan, 2016, pp (PRESENTADO).

Patentes solicitadas:

- R. M del Toro, **F. Castaño**, R. E. Haber, "*Method and system for monitoring a machining operation in real time*". Consejo Superior de Investigaciones Científicas, Spain. **WO2014072554 A1**, May 2014.

Trabajo futuro

Esta Tesis Doctoral ha abierto otras líneas de investigación, algunas de las cuales se tratarán de abordar en trabajos futuros.

Desde el punto de vista científico, se pretende profundizar en la evaluación y el perfeccionamiento de la plataforma de tiempo real, modular, en red y reconfigurable para el control de procesos. La modularidad de la plataforma se corroborará mediante el uso de un módulo que se ha tenido en cuenta en la parte de diseño para embeber sistemas de control, cuyos objetivos serán disminuir los errores de acabado e incrementar la productividad en procesos de microfabricación.

En este sentido, ya se han dado los primeros pasos en la evaluación del diseño e implementación de la arquitectura y de los módulos que la forman en el control de sistemas complejos. A. Fernández, en su trabajo de fin de grado [269], se plantea el gran reto de desarrollar un sistema de control que permita compensar o reducir el efecto que producen las vibraciones durante las operaciones de fabricación, lo que supone un notable incremento en la eficiencia de estos procesos. A partir de los antecedentes ya conocidos sobre las afectaciones que producen las vibraciones en el acabado superficial en procesos de micromecanizado, además de las tolerancias en las piezas que se fabrican, se decide el diseño e implementación de un sistema de medición y compensación activa de vibraciones empleando como elementos de actuación dispositivos piezoeléctricos. El acondicionamiento de la arquitectura al control de las vibraciones, además de la incorporación de un nuevo (sensor capacitivo de desplazamiento piezoeléctrico), sin necesidad de cambiar el diseño, demuestra la modularidad de la arquitectura de tiempo real. Se han obtenido únicamente resultados parciales y por tanto, se prevén nuevas modificaciones y mejoras en este sistema de control, contando para ello, con la inestimable ayuda de nuevos alumnos que con sus trabajos de fin de grado y master, ayuden a la resolución de ciertos retos futuros.

En segundo lugar, se continuará trabajando en la idea fundamental de poner a disposición, las estrategias embebidas en la plataforma de tiempo real, modular, en red y reconfigurable con capacidades de interactuar con sistemas intermediarios, para que se nutran sistemas de supervisión distribuidos a nivel global o de más alto nivel, constituyendo la base para el desarrollo de sistemas distribuidos de control inteligente con capacidades cognitivas a más alto nivel. En esta línea se encuentra enmarcado dentro del proyecto de investigación CONMICRO [173], en fase de finalización.

También con un enfoque distribuido y separado en dos niveles, local y global, está el proyecto, ya iniciado, AM4G [270] en el que se aplicarán las estrategias de modelo desarrolladas en esta Tesis Doctoral, GFCM y HIM, aunque, a la monitorización del estado (CbM, *Condition-based Monitoring*) de la máquina herramienta a nivel local, en consonancia con los nuevos desafíos de los sistemas ciber-físicos (CPS, *Cyber-Physical System*). Por una parte, se pretende generar un registrador integrado de eventos y alarmas que sea modular y configurable. Se pretende determinar qué acciones locales, sobre la máquina deben realizarse de forma inmediata (parada de emergencia, parada programada, disminución de la velocidad...) en coordinación estrecha con el PLC y CNC de la máquina. Para el modelo de

esas acciones locales a partir de información de variables internas del CNC, se utilizará HIM. Por otra parte, se pretende conectar con el servidor y/o cliente para la gestión asistida de servicio por parte del operario. Es decir que nos centraremos en la conectividad con sistemas de CbM y con servidores centrales de datos para cargar en el CNC desde el servidor un asistente personalizado a partir de los datos locales y teniendo en cuenta la información global de la que él dispone. Es decir, permitirá la descarga de algoritmos sencillos de búsqueda de patrones desde el servidor. El algoritmo por excelencia seleccionado para búsqueda de patrones es GFCM.

En tercer lugar, en esta Tesis doctoral se materializó el desarrollo de un sensor inteligente para la caracterización de procesos. Esta investigación no quedará en saco roto, ya que en unos meses dará comienzo un proyecto europeo cuyo acrónimo es IoSENSE [271], cuyo principal objetivo es el desarrollo de una línea piloto flexible FE/BE de sensores para el internet de las cosas. Se pretende impulsar la competitividad europea de industrias de Componentes y Semiconductores mediante el establecimiento de tres líneas piloto de producción de componentes de sensores / MEMS, innovadores e integrables en el Internet de todas las Cosas. En este caso, el proceso o sistema al que se aplicarán estos sensores es muy variado. Sin embargo, dentro de las tareas a desarrollar se incluye comprobar el desempeño de técnicas de modelado del comportamiento y de la vida útil de sensores en el internet de las cosas. Se barajarán métodos basados en AI, entre los que se incluyen los desarrollados en esta Tesis Doctoral.

BIBLIOGRAFÍA

- [1] E. Commission, "Strategic investments in European manufacturing to rise to global challenges," in *MANUFUTURE 2015*, Luxembourg, 2015.
- [2] R. E. Haber, C. R. Peres, A. Alique, S. Ros, C. González, and J. R. Alique, "Toward intelligent machining: Hierarchical fuzzy control for the end milling process," *IEEE Transactions on Control Systems Technology*, vol. 6, pp. 188-199, 1998.
- [3] R. T. Dodhiawala, N. Sridharan, P. Raulefs, and C. Pickering, "Real-Time AI Systems: A Definition and An Architecture," in *IJCAI*, 1989, pp. 256-264.
- [4] C. A. O'Reilly and A. S. Cromarty, "'Fast' Is Not 'Real-Time': Designing Effective Real-Time AI Systems," 1985, pp. 249-257.
- [5] T. J. Laffey, P. A. Cox, J. L. Schmidt, S. M. Kao, and J. Y. Readk, "Real-time knowledge-based systems," *AI magazine*, vol. 9, p. 27, 1988.
- [6] M. P. Georgeff and F. F. Ingrand, "Decision-making in an embedded reasoning system," presented at the Proceedings of the 11th international joint conference on Artificial intelligence - Volume 2, Detroit, Michigan, 1989.
- [7] J. A. Stankovic, "Misconceptions about real-time computing: a serious problem for next-generation systems," *Computer*, vol. 21, pp. 10-19, 1988.
- [8] S. J. Young, *Real time languages: design and development*: Halsted Press, 1982.
- [9] B. Randell, J.-C. Laprie, H. Kopetz, and B. Littlewood, *Predictably Dependable Computing Systems*: Springer Publishing Company, Incorporated, 2012.
- [10] C. L. Liu and J. W. Layland, "Scheduling Algorithms for Multiprogramming in a Hard-Real-Time Environment," *J. ACM*, vol. 20, pp. 46-61, 1973.
- [11] W. Yuan and K. Nahrstedt, "Energy-efficient soft real-time CPU scheduling for mobile multimedia systems," *SIGOPS Oper. Syst. Rev.*, vol. 37, pp. 149-163, 2003.

- [12] M. Bramberger, A. Doblender, A. Maier, B. Rinner, and H. Schwabach, "Distributed embedded smart cameras for surveillance applications," *Computer*, vol. 39, pp. 68-75, 2006.
- [13] Y. Ti-Yen and W. Wolf, "Communication synthesis for distributed embedded systems," in *Computer-Aided Design, 1995. ICCAD-95. Digest of Technical Papers., 1995 IEEE/ACM International Conference on*, 1995, pp. 288-294.
- [14] M. Sánchez, U. Cortés, J. Lafuente, I. R. Roda, and M. Poch, "DAI-DEPUR: An integrated and distributed architecture for wastewater treatment plants supervision," *Artificial Intelligence in Engineering*, vol. 10, pp. 275-285, 1996.
- [15] U. Brinkschulte, A. Bechina, F. Picioroaga, E. Schneider, T. Ungerer, J. Kreuzinger, *et al.*, "A microkernel middleware architecture for distributed embedded real-time systems," in *Reliable Distributed Systems, 2001. Proceedings. 20th IEEE Symposium on*, 2001, pp. 218-226.
- [16] M. Reichenbach, B. Pfundt, and D. Fey, "Designing and manufacturing of real embedded multi-core CPUs: A holistic teaching approach in computer architecture," in *Microelectronics Education (EWME), 10th European Workshop on*, 2014, pp. 213-218.
- [17] D. Lipiński and M. Majewski, "Intelligent Monitoring and Optimization of Micro- and Nano-Machining Processes," in *Mechatronics - Ideas for Industrial Application*. vol. 317, J. Awrejcewicz, R. Szewczyk, M. Trojnacki, and M. Kaliczyńska, Eds., ed: Springer International Publishing, 2015, pp. 101-110.
- [18] S. W. A. Hashmi, M. Rehan, M. Aamir, H. Kumar, and F. Liaquat, "Distributed process monitoring and control using FPGA," in *Wireless Communications, Vehicular Technology, Information Theory and Aerospace & Electronic Systems (VITAE), 2014 4th International Conference on*, 2014, pp. 1-5.
- [19] I. Humphreys, G. Eisenblätter, and G. E. O'Donnell, "FPGA based Monitoring Platform for Condition Monitoring in Cylindrical Grinding," *Procedia CIRP*, vol. 14, pp. 448-453, // 2014.
- [20] U. Mönks, H. Trsek, L. Dürkop, V. Geneiß, and V. Lohweg, "Towards distributed intelligent sensor and information fusion," *Mechatronics*, 2015.
- [21] J. Kolodko and L. Vlacic, "Cooperative autonomous driving at the Intelligent Control Systems Laboratory," *Intelligent Systems, IEEE*, vol. 18, pp. 8-11, 2003.
- [22] G. Fiol-Roig, "Knowledge-based architecture for real time supervision of dynamic processes," in *Proceedings of the Eighth IASTED International Conference on Artificial Intelligence and Soft Computing*, Marbella, 2004, pp. 322-327.
- [23] A. M. Turing, "Computing machinery and intelligence," in *Parsing the Turing Test: Philosophical and Methodological Issues in the Quest for the Thinking Computer*, ed: Springer Netherlands, 2009, pp. 23-65.
- [24] L. A. Zadeh, "Soft Computing and Fuzzy Logic," *IEEE Software*, vol. 11, pp. 48-56, 1994.
- [25] L. A. Zadeh, "Some reflections on soft computing, granular computing and their roles in the conception, design and utilization of information/intelligent systems," *Soft Computing*, vol. 2, pp. 23-25, 1998/04/01 1998.

-
- [26] J. L. Verdegay, R. R. Yager, and P. P. Bonissone, "On heuristics as a fundamental constituent of soft computing," *Fuzzy Sets and Systems*, vol. 159, pp. 846-855, 2008.
- [27] P. P. Bonissone, Y. U. T. O. Chen, K. Goebel, and P. S. Khedkar, "Hybrid soft computing systems: Industrial and commercial applications," *Proceedings of the IEEE*, vol. 87, pp. 1641-1667, 1999.
- [28] F. Glover, "Future paths for integer programming and links to artificial intelligence," *Computers and Operations Research*, vol. 13, pp. 533-549, 1986.
- [29] I. Osman and G. Laporte, "Metaheuristics: A bibliography," *Annals of Operations Research*, vol. 63, pp. 511-623, 1996/10/01 1996.
- [30] B. Denby and S. Le Hégarat-Masclé, "Swarm intelligence in optimisation problems," *ACAT 2002*, vol. 502, pp. 364-368, 2003.
- [31] T. Back, U. Hammel, and H. P. Schwefel, "Evolutionary computation: Comments on the history and current state," *IEEE Transactions on Evolutionary Computation*, vol. 1, pp. 3-17, 1997.
- [32] Á. E. Eiben, R. Hinterding, and Z. Michalewicz, "Parameter control in evolutionary algorithms," *IEEE Transactions on Evolutionary Computation*, vol. 3, pp. 124-141, 1999.
- [33] Z. Michalewicz, "Evolutionary algorithms for constrained parameter optimization problems," *Evolutionary Computation*, vol. 4, pp. 1-32, 1996.
- [34] Y. Jin and J. Branke, "Evolutionary optimization in uncertain environments - A survey," *IEEE Transactions on Evolutionary Computation*, vol. 9, pp. 303-317, 2005.
- [35] L. N. de Castro, "Fundamentals of natural computing: an overview," *Physics of Life Reviews*, vol. 4, pp. 1-36, 2007.
- [36] K. J. Kim and S. B. Cho, "A comprehensive overview of the applications of artificial life," *Artificial Life*, vol. 12, pp. 153-182, 2006.
- [37] C. P. Lim and L. C. Jain, "Advances in swarm intelligence," in *Studies in Computational Intelligence* vol. 248, C. P. Lim, L. C. Jain, and S. Dehuri, Eds., ed, 2009, pp. 1-7.
- [38] M. Dorigo, V. Maniezzo, and A. Coloni, "Ant system: Optimization by a colony of cooperating agents," *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, vol. 26, pp. 29-41, 1996.
- [39] J. Kennedy and R. Eberhart, "Particle swarm optimization," in *Proceedings of the 1995 IEEE International Conference on Neural Networks. Part 1 (of 6)*, Piscataway, NJ, United States
Perth, Aust, 1995, pp. 1942-1948.
- [40] T. Weise, "Global optimization algorithms-theory and application," *Self-Published*, 2009.
- [41] S. Russell and P. Norvig, "Artificial intelligence: a modern approach," 1995.
- [42] V. Černý, "Thermodynamical approach to the traveling salesman problem: An efficient simulation algorithm," *Journal of Optimization Theory and Applications*, vol. 45, pp. 41-51, 1985/01/01 1985.
-

- [43] S. Kirkpatrick, C. D. Gelatt, and M. P. Vecchi, "Optimization by Simulated Annealing," *Science*, vol. 220, pp. 671-680, 1983.
- [44] R. Y. Rubinstein, "Optimization of computer simulation models with rare events," *European Journal of Operational Research*, vol. 99, pp. 89-112, 5/16/ 1997.
- [45] J. A. Nelder and R. Mead, "A Simplex Method for Function Minimization," *The Computer Journal*, vol. 7, pp. 308-313, January 1, 1965 1965.
- [46] P. P. Bonissone, "Hybrid soft computing systems: where are we going?," in *ECAI*, 2000, pp. 739-746.
- [47] D. Heckerman, D. Geiger, and D. Chickering, "Learning Bayesian networks: The combination of knowledge and statistical data," *Machine Learning*, vol. 20, pp. 197-243, 1995/09/01 1995.
- [48] R. R. Yager and D. P. Filev, "Including probabilistic uncertainty in fuzzy logic controller modeling using Dempster-Shafer theory," *Systems, Man and Cybernetics, IEEE Transactions on*, vol. 25, pp. 1221-1230, 1995.
- [49] E. H. Mamdani and S. Assilian, "An experiment in linguistic synthesis with a fuzzy logic controller," *International Journal of Man-Machine Studies*, vol. 7, pp. 1-13, 1975/01/01 1975.
- [50] T. Takagi and M. Sugeno, "Fuzzy identification of systems and its applications to modeling and control," *Systems, Man and Cybernetics, IEEE Transactions on*, vol. SMC-15, pp. 116-132, 1985.
- [51] M. Sugeno and G. T. Kang, "Structure identification of fuzzy model," *Fuzzy Sets and Systems*, vol. 28, pp. 15-33, 10// 1988.
- [52] J. Moody and C. J. Darken, "Fast learning in networks of locally-tuned processing units," *Neural Comput.*, vol. 1, pp. 281-294, 1989.
- [53] W. T. Miller, III, F. H. Glanz, and L. G. Kraft, III, "CMAS: an associative neural network alternative to backpropagation," *Proceedings of the IEEE*, vol. 78, pp. 1561-1567, 1990.
- [54] R. R. Selmic and F. L. Lewis, "Neural-network approximation of piecewise continuous functions: application to friction compensation," *Neural Networks, IEEE Transactions on*, vol. 13, pp. 745-751, 2002.
- [55] R. Grino, G. Cembrano, and C. Torras, "Non-linear system identification using additive dynamic neural networks-two on-line approaches," *Circuits and Systems I: Fundamental Theory and Applications, IEEE Transactions on*, vol. 47, pp. 150-165, 2000.
- [56] T. Kohonen, "Self-organized formation of topologically correct feature maps," *Biological Cybernetics*, vol. 43, pp. 59-69, 1982/01/01 1982.
- [57] J. J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities," *Proceedings of the national academy of sciences*, vol. 79, pp. 2554-2558, 1982.
- [58] G. A. Carpenter and S. Grossberg, "A massively parallel architecture for a self-organizing neural pattern recognition machine," *Computer Vision, Graphics, and Image Processing*, vol. 37, pp. 54-115, 1// 1987.

-
- [59] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Computation*, vol. 9, pp. 1735-1780, 1997.
- [60] J. Zhao and J. Shawe-Taylor, "Stochastic connection neural networks," 1995.
- [61] R. M. d. Toro Matamoros, "Métodos clásicos y de soft-computing en la optimización de procesos complejos: Aplicación a un proceso de fabricación," Ingeniería Informática, Universidad Autónoma de Madrid, 2011.
- [62] R. Haber, R. Toro, J. Godoy, and A. Gajate, "Intelligent Tuning of Fuzzy Controllers by Learning and Optimization," in *Fuzzy Modeling and Control: Theory and Applications*. vol. 9, F. Matía, G. N. Marichal, and E. Jiménez, Eds., ed: Atlantis Press, 2014, pp. 135-158.
- [63] D. E. Goldberg, *Genetic Algorithms in Search, Optimization and Machine Learning*: Addison-Wesley Longman Publishing Co., Inc., 1989.
- [64] J. Koza, "Genetic programming as a means for programming computers by natural selection," *Statistics and Computing*, vol. 4, pp. 87-112, 1994/06/01 1994.
- [65] L. J. Fogel, "On the organization of intellect," 1964.
- [66] I. Rechenberg, "Cybernetic solution path of an experimental problem," 1965.
- [67] L. A. Zadeh, "Probability measures of Fuzzy events," *Journal of Mathematical Analysis and Applications*, vol. 23, pp. 421-427, 8// 1968.
- [68] P. Smets, "The degree of belief in a fuzzy event," *Information Sciences*, vol. 25, pp. 1-19, 1981.
- [69] D. J. Montana and L. Davis, "Training feedforward neural networks using genetic algorithms ." in *Proceedings of the 11th International Joint Conference on Artificial Intelligence (IJCAI-89)*, San Francisco, CA, 1989, pp. 762-767.
- [70] V. Maniezzo, "Genetic evolution of the topology and weight distribution of neural networks," *IEEE Transactions on Neural Networks*, vol. 5, pp. 39-53, 1994.
- [71] D. B. Fogel, L. J. Fogel, and V. W. Porto, "Evolutionary methods for training neural networks," in *IEEE Conference on Neural Networks for Ocean Engineering*, Washington, DC, USA, 1991, pp. 317-327.
- [72] J. R. McDonnell and D. Waagen, "Evolving neural network connectivity," in *IEEE International Conference on Neural Networks (ICNN'93)*, San Francisco, CA, 1993, pp. 863-868.
- [73] R. A. Jacobs, "Increased rates of convergence through learning rate adaptation," *Neural Networks*, vol. 1, pp. 295-307, 1988.
- [74] P. Arabshahi, J. J. Choi, R. J. Marks, and T. P. Caudell, "Fuzzy control of backpropagation," in *IEEE International Conference on Fuzzy Systems (FUZZ-IEEE'92)*, San Diego, CA, USA, 1992, pp. 967-972.
- [75] F. Herrera and M. Lozano, "Adaptive genetic algorithms based on fuzzy techniques," in *Information Processing and Management of Uncertainty in Knowledge-Based Systems (IPMU'96)*, Granada, Spain, 1996, pp. 775-780.
- [76] R. Kumari, V. K. Sharma, and S. Kumar, "Adaptive Neural Fuzzy Inference System for Employability Assessment," *assessment*, vol. 3, pp. 159-164, 2014.
-

- [77] J. S. R. Jang and C. T. Sun, "Functional equivalence between radial basis function networks and fuzzy inference systems," *Neural Networks, IEEE Transactions on*, vol. 4, pp. 156-159, 1993.
- [78] H. Bersini, G. Bontempi, and C. Decaestecker, "Comparing RBF and fuzzy inference systems on theoretical and practical basis," *Proc. Int. Conf. Artificial Neural Networks. ICANN '95*, vol. 1, pp. 169-174, 1995.
- [79] D. Nauck, "A Fuzzy Perceptron as a Generic Model for Neuro-Fuzzy Approaches," in *Proceedings of Fuzzy-systeme'94, Second GI-workshop*, Munich, 1994.
- [80] D. Nauck and R. Kruse, "Neuro-Fuzzy Classification with NEFCLASS," in *Operations Research Proceedings 1995*, Berlin, 1996, pp. 294-299.
- [81] A. Gajate and R. E. Haber, "Internal model control based on a neurofuzzy system for network applications. a case study on the high-performance drilling process," *IEEE Transactions on Automation Science and Engineering*, vol. 6, pp. 367-372, 2009.
- [82] J.-S. R. Jang, "ANFIS: adaptive-network-based fuzzy inference system," *IEEE Transactions on Systems, Man and Cybernetics*, vol. 23, pp. 665-685, 1993.
- [83] O. Cordón, F. Herrera, and M. Lozano, "A Classified Review On The Combination Fuzzy Logic-Genetic Algorithms Bibliography: 1989 -1995," Dept. of Computer Science and A.I., University of Granada. Technical Report DECSAI-95129, December 1996.
- [84] C. L. Karr, "Design of an adaptive fuzzy logic controller using genetic algorithms," in *Proc. Int. Conf. Genetic Algorithms (ICGA '91)*, San Diego, CA, 1991, pp. 450-456.
- [85] M. A. Lee and H. Tagaki, "Dynamic control of genetic algorithm using fuzzy logic techniques," in *Proc. 5th Int. Conf. Genetic Algorithms.*, San Mateo, CA, 1992, pp. 76-83.
- [86] P. P. Bonissone, P. S. Khedkar, and Y. Chen, "Genetic algorithms for automated tuning of fuzzy controllers: a transportation application," in *Proceedings of the Fifth IEEE International Conference on Fuzzy Systems (FUZZ-IEEE '96)*, New Orleans, LA, 1996, pp. 674-680.
- [87] L. Zheng, "A practical guide to tune of proportional and integral (PI) like fuzzy controllers," in *IEEE International Conference on Fuzzy Systems*, 1992, pp. 633-640.
- [88] M. Correa, C. Bielza, M. D. J. Ramirez, and J. R. Alique, "A Bayesian network model for surface roughness prediction in the machining process," *International Journal of Systems Science*, vol. 39, pp. 1181-1192, 2008.
- [89] E. B. Flynn and M. D. Todd, "Bayesian probabilistic structural modeling for optimal sensor placement in ultrasonic guided wave-based structural health monitoring," in *Proceedings of SPIE - The International Society for Optical Engineering*, San Diego, CA, 2010.
- [90] P. Elliott and B. Williams, "DNNF-based belief state estimation," in *Proceedings of the National Conference on Artificial Intelligence*, Boston, MA, 2006, pp. 36-41.
- [91] C. Alippi and V. Piuri, "Experimental neural networks for prediction and identification," *IEEE Transactions on Instrumentation and Measurement*, vol. 45, pp. 670-676, 1996.

-
- [92] D. W. Coit, B. T. Jackson, and A. E. Smith, "Static neural network process models: Considerations and case studies," *International Journal of Production Research*, vol. 36, pp. 2953-2967, 1998.
- [93] C. Feng, X. Wang, and Z. Yu, "Neural networks modelling of honing surface roughness parameter defined by ISO 13565," *SIAM Journal of Manufacturing Systems*, vol. 21, pp. 1-35, 2002.
- [94] J. Chen and C.-M. Liao, "Dynamic process fault monitoring based on neural network and PCA," *Journal of Process Control*, vol. 12, pp. 277-289, 2// 2002.
- [95] J.-b. Yu and L.-f. Xi, "A neural network ensemble-based model for on-line monitoring and diagnosis of out-of-control signals in multivariate manufacturing processes," *Expert Systems with Applications*, vol. 36, pp. 909-921, 1// 2009.
- [96] N. Gebraeel, M. Lawley, R. Liu, and V. Parmeshwaran, "Residual life predictions from vibration-based degradation signals: a neural network approach," *Industrial Electronics, IEEE Transactions on*, vol. 51, pp. 694-700, 2004.
- [97] "Neural-Network Models of Rainfall-Runoff Process," *Journal of Water Resources Planning and Management*, vol. 121, pp. 499-508, 1995.
- [98] C. K. Yoo, P. A. Vanrolleghem, and I.-B. Lee, "Non-linear modeling and adaptive monitoring with fuzzy and multivariate statistical methods in biological wastewater treatment plants," *Journal of Biotechnology*, vol. 105, pp. 135-163, 10/9/ 2003.
- [99] K. Becker, B. Thull, H. Käsmacher-Leidinger, S. Johannes, G. Rau, G. Kalff, *et al.*, "Design and validation of an intelligent patient monitoring and alarm system based on a fuzzy logic process model," *Artificial Intelligence in Medicine*, vol. 11, pp. 33-53, 9// 1997.
- [100] P. F. Fantoni, "A NEURO-FUZZY MODEL APPLIED TO FULL RANGE SIGNAL VALIDATION OF PWR NUCLEAR POWER PLANT DATA," *International Journal of General Systems*, vol. 29, pp. 305-320, 2000/01/01 2000.
- [101] W. Wang, F. Ismail, and F. Golnaraghi, "A neuro-fuzzy approach to gear system monitoring," *Fuzzy Systems, IEEE Transactions on*, vol. 12, pp. 710-723, 2004.
- [102] R. Kothamasu and S. H. Huang, "Adaptive Mamdani fuzzy model for condition-based maintenance," *Fuzzy Sets and Systems*, vol. 158, pp. 2715-2733, 12/16/ 2007.
- [103] C. Waewsak, A. Nopharatana, and P. Chaiprasert, "Neural-fuzzy control system application for monitoring process response and control of anaerobic hybrid reactor in wastewater treatment and biogas production," *Journal of Environmental Sciences*, vol. 22, pp. 1883-1890, 12// 2010.
- [104] T. Kamel, Y. Biletskiy, and L. Chang, "Fault diagnosis and on-line monitoring for grid-connected single-phase inverters," *Electric Power Systems Research*, vol. 126, pp. 68-77, 2015.
- [105] K. Zarkogianni, K. Mitsis, E. Litsa, M. T. Arredondo, G. Fico, A. Fioravanti, *et al.*, "Comparative assessment of glucose prediction models for patients with type 1 diabetes mellitus applying sensors for glucose and physical activity monitoring," *Medical and Biological Engineering and Computing*, 2015.
-

- [106] M. Dzakpasu, M. Scholz, V. McCarthy, S. Jordan, and A. Sani, "Adaptive neuro-fuzzy inference system for real-time monitoring of integrated-constructed wetlands," *Water Science and Technology*, vol. 71, pp. 22-30, 2015.
- [107] A. I. Azmi, "Monitoring of tool wear using measured machining forces and neuro-fuzzy modelling approaches during machining of GFRP composites," *Advances in Engineering Software*, vol. 82, pp. 53-64, 2015.
- [108] J. Kim and P. Bentley, "The artificial immune model for network intrusion detection," in *7th European Conference on Intelligent Techniques and Soft Computing (EUFIT'99)*, Aachen, Germany, 1999.
- [109] X. Li, L. Gao, X. Shao, C. Zhang, and C. Wang, "Mathematical modeling and evolutionary algorithm-based approach for integrated process planning and scheduling," *Computers & Operations Research*, vol. 37, pp. 656-667, 4// 2010.
- [110] M. Foukarakis, A. Leonidis, M. Antona, and C. Stephanidis, "Combining Finite State Machine and Decision-Making Tools for Adaptable Robot Behavior," in *Universal Access in Human-Computer Interaction. Aging and Assistive Environments*. vol. 8515, C. Stephanidis and M. Antona, Eds., ed: Springer International Publishing, 2014, pp. 625-635.
- [111] M. M. Silva Junior, F. C. Cruz, P. C. M. A. Farias, E. F. Simas Filho, M. C. S. Albuquerque, I. C. da Silva, *et al.*, "Neural decision support system for ultrasound nondestructive evaluation embedded in a DSP," in *Instrumentation and Measurement Technology Conference (I2MTC), 2015 IEEE International*, 2015, pp. 416-421.
- [112] R. E. King, "Expert supervision and control of a large-scale plant," *Journal of Intelligent and Robotic Systems*, vol. 5, pp. 167-176, 1992.
- [113] W. Treutterer, R. Cole, K. Lüddecke, G. Neu, C. Rapson, G. Raupp, *et al.*, "ASDEX upgrade discharge control system - A real-time plasma control framework," *Fusion Engineering and Design*, vol. 89, pp. 146-154, 2014.
- [114] K. Cantillo, R. E. Haber, J. E. Jiménez, Á. Alique, and R. Galán, "CORBA-Based open platform for processes monitoring. An application to a complex electromechanical process," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* vol. 3036, ed, 2004, pp. 523-526.
- [115] G. Viano, A. Parodi, J. Alty, C. Khalil, I. Angulo, D. Biglino, *et al.*, "Adaptive user interface for process control based on multi-agent approach," *Proceedings of the Working Conference on Advance Visual Interfaces (AVI 2000)*, pp. 201-204, 2000.
- [116] 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*, vol. 54-55, pp. 55-65, 2012.
- [117] D. I. D. Cho and H. J. Yoo, "Microfabrication methods for biodegradable polymeric carriers for drug delivery system applications: A review," *Journal of Microelectromechanical Systems*, vol. 24, pp. 10-18, 2015.
- [118] S. K. Vajpai, R. K. Dube, A. Kanwat, and S. Kumawat, "Synthesis and characterisation of Cu-W nanocomposite strips," *Materials Science and Technology (United Kingdom)*, vol. 29, pp. 285-293, 2013.

-
- [119] E. Uhlmann, S. Piltz, and K. Schauer, "Micro milling of sintered tungsten-copper composite materials," *Journal of Materials Processing Technology*, vol. 167, pp. 402-407, 2005.
- [120] J. Cecil, M. B. Bharathi Raj Kumar, Y. Lu, and V. Basallali, "A review of micro-devices assembly techniques and technology," *International Journal of Advanced Manufacturing Technology*, 2015.
- [121] S. Skoczypiec, "Application of laser and electrochemical interaction in sequential and hybrid micromachining processes," *Bulletin of the Polish Academy of Sciences: Technical Sciences*, vol. 63, pp. 305-314, 2015.
- [122] P. Piljek, Z. Keran, and M. Math, "Micromachining–Review of Literature from 1980 to 2010," *Interdisciplinary Description of Complex Systems*, vol. 12, pp. 1-27, 2014.
- [123] F. Schmitt and A. Olowinsky, "Chapter 26 - Laser Beam Micro-joining A2 - Qin, Yi," in *Micromanufacturing Engineering and Technology (Second Edition)*, ed Boston: William Andrew Publishing, 2015, pp. 613-635.
- [124] R. Leach, "Chapter 1 - Introduction to Metrology for Advanced Manufacturing and Micro- and Nanotechnology," in *Fundamental Principles of Engineering Nanometrology (Second Edition)*, ed Oxford: William Andrew Publishing, 2014, pp. 1-6.
- [125] M. J. Jackson, M. D. Whitfield, G. M. Robinson, R. G. Handy, J. S. Morrell, J. P. Davim, *et al.*, "Fundamentals of Machining," in *Machining with Nanomaterials*, J. M. Jackson and S. J. Morrell, Eds., ed Cham: Springer International Publishing, 2015, pp. 1-35.
- [126] P. Cardoso and J. P. Davim, "A brief review on micromachining of materials," *Reviews on Advanced Materials Science*, vol. 30, pp. 98-102, 2012.
- [127] D. Huo, *Micro-cutting: fundamentals and applications*: John Wiley & Sons, 2013.
- [128] E. P. DeGarmo, J. T. Black, and R. A. Kohser, *Materiales y procesos de fabricación*, 2nd ed. vol. 1. Barcelona: Reverte, S.A., 1994.
- [129] E. Gentili, L. Tabaglio, and F. Aggogeri, *Review on micromachining techniques*: Springer, 2005.
- [130] Y. Okazaki, N. Mishima, and K. Ashida, "Microfactory- concept, history and developments," *Transactions of ASME. Journal of Manufacturing Engineering*, vol. 126, pp. 837-844, 2004.
- [131] -. WTEC Report, "Additive/Subtractive Manufacturing in Europe," www.wtec.org, 2004.
- [132] H. S. Jang and D. S. Park, "Microfabrication of Microchannels for Fuel Cell Plates," *Sensors*, vol. 10, pp. 167-175, 2009.
- [133] R. Teti, K. Jemielniak, G. O'Donnell, and D. Dornfeld, "Advanced monitoring of machining operations," *CIRP Annals - Manufacturing Technology*, vol. 59, pp. 717-739, 2010.
- [134] Z. Cao and H. Li, "Research of micro burr in miniaturized milling process," vol. 566, ed. Jeju Island, 2012, pp. 612-615.
-

- [135] Z. Liu, X. Wang, and Z. Fang, "Principal composition analysis of the characteristic parameter of vibration signal in micro milling process," *Nanotechnology and Precision Engineering*, vol. 8, pp. 269-274, 2010.
- [136] M. Muradov, J. Cullen, and A. Mason, "Real-Time Monitoring of Meat Drying Process Using Electromagnetic Wave Sensors," in *Next Generation Sensors and Systems*. vol. 16, S. C. Mukhopadhyay, Ed., ed: Springer International Publishing, 2016, pp. 221-233.
- [137] M. D. Judd, Y. Li, and I. B. B. Hunter, "Partial discharge monitoring of power transformers using UHF sensors. Part I: sensors and signal interpretation," *Electrical Insulation Magazine, IEEE*, vol. 21, pp. 5-14, 2005.
- [138] M. F. H. Işık, M. R.; Yanmaz, H.; Yilmaz, C., "Fault Detection and Protection of Induction Motor by Real Time Monitoring and Controlling of the Motor Parameters," *Journal of Automation and Control Engineering*, vol. 4, p. 5, 2016.
- [139] P. V. Er, C. S. Teo, and K. K. Tan, "Approach towards sensor placement, selection and fusion for real-time condition monitoring of precision machines," *Mechanical Systems and Signal Processing*, vol. 68–69, pp. 105-124, 2// 2016.
- [140] M. Nouri, B. K. Fussell, B. L. Ziniti, and E. Linder, "Real-time tool wear monitoring in milling using a cutting condition independent method," *International Journal of Machine Tools and Manufacture*, vol. 89, pp. 1-13, 2// 2015.
- [141] A. Caggiano, R. Teti, R. Perez, and P. Xirouchakis, "Wire EDM Monitoring for Zero-defect Manufacturing based on Advanced Sensor Signal Processing," *Procedia CIRP*, vol. 33, pp. 315-320, // 2015.
- [142] E. Portillo, M. Marcos, I. Cabanes, and D. Orive, "Real-time monitoring and diagnosing in wire-electro discharge machining," *The International Journal of Advanced Manufacturing Technology*, vol. 44, pp. 273-282, 2009/09/01 2009.
- [143] I. Cabanes, E. Portillo, M. Marcos, and J. A. Sánchez, "An industrial application for on-line detection of instability and wire breakage in wire EDM," *Journal of Materials Processing Technology*, vol. 195, pp. 101-109, 1/1/ 2008.
- [144] K. L. Petri, R. E. Billo, and B. Bidanda, "A Neural Network Process Model for Abrasive Flow Machining Operations," *Journal of Manufacturing Systems*, vol. 17, pp. 52-64, 1998.
- [145] H. C. Zhang and S. H. Huang, "Applications of neural networks in manufacturing: A state-of-the-art survey," *International Journal of Production Research*, vol. 33, pp. 705-728, 1995.
- [146] I. N. Tansel, T. T. Arkan, W. Y. Bao, N. Mahendrakar, B. Shisler, D. Smith, *et al.*, "Tool wear estimation in micro-machining.: Part I: tool usage–cutting force relationship," *International Journal of Machine Tools and Manufacture*, vol. 40, pp. 599-608, 3// 2000.
- [147] I. N. Tansel, T. T. Arkan, W. Y. Bao, N. Mahendrakar, B. Shisler, D. Smith, *et al.*, "Tool wear estimation in micro-machining.: Part II: neural-network-based periodic inspector for non-metals," *International Journal of Machine Tools and Manufacture*, vol. 40, pp. 609-620, 3// 2000.

-
- [148] J. Ranjan, K. Patra, and T. Szalay, "Application of Artificial neural network and wavelet packet transform for vibration signal based monitoring in mechanical micro drilling," in *2015 1st International Conference On Futuristic Trends in Computational Analysis and Knowledge Management, ABLAZE 2015*, 2015, pp. 1-6.
- [149] W.-H. Hsieh, M.-C. Lu, and S.-J. Chiou, "Application of backpropagation neural network for spindle vibration-based tool wear monitoring in micro-milling," *The International Journal of Advanced Manufacturing Technology*, vol. 61, pp. 53-61, 2012/07/01 2012.
- [150] E. Swidenbank, S. McLoone, D. Flynn, G. W. Irwin, M. D. Brown, and B. W. Hogg, "Neural network based control for synchronous generators," *Energy Conversion, IEEE Transactions on*, vol. 14, pp. 1673-1678, 1999.
- [151] K. P. Zhu, G. S. Hong, and Y. S. Wong, "A comparative study of feature selection for hidden Markov model-based micro-milling tool wear monitoring," *Machining Science and Technology*, vol. 12, pp. 348-369, 2008.
- [152] M. A. Hassan, M. A. El-Sharief, A. Aboul-Kasem, S. Ramesh, and J. Purbolaksono, "A fuzzy model for evaluation and prediction of slurry erosion of 5127 steels," *Materials & Design*, vol. 39, pp. 186-191, 8// 2012.
- [153] Q. Ren, M. Balazinski, K. Jemielniak, L. Baron, and S. Achiche, "Experimental and fuzzy modelling analysis on dynamic cutting force in micro milling," *Soft Computing*, vol. 17, pp. 1687-1697, 2013/09/01 2013.
- [154] G. Skrabalak, M. Zybura-Skrabalak, and A. Ruszaj, "Building of rules base for fuzzy-logic control of the ECDM process," *Journal of Materials Processing Technology*, vol. 149, pp. 530-535, 6/10/ 2004.
- [155] X. H. Suganthi, U. Natarajan, S. Sathiyamurthy, and K. Chidambaram, "Prediction of quality responses in micro-EDM process using an adaptive neuro-fuzzy inference system (ANFIS) model," *The International Journal of Advanced Manufacturing Technology*, vol. 68, pp. 339-347, 2013/09/01 2013.
- [156] 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*, vol. 24, pp. 19-32, 2013/01/01 2013.
- [157] S. Samanta and S. Chakraborty, "Parametric optimization of some non-traditional machining processes using artificial bee colony algorithm," *Engineering Applications of Artificial Intelligence*, vol. 24, pp. 946-957, 9// 2011.
- [158] P. Rajesh Kumar, Y. Vinod, and J. Ramkumar, "Neural Network Based Modelling and GRA Coupled PCA Optimization of Hole Sinking Electro Discharge Micromachining," *International Journal of Manufacturing, Materials, and Mechanical Engineering (IJMMME)*, vol. 4, pp. 1-21, 2014.
- [159] M. Alakesh, "Taguchi, Fuzzy Logic and Grey Relational Analysis Based Optimization of ECSM Process during Micro Machining of E-Glass-Fibre-Epoxy Composite," in *Computational Methods for Optimizing Manufacturing Technology: Models and Techniques*, J. P. Davim, Ed., ed Hershey, PA, USA: IGI Global, 2012, pp. 242-261.
-

- [160] G. Beruvides, R. Quiza, M. Rivas, F. Castano, and R. E. Haber, "A fuzzy-genetic system to predict the cutting force in microdrilling processes," in *Industrial Electronics Society, IECON 2014 - 40th Annual Conference of the IEEE*, 2014, pp. 34-37.
- [161] Y.-M. Zhu, J.-P. Chen, and G. Zheng, "Application of Neural Network on Burr Expert System in Micro-machining," *International Journal of Intelligent Systems and Applications (IJISA)*, vol. 3, p. 1, 2011.
- [162] D. Goswami and S. Chakraborty, "Differential search algorithm-based parametric optimization of electrochemical micromachining processes," *International Journal of Industrial Engineering Computations*, vol. 5, pp. 41-54, 2014.
- [163] C. Venkatesh, N. M. Arun, and R. Venkatesan, "Optimization of micro drilling parameters of B4C DRMM Al 6063 composite in μ ECM using Taguchi coupled Fuzzy Logic," in *12th Global Congress on Manufacturing and Management, GCMM 2014*, 2014, pp. 975-985.
- [164] K. K. Saxena, S. Agarwal, and J. Mukhopadhyay, "Effect of machining parameters on surface roughness in μ -EDM of conductive SiC," in *ASME 2014 International Mechanical Engineering Congress and Exposition, IMECE 2014*, 2014.
- [165] S. M. Karazi, A. Issa, and D. Brabazon, "Comparison of ANN and DoE for the prediction of laser-machined micro-channel dimensions," *Optics and Lasers in Engineering*, vol. 47, pp. 956-964, 9// 2009.
- [166] D. Teixidor, M. Grzenda, A. Bustillo, and J. Ciurana, "Modeling pulsed laser micromachining of micro geometries using machine-learning techniques," *Journal of Intelligent Manufacturing*, vol. 26, pp. 801-814, 2015.
- [167] V. B. Pansare and S. B. Sharma, "Chip load-responsive optimization of micro-milling of engineering materials," *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, pp. 1-6, 2015/08/13 2015.
- [168] Q. Ren, M. Balazinski, L. Baron, K. Jemielniak, R. Botez, and S. Achiche, "Type-2 fuzzy tool condition monitoring system based on acoustic emission in micromilling," *Information Sciences*, vol. 255, pp. 121-134, 1/10/ 2014.
- [169] G. Beruvides, F. Castano, R. E. Haber, R. Quiza, and M. Rivas, "Artificial intelligence-based modelling and optimization of microdrilling processes," in *Computational Intelligence for Engineering Solutions (CIES), 2014 IEEE Symposium on*, 2014, pp. 49-53.
- [170] K. V. Rao, K. P. Vidhu, T. A. Kumar, N. N. Rao, P. B. G. S. N. Murthy, and M. Balaji, "An artificial neural network approach to investigate surface roughness and vibration of workpiece in boring of AISI1040 steels," *The International Journal of Advanced Manufacturing Technology*, pp. 1-9, 2015/08/02 2015.
- [171] "Sistema de control cognitivo en red para procesos de mecanizado de alto rendimiento (COGNETCON)," ed: Ministerio de Ciencia e Innovación. DPI2008-01978, 2009 - 2011.
- [172] "Investigación Industrial sobre Métodos de Microfabricación Inteligente de Componentes Aeroespaciales en Aleaciones de Tungsteno (MICALET)," ed. Pequeña

- Empresa (11-50): Centro para el Desarrollo Tecnológico Industrial (CDTI), 2010-2012.
- [173] "Control cognitivo artificial en procesos de micromecanizado mecánico. Método y aplicación (CONMICRO)," ed. DPI2012-35504: Ministerio de Economía y Competitividad (MINECO), 2013 - 2015.
- [174] A. V. Oppenheim, R. W. Schaffer, and J. R. Buck, *Discrete-Time Signal Processing*, 2nd ed. New Jersey: Prentice Hall, 1999.
- [175] S. G. Mallat, "Theory for multiresolution signal decomposition: the wavelet representation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 11, pp. 674-693, 1989.
- [176] I. Daubechies, "Wavelet transform, time-frequency localization and signal analysis," *IEEE Transactions on Information Theory*, vol. 36, pp. 961-1005, 1990.
- [177] N. E. Huang, Z. Shen, S. R. Long, M. C. Wu, H. H. Shih, Q. Zheng, *et al.*, "The empirical mode decomposition and the Hilbert spectrum for non-linear and non-stationary time series analysis," *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, vol. 454, pp. 903-995, 1998.
- [178] N. E. Huang and S. S. Shen, *Hilbert-Huang transform and its applications*: World Scientific Pub Co Inc, 2005.
- [179] T. Kalvoda and Y. R. Hwang, "Analysis of signals for monitoring of non-linear and non-stationary machining processes," *Sensors and Actuators, A: Physical*, vol. 161, pp. 39-45, 2010.
- [180] T. Kalvoda and Y. R. Hwang, "A cutter tool monitoring in machining process using Hilbert-Huang transform," *International Journal of Machine Tools and Manufacture*, vol. 50, pp. 495-501, 2010.
- [181] R. E. Haber, J. E. Jimenez, C. R. Peres, and J. R. Alique, "An investigation of tool-wear monitoring in a high-speed machining process," *Sensors and Actuators a-Physical*, vol. 116, pp. 539-545, Oct 2004.
- [182] K. Jemielniak, S. Bombiński, and P. X. Aristimuno, "Tool condition monitoring in micromilling based on hierarchical integration of signal measures," *CIRP Annals - Manufacturing Technology*, vol. 57, pp. 121-124, 2008.
- [183] E. Gandarias, S. Dimov, D. T. Pham, A. Ivanov, K. Popov, R. Lizarralde, *et al.*, "New methods for tool failure detection in micromilling," *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, vol. 220, pp. 137-144, 2006.
- [184] B. C. Ulmer Jr and T. R. Kurfess, "Integration of an open architecture controller with a diamond turning machine," *Mechatronics*, vol. 9, pp. 349-361, 1999.
- [185] I. N. Tansel, "Identification of the prefailure phase in microdrilling operations using multiple sensors," *International Journal of Machine Tools and Manufacture*, vol. 34, pp. 351-364, 1994.
- [186] I. Tansel, O. Rodriguez, M. Trujillo, E. Paz, and W. Li, "Micro-end-milling - I. Wear and breakage," *International Journal of Machine Tools and Manufacture*, vol. 38, pp. 1419-1436, 1998.

- [187] G. Qi, "A method of tool breakage detection in cnc high-speed milling," vol. 138-189, ed. Sanya, 2012, pp. 598-603.
- [188] P. Y. Sevilla-Camacho, G. Herrera-Ruiz, J. B. Robles-Ocampo, and J. C. Jáuregui-Correa, "Tool breakage detection in CNC high-speed milling based in feed-motor current signals," *International Journal of Advanced Manufacturing Technology*, vol. 53, pp. 1141-1148, 2011.
- [189] D. E. Lee, I. Hwang, C. M. O. Valente, J. F. G. Oliveira, and D. A. Dornfeld, "Precision manufacturing process monitoring with acoustic emission," *International Journal of Machine Tools and Manufacture*, vol. 46, pp. 176-188, 2006.
- [190] M. C. Schmittziel, R. E. Haber Guerra, Á. Escribano, and J. Escribano, "The state-of-the-art in nano-turning," Atlanta, GA, 2007, pp. 211-220.
- [191] D. A. Dornfield, Y. Lee, and A. Chang, "Monitoring of ultraprecision machining processes," *International Journal of Advanced Manufacturing Technology*, vol. 21, pp. 571-578, 2003.
- [192] M. C. Schmittziel, R. E. Haber, Á. Escribano, and J. Escribano, "The state of the art in nano-turning," presented at the International Manufacturing Science & Engineering, MSEC2007, Atlanta, Georgia USA, 2007.
- [193] D. E. Lee, I. Hwang, C. M. O. Valente, J. F. G. Oliveira, and D. A. Dornfeld, "Precision manufacturing process monitoring with acoustic emission," *International Journal of Machine Tools & Manufacture*, vol. 46, pp. 176-188, Feb 2006.
- [194] J. D. Drescher and T. A. Dow, "Tool Force Model Development for Diamond Turning," *Precision Engineering-Journal of the American Society for Precision Engineering*, vol. 12, pp. 29-35, Jan 1990.
- [195] T. A. Dow, E. L. Miller, and K. Garrard, "Tool force and deflection compensation for small milling tools," *Precision Engineering*, vol. 28, pp. 31-45, 2004.
- [196] C. K. Ng, S. N. Melkote, M. Rahman, and A. S. Kumar, "Experimental study of micro- and nano-scale cutting of aluminum 7075-T6," *International Journal of Machine Tools & Manufacture*, vol. 46, pp. 929-936, Jul 2006.
- [197] T. G. Bifano and Y. Yi, "Acoustic-Emission as an Indicator of Material-Removal Regime in Glass Micromachining," *Precision Engineering-Journal of the American Society for Precision Engineering*, vol. 14, pp. 219-228, Oct 1992.
- [198] J. J. Liu and D. A. Dornfeld, "Modeling and analysis of acoustic emission in diamond turning," *Journal of Manufacturing Science and Engineering-Transactions of the Asme*, vol. 118, pp. 199-207, May 1996.
- [199] C. L. Yen, M. C. Lu, and J. L. Chen, "Applying the self-organization feature map (SOM) algorithm to AE-based tool wear monitoring in micro-cutting," *Mechanical Systems and Signal Processing*, vol. 34, pp. 353-366, 2013.
- [200] I. S. Kang, J. S. Kim, M. C. Kang, and K. Y. Lee, "Tool condition and machined surface monitoring for micro-lens array fabrication in mechanical machining," *Journal of Materials Processing Technology*, vol. 201, pp. 585-589, 2008.

-
- [201] Y. Nakao and D. A. Dornfeld, "Diamond turning using position and AE dual feedback control system," *Precision Engineering-Journal of the International Societies for Precision Engineering and Nanotechnology*, vol. 27, pp. 117-124, Apr 2003.
- [202] S. Huang, D. H. Zhang, W. Y. Leong, H. L. Chan, K. M. Goh, J. B. Zhang, *et al.*, "Detecting tool breakage using accelerometer in ball-nose end milling," Hanoi, 2008, pp. 927-933.
- [203] J. Zhang, C. Li, J. You, and L. Yao, "Research on measurement system of six-axis piezoelectric accelerometer," *Yadian Yu Shengguang/Piezoelectrics and Acoustooptics*, vol. 34, pp. 699-702+707, 2012.
- [204] A. A. Mohammed, S. M. Haris, and M. Z. Nuawi, "Performance evaluation and compression of some actuators and sensors piezoelectric elements," Sanya, Hainan, 2012, pp. 65-70.
- [205] R. M. Del Toro, R. E. Haber, and M. C. Schmittiel, "Detecting Nano-Scale Vibrations in Rotating Devices by Using Advanced Computational Methods," *Sensors*, vol. 10, pp. 4983-4995, 2010.
- [206] M. Kumar, K. Dotson, and S. N. Melkote, "An experimental technique to detect tool-workpiece contact in micromilling," *Journal of Manufacturing Processes*, vol. 12, pp. 99-105, 2010.
- [207] S. C. Fawcett, "Small amplitude vibration compensation for precision diamond turning," *Precision Engineering*, vol. 12, pp. 91-96, 1990.
- [208] G.-L. Chern and Y.-C. Chang, "Using two-dimensional vibration cutting for micro-milling," *International Journal of Machine Tools and Manufacture*, vol. 46, pp. 659-666, 2006.
- [209] M. Zhou, X. J. Wang, B. K. A. Ngoi, and J. G. K. Gan, "Brittle-ductile transition in the diamond cutting of glasses with the aid of ultrasonic vibration," *Journal of Materials Processing Technology*, vol. 121, pp. 243-251, 2002.
- [210] A. Akhavan Farid, S. Sharif, and M. H. Idris, "Chip morphology study in high speed drilling of Al-Si alloy," *International Journal of Advanced Manufacturing Technology*, vol. 57, pp. 555-564, 2011.
- [211] S. A. Ashrafi, A. Davoudinejad, M. M. Barzani, and P. Salehi, "Investigation into effect of tool wear on drilling force and surface finish while dry drilling aluminum 2024," vol. 548, ed. Chengdu, 2012, pp. 387-392.
- [212] K. Patra, S. K. Pal, and K. Bhattacharyya, "Strategies for intelligent tool wear prediction in a machining process," Nara, 2010, pp. 623-626.
- [213] H. Rafezi, J. Akbari, and M. Behzad, "Tool condition monitoring based on sound and vibration analysis and wavelet packet decomposition," Sharjah, 2012.
- [214] S. Tangjitsitcharoen and V. Boranintr, "Integration of in-process monitoring and statistical process control of surface roughness on CNC turning process," *International Journal of Computer Integrated Manufacturing*, vol. 26, pp. 227-236, 2013/03/01 2012.
-

- [215] C. B. Cheng and E. S. Lee, "Nonparametric fuzzy regression - k-NN and kernel smoothing techniques," *Computers and Mathematics with Applications*, vol. 38, pp. 239-251, 1999.
- [216] W. Pedrycz and M. Reformat, "Evolutionary Fuzzy Modeling," *IEEE Transactions on Fuzzy Systems*, vol. 11, pp. 652-665, 2003.
- [217] R. Xu and D. Wunsch II, "Survey of clustering algorithms," *IEEE Transactions on Neural Networks*, vol. 16, pp. 645-678, 2005.
- [218] W. Pedrycz and K. C. Kwak, "The development of incremental models," *IEEE Transactions on Fuzzy Systems*, vol. 15, pp. 507-518, 2007.
- [219] J. M. Keller, M. R. Gray, and J. A. Givens, "Fuzzy k-nearest neighbor algorithm," *IEEE Transactions on Systems, Man and Cybernetics*, vol. 15, pp. 580-585, 1985.
- [220] K. Hattori and M. Takahashi, "A new nearest-neighbor rule in the pattern classification problem," *Pattern Recognition*, vol. 32, pp. 425-432, 1999.
- [221] 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*, vol. 59, pp. 604-615, 2010.
- [222] 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*, vol. 9, pp. 889-895, 2009.
- [223] N. Metropolis, A. W. Rosenbluth, M. N. Rosenbluth, A. H. Teller, and E. Teller, "Equation of state calculations by fast computing machines," *The Journal of Chemical Physics*, vol. 21, pp. 1087-1092, 1953.
- [224] W. K. Hastings, "Monte carlo sampling methods using Markov chains and their applications," *Biometrika*, vol. 57, pp. 97-109, 1970.
- [225] L. Ingber. (1995, Adaptive simulated annealing (ASA): Lessons learned. *Polish Journal Control and Cybernetics (Simulated Annealing Applied to Combinatorial Optimization)*. Available: <http://www.ingber.com/#ASA>
- [226] D. Y. Sun and P. M. Lin, "The solution of time optimal control problems by simulated annealing," *Journal of Chemical Engineering of Japan*, vol. 39, pp. 753-766, 2006.
- [227] J. C. Bezdek, R. Ehrlich, and W. Full, "FCM: The fuzzy c-means clustering algorithm," *Computers and Geosciences*, vol. 10, pp. 191-203, 1984.
- [228] W. Kuo-Lung, "Analysis of parameter selections for fuzzy c-means," *Pattern Recognition*, vol. 45, pp. 407-415, 2012.
- [229] I. Berget, B.-H. Mevik, and T. Næs, "New modifications and applications of fuzzy c-means methodology," *Computational Statistics & Data Analysis*, vol. 52, pp. 2403-2418, 2008.
- [230] 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*, vol. 39, pp. 578-591, 2009.
- [231] F. Höppner and F. Klawonn, "Improved fuzzy partitions for fuzzy regression models," *International Journal of Approximate Reasoning*, vol. 32, pp. 85-102, 2003.

-
- [232] L. Xu, A. Krzyzak, and E. Oja, "Rival penalized competitive learning for clustering analysis, RBF net, and curve detection," *IEEE Transactions on Neural Networks*, vol. 4, pp. 636-649, 1993.
- [233] A. Gajate, R. E. Haber, P. I. Vega, and J. R. Alique, "A transductive neuro-fuzzy controller: Application to a drilling process," *IEEE Transactions on Neural Networks*, vol. 21, pp. 1158-1167, 2010.
- [234] Q. Song and N. Kasabov, "TWNFI - a transductive neuro-fuzzy inference system with weighted data normalization for personalized modeling," *Neural Networks*, vol. 19, pp. 1591-1596, 2006.
- [235] Q. Song and N. K. Kasabov, "NFI: A neuro-fuzzy inference method for transductive reasoning," *IEEE Transactions on Fuzzy Systems*, vol. 13, pp. 799-808, 2005.
- [236] P. L. Menezes, I. V. Avdeev, M. R. Lovell, and C. F. Higgs Iii, "An explicit finite element model to study the influence of rake angle and friction during orthogonal metal cutting," *International Journal of Advanced Manufacturing Technology*, vol. 73, pp. 875-885, 2014.
- [237] E. Aras and A. Albedah, "Extracting cutter/workpiece engagements in five-axis milling using solid modeler," *The International Journal of Advanced Manufacturing Technology*, 2014.
- [238] J. Xu, B. Rong, H. Z. Zhang, D. S. Wang, and L. Li, "Investigation of cutting force in high feed milling of Ti6Al4V," vol. 770, ed. Nanjing, 2014, pp. 106-109.
- [239] R. E. Haber, J. E. Jiménez, C. R. Peres, and J. R. Alique, "An investigation of tool-wear monitoring in a high-speed machining process," *Sensors and Actuators, A: Physical*, vol. 116, pp. 539-545, // 2004.
- [240] S. Min, H. Sangermann, C. Mertens, and D. Dornfeld, "A study on initial contact detection for precision micro-mold and surface generation of vertical side walls in micromachining," *CIRP Annals - Manufacturing Technology*, vol. 57, pp. 109-112, // 2008.
- [241] A. Kus, Y. Isik, M. Cakir, S. Coşkun, and K. Özdemir, "Thermocouple and Infrared Sensor-Based Measurement of Temperature Distribution in Metal Cutting," *Sensors*, vol. 15, p. 1274, 2015.
- [242] G. Wang, Y. Yang, and Z. Li, "Force Sensor Based Tool Condition Monitoring Using a Heterogeneous Ensemble Learning Model," *Sensors*, vol. 14, p. 21588, 2014.
- [243] H. Perez, E. Diez, J. J. Marquez, and A. Vizan, "An enhanced method for cutting force estimation in peripheral milling," *International Journal of Advanced Manufacturing Technology*, vol. 69, pp. 1731-1741, // 2013.
- [244] P. Rodríguez and J. E. Labarga, "A new model for the prediction of cutting forces in micro-end-milling operations," *Journal of Materials Processing Technology*, vol. 213, pp. 261-268, 2013.
- [245] Y. V. Srinivasa and M. S. Shunmugam, "Mechanistic model for prediction of cutting forces in micro end-milling and experimental comparison," *International Journal of Machine Tools and Manufacture*, vol. 67, pp. 18-27, 2013.
-

- [246] R. E. Haber, J. R. Alique, S. Ros, and R. H. Haber, "Modeling and simulation of high-speed machining processes based on matlab/simulink," in *ICCS 2005, 5th International Conference, Atlanta, GA, USA*, Atlanta, GA, 2005, pp. 627-634.
- [247] M. Rizal, J. A. Ghani, M. Z. Nuawi, and C. H. Che Haron, "Development and testing of an integrated rotating dynamometer on tool holder for milling process," *Mechanical Systems and Signal Processing*, vol. 52–53, pp. 559-576, 2// 2015.
- [248] K. Popov, S. Dimov, A. Ivanov, D. T. Pham, and E. Gandarias, "New tool-workpiece setting up technology for micro-milling," *International Journal of Advanced Manufacturing Technology*, vol. 47, pp. 21-27, // 2010.
- [249] A. A. Sodemann and J. R. Mayor, "Parametric investigation of precision in tool-workpiece conductivity touch-off method in micromilling," Greenville, SC, 2009, pp. 565-572.
- [250] T. Nakamura, K. Funabashi, and H. Hasegawa, "In-process measurement of coated tool wear by spreading resistance," *Bulletin of the Japan Society of Precision Engineering*, vol. 25, pp. 152-153, 1991.
- [251] R. E. Haber, J. E. Jiménez, A. Jiménez, and J. López-Coronado, "Cutting force model for high speed machining process," *Revista De Metalurgia*, vol. 40, pp. 247-258, Jul-Aug 2004.
- [252] S. Engin and Y. Altintas, "Mechanics and dynamics of general milling cutters. Part I: helical end mills," *International Journal of Machine Tools & Manufacture*, vol. 41, pp. 2195-2212, Dec 2001.
- [253] B. M. Imani, M. H. Sadeghi, and M. A. Elbestawi, "An improved process simulation system for ball-end milling of sculptured surfaces," *International Journal of Machine Tools & Manufacture*, vol. 38, pp. 1089-1107, Sep 1998.
- [254] L. K. Gillespie, "Rough to Measure," *MICROmanufacturing*, vol. 1, pp. 50-55, 2008.
- [255] N. Logothetis and H. P. Wynn, *Quality through design: experimental design, off-line quality control, and Taguchi's contributions*: Oxford University Press, USA, 1994.
- [256] O. Abouelatta and J. Madl, "Surface Roughness Prediction Based on Cutting Parameters and Tool Vibration in Turning," *Journal of Materials Processing Technology*, vol. 118, pp. 269–277, 2001.
- [257] D. Salgado, F. Alonso, I. Cambero, and A. Marcelo, "In-Process Surface Roughness Prediction System Using Cutting Vibrations in Turning," *International Journal of Advanced Manufacturing Technology*, vol. 43, pp. 40-51, 2009.
- [258] D. Song, N. Otani, T. Aoki, Y. Kamakoshi, Y. Ohara, and H. Tamaki, "A New Approach to Cutting State Monitoring in End-mill Machining," *International Journal of Machine Tools and Manufacture*, vol. 45, pp. 909–921, 2005.
- [259] Y. Guo and S. Ammala, "Real-time AE Monitoring for Surface Damage in Hard Machining," *International Journal of Machine Tools and Manufacture*, vol. 45, pp. 1622–1627, 2005.
- [260] S. Rawat and H. Attia, "Characterization of the Dry High Speed Drilling Process of Woven Composites Using Machinability Maps Approach," *CIRP Annals* vol. 58, pp. 105–108, 2009.

-
- [261] J. Yi, L. Jiao, X. Wang, J. Xiang, M. Yuan, and S. Gao, "Surface roughness models and their experimental validation in micro milling of 6061-T6 al alloy by response surface methodology," *Mathematical Problems in Engineering*, vol. 2015, 2015.
- [262] G. Zhang and S. To, "A novel surface quality evaluation method in ultra-precision raster milling using cutting chips," *Journal of Materials Processing Technology*, vol. 219, pp. 328-338, 2015.
- [263] C. Bandapalli, K. K. Singh, B. M. Sutaria, and D. V. Bhatt, "Experimental investigation of machinability parameters in high-speed micro-end milling of titanium (grade-2)," *International Journal of Advanced Manufacturing Technology*, 2015.
- [264] H. Chang, J. Kim, H. Kim, D. Jang, and D. Han, "In-process Surface Roughness Prediction Using Displacement Signals from Spindle Motion," *International Journal of Machine Tools and Manufacture*, vol. 47, pp. 1021–1026, 2007.
- [265] 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*, vol. 37, pp. 1201–1217, 1997.
- [266] 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*, vol. 21, pp. 339-347, 2003.
- [267] S. Z. Chavoshi, "Modelling of surface roughness in CNC face milling of alloy stellite 6," *International Journal of Computational Materials Science and Surface Engineering*, vol. 5, pp. 304-321, 2013.
- [268] V. S. Sooraj and J. Mathew, "An experimental investigation on the machining characteristics of microscale end milling," *International Journal of Advanced Manufacturing Technology*, vol. 56, pp. 951-958, 2011.
- [269] A. Fernández, "Sistema de Control para Compensación de Vibraciones en procesos de Microfabricación," *Electrónica y Automática*, Universidad Politécnica de Madrid, 2015.
- [270] "Advanced Manufacturing 4th Generation," ed. Programa Cien 2015: Centro para el Desarrollo Tecnológico Industrial (CDTI), 2015-2017.
- [271] "Flexible FE/BE Sensor Pilot Line for the Internet of Everything," ed: ECSEL Joint Undertaking, 2016-2019.

ANEXO I. GLOSARIO DE TÉRMINOS

Siglas

FCM	Fuzzy c-means
FE	Factores de Escala
FFT	Transformada Rápida de Fourier (<i>Fast Fourier Transform</i>)
FIFO	Primero en entrar, primero en salir (<i>First In First Out</i>)
FIR	Respuesta Finita
FIW	Señal que se corresponde al ancho de pulso de DIF
FIW-m	Señal que se corresponde al ancho de pulso FIW filtrado
F-kNN	Agrupamiento borroso por cercanía de vecinos (<i>Fuzzy k-Nearest Neighbor</i>)
FNN	Red neuronal hacia atrás (<i>Feedforward NN</i>)
FP	Funciones de Pertenencia
FPE	Error de Predicción Final (Final Prediction Error)
FPGA	<i>Field Programmable Gate Array</i>
FTS	<i>Fast Tool Servo</i>
GFCM	Agrupamiento borroso generalizado <i>c-means</i>
GFF	Pre-Alimentación Generalizada (<i>generalized feed forward</i>)
G-G	Gath-Geva
GIFP-FCM	Agrupamiento borroso generalizado con particiones mejoradas (<i>Generalized Fuzzy C-Means with Improved Fuzzy Partitions</i>)
G-K	Gustafson-Kessel
HC	<i>Hill Climbing</i>
HHT	Transformada de Hilbert-Huang
HIM	Modelado híbrido incremental (<i>Hybrid Incremental Modelling</i>)
HMI	Interfaz hombre-máquina (<i>Human-Machine Interface</i>)
HP	Filtro Paso Alto
IFP-FCM	Agrupamiento borroso con particiones mejoradas (<i>Fuzzy c-means with</i>

	<i>Improved Fuzzy partitions)</i>
IIR	Respuesta a Impulso Infinita
IMF	Funciones de Modos Intrínsecos (<i>Intrinsic Mode Functions</i>)
kNN	k-Nearest Neighbors
LIGA	Litografía por Impresión Galvanoplástica (<i>Lithographie Galvanoformung Abformung</i>)
LP	Filtro Paso Bajo
LSTM	Memoria a corto plazo (<i>Long Short Term Memory</i>)
MAE	Error Absoluto Medio
MEMS	Sistemas de Fabricación Micro-Electro-Mecánicos
Micro-AJM	Micro-Mecanizado Chorro de Material Abrasivo (<i>Micro Abrasive jet machining</i>)
Micro-ECM	Micro-Mecanizado Electroquímico (<i>Micro Electro-Chemical Machining</i>)
Micro-EDM	Micro-Mecanizado por Electro-Erosión (<i>Micro Electro-Discharge Machining</i>)
Micro-LBM	Micro-Mecanizado con Rayo Láser (<i>Micro Laser-Beam Machining</i>)
Micro-PCM	Micro-Mecanizado Fotoquímico (<i>Photochemical micromachining</i>)
Micro-USM	Micro-Mecanizado por Ultrasonidos (<i>Micro Ultrasonic Machining</i>)
MLP	Perceptrón multicapa (<i>Multiple Layer Perceptron</i>)
MNN	Red Neuronal Modular (<i>Modular Neural Network</i>)
MRE	Error Relativo Medio (<i>Mean Relative Error</i>)
MSE	Error Cuadrático Medio (<i>Mean Squared Error</i>)
NEFCLASS	Clasificación neuroborrosa (<i>NEuro-Fuzzy CLASSification</i>)
NEFCON	Control neuroborroso (<i>Neuro-Fuzzy Control</i>)
NM	Nelder-Mead
NN	Red neuronal (<i>Neural Networks</i>)
NN SL	Red neuronal de una sola capa (<i>Neural Networks Single Layer</i>)
NSSE	Ruido en la Suma de Errores Cuadráticos (<i>Noise of Sum of Squared Errors</i>)
PCB	Placa de circuito impreso
PDCS	Sistemas de Cómputo Predeciblemente Confiables
PG	Programación Genética
PLC	Controlador lógico programable (<i>Programmable Logic Controller</i>)
PSO	Optimización por enjambre de partículas (<i>Particle Swarm Optimisation</i>)
PVD	Deposición Física por Vapor (<i>physical vapor deposition</i>)
PXI	Extensiones PCI para instrumentación (<i>PCI eXtensions for Instrumentation</i>)
RBF	Función de base radial (<i>Radial Basis Function</i>)
RF-MEMS	Radio Frecuencias de Sistemas de Fabricación micro-electro-mecánico
rms	Valor Cuadrático Medio (Root Mean Square)
RNA	Redes Neuronales Artificiales
RNN	Redes neuronales recurrentes (<i>Recurrent Neural Networks</i>)
RPCL	Aprendizaje competitivo por rival penalizado
RSM	Método de respuesta de superficie (<i>Response Surface Method</i>)
SA	Temple Simulado

SCADA	Control supervisado y adquisición de datos (<i>Supervisory Control And Data Acquisition</i>)
SCN	Redes Neuronales de conexión estocástica (<i>Stochastic Connection Neural Network</i> s)
SI	Inteligencia de enjambre (<i>Swarm Intelligence</i>)
SNSE	Suma de Errores Normalizados Cuadráticos
SOM	Mapa de auto organización (<i>Self-Organizing Map</i>)
SPF	Simulación de Procesos Físicos
SSE	Suma de Errores Cuadráticos (<i>Sum of Squared Errors</i>)
STFT	Transformada de Fourier de Tiempo (<i>Short-Time Fourier Transform</i>)
STP	Sistema cabezal-herramienta-pieza
TS	Búsqueda Tabú (<i>Tabu Search</i>)
TSK	Takagi-Sugeno-Kang
WCu	Aleación Wolframio-Cobre
WT	Transformada Wavelet (<i>Wavelet Transform</i>)
Z _{STP}	Impedancia sistema cabezal-herramienta-pieza

Ecuaciones

λ	Coefficiente de recompensa (GFCM)
ς	Valor de umbral (SA)
$[x, y, z]_k$	Estimación de la posición para cada estado
$\partial E/\partial h(s)$	Derivada parcial de la función de error a minimizar con respecto al parámetro a actualizar
$\mu(j)$	Valor medio de la variable j -ésima (HIM)
A	Área de la sección transversal uniforme del material
a	Escala en <i>wavelet</i>
$a(t)$	Amplitud instantánea en la HHT
A_c	Área de la sección transversal uniforme del área de contacto
Ac_{zrms}	Valor rms de la vibración en el eje Z
a_e	Profundidad radial de corte [mm]
A_{max}	Valor máximo de la vibración en el eje Z
a_p	Profundidad axial de corte [mm]
A_{Tj}	Área total del contacto para cada labio de la herramienta de corte
A_{TM}	Valor medio del área de contacto para cada vuelta de la herramienta
b	Desplazamiento en <i>wavelet</i>
c	Número total de <i>clusters</i> (GFCM)
$C(a,b)$	Familia de la transformada <i>wavelet</i> de una señal $s(t)$
D	Diámetro radial de la herramienta en [mm].
D_i	Conjunto de puntos de entrada al algoritmo en F-kNN (HIM)

d_i	i -ésimo de los k vecinos en F-kNN (HIM)
dS	Sección infinitesimal del filo de corte de la herramienta
D_T	Número de parámetros del espacio de estados (SA)
dz	Altura diferencial de un segmento de viruta.
E	Magnitud del campo eléctrico en [V (Voltios) m^{-1}]
$e(x)$	Energía para el conjunto de estados x (SA)
E_k	Estado previo con "energía" (SA)
E_{k+1}	Nuevo estado con "energía" (SA)
$\mathcal{E}(x)$	Error de la predicción del modelo básico (HIM)
ϕ	Ángulo de rotación del filo de la fresa
f	Avance de la máquina [mm/min]
$\phi_{\varepsilon\xi}$	Ángulo de inmersión radial en el punto final
f_j	Componente compleja correspondiente a la frecuencia j
$\phi_j(z)$	Ángulo de inmersión para el diente j a la profundidad de corte z
f_{nm}	Velocidad de avance nominal
ϕ_π	Paso angular entre dientes
$\phi_{\sigma\tau}$	Ángulo de inmersión radial en el punto de inicio
f_z	Avance por diente en [mm / rev]
G	Conductancia eléctrica del material en [Ω^{-1} (Ohmios) m]
$G(x)$	Distribución más probable de Gibbs (SA)
$gT(x)$	Densidad de probabilidad del espacio de estado de D parámetros (SA)
H	Operador de Hamiltoniano (SA)
h	Parámetro a utilizar en el aprendizaje (Retropropagación de errores)
$h(\phi, z)$	Espesor de la viruta
$h(\Delta E)$	Probabilidad de aceptación de una nueva función de coste (SA)
$h(\omega)$	Espectro marginal de Hilbert en la HHT
$h[k]_{med}$	Filtro de respuesta a impulso finita de media móvil
$h[k]_{rms}$	Filtro de respuesta a impulso finita de media cuadrática móvil
h_1	Primera componente de la primera envolvente en IMF
$H_1(e^{j\omega})$	Transformada de Fourier de la respuesta al impulso del filtro $h[k]$
$h_r(\phi, z)$	Espesor radial de la viruta
il	Índice para cada iteración (GFCM)
IT	Máximo de número de iteraciones (GFCM)
J	Densidad de corriente en [A (Amperios) m^{-1}]
J_{FCM}	Minimización de la función objetivo con FCM (GFCM)
k	Pasos del tiempo de templado (k) (SA)
K_{def}	Coefficiente de proporcionalidad o de "deformación"
K_{HIM}	Valores iniciales de los parámetros del modelo híbrido (SA)

k_n	Número de vecinos en F-kNN (HIM)
ℓ	Longitud del material
L_0	Distancia inicial entre el centro de la herramienta y el borde de la pieza, en el la inserción entre la herramienta y la pieza
m	Grado del polinomio del modelo local (HIM)
m_1	Valor medio de la primer envolvente de IMF
MAE	Error Absoluto Medio (SA)
v	Velocidad del cabezal en [rev / min]
n	Velocidad de giro del cabezal en [rev / min]
N_f	Número de dientes de la herramienta de corte
n_i	Centro de la función de pertenencia correspondiente al consecuente i (GFCM)
N_s	Conjunto en el promedio de los valores más cercanos en F-kNN (HIM)
Θ	Función fase en la HHT
$O(x_i)$	Valor de salida del punto x_i del polinomio de grado m (HIM)
p	Coefficiente de borrosidad en F-kNN (HIM y GFCM)
P	Probabilidad del coste (SA)
$p(x)$	Conjunto de distribuciones de probabilidad (SA)
P_0	Un punto en el filo de corte
q	Punto objetivo del polinomio de grado m (HIM)
r	Radio radial de la herramienta en [mm]
R	Resistencia eléctrica de un material en [Ω (Ohmios)]
$r(n_i)$	Valores objetivos de los puntos del conjunto N en F-kNN (HIM)
$r(q)$	Valor del punto objetivo q en F-kNN (HIM)
r_1	Residuo primero de la primera IMF
R^2	Índice de correlación
R_a	Valor de la rugosidad media aritmética del perfil
R_c	Resistencia eléctrica del contacto durante el corte en [Ω (Ohmios)]
rdc	Tasa de reducción de temperatura (SA)
R_M	Parámetro para comparar la probabilidad de aceptación (Criterio de Metropolis) (SA)
R_q	Valor de rugosidad desviación media cuadrática del perfil
s	Número de iteración del algoritmo de aprendizaje (Retropropagación de errores)
$S(n_i, q)$	Similitud entre los puntos N y q en F-kNN (HIM)
SE	Valor máximo de entropía (SA)
t'_{max}	Tiempo en el que se alcanza la máxima profundidad radial en la salida de la herramienta del material
t_0	Tiempo inicial en la entrada y salida de la herramienta del material
T^a	Temperatura de templado (SA)
$T^a(k)$	Planificación de la “temperatura de templado” (SA)

T_0^a	Temperatura inicial
t_c	Tiempo de contacto
t_f	Tiempo final en la entrada y salida de la herramienta del material
T_{in}	Tiempo de entrada
T_k	Instante de tiempo en que se produce el cambio de estado
t_{max}	Tiempo en el que se alcanza la máxima profundidad radial en la entrada de la herramienta del material
T_{out}	Tiempo de salida
T_{tran}	Tiempo de transición
u_{ij}	la pertenencia del dato j al cluster i (GFCM)
V_C	Velocidad de corte [m/s]
v_i	Centro del cluster i (GFCM)
$V_{in}(k)$	Muestra en el instante actual k de la variable de entrada
$V_o(k)$	La señal filtrada FIW – m
ws	Número total de muestras un total de muestras igual a la ventana de datos
$Y_B(x_i)$	Salida del polinomio de grado m (HIM)
z	Segmento de viruta
Z	Función de partición (SA)
z_i^j	Normalización de los puntos de entrada x_i^j (HIM)
α	Parámetro para generalizar el uso de IFP-FCM (GFCM)
β_{break}	Valor porcentual para la determinar el estado INTERRUMPIDO
$\Delta[x, y, z]_k$	Media de los valores diferenciales del vector de posición
δ_i	Anchura de la función de pertenencia correspondiente al consecuente i (GFCM)
ΔT	Tiempo entre muestras de la variable de entrada
ζ	Constante de reducción (SA)
η	Tasa de aprendizaje (Retropropagación de errores)
ρ_p	Resistividad estática de la pieza en [Ω (Ohmios) m]
ρ_t	Resistividad estática de la herramienta de corte en [Ω (Ohmios) m]
σ	Conductividad eléctrica de un material [$\Omega^{-1} m^{-1}$]
$\sigma(j)$	Desviación típica de la variable j -ésima (HIM)
τ	Inverso de la frecuencia de corte del filtro
ψ	la distancia a utilizar (euclidea en la mayoría de los casos) (GFCM)
$\psi_{a,b}(t)$	Funciones <i>wavelet</i> hijas
Ω	Velocidad del cabezal en [rad / seg.]
ω_j	Frecuencia instantánea en la HHT
Γ_i	Función de pertenencia (GFCM)
ϵ	Umbral (GFCM)