



Universidad de Matanzas
Facultad de Ciencias Técnicas



SISTEMA EXPERTO PARA LA SELECCIÓN DE PARÁMETROS ÓPTIMOS EN EL MICROFRESADO DE RANURAS DE Ti6Al4V

Tesis Presentada como Requisito Parcial
para la Obtención del Título de
Máster en Ingeniería Asistida por Computadora

Autor: Ing. Iván La Fé Perdomo

Tutores: Dr.C. Ramón Quiza Sardiñas

M.Sc. Gerardo Beruvides López

Matanzas, 2017

DECLARACIÓN DE AUTORIDAD Y NOTA LEGAL

Yo, Iván La Fé Perdomo, declaro que soy el único autor de la siguiente tesis, titulada SISTEMA EXPERTO PARA LA SELECCIÓN DE PARÁMETROS ÓPTIMOS EN EL MICROFRESADO DE RANURAS DE Ti6Al4V y, en virtud de tal, cedo el derecho de copia de la misma a la Universidad de Matanzas, bajo la licencia *Creative Commons* de tipo *Reconocimiento No Comercial Sin Obra Derivada*, con lo cual se permite su copia y distribución por cualquier medio siempre que mantenga el reconocimiento de sus autores, no haga uso comercial de la obra y no realice ninguna modificación de ella.

Matanzas, 5 de diciembre de 2016.

Iván La Fé Perdomo

RESUMEN

El creciente aumento de los procesos de micro mecanizado, especialmente el microfresado, está motivado por la variedad de elementos de configuración compleja que pueden ser obtenidos a través de estas operaciones, especialmente para las ramas de la medicina (implantes) y de la industria aeroespacial (componentes). En este trabajo se propone un sistema experto híbrido para la selección de los parámetros de corte óptimos en el microfresado de ranuras de Ti6Al4V. El sistema está compuesto por cuatro fases: estudio experimental del proceso de microcorte; modelación de la fuerza de corte y la rugosidad superficial usando redes neuronales artificiales; proceso de optimización multiobjetivo aplicando el método de entropía cruzada, el cual considera simultáneamente la productividad y la calidad superficial y, como paso final, la toma de decisión donde la solución más adecuada para las condiciones específicas del taller son seleccionadas con la implementación de un sistema de inferencia borroso. El sistema propuesto puede ser mejorado de forma continua, con la incorporación de nuevos valores (que se obtienen de la ejecución real del proceso) a la base de datos empíricos usada para el ajuste de los modelos. Se desarrolló un estudio de caso relacionado con el microfresado de Ti6Al4V con el objetivo de validar el modelo propuesto. Los resultados obtenidos muestran la fiabilidad y aplicación del sistema propuesto en la solución de problemas prácticos.

Palabras claves: Sistema híbrido experto; Redes neuronales; Optimización multiobjetivo; Método de entropía cruzada; Sistema de inferencia borroso; Microfresado.

ABSTRACT

The increasing rise of micromachining processes, especially the micromilling is motivated by the variety of parts of complex configuration that can be obtained through this operations, for medical (implants) and aeronautical (components) applications. A hybrid expert system for selecting optimal cutting parameters in the grooves micromilling is proposed in this study. The system is composed by four steps: experimental study of the microcutting process; artificial neural network-based modelling of the cutting force and surface roughness; multiobjective optimization of the process, which simultaneously considers the productivity and surface quality, and is carried out by using a cross-entropy method; and the decision-making were the most proper solution for the specific workshop conditions is selected through fuzzy inference systems. The proposed system can be continuously enhanced by incorporating the new values, resulting from the actual executed process, to the empirical dataset used for fitting the models. A study case involving micromilling of Ti6Al4V titanium alloy was carried out in order to validate the proposed model. The outcomes showed the reliability of the proposed system and its applicability for solving practical problems.

Keywords: Hybrid expert system; Neural networks; Multiobjective optimization; Cross-entropy method; Fuzzy inference systems; Micromilling.

TABLA DE CONTENIDO

Introducción	1
Capítulo 1. Estado del Arte	4
1.1 Importancia y aplicación de los sistemas expertos	4
1.1.1 Capacidades de los sistemas expertos	4
1.1.2 Consideraciones para la implementación de un SE	6
1.1.3 Particularidades de los SE.....	7
1.1.4 Beneficios y limitaciones de los SE.....	9
1.1.5 Objetivos de los sistemas expertos.....	10
1.2 Modelación de los procesos de micromaquinado	13
1.2.1 Modelación empírica	14
1.3 Optimización del proceso de microfresado.....	20
1.3.1 Principios básicos de la optimización del microfresado	20
1.3.4 Criterios de optimización.....	21
1.3.5 Formulación general del problema de optimización multiobjetivo.....	22
1.3.6 Descripción del algoritmo para la optimización multiobjetivo.....	25
1.4 Conclusiones parciales.....	27
Capítulo 2. Materiales y Métodos.....	29
2.1 Arquitectura del Sistema Experto	29
2.2 Adquisición de datos.....	32
2.2.1 Equipamiento experimental	32
2.2.2 Diseño experimental	34
2.2.3 Procesamiento de la señal de fuerza	34

2.3 Modelación	38
2.4 Optimización.....	39
2.5 Toma de decisiones.....	41
2.6 Conclusiones parciales del capítulo	45
Capítulo 3 Análisis de los Resultados.....	46
3.1 Análisis de los modelos de redes neuronales	46
<i>3.1.1 Modelo de rugosidad superficial</i>	<i>46</i>
<i>3.1.2 Modelo de fuerza de corte.....</i>	<i>49</i>
3.2 Optimización.....	51
3.3 Toma de decisiones.....	53
3.4 Conclusiones parciales del capítulo	54
Conclusiones	55
Recomendaciones	56
Referencias Bibliográficas.....	57

INTRODUCCIÓN

La miniaturización de componentes juega un papel fundamental en el desarrollo de tecnologías para las industrias aeroespacial, biomédica, automovilística y la de semiconductores. El micromaquinado es una de las tecnologías claves que aseguran la realización de productos industriales, de variadas aplicaciones y de dimensiones reducidas (Asad, *et al.*, 2007).

Es bien conocido el hecho de que la planeación de un proceso, es la tarea de transformar las especificaciones de diseño en instrucciones de fabricación. En contraste con los procesos convencionales de maquinado, la toma de decisiones (*decision-making*, DM) en el micromaquinado, que persigue alcanzar la precisión y calidad necesaria, es un reto. En este sentido, la planificación de procesos asistida por computadora, es un método muy útil en la automatización del rango de decisión requerido para programar la fabricación del microproducto.

El objetivo de la manufactura moderna consiste en tener un control eficiente sobre la organización de los procesos, para alcanzar producciones de alta calidad a menores precios y en cortos períodos de tiempo. Para alcanzar mejor calidad a un precio menor, se debe prestar especial atención en la división de los procesos de fabricación, con el empleo de mejores herramientas de corte y máquinas de alta precisión, etc. Sin embargo, esto no es suficiente para elevar la productividad en la mayoría de los casos. La selección de la herramienta adecuada para la operación adecuada es importante, pero también debe considerarse el desgaste de la misma para una mayor eficiencia del proceso (Cakir y Cavdar, 2006).

Se ha planteado que en sistemas complejos de fabricación, la eficiencia de una integración entre la inteligencia artificial y las técnicas avanzadas de optimización en un sistema de apoyo a la toma de decisiones sería mayor que la de un sistema simple. Esto ha originado, recientemente, un auge de los sistemas expertos (SE) aplicados en la industria. Se supone que ellos son capaces de resolver problemas en áreas donde las computadoras han fallado previamente o que, en la práctica, nunca han abordado (Chandrasekaran, *et al.*, 2010).

El establecimiento de parámetros de maquinado eficientes ha sido un problema que ha enfrentado la industria manufacturera en casi un siglo de trabajo y que todavía es objeto de estudio. Los parámetros óptimos de fabricación son la gran preocupación en el entorno industrial, donde la economía en las operaciones de maquinado desempeñan un rol fundamental para la competitividad del mercado (Kumar, 2015).

Aunque varios esfuerzos se han hecho para optimizar la selección de los parámetros de corte en el micromaquinado (Beruvides, *et al.*, 2016; Cardoso y Davim, 2010; Krimpenis, *et al.*, 2014; Kumar, *et al.*, 2014; Kuram y Ozcelik, 2016; Natarajan, *et al.*, 2011; Periyanan, *et al.*, 2011; Saedon, *et al.*, 2012; Surmann y Krebs, 2012), de la revisión realizada a los trabajos científicos publicados se puede concluir que la mayoría de estos se restringen solamente a la aplicación del método de optimización, de ahí que se formule el siguiente **problema científico**: las metodologías y herramientas existentes no garantizan la selección de parámetros óptimos de corte en las operaciones de micromaquinado, especialmente en el microfresado, en las condiciones reales de la práctica industrial.

Para dar solución a este problema, se plantea la siguiente **hipótesis**: la implementación de un sistema experto, basado en técnicas de inteligencia artificial, permite seleccionar con precisión y flexibilidad los parámetros óptimos del régimen de corte en el proceso de microfresado de ranuras.

Para validar la hipótesis anterior se propone como **objetivo general** del presente trabajo: implementar un sistema experto, utilizando técnicas de inteligencia artificial, que permita seleccionar los parámetros de corte óptimos en el proceso de microfresado de ranuras, y validarlo mediante un estudio de caso.

En vista a cumplimentar el objetivo anterior, se han trazado un grupo de **objetivos específicos**:

1. Desarrollar modelos empíricos, basados en inteligencia artificial, que permitan relacionar las variables del proceso de microfresado con los parámetros del régimen de corte.
2. Desarrollar un método de optimización para el proceso de microfresado, utilizando entropía cruzada.
3. Implementar un sistema experto que combine las técnicas de modelación, optimización y la toma de decisión por lógica borrosa.

CAPÍTULO 1. ESTADO DEL ARTE

Este capítulo tiene como objetivo establecer los presupuestos teóricos fundamentales de la investigación desarrollada, basándose en un análisis crítico de las fuentes bibliográficas actualizadas, consultadas al respecto.

1.1 Importancia y aplicación de los sistemas expertos

1.1.1 Capacidades de los sistemas expertos

Un sistema experto (SE) (también conocido como sistema basado en el conocimiento) es un conjunto de programas que, sobre una base de conocimientos, posee información de uno o más expertos en un área específica. Se puede entender como una rama de la inteligencia artificial, donde el poder de resolución de un problema en un programa de computadora viene del conocimiento de un dominio específico. Estos sistemas imitan las actividades de un humano para resolver problemas de distinta índole (no necesariamente tiene que ser de inteligencia artificial). También se dice que un SE se basa en el conocimiento declarativo (hechos sobre objetos, situaciones) y el conocimiento de control (información sobre el seguimiento de una acción).

Un Sistema Experto está conformado por:

- Base de conocimientos (BC): Contiene conocimiento modelado extraído del diálogo con un experto.
- Base de hechos (Memoria de trabajo): contiene los hechos sobre un problema que se ha descubierto durante el análisis.
- Motor de inferencia: Modela el proceso de razonamiento humano.

- Módulos de justificación: Explica el razonamiento utilizado por el sistema para llegar a una determinada conclusión.
- Interfaz de usuario: es la interacción entre el SE y el usuario, y se realiza mediante el lenguaje natural.

La Fig. 1.1 muestra la estructura principal de un sistema experto propuesta por (Tan, 2007), donde se refleja la intrínseca dependencia del SE con el conocimiento humano.

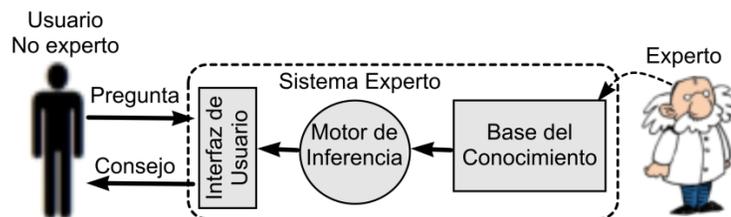


Figura 1.1 Diagrama de un sistema experto

Los sistemas expertos pueden ser categorizados según el área de interés y el propósito de su aplicación; (Tan, *et al.*, 2012; Tan, *et al.*, 2013), reparación, interpretación, predicción (Moorkherjee y Bhattacharyya, 2001), diseño y planificación, simulación (Negnevitsky, 2002), reingeniería (Asgharizadeh, *et al.*, 2011), control, clasificación o identificación, etc. Cada tipo de SE aplica diferentes reglas, códigos, secuencias de algoritmos y métodos interactivos entre el usuario y el programa. Los sistemas expertos difieren de los *softwares* tradicionales por dos razones: el conocimiento es separado del mecanismo de inferencia, y los SE son capaces de explicar su razonamiento. El núcleo de cualquier SE está compuesto por dos tipos fundamentales de conocimiento: el estático y el dinámico (Chtourou, *et al.*, 2005). El primero agrupa los conceptos que describen la experiencia humana, mientras que el segundo se refiere a los mecanismos de razonamiento.

La calidad de un SE se comprueba en la habilidad que posea el mismo no solo de tomar las decisiones más adecuadas, sino explicarlas lo suficientemente bien al usuario (Gatton, *et al.*, 1990).

1.1.2 Consideraciones para la implementación de un SE

En un SE, los problemas se resuelven usando un modelo computacional del razonamiento humano. Un sistema experto para la toma de decisiones (SETD) debe:

- ser capaz de resolver problemas de naturaleza práctica;
- arribar siempre a soluciones correctas;
- adaptarse a los cambios en el ambiente específico de aplicación.

Los expertos han acumulado conocimiento a través de los años en sus respectivos campos profesionales, por lo que son capaces de formular decisiones precisas y explicar las bases en las que formulan sus conclusiones. Sin embargo, ellos no son siempre confiables o están disponibles, por lo que un sistema que pueda aprender sin mucha intervención humana y tomar decisiones inteligentes es una herramienta muy útil (Patel y Ranganathan, 2001).

El diseño de un eficiente SETD depende de: la adquisición del conocimiento (AC) y la explicación de las decisiones. Durante la AC, la base del conocimiento de un SE se forma con la interacción entre un experto y el conocimiento ingenieril. El proceso de AC se puede explicar en los siguientes pasos (Kidd, 1987):

- extracción del conocimiento;
- representación formal del conocimiento;
- codificación;

- validación.

El desarrollo de la base del conocimiento comienza con la extracción del conocimiento del ingeniero y con la formalización de la información adquirida del experto; este proceso se puede ver afectado por las siguientes limitaciones:

- no disponibilidad de un ingeniero con vasta experiencia;
- no disposición del experto a compartir el conocimiento;
- divergencia de criterios entre expertos;
- no uniformidad en la representación del conocimiento del experto.

Debido a que la calidad de la representación del conocimiento (RC) afecta la eficiencia, velocidad y el mantenimiento del sistema, el método de RC es considerado crítico en la mayoría de la literatura consultada. Dentro de los métodos para la RC, el más utilizado en los procesos de manufactura es el de producción de reglas (Vitanov, *et al.*, 1995); este consiste en conjunto de reglas *IF* (premisa) *THEN* (acción o conclusión), que basadas y formuladas en el criterio de un experto dan más flexibilidad al tratamiento creativo de los SE. La AC en bases del conocimiento, a partir de las cuales son obtenidos los resultados por el motor de inferencia, es el sello distintivo de un SE.

1.1.3 Particularidades de los SE

Existen varios niveles de tecnologías disponibles para los SE. Según (Sharma y Bhargava, 2014) hay dos aspectos importantes a tener en cuenta a la hora de seleccionar las herramientas a incluir en la arquitectura de un sistema experto:

- que estas tienen que estar acorde con la capacidad y nivel de sofisticación del SE, en particular, con la necesidad de integrarlas con otros subsistemas, tales como bases de datos y otros componentes de un sistema de información;
- las herramientas tienen que estar acorde a las capacidades de todo el equipo que creará la arquitectura del SE.

Dentro de los diferentes tipos de sistema experto que se pueden emplear, se destacan:

- SE tipo *shell*; el principal rasgo de este sistema es que no posee base de conocimiento. La *shell* proporciona al desarrollador del SE un motor de inferencia, una interfaz de usuario y las facilidades para la explicación de la adquisición del conocimiento.
- SE de ambiente desarrollado; estos sistemas se expanden más allá de los antes mencionados. Pueden ser ejecutados en estaciones de trabajo de ingeniería, minicomputadoras, grandes ordenadores; lo cual ofrece una estrecha integración con grandes bases de datos, y respalda la construcción de grandes sistemas expertos.
- Lenguajes de programación de alto nivel; varios SE de ambiente desarrollado han sido rescritos de LISP¹ a lenguajes más empleados en el mundo comercial como es el caso de C o C++.

¹ LISP es el segundo más viejo lenguaje de programación de alto nivel de extenso uso hoy en día; solamente el FORTRAN es más viejo. Al igual que el FORTRAN, el LISP ha cambiado mucho desde sus comienzos, y han existido un número de dialectos en su historia. Hoy, los dialectos LISP de propósito general más ampliamente conocidos son el Common Lisp y el Scheme.

1.1.4 Beneficios y limitaciones de los SE

Un SE no es el sustituto del conocimiento de un trabajador, a la hora de resolver un problema. Pero estos sistemas reducen drásticamente la cantidad de trabajo que el individuo debe hacer para llevar a cabo determinada tarea, y dejan a las personas con la parte creativa y de innovación a la hora de solucionar un problema (Kumar, 2015).

Entre los beneficios organizacionales de los SE se encuentran:

- un sistema experto completa su parte de la tarea más rápido que un experto humano;
- el rango de error de un sistema exitoso es bajo, algunas veces mucho menor que el error humano en la misma tarea;
- los SE hacen consistentes recomendaciones;
- los SE pueden captar la escasa experticia de un único experto calificado;
- las industrias pueden ejecutar los SE en ambientes hostiles para los humanos.

Ninguna tecnología ofrece una solución total y fácil. Grandes sistemas son costosos y requieren de un tiempo de desarrollo significativo y recursos computacionales. Los SE también tienen sus limitaciones, las cuales incluyen:

- limitaciones con la tecnología;
- problemas con la adquisición del conocimiento;
- flexibilidad: un humano es sumamente flexible a la hora de aceptar datos para la resolución de un problema.
- conocimiento no estructurado: un SE no es capaz de manejar conocimiento poco estructurado.

1.1.5 Objetivos de los sistemas expertos

En la literatura consultada los sistemas expertos en procesos de maquinado van dirigidos principalmente a fenómenos como: la selección de los parámetros en el corte de metales (Almeshai y Oraby, 2003; Cakir y Cavdar, 2006; Iqbal, *et al.*, 2007; Leo, *et al.*, 2014; Rubio y de la Sen, 2008; Rubio, *et al.*, 2013; Suhail, *et al.*, 2011; Tolouei-Rad y Bidhendi, 1997; Vitanov, *et al.*, 1995; Wong y Hamouda, 2002; Wong y Hamouda, 2003; Wong, *et al.*, 1999; Xue-bin, *et al.*, 2013; Zaquini, *et al.*, 2007; Zhou y Wysk, 1992), el monitoreo del desgaste de la herramienta (Alto, *et al.*, 1994; Mesina y Langari, 2001; Naidu y Asati, 2014; Silva, *et al.*, 2006; Zhou y Wysk, 1992), en la selección de herramientas de corte (Chougule, *et al.*, 2014; Wang, *et al.*, 2014) y máquinas herramientas en sistemas de fabricación (Chtourou, *et al.*, 2005), para la selección de materiales en procesos convencionales y no convencionales de maquinado (Azaryoon, *et al.*, 2015; Giachetti, 1998), en análisis de productividad (Rao, *et al.*, 2005), en la predicción y control de la rebaba en el micromaquinado (Wang, *et al.*, 2014; Zhu, *et al.*, 2011)

(Chandrasekaran, *et al.*, 2010; Kumar, 2015) en sus publicaciones hacen una revisión detallada del empleo de las técnicas de *soft-computing* en los sistemas expertos para establecer la relación entre las entradas y las salidas en los diferentes procesos de manufactura (fundición, soldadura, maquinado, conformación).

En el caso específico de los procesos de manufactura para la implementación de un sistema experto se proponen dos pasos. Primeramente, crear una base de conocimiento acerca de la operación en estudio y posteriormente aplicar una serie de reglas pseudo-

heurísticas (extraídas del conocimiento o experiencia) para inferir una solución, a menudo este último paso se hace empleando la lógica borrosa (LB) o el razonamiento. Algunos acercamientos a esta temática en la literatura se encuentra el de (Wong y Hamouda, 2003) donde se desarrolla un SE borroso *online* para la selección de datos en el maquinado y usando como mecanismo de razonamiento la LB. También en (Iqbal, *et al.*, 2007) la vida útil de la herramienta y la rugosidad superficial de la pieza son mejoradas usando datos experimentales, complementados con una serie de reglas *IF-THEN* y técnicas de análisis de varianza y optimización numérica. En la investigación de (Suhail, *et al.*, 2011) se presenta una estructura multi-entradas y multi-salidas modeladas por una red adaptativa basada en un sistema de inferencia borroso (*adaptive network based fuzzy inference system*, ANFIS) la cual es capaz de identificar los parámetros de corte adecuados una vez que la rugosidad superficial deseada y las mediciones *in-process* de la temperatura superficial son entradas al sistema. Un SE para la predicción del tamaño de la rebaba y la optimización de los parámetros de corte para el control de la misma es propuesto por (Zhu, *et al.*, 2011), es empleada un red neuronal del tipo *backpropagation* como método de razonamiento. Un trabajo con características comunes al anterior es propuesto por (Wang, *et al.*, 2014), aplicando el SE a la tecnología para remover la rebaba en la operación de fresado.

Vitanov (1995) aplicó un SE del tipo *shell* para la selección de los parámetros adecuados en el corte de metales (ver Fig. 1.2).

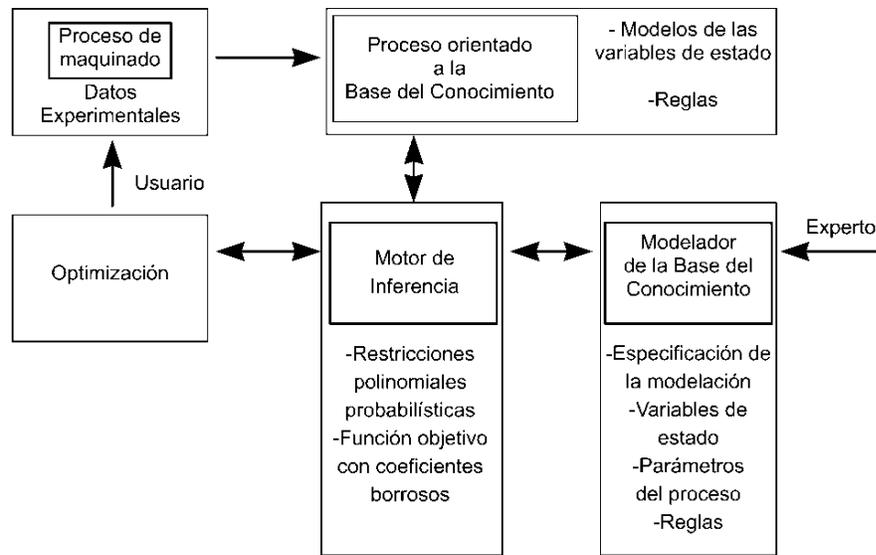


Figura 1.2 Estructura del SE propuesto por (Vitanov, et al., 1995)

En este sistema se evidencian las dos fases antes mencionadas: 1) la fase preparatoria o de entrenamiento y 2) la fase de selección u optimización. Para poder cumplir con el objetivo del SE, este se creó con dos bases de conocimientos, la del modelador de la BC y la del proceso orientado a la BC. La primera BC mencionada hace referencia al conocimiento del profesional (experto) en el campo del corte de metales. En la fase 1 el experto determina la descripción matemática apropiada de las variables de estado (VE) del proceso (ej. vida útil de la herramienta, productividad, costos de operación, fuerzas de corte permisibles, capacidad de carga del mecanismo de avance, rugosidad superficial, etc.). Por otro lado la idea de emplear la otra BC es obtener información de cuales variables de estado deben ser empleadas y que parámetros se optimizarán con el objetivo de alcanzar un nivel adecuado de precisión de la VE.

Todas las publicaciones analizadas muestran resultados positivos y plantean diversas formas de implementar la arquitectura de un SE, por lo cual existe una gran variedad de aplicaciones para los mismos.

El autor quisiera destacar que existen muy pocos reportes del empleo de sistemas expertos a los procesos de micromaquinado, por lo que basado en la literatura analizada, en el capítulo 2 se expondrá una propuesta de SE para la selección de parámetros de corte óptimos en el microfresado de ranuras para aleaciones de titanio.

1.2 Modelación de los procesos de micromaquinado

Las técnicas de modelación son usadas para obtener una representación comprensiva de un proceso y por ende poder simularlo, explicarlo y predecir las variables más influyentes del mismo. Por esa razón la modelación puede ser definida como la relación entre los parámetros de entrada y salida de un proceso. Los parámetros de entrada incluyen a: regímenes de corte, geometría de la herramienta y de la pieza de trabajo; estas son las variables físicas fundamentales del proceso, las cuales son utilizadas para obtener mejores rendimientos en el micromaquinado tales como: vida útil de la herramienta, tiempo de maquinado, rugosidad superficial, etc. En ingeniería, la modelación se divide en dos grupos fundamentales: fenomenológica (donde se incluyen los modelos numéricos y los analíticos) y modelación empírica donde los métodos estadísticos y los basados en inteligencia artificial son muy representativos y útiles (Quiza, *et al.*, 2012).

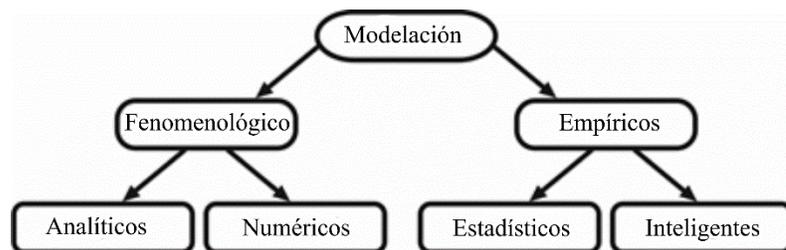


Figura 1.3 Clasificación de las técnicas de modelación según (Quiza, *et al.*, 2012)

1.2.1 Modelación empírica

Un modelo empírico puede ser definido como la representación de las relaciones entre entradas y salidas, basándose en datos experimentales. Los modelos empírico-matemáticos relacionan a n -variables no aleatorias de entrada, $x \in \mathbb{R}^n$ con una variable aleatoria escalar de salida, $y(x)$. En los modelos de múltiples entradas y múltiples salidas, estas últimas pueden ser manipuladas por separado y por lo tanto se pueden considerar modelos de varias entradas y salida única (Grafarend, 2006).

La modelación empírica puede ser realizada por cualquier tipo de técnica de modelado por ordenador, basándose en observaciones empíricas y no en relaciones matemáticas descriptivas del sistema que se modela. En resumen, los modelos empíricos se pueden clasificar en dos grupos: estadísticos y los basados en inteligencia artificial (IA), los cuales se describen en las siguientes subsecciones.

1.2.1.1 Modelos estadísticos

En modelación estadística, los análisis por regresión son transformaciones matemáticas que se emplean para determinar la relación entre variables. Los modelos de regresión son empleados en el micromaquinado principalmente para establecer relaciones entre parámetros característicos del proceso como: fuerzas, vibraciones, emisiones acústicas, calidad superficial, productividad y el rango de remoción del material (*material removal rate*, MRR) (Shetty, *et al.*, 2016).

Un modelo predictivo usado para el microtorneado de cerámica fue propuesto por (Kibria, *et al.*, 2012). En esta investigación se desarrolla un método para establecer la

relación entre los parámetros del proceso, tales como: potencia media del láser, frecuencia del pulso, velocidad de rotación de la pieza, presión de aire y el avance en la dirección del eje y con algunas variables de respuesta entre las que se destacan, la rugosidad superficial y la desviación en la profundidad de corte, a fin de lograr la calidad deseada de la superficie y la precisión dimensional durante las operaciones de micro-torneado usando sistemas láser. Los coeficientes de determinación (R^2) de los modelos obtenidos para el análisis de la rugosidad superficial y la desviación en la profundidad de corte fueron de 0,961 y 0,958 respectivamente. Estos valores tan cerca de 1 indican que existe un buen ajuste entre las predicciones del modelo y el conjunto de valores experimentales.

De la misma manera, Bhandari *et al.*, (2014) desarrolló un modelo por regresión lineal múltiple para controlar la rebaba mediante resultados experimentales en el proceso de microtaladrado. En esa investigación fueron definidos tres tipos de rebabas diferentes dependiendo de la localización (en la entrada, la intermedia y la rebaba de salida), y aplicando una matriz ortogonal como diseño experimental se determinó la relación existente entre los parámetros del proceso y la altura de la rebaba (ver ec. 1.1).

$$Burr = 142,619 + 0,00034 \cdot n - 0,12 \cdot d + 0,384 \cdot f; \quad (1.1)$$

donde, la velocidad del husillo, n (min^{-1}), el avance, f (mm/s) y el diámetro de la herramienta, d (m) son las variables independientes en función de la altura de la rebaba (m) con un coeficiente de determinación, R^2 de 0,626.

Algo similar, pero en este caso aplicado al microfresado es propuesto por (Saklakoglu y Kasman, 2010). Un análisis ANOVA es empleado para determinar la significación del

modelo de RLM que caracteriza la rugosidad superficial (SR) y la profundidad del área maquinada (Dm). Las siguientes ecuaciones describen los modelos de regresión de segundo orden obtenidos:

$$SR = -13,8970 + 0,3858 \cdot P + 0,0397 \cdot F + 0,0206 \cdot SS - \dots ; \quad (1.2)$$

$$-45,3704 \cdot FS - 0,0005 \cdot P \cdot SS$$

$$Dm = 103,73 + 1,05 \cdot P + 0,25 \cdot F - 0,13 \cdot SS - 1540,15 \cdot FS; \quad (1.3)$$

El análisis fue llevado a cabo con un 95% de confiabilidad, donde el valor de F , es el error medio cuadrático de los residuales usado para determinar la significación de un factor, el valor de P reporta el nivel de significación y SS es la suma de los cuadrados ajustada. Los valores predichos obtenidos del modelo de regresión para SR y Dm son muy cercanos a los valores experimentales, lo cual indica que el modelo puede ser usado para predecir la rugosidad superficial y la profundidad del fresado.

1.2.1.2 Modelación empírica mediante técnicas de inteligencia artificial

Los métodos de Inteligencia Artificial (IA) son un conjunto de herramientas y paradigmas que están diseñados para comprender y emular la inteligencia humana y otros sistemas naturales complejos. Aunque muy lejos de esos objetivos, las técnicas basadas en IA han encontrado un amplio espectro de aplicación en varias ramas del conocimiento. Las técnicas más usadas para modelar procesos físicos inspiradas en IA son: las Redes Neuronales Artificiales (RNA's), sistemas de inferencia borrosa (*fuzzy inference system*, FIS), sistemas neuro-borrosos de inferencia (ANFIS) y los métodos probabilísticos (Quiza, *et al.*, 2014).

El desarrollo de las tecnologías basadas en IA ofrece nuevas oportunidades no solo en aplicaciones convencionales (sistemas expertos, bases de datos inteligentes, diagnósticos

técnicos, etc.), sino que también son empleadas en sistemas de completa autonomía y en el control y monitoreo de los procesos de manufactura (Kussul, *et al.*, 2010).

La ventaja de las redes neuronales es su habilidad para llevar a cabo estimados continuos. Sus desventajas son su complejidad relativa y también la gran experiencia y estudios de ensayo y error que se necesitan para implementar exitosamente un sistema de estrategia de monitoreo de base neuronal.

En el micromaquinado han utilizado también las RNA's para el monitoreo de procesos de microtaladrado (Fu, *et al.*, 2007) y de microfresado combinándolo con estadística (Tansel, *et al.*, 2000) y combinándolo con la transformada de *wavelet* (Tansel, *et al.*, 2000).

Los sistemas borrosos han tenido un gran auge dentro de las técnicas de modelación de datos, por lo cual se reportan en la literatura varios libros (Ramík, 2001; Ross, 2004; Siler y Buckley, 2005) destinados a su implementación, pero éstos, a su vez, presentaban dificultades a la hora de establecer las funciones de membresía ya que el resultado alcanzado pudiera estar entre dos valores lógicos posibles; debido a esto surgen las técnicas neuro-borrosas las cuales mantiene los principios de los primeros, pero agregan el autoentrenamiento que proporcionan las redes neuronales por lo cual éstas ya son capaces de tomar sus propias decisiones. Los sistemas neuro-borrosos (*neuro-fuzzy system*, NFS) se encuentran altamente extendidos en el monitoreo del desgaste de las herramientas de corte (Dweiri, *et al.*, 2003; Jang, 1993; Li, *et al.*, 2000; Sharma, *et al.*, 2007; Yumak y Ertunc, 2006).

Otra herramienta que se utiliza en la modelación empírica de los procesos de corte de metales es el modelo oculto de Markov (*hidden Markov model*, HMM); (Atlas, *et al.*, 2000; Zhu, *et al.*, 2009) usan este método para obtener un modelo del desgaste de la herramienta. Las ventajas de los HMM consisten en que son sumamente sencillos de inicializar e implementar. No obstante, los HMM contienen típicamente un gran número de parámetros y por tanto necesitan grandes cantidades de información, para ser entrenados.

Finalmente, existen técnicas que, aunque no tan empleadas, han sido reportadas ocasionalmente. En este grupo se encuentran las máquinas de soporte vectorial (*support vector machine*, SVM) (Kwon, *et al.*, 2006; Shi y Gindy, 2007; Widodo y Yang, 2007), el soporte vectorial bayesiano, las redes neuronales bayesianas (Dong, *et al.*, 2006), las redes abductivas (Quiza y Davim, 2009), los métodos de algoritmos genéticos (Cus y Balic, 2003), y los métodos de enjambre de partículas (Fernández-Martínez y García-Gonzalo, 2009).

Las técnicas de IA son ampliamente usadas en las operaciones de micromaquinado debido a la complejidad y las no linealidades de las señales y eventos presentes en el proceso. El objetivo principal para la aplicación de cualquiera de los métodos antes mencionados es relacionar la información recopilada (fuerza, vibración, emisión acústica y variables internas, como: posición, corriente y potencia, etc.) durante el proceso de corte con los parámetros de calidad (rugosidad superficial, formación de rebabas, errores de geometría). Además estos modelos de predicción, monitoreo o control reducen el costo e incrementan la productividad. El empleo de las técnicas de inteligencia artificial

ha sido abundantemente descrito en la literatura, la tabla 1.1 muestra un breve resumen de los trabajos publicados recientemente relacionados con la materia en cuestión.

Tabla 1.1 Modelos inteligentes: una breve descripción

<i>Operación*</i>	<i>Objetivo</i>	<i>Variables</i>	<i>Algoritmos</i>	<i>Autores</i>
Fresado	Monitoreo del desgaste	Vibraciones	Red neuronal con <i>backpropagation</i>	(Hsieh, <i>et al.</i> , 2011)
Torneado	Rigidez de la máquina y características del material	Fuerzas de corte	Reglas borrosas	(Mandal, <i>et al.</i> , 2013)
Taladrado	Detección <i>on-line</i> de la excentricidad	Señal de fuerzas y parámetros de corte	Red neuronal <i>feed-forward</i>	(Beruvides, <i>et al.</i> , 2014)
Fresado	Modelación de la rugosidad superficial	Señales de vibración	<i>Adaptive network-based fuzzy inference system</i> (ANFIS)	(Beruvides, <i>et al.</i> , 2016)
Torneado	Predicción del desgaste	Reconocimiento de patrones	Red neuronal	(D'Addona, <i>et al.</i> , 2015)
Fresado	Identificación del desgaste en el flanco de la herramienta	Rasgos de las fuerzas de corte	Modelo continuo de Hidden-Markov	(Zhu, <i>et al.</i> , 2009)
Taladrado	Rotura de la herramienta y detección del desgaste	Corriente de entrada del motor del accionamiento	Red neuronal	(Fu, <i>et al.</i> , 2007)
Fresado	Vida útil	Componentes de la fuerza de corte	Modelo de lógica borrosa (Takagi-Sugeno-Kang)	(Ren, <i>et al.</i> , 2013)

* Todas las operaciones están referidas a los procesos en la micro-escala.

A menudo, las técnicas de modelación, especialmente las basadas en IA son el paso intermedio para alcanzar los parámetros óptimos de una cadena de producción (Bhavsar,

et al., 2015). Indudablemente, al menos un modelo robusto es imprescindible para llevar a cabo la optimización y esta representación es necesaria para establecer las relaciones entre las variables independientes y dependientes. Un ejemplo es una optimización de control adaptativo para el microfresado de aceros endurecidos presentada por (Coppel, *et al.*, 2015). Los autores proponen un sistema para la optimización del control adaptativo y a su vez optimizar los parámetros de corte usando una red neuronal que estima el desgaste de la herramienta de corte.

1.3 Optimización del proceso de microfresado

1.3.1 Principios básicos de la optimización del microfresado

La optimización de los procesos productivos, en general, se puede llevar a cabo en tres niveles básicos (Shaw, 1984):

- Establecimiento de mejoras relativas a los actuales métodos de producción.
- Selección de nuevos métodos de producción con el equipamiento existente.
- Desarrollo de equipamiento nuevo.

La determinación de los parámetros óptimos de cualquier operación de micromaquinado es por lo general una tarea difícil, donde se deben tener en cuenta los siguientes aspectos: conocimiento del proceso, ecuaciones empíricas para desarrollar restricciones reales, conocer las características y capacidades técnicas de la máquina herramienta, desarrollar un criterio de optimización efectivo, y por último tener conocimiento de las técnicas numéricas, matemáticas, heurísticas, etc. que se emplean en la optimización (Pawar y Venkata Rao 2012). La optimización de las operaciones de microcorte, es un proceso aún

más complejo, debido a, el efecto del tamaño (Liu, *et al.*, 2014) y la influencia del radio del filo de la herramienta (Altintas y Jin, 2011). Además, ya que la rigidez de las herramientas de microfresado es baja debido a la alta proporción entre longitud/diámetro, el incremento de las fuerzas de corte en el proceso, podría causar fenómenos indeseados como: la deflexión de la herramienta, imperfecciones en el producto final e incluso daños en la propia herramienta (Pratap, *et al.*, 2015).

En el microfresado, como en el resto de los procesos de micromaquinado, los parámetros principales que controlan el proceso, son las variables del régimen de corte: profundidad, avance y revoluciones del husillo. Como mismo ocurre en las operaciones de maquinado convencional, la selección de los parámetros del proceso recae principalmente en el criterio humano y la experiencia de los técnicos (Yusup, *et al.*, 2012). Por tanto, la optimización del mismo se basa en la selección de un régimen de corte que maximice o minimice (según corresponda) uno o varios criterios determinados.

1.3.4 Criterios de optimización

La optimización de procesos físicos involucra el uso de modelos, representados por funciones que nunca van a satisfacer las condiciones de, continuidad, derivabilidad y unimodalidad, las cuales son requeridas por las técnicas numéricas y analíticas convencionales (Bharathi y Baskar, 2010). La alternativa está en el empleo de las heurísticas de optimización, basadas en el uso de las herramientas de *soft-computing* (Chandrasekaran, *et al.*, 2010). Estas técnicas son especialmente útiles en la optimización multiobjetivo (*multi-objective optimization*, MO), donde varios objetivos, diferentes y a

menudo interconectados, son considerados (López-Jaimes y Coello, 2014). La Fig. 1.4 muestra los pasos básicos para la solución de un problema de MO.

Varios acercamientos en la optimización de las condiciones de corte en el proceso de microfresado han sido reportados en la literatura. Uno de ellos, Saedon (Saedon, *et al.*, 2012) y coautores optimizaron la vida útil de la herramienta en el microfresado del acero endurecido AISI D2 usando como método una superficie de repuesta de segundo orden. Por otro lado Kuram y Ozcelik (2016) emplearon el método de Taguchi para la optimización del desgaste de la herramienta, la rugosidad superficial y las fuerzas de corte en el microfresado de Ti6Al4V e Inconel 718. Ellos optimizaron cada objetivo independientemente y, después seleccionaron las condiciones de corte apropiadas para comparar los resultados obtenidos. Krimpenis y colaboradores (2014) presentaron la optimización del proceso de microfresado, considerando el tiempo de corte y la rugosidad superficial alcanzada, pero emplearon una aproximación *a priori* donde ambos objetivos son combinados en uno solo mediante una suma ponderada. Cardoso *et al.* (2010) también emplearon una técnica *a priori* (agregación no lineal) para la optimización del tiempo de maquinado y la rugosidad superficial en el microfresado de aleaciones de aluminio Al 2011.

1.3.5 Formulación general del problema de optimización multiobjetivo

De forma general, un problema de optimización multiobjetivo puede considerarse aquel en el cual es necesario optimizar $\mathbf{y}(\mathbf{x})$, sujeto a $\Omega = \{\mathbf{x} \in \mathbf{R}^N: \mathbf{g}(\mathbf{x}) \leq 0\}$, donde \mathbf{x} es el vector de las variables de decisión (o variables de optimización), $\mathbf{y}(\mathbf{x})$ es el vector de las funciones objetivos ($\mathbf{y}_1(\mathbf{x}), \dots, \mathbf{y}_Y(\mathbf{x})$); y Ω es un conjunto no nulo de R^N , llamado espacio

de búsqueda. El vector $\mathbf{g}(\mathbf{x}) = \mathbf{g}_1(\mathbf{x}), \dots, \mathbf{g}_G(\mathbf{x})$, representa a las G restricciones del sistema (Abbass, *et al.*, 2001). Por comodidad, se considera que todos los objetivos deben ser minimizados. Evidentemente, cualquier objetivo a minimizar puede, sin pérdida de rigor, convertirse en objetivo a maximizar multiplicando la respectiva ecuación por -1.

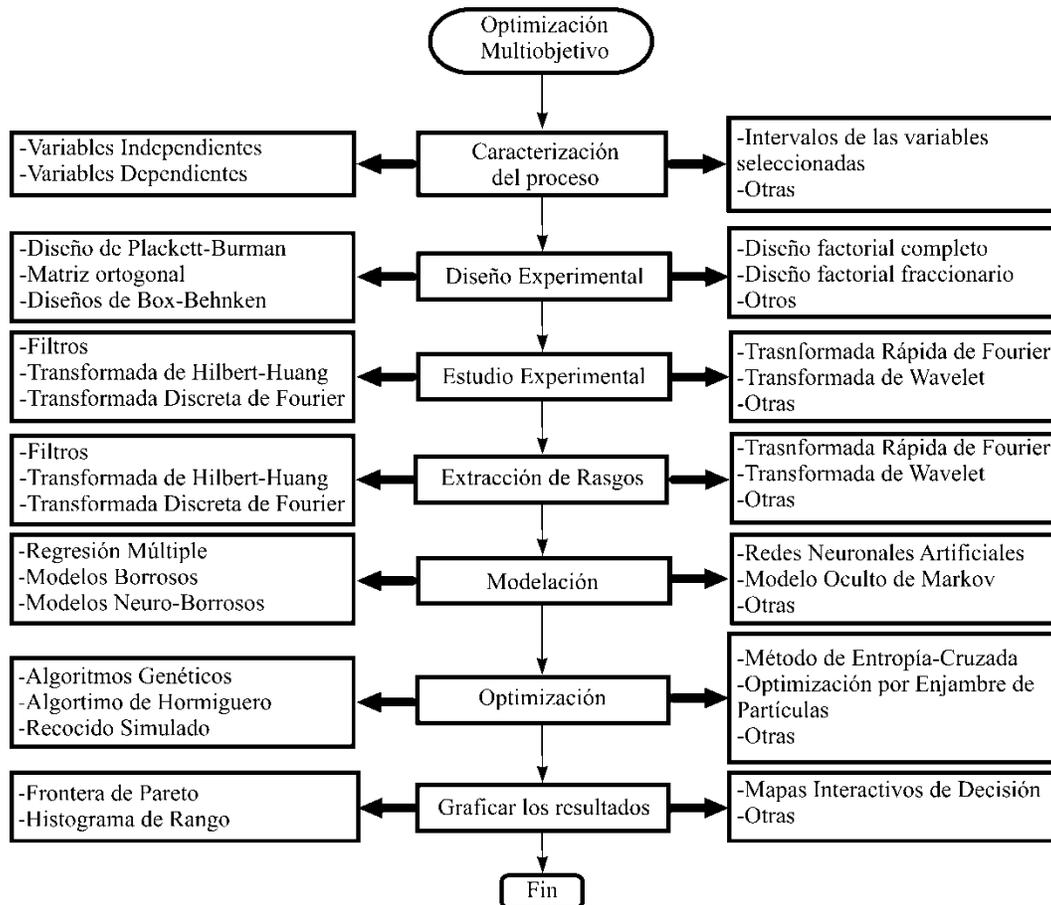


Figura 1.4. Procedimiento clásico para la optimización multiobjetivo

Existen tres vías básicas de enfocar un problema de optimización multiobjetivo, en cuanto a la forma de la toma de decisiones (Van Veldhuizen y Lamont, 2000).

- *A priori*: La toma de decisiones precede a la optimización. Se basa en la combinación de los diversos objetivos en una función de costo escalar, convirtiendo el problema en uno de un solo objetivo. Dentro de este grupo se destacan la

escalarización por combinación (lineal o no lineal); la ponderación de los criterios por ordenamiento y las técnicas de min-max.

- *Progresivas*: La toma de decisiones se realiza conjuntamente con la optimización, a través del suministro de información parcial sobre la precedencia de los criterios. Esta información se integra dentro del propio algoritmo de solución. Es un enfoque intermedio entre los otros dos.
- *A posteriori*: La toma de decisiones se realiza luego de que la optimización ha llegado a un conjunto de soluciones igualmente factibles, denominadas conjunto óptimo de Pareto. Según reporta la bibliografía (Van Veldhuizen y Lamont, 2000), las técnicas *a posteriori* ofrecen los mejores resultados y constituyen el foco de atención de las actuales investigaciones sobre optimización multiobjetivo.

Las soluciones óptimas de Pareto también se denominan soluciones no inferiores, admisibles, eficientes o no dominadas (Quiza, 2004). Estas soluciones se consideran óptimas en el sentido de que no hay ninguna otra, dentro del espacio de búsqueda considerado, que mejore uno de los objetivos buscados sin empeorar a la vez los otros (Abbass, *et al.*, 2001).

Los métodos *a posteriori* se basan en la determinación previa de la frontera de Pareto, para luego, a partir de ella, tomar la decisión correspondiente. Este enfoque tiene la ventaja de que no limita la toma de decisiones a un único valor, sino que permite la consideración de diferentes opciones razonablemente eficientes (Quiza, 2004).

1.3.6 Descripción del algoritmo para la optimización multiobjetivo

El algoritmo llamado Entropía Cruzada para la Optimización Multiobjetivo modificado (*Multi-Objective Cross-entropy Algorithm*, MOCE+) recientemente reportado por (Beruvides, *et al.*, 2016), está enfocado en la solución de problemas de MO y está basado en las aproximaciones al método de CE propuesto por (Bekker y Aldrich, 2011).

$$\min y = f(x) : x \in R^n, y \in R^m; \quad (1.4)$$

donde

$$l_i \leq x_i \leq u_i, i = 1 \dots n; \quad (1.5)$$

restringido por

$$g_i(x) \leq 0, i = 1 \dots p; \quad (1.6)$$

El método crea en el primer paso una población élite vacía $x_{ij}^* = \{\emptyset\}$ donde se almacenan las mejores soluciones durante todo el tiempo de ejecución del algoritmo; entonces un ciclo de N iteraciones (ciclo exterior) es ejecutado, donde se calculan los valores de las medias y las desviaciones estándar (μ_i, σ_i) para cada variable de decisión en su correspondiente intervalo:

$$\mu_i = l_i + U(0,1)(u_i - l_i), i = 1 \dots n; \quad (1.7)$$

$$\sigma_i = 10(u_i - l_i), i = 1 \dots n; \quad (1.8)$$

Posteriormente se ejecuta un ciclo anidado en el algoritmo hasta que se alcanza algún criterio de parada, este ciclo comienza inicializando una población de trabajo (PT) $\{x_{ij}; i = 1 \dots Z, j = 1 \dots n\}$ a partir de la población inicial, la cual puede ser creada de dos maneras diferentes. Si la población elite está vacía o si es la primera iteración en el ciclo, la población de trabajo es generada a partir de una distribución normal aleatoria, con media μ_i y desviación σ_i , truncada en el intervalo $[l_i, u_i]$, para cada variable

independiente. En otras palabras la población de trabajo es creada a partir de la población elite.

Una vez creada la PT, cada solución es evaluada, obteniéndose el conjunto de vectores objetivos $\{y_{ij} = f_j(x_{i1}, \dots, x_{in}), i = 1 \dots Z, j = 1 \dots m\}$. Después de este paso, se le hizo una mejora al algoritmo propuesto por (Bekker y Aldrich, 2011), con el objetivo de tratar con las restricciones, esta variación se explica en la aplicación de una aproximación en la penalización que modifica los valores de la función objetivo mediante la expresión:

$$y_{ij} = y_{ij} + \sum_{k=1}^p (\gamma_k \max(0, g_k(x_{i1}, \dots, x_{in}))), i = 1 \dots N, j = 1 \dots m; \quad (1.9)$$

donde, γ_k , $k = 1, \dots, p$, son los pesos prescritos para cada restricción. Después cada solución en la PT es ranqueada por la dominancia de Pareto, en otras palabras considerando el número de otras soluciones que esta domina. La población elite, es incrementada con la adición de las todas la soluciones con una baja dominancia que se compara con cierto valor de umbral preestablecido, λ_t . En el próximo paso, las medias y la desviación estándar para cada variable son actualizadas a partir de los valores de la población elite, aplicando el factor de aplanamiento α :

$$\mu_i^t = \alpha \mu_i^{t-1} + (1 - \alpha) \text{mean}(x_i^*), i = 1 \dots n; \quad (1.10)$$

$$\sigma_i^t = \alpha \sigma_i^{t-1} + (1 - \alpha) \text{stdev}(x_i^*), i = 1 \dots n; \quad (1.11)$$

Finalmente, tres condiciones de parada son evaluadas, calculándose el cambio en la desviación estándar para cada variable:

$$\varepsilon_j = |\sigma_j - \sigma_j^{old}|; \quad (1.12)$$

La primera condición que debe cumplirse es que todos los cambios antes calculados deben ser menores o iguales que un valor prefijado, ε^{max} :

$$\max_{j=1}^n (\varepsilon_j) \leq \varepsilon^{max}; \quad (1.13)$$

La segunda condición se cumple si el número de evaluaciones, S , el cual es incrementado en cada iteración del ciclo interior del algoritmo, es mayor o igual a un valor prescrito:

$$S \geq S^{max}; \quad (1.14)$$

Si alguna de las condiciones anteriormente mencionadas se cumple, el ciclo interno para y la población elite es ranqueada y filtrada para almacenar solo, las mejores soluciones Z_{max}^* . En este punto se introduce otra modificación al algoritmo: se disminuye el valor de umbral por un factor κ :

$$\lambda_t = (1 - \kappa) \lambda_{t-1}; \quad (1.15)$$

Este cambio significa que, se emplean amplios niveles de umbrales para la primera iteración (donde la preservación de la diversidad es importante), y niveles de umbrales más pequeños para la iteración final, lo que trae consigo que la población elite se acerque más a la verdadera frontera de Pareto.

1.4 Conclusiones parciales

Como resultado de la revisión bibliográfica expuesta anteriormente, se ha podido arribar a las siguientes conclusiones parciales:

1. Los sistemas expertos tienen como objetivo incrementar la productividad y calidad, permitiendo a su vez la automatización de los procesos de maquinado. Dentro del

micromaquinado, su importancia se acentúa debido a la complejidad de las operaciones.

2. Fueron analizados las diferentes técnicas de modelación empíricas, resaltándose la amplia aplicación de los paradigmas basados en IA a los procesos de manufactura.
3. La optimización multiobjetivo *a posteriori* es la aproximación más conveniente en la solución de problemas donde múltiples objetivos conflictivos deben ser simultáneamente considerados. Con esta técnica se obtiene un conjunto de soluciones óptimas, representando diferentes combinaciones de objetivos.

CAPÍTULO 2. MATERIALES Y MÉTODOS

En el siguiente capítulo se describe el sistema experto propuesto para la selección de los parámetros de corte óptimos en el microfresado de ranuras. También se detalla el procedimiento experimental, así como las técnicas empleadas para: el tratamiento de la señal de fuerza, la modelación de las variables a estudiar, así como los parámetros del MOCE+ usado.

2.1 Arquitectura del Sistema Experto

El propósito del sistema experto propuesto es la selección de los parámetros de corte óptimos para el microfresado de ranuras. El sistema está formado por cuatro bloques principales, donde se incluyen, dispositivos físicos y procedimientos para la modelación, la optimización y la toma de decisiones (ver Fig. 2.1):

- *Adquisición de datos.* Está formado por el centro de micromaquinado, incluyendo los sensores y dispositivos de procesamiento y almacenamiento de los datos del proceso de corte.
- *Modelación.* Está basado en técnicas de *soft-computing*, a través de las cuales se establecen las relaciones entre las variables de entrada y salida que representan el proceso y que serán usadas como objetivos y restricciones en la optimización de los parámetros de corte.
- *Optimización.* Permite obtener el conjunto de soluciones óptimas, correspondientes a las diferentes combinaciones de los valores de las funciones objetivos. Utiliza un enfoque de optimización multiobjetivo *a posteriori* basado en heurísticas.

- *Toma de decisiones.* Las soluciones más apropiadas son seleccionadas en dependencia de las condiciones específicas de trabajo.

El procedimiento comienza con un diseño de experimentos, el cual cubre los valores de los parámetros de corte comúnmente utilizados (velocidad de corte, avance y la profundidad de corte axial). Posteriormente se ejecuta el proceso de corte para obtener los valores de la rugosidad superficial y otras variables representativas, como las fuerzas de corte en cada punto experimental. Los datos guardados, son empleados en la modelación de las variables antes mencionadas. Se escogen para la modelación las redes neuronales, debido a su demostrado rendimiento y la gran variedad de aplicaciones reportada sobre las mismas. Por consiguiente, los modelos basados en RNA's son entrenados para describir la relación entre los parámetros de corte y las variables medidas.

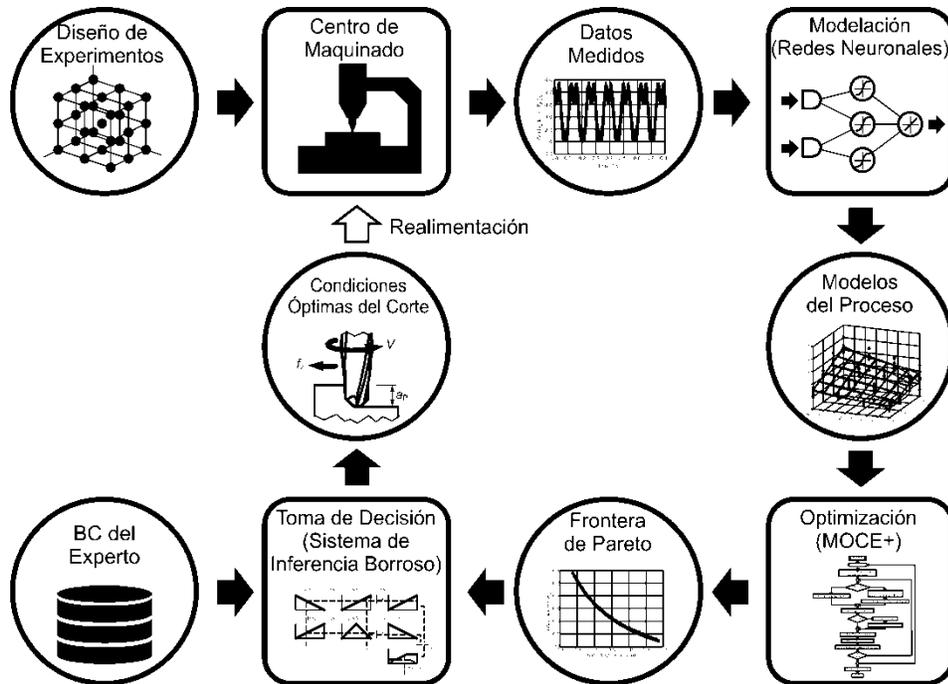


Figura 2.1 Diagrama del sistema experto propuesto

En el próximo paso, se ejecuta la optimización multiobjetivo. El uso de dos funciones objetivos satisfacen muchos requerimientos industriales a través de aproximaciones comprensivas, en este estudio son consideradas: la productividad y la calidad superficial. Con el objetivo de mantener la fuerza de corte en un rango permisible y evitar afectaciones a la vida útil de la herramienta, esta es considerada como una restricción. El proceso de optimización se realizó aplicando el método de entropía cruzada, previamente reportado (Beruvides, *et al.*, 2016); con el mismo se obtienen un conjunto de soluciones óptimas, en el sentido de que no hay otra solución superior en el espacio de búsqueda cuando son considerados simultáneamente todos los objetivos de la optimización. Estas soluciones son conocidas como el conjunto de Pareto y gráficamente se pueden representar en la llamada frontera de Pareto (FP).

El procedimiento para la toma de decisiones parte de la previamente obtenida FP y selecciona la condición de corte más conveniente. Este procedimiento considera la importancia relativa de los objetivos de la optimización para las condiciones específicas de la producción, a través de un sistema de inferencia difusa sustentado por la base del conocimiento del experto (Khayyam, *et al.*, 2015; Tsai, *et al.*, 2014). Una característica importante del SE propuesto es el entrenamiento con realimentación. Los datos actuales obtenidos después de una operación son incorporados en un *data set* y los modelos son ajustados nuevamente, con el objetivo de mejorar la calidad de los modelos del proceso.

2.2 Adquisición de datos

2.2.1 Equipamiento experimental

El proceso estudiado fue el microfresado de ranuras de la aleación de titanio Ti6Al4V. La misma tiene una composición química de: Ti (88,8%), Al (6,62%), V (4,55%), Fe (0,02%), Zr (0,03%), O (0,55%), N (0,5%) y H (0,3%); se utilizó con tratamiento térmico de solubilización entre 900-955°C, y envejecido a 540°C con una dureza de 107,7 HRB.

Los experimentos se ejecutaron en un centro de maquinado de tres ejes KERN Evo (Fig. 2.3a) con una velocidad máxima de rotación de 50 000 rev/min. La herramienta de corte utilizada fue una microfresa *Union Tools HLS 2005-015* (Fig. 2.3b), con dos filos de corte y un ángulo de la hélice de 30° y diámetro de 0,5 mm.

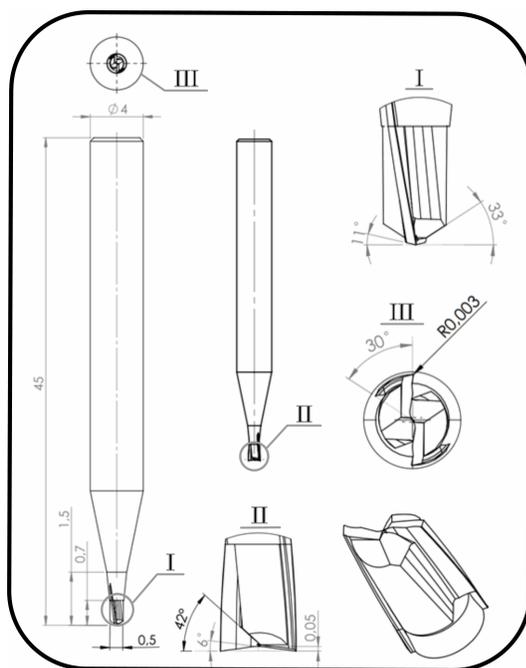


Figura 2.2 Esquema de la microfresa

Las fuerzas de corte en las direcciones del avance (x), transversal (y) y axial (z) fueron medidas con un dinamómetro piezoeléctrico *Kistler Minidyn 9256* (Fig. 2.3c), con un rango para las mediciones de $(-250 \dots 250)$ N para todas las componentes de la fuerza, y una frecuencia natural de $f_x \approx 4.0$ kHz, $f_y \approx 4.8$ kHz and $f_z \approx 4.6$ kHz. La sensibilidad del dinamómetro es de 26 pC/N en las direcciones x y y , y 13 pC/N en la dirección de z .

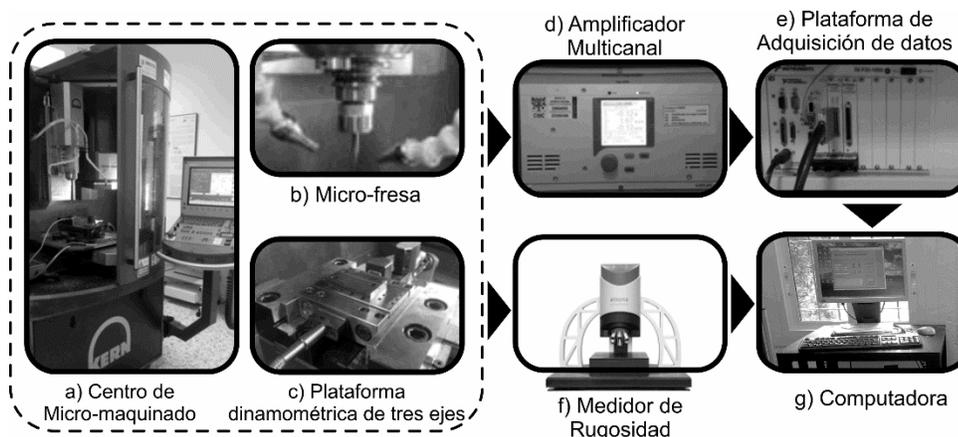


Figura 2.3 Equipamiento experimental

Las señales de los datos fueron amplificadas (Fig. 2.3d) e introducidas en una tarjeta de adquisición de datos *National Instruments NI PXI 6251*, con una frecuencia de muestreo de 50 kHz, y fueron procesadas en el controlador adjunto *National Instruments PXI-8187* (Fig. 2.3e).

Para la medición de la rugosidad superficial se usó un *Form Talysurf PGI* (Fig. 2.3f), este instrumento fue desarrollado especialmente para la industria óptica y opera con precisión nanométrica.

2.2.2 Diseño experimental

Con el objetivo de obtener la mayor información posible del estudio experimental, se seleccionó un diseño factorial completo para los experimentos, donde se escogieron tres niveles para la velocidad de corte y cuatro niveles para el avance y la profundidad de corte axial (Tabla 2.1). Se realizaron tres réplicas para cada punto experimental, determinándose para cada uno de ellos la fuerza de corte resultante y la rugosidad superficial:

$$F_C = \sqrt{F_x^2 + F_y^2 + F_z^2}; \quad (2.1)$$

Tabla 2.1 Niveles del diseño experimental

<i>Factores experimentales</i>	<i>Niveles experimentales</i>			
Velocidad de corte, V [m/min]	32	52	72	
Avance, f_z [μm]	5	10	15	20
Profundidad de corte, a_P [μm]	13	20	27	34

2.2.3 Procesamiento de la señal de fuerza

Con el objetivo de poder contrastar mejor las señales experimentales de las fuerzas con los resultados obtenidos en la modelación es conveniente eliminar las vibraciones naturales del sistema, ya que no proceden del proceso de microfresado, sino del comportamiento dinámico del sistema pieza-herramienta.

Para reducir el ruido presente en la señal de fuerza experimental se empleó el método del valor promedio. El cual consiste en tomar varios ciclos de la señal y obtener el valor medio. Estos ciclos incluyen a su vez las fuerzas correspondientes a varias vueltas de la

herramienta. Al obtener el valor medio se elimina el “ruido” provocado por las vibraciones, ya que su frecuencia no es un múltiplo entero de la frecuencia principal de la señal y por tanto presentarán un valor aleatorio en cada ciclo, consiguiéndose así la eliminación de las señales que no tengan la misma frecuencia que la señal principal.

Finalmente, el valor medio de la señal de fuerza, correspondiente al corte de un solo filo, fue determinado superponiendo y promediando todas las muestras (Fig. 2.4). Después de completar el procesamiento de la señal, se obtuvieron 144 valores para la fuerza de corte, coincidiendo con las tres réplicas para 48 puntos experimentales (ver Tabla 2.2). De la misma manera, se obtuvieron 144 valores de rugosidad superficial para las mediciones correspondientes.

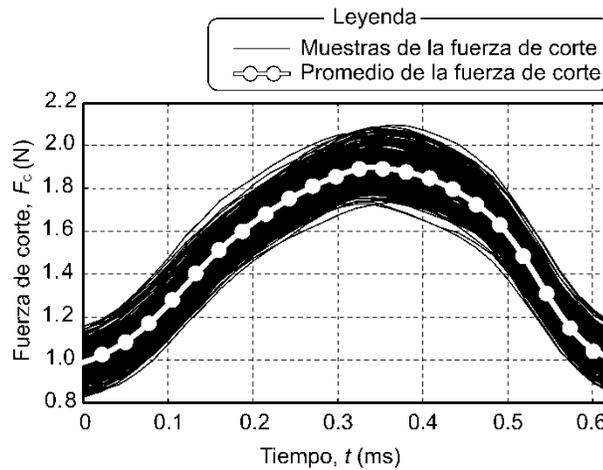


Figura 2.4 Procesamiento de la fuerza de corte

Tabla 2.2 Resultados experimentales

No.	V [m/min]	f_z [μm]	a_p [μm]	R_a [μm]			F_C [N]		
				Rep. 1	Rep. 2	Rep. 3	Rep. 1	Rep. 2	Rep. 3
1	32	5	13	0,3320	0,3300	0,3200	1,1703	0,7099	0,6668
2	32	10	13	0,3820	0,3980	0,3790	0,8630	1,0192	0,9774
3	32	15	13	0,4110	0,4120	0,3910	1,5589	1,2376	1,2676
4	32	20	13	0,4450	0,4470	0,4270	0,7191	1,4872	1,5281
5	32	5	20	0,3570	0,3610	0,3490	1,2669	0,9432	0,9727
6	32	10	20	0,3740	0,3810	0,3770	1,8565	1,4051	1,4479
7	32	15	20	0,4200	0,4150	0,4190	2,2501	1,7379	1,8602
8	32	20	20	0,4780	0,4740	0,4690	2,8102	2,0385	2,2512
9	32	5	27	0,3780	0,3730	0,3810	1,5074	1,3371	1,2421
10	32	10	27	0,4070	0,4150	0,4130	1,9642	2,1432	1,8364
11	32	15	27	0,4720	0,4780	0,4830	2,6898	2,0602	2,3869
12	32	20	27	0,5120	0,5190	0,5150	2,5641	2,9784	3,0078
13	32	5	34	0,3940	0,3960	0,3980	1,4732	1,6013	1,4503
14	32	10	34	0,4120	0,4070	0,4210	2,2068	1,9821	2,2137
15	32	15	34	0,4850	0,4910	0,4700	2,9103	2,3720	2,9035
16	32	20	34	0,5500	0,5410	0,5610	3,0541	2,8513	3,4890
17	52	5	13	0,2960	0,2830	0,2740	1,0534	0,9886	0,8728
18	52	10	13	0,3290	0,3410	0,3340	1,1545	1,4551	1,1438
19	52	15	13	0,3370	0,3520	0,3680	1,7683	1,7203	1,4699
20	52	20	13	0,3540	0,3730	0,3820	1,9710	2,0629	1,8484
21	52	5	20	0,3280	0,3120	0,3190	1,1590	1,1264	1,0066
22	52	10	20	0,3560	0,3490	0,3610	1,5206	1,5371	1,5615
23	52	15	20	0,3710	0,3710	0,3770	1,9770	1,8574	2,0281
24	52	20	20	0,3950	0,3910	0,3990	2,4326	2,3325	2,4659

Continúa...

Tabla 2.2 Resultados experimentales (cont.)

No.	V [m/min]	f_z [μm]	a_p [μm]	R_a [μm]		F_C [N]			
				Rep. 1	Rep. 2	Rep. 1	Rep. 2	Rep. 1	Rep. 2
25	52	5	27	0,3530	0,3570	0,3510	1,3191	1,3238	1,4049
26	52	10	27	0,3870	0,3910	0,3910	1,5415	1,8305	1,9417
27	52	15	27	0,4130	0,4170	0,4180	2,2709	2,1313	2,4995
28	52	20	27	0,4560	0,4490	0,4510	2,7089	2,7274	2,9793
29	52	5	34	0,3530	0,3730	0,3750	1,1993	1,5518	1,5755
30	52	10	34	0,3780	0,3910	0,3930	1,9678	2,0006	2,2562
31	52	15	34	0,3930	0,4150	0,4100	2,5782	2,4869	2,7747
32	52	20	34	0,4300	0,4360	0,4440	3,2514	2,9987	3,4230
33	72	5	13	0,2130	0,2150	0,2130	0,7925	1,0906	4,3114
34	72	10	13	0,2910	0,2960	0,2950	0,6857	1,4565	1,4828
35	72	15	13	0,3480	0,3440	0,3120	1,3802	1,7617	2,1530
36	72	20	13	0,3610	0,3610	0,3620	1,4937	2,0850	2,6573
37	72	5	20	0,2910	0,2870	0,2950	0,9721	1,2160	1,2745
38	72	10	20	0,3380	0,3310	0,3330	0,7426	1,7236	1,9281
39	72	15	20	0,3530	0,3490	0,3610	1,5548	2,0809	2,5267
40	72	20	20	0,3820	0,3790	0,3890	1,8975	1,9763	3,0033
41	72	5	27	0,2810	0,2930	0,2960	1,0683	1,4157	1,5173
42	72	10	27	0,3750	0,3690	0,3790	1,4273	1,9274	1,8370
43	72	15	27	0,3990	0,3890	0,4010	1,8346	2,3679	2,7711
44	72	20	27	0,4460	0,4390	0,4510	1,7193	2,6838	3,4581
45	72	5	34	0,2890	0,2930	0,2950	1,0327	1,5710	1,7567
46	72	10	34	0,3190	0,3150	0,3120	1,5830	2,1731	2,5305
47	72	15	34	0,3340	0,3410	0,3430	2,0761	2,6263	3,4035
48	72	20	34	0,3540	0,3690	0,3650	2,9431	3,0043	4,1128

2.3 Modelación

Se emplearon dos redes neuronales del tipo perceptrón multicapas (*multilayer perceptron*, MLP²), con el objetivo de obtener los modelos que relacionan las variables de decisión con los objetivos y restricciones a utilizar en la optimización. Para cada modelo, la topología de la red está compuesta por tres entradas (velocidad de corte, avance y profundidad de corte), una salida (variable modelada, F_C ó R_a) y una sola capa oculta formada por cuatro neuronas (Fig 2.5)

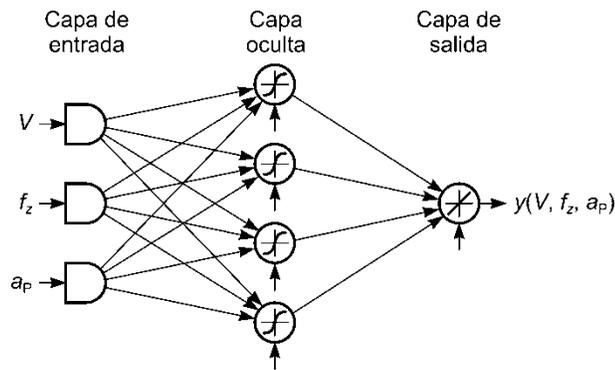


Figura 2.5 Topología del MLP

Los valores de entrada y salida del modelo fueron normalizados en el intervalo $[-1, 1]$, usando interpolación lineal. Se seleccionó como función de transferencia para la capa oculta la sigmoidea hiperbólica, y para la neurona de la capa de salida la función de transferencia es la lineal.

Para el entrenamiento de ambos modelos (rugosidad superficial y fuerza de corte) se empleó el método de retropropagación del error (*back-propagation*) con momento y velocidad de aprendizaje adaptativa. Para la velocidad de aprendizaje se seleccionó

²Todos los códigos usados en esta investigación están disponibles en <http://gifas.umcc.cu/software/mmo.7z>

inicialmente un valor de 0,01; con razones de incremento y decrecimiento de 1,05 y 0,95; respectivamente. El valor para la constante de momento fue de 0,9.

Los procesos de entrenamiento se detuvieron, en ambos casos, al transcurrir 20 000 iteraciones, independientemente del ajuste (suma de los errores cuadráticos) alcanzado por las redes.

2.4 Optimización

Para la optimización fue seleccionado el método mejorado de entropía cruzada multiobjetivo (*improved multiobjective cross-entropy*, MOCE+) recientemente reportado por Beruvides y coautores (2016). Las variables de decisión para la optimización del proceso de microfresado fueron la velocidad de corte, V , y el avance, f_z . Ambas variables son restringidas en sus respectivos intervalos experimentales donde fueron obtenidos los modelos empíricos:

$$32 \text{ m/min} \leq V \leq 72 \text{ m/min}, \quad (2.2a)$$

$$5 \mu\text{m} \leq f_z \leq 20 \mu\text{m}, \quad (2.2b)$$

La profundidad de corte axial se consideró constante, ya que esta corresponde con la profundidad de la ranura y como consecuencia es un parámetro que se da como una especificación de diseño. En este caso de estudio, el valor de la profundidad de corte es de $a_p = 25 \mu\text{m}$.

Los objetivos seleccionados para la optimización fueron: el tiempo de corte unitario (i.e. el inverso de la velocidad de remoción del material) y la rugosidad superficial, ya que

ellos caracterizan respectivamente la productividad y la calidad del proceso. Estos dos objetivos son normalmente conflictivos entre sí.

El tiempo de corte unitario, τ_0 , puede ser analíticamente calculado a partir de los parámetros de corte, con la expresión:

$$\tau_0 = \frac{10^3 \pi}{f_z a_p V z}, \quad (2.3)$$

donde, z es el número de dientes de la herramienta (para la microfresa en estudio, $z = 2$).

La rugosidad superficial, R_a , se calcula usando el modelo basado en la red neuronal explicada en la sección anterior (ver Código 3.1 en el próximo capítulo):

$$R_a = f_{MLP}(V, f_z, a_p), \quad (2.4)$$

Además de las restricciones donde se indican los intervalos de las variables de decisión (ecs. 2.2a y 2.2b), otra restricción a tener en cuenta incluye el esfuerzo máximo causado por la fuerza de corte, la cual se puede expresar como:

$$\tau_{eq} = \frac{F_c \sqrt{L^2 + D^2}}{(\pi/16)D^3} \leq \frac{\tau_U}{\eta}, \quad (2.5)$$

donde, τ_{eq} es el esfuerzo equivalente en la sección más cargada; L , es la longitud del filo de la herramienta de corte; D , diámetro de la herramienta; τ_U , el esfuerzo máximo del material de la herramienta de corte; y η , el coeficiente de seguridad.

Los parámetros de la herramienta son $L = 1,5\text{mm}$ y $D = 0,5\text{mm}$. El material de la herramienta es carburo de tungsteno con $\tau_U = 700\text{MPa}$. Se seleccionó un factor de seguridad elevado, $\eta = 5,0$, debido a las características dinámicas del proceso de microfresado.

La fuerza de corte, F_C , se puede calcular como función de los parámetros de corte usando el modelo basado en el MLP mostrado en el Código 3.2 del próximo capítulo:

$$F_C = f'_{MLP}(V, f_z, a_p), \quad (2.6)$$

La restricción de la ec. 2.5 puede ser reelaborada, más formalmente, para quedar de la siguiente manera:

$$\frac{16\eta f'_{MLP}(V, f_z, a_p)\sqrt{L^2 + D^2}}{\pi D^3 \tau_U} - 1 \leq 0, \quad (2.7)$$

2.5 Toma de decisiones

En esta investigación para la toma de decisiones se empleó un sistema de inferencia borroso (*fuzzy inference system*, FIS) del tipo de Mamdani, ya que este tipo de sistemas son intuitivos en sus relaciones, se adaptan muy bien a las entradas humanas en base a la verbalización y, por lo tanto, han alcanzado una amplia difusión en aplicaciones prácticas.

Una vez obtenida la frontera de Pareto, se debe seleccionar una solución de la misma, con el propósito de establecer los parámetros del proceso de microfresado. Como todas las soluciones en dicha frontera son igualmente buenas, desde el punto de vista matemático, la selección debe realizarse en base a la preferencia de los objetivos que se establezca en dependencia de las condiciones concretas de producción.

La toma de decisión a través de la estimación de la solución más apropiada no es un asunto sencillo, y se puede explicar desde diferentes puntos de vista a partir de los criterios de expertos y tecnólogos, además es bastante difícil la formalización de estos criterios en términos matemáticos. Esta selección es llevada a cabo usualmente en los

procesos de maquinado, considerando la preferencia entre los objetivos (p. ej. tiempo unitario y calidad superficial). Cuando se pretende elevar la productividad, la solución con menor tiempo unitario (pero mayor rugosidad superficial) se debe seleccionar. Por el contrario, cuando la calidad de la pieza es el objetivo fundamental, la solución más conveniente es minimizar la rugosidad superficial, sacrificando el tiempo de corte unitario. Finalmente, cuando no están claras las prioridades entre los dos objetivos, se debe tomar una solución compensada o de compromiso (*trade-off solution*).

Un procedimiento simple, basado en el criterio de operadores expertos y tecnólogos es propuesto con un proceso de toma de decisiones implementado en tres pasos (Fig. 2.6). En el primer paso, las preferencias por los objetivos se entran como números enteros, P_1 y P_2 (ec. 2.8), donde el menor valor le asigna más importancia a un objetivo con respecto al otro. De esta forma, las preferencias industriales pueden ser expresadas comprensivamente y de manera que puedan ser fácilmente entendidas en todos los niveles de la fábrica, desde el operario de la máquina herramienta hasta los departamentos de planificación y producción.

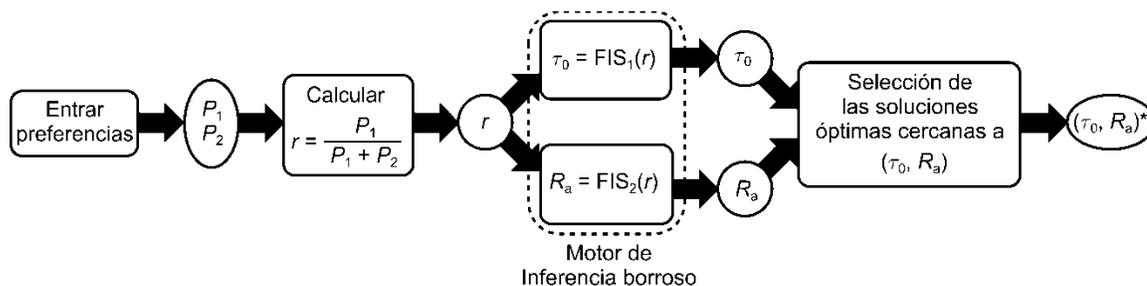


Figura 2.6 Estructura del sistema de toma de decisiones

P_1 refleja el interés del sector industrial, encaminado a establecer la productividad como prioridad en todos los escenarios. Por otro lado, existen situaciones en las cuales una maximización de la productividad debe ser penalizada, debido a los rigurosos requisitos

de calidad superficial, por ejemplo: componentes aeronáuticos e implantes bio-compatibles. Toda vez que las prioridades han sido establecidas por medio de P_1 y P_2 , el llamado *ratio* de los objetivos, es calculado por la expresión:

$$r = \frac{P_1}{P_1 + P_2}, \quad (2.8)$$

El valor calculado de r es usado como entrada en el FIS, el cual predice los valores para cada objetivo correspondiente a ese *ratio*. Ambos FIS usan las mismas funciones de pertenencia borrosas para la entrada (Fig. 2.7a), marcadas como *LOW*, *MED* y *HIGH*. *MED* es una función de tipo triangular mientras que *LOW* y *HIGH* son del tipo trapezoidal.

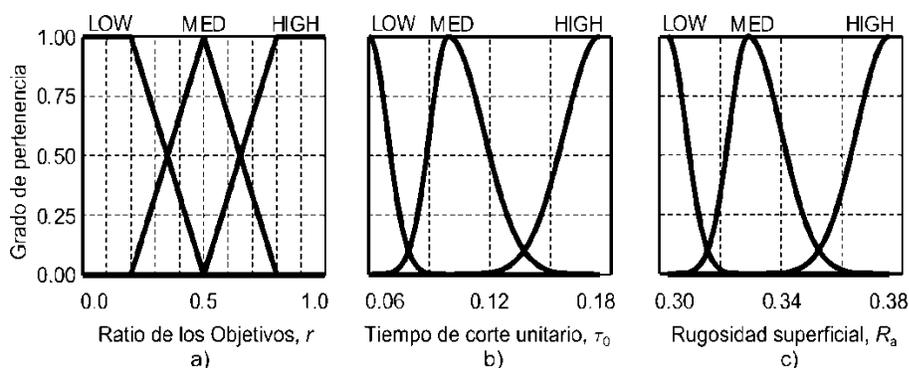


Figura 2.7 Funciones de pertenencia

Las funciones de salida para las dos salidas del FIS son similares en la forma, pero tienen diferentes valores. Estas dependen de la distribución de cada objetivo previamente obtenido en la frontera de Pareto, y están basadas en tres puntos: los puntos de los extremos (donde un objetivo es máximo y el otro es mínimo), y_i^{\min} y y_i^{\max} , y el punto medio, \hat{y}_i , el cual es el más cercano al origen de coordenadas cuando todos los objetivos son normalizados en el intervalo [0,1].

Basado en estos puntos, LOW es una función de pertenencia Gaussiana con una media igual al valor mínimo del objetivo, $\mu_i^{\text{LOW}} = y_i^{\text{min}}$, y una desviación estándar que permite obtener el valor de la función de pertenencia en el punto medio (10^{-4}):

$$\sigma_i^{\text{LOW}} = \sqrt{-\frac{(\hat{y}_i - y_i^{\text{min}})^2}{2\ln(10^{-4})}}, \quad (2.9)$$

HIGH es una función Gaussiana también, donde el valor medio es el resultado máximo del objetivo, $\mu_i^{\text{HIGH}} = y_i^{\text{max}}$, y la desviación estándar es calculada de forma similar a la función LOW:

$$\sigma_i^{\text{HIGH}} = \sqrt{-\frac{(y_i^{\text{max}} - \hat{y}_i)^2}{2\ln(10^{-4})}}, \quad (2.10)$$

Finalmente, MED combina dos funciones Gaussianas, donde ambas tienen la misma media, la cual corresponde al punto medio, $\mu_i^{\text{MED},1} = \mu_i^{\text{MED},2} = \hat{y}_i$, pero con diferente desviación estándar, $\sigma_i^{\text{MED},1} = \sigma_i^{\text{LOW}}$ and $\sigma_i^{\text{MED},2} = \sigma_i^{\text{HIGH}}$.

Las reglas borrosas para ambos sistemas de inferencia borrosos son definidas de manera simple, estableciendo una relación directa entre el *ratio* y el primer objetivo (tiempo de corte unitario) y una relación inversa entre el *ratio* y el segundo objetivo (rugosidad superficial) (Código 2.1)

Código 2.1. Reglas borrosas para los Sistemas de Inferencia Borroso

```
%Objetivos (tiempo de corte unitario y rugosidad superf.)
si (r es LOW) entonces (t0 es LOW) Y (Ra es HIGH)
si (r es MED) entonces (t0 es MED) Y (Ra es MED)
si (r es HIGH) entonces (t0 es HIGH) Y (Ra es LOW)
```

2.6 Conclusiones parciales del capítulo

Como resultado del estudio experimental y la propuesta del sistema experto se puede llegar a las siguientes conclusiones:

1. El sistema propuesto combina varias técnicas de *soft-computing* para modelar empíricamente, la fuerza de corte y la rugosidad superficial, en dependencia del régimen de corte.
2. Dada la utilización de redes neuronales, el sistema es potencialmente capaz de modelar las relaciones complejas no lineales de las variables citadas con los parámetros del régimen de corte, tal como tienen lugar en las condiciones de maquinado modernas.
3. Se han establecido las principales características del proceso de optimización multiobjetivo del microfresado de ranuras, definiendo las funciones objetivos, las variables de optimización y las restricciones.

CAPÍTULO 3 ANÁLISIS DE LOS RESULTADOS

Como resultado del capítulo anterior, se obtuvieron los datos experimentales necesarios para llevar a cabo el sistema experto propuesto. En el presente capítulo, este sistema es aplicado a un caso de estudio concreto, para estudiar su eficacia y analizar los resultados obtenidos.

3.1 Análisis de los modelos de redes neuronales

3.1.1 Modelo de rugosidad superficial

El entrenamiento de la red neuronal para el modelo de rugosidad superficial se llevó a cabo según lo explicado en la sección 2.3. La Fig. 3.1 muestra el comportamiento del error medio cuadrático normalizado para todo el entrenamiento de dicho modelo. Como se puede observar, en las primeras 4 000 iteraciones ocurre una marcada disminución del error; en el resto del proceso, el decrecimiento es mucho menos marcado.

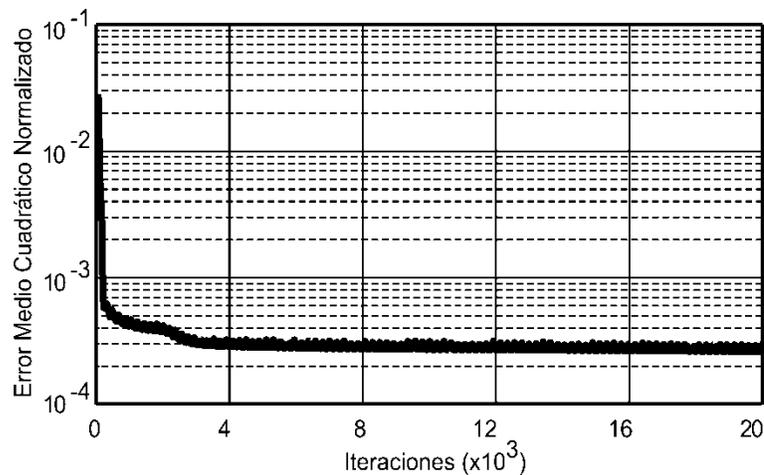


Figura 3.1 Entrenamiento del modelo de rugosidad superficial

En la tabla ANOVA (tabla 3.1) se puede observar que como el valor de la probabilidad asociado al estadígrafo F de Fisher, es menor que 0,01 existe una relación estadísticamente significativa entre las variables, con un coeficiente de confiabilidad del 99%. El modelo obtenido tiene un coeficiente de determinación, R^2 , de 0,934 (0,923 ajustado para los grados de libertad del modelo). Esto indica que el modelo ajustado explica el 93% de la variabilidad de la rugosidad superficial. El error medio absoluto y el error estándar de las estimaciones son, 13.5×10^{-3} y 16.2×10^{-3} , respectivamente.

Tabla 3.1 ANOVA para el modelo de la rugosidad superficial

Fuente	Suma de cuadrados	Grados de libertad	Media cuadrática	F -ratio	p -value
Modelo	0,556	20	0,028	174,9	0,000
Residuales	0,019	123	0,0001		
Total	0,575	143			

Como se puede observar en la representación gráfica del modelo (Fig. 3.2a), si aumenta la velocidad disminuye la rugosidad superficial, mientras que si aumenta el avance aumenta la rugosidad superficial. Por el contrario la rugosidad no se ve significativamente afectada por la profundidad de corte.

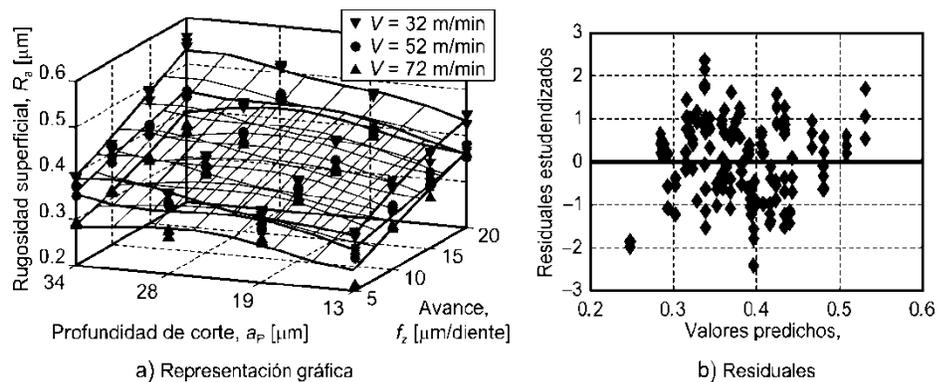


Figura 3.2 Representación del modelo de rugosidad superficial

Los residuales studentizados del modelo de rugosidad superficial (Fig. 3.2b) están en el intervalo [-3, 3], lo que sugiere que no existe ningún dato *outliers*.

Código 3.1 Implementación en MATLAB del modelo de rugosidad superficial

```
function y = RaModel(x)
    n = size(x, 1);
    w1 = [ 4.21544e-01, 1.09434e-01, -1.28515e+00; ...
          -9.91985e-01, -4.51101e-01, 4.52909e-01; ...
          -1.50237e+00, -2.11918e-01, 1.72779e+00; ...
          -2.64475e-01, -2.48586e-01, 2.81477e-01 ];
    w2 = [-6.66551e-01, 8.47855e-01, 4.93949e-01, ...
          -2.65415e+00];
    b1 = [-9.60873e-01; ...
          1.33915e-01; ...
          -2.08309e+00; ...
          -2.74953e-02 ];
    b2 = [-1.76566e-01 ];
    xi = [ 3.20000e+01, 7.20000e+01; ...
          5.00000e+00, 2.00000e+01; ...
          1.30000e+01, 3.40000e+01 ];
    xo = [-1.00000e+00, 1.00000e+00; ...
          -1.00000e+00, 1.00000e+00; ...
          -1.00000e+00, 1.00000e+00 ];
    yi = [-1.00000e+00, 1.00000e+00 ];
    yo = [ 2.13000e-01, 5.61000e-01 ];
    xi_min = repmat(xi(:, 1), 1, n);
    xi_max = repmat(xi(:, 2), 1, n);
    xo_min = repmat(xo(:, 1), 1, n);
    xo_max = repmat(xo(:, 2), 1, n);
    yi_min = repmat(yi(:, 1), 1, n);
    yi_max = repmat(yi(:, 2), 1, n);
    yo_min = repmat(yo(:, 1), 1, n);
    yo_max = repmat(yo(:, 2), 1, n);
    x = xo_min + (xo_max - xo_min).* ...
        (x.' - xi_min)./(xi_max - xi_min);
    a1 = tansig(w1*x + repmat(b1, 1, n));
    a2 = purelin(w2*a1 + repmat(b2, 1, n));
    y = (yo_min + (yo_max - yo_min).* ...
        (a2 - yi_min)./(yi_max - yi_min)).';
end
```

3.1.2 Modelo de fuerza de corte

El proceso de entrenamiento para el modelo de la fuerza de corte se ejecutó también hasta 20 000 iteraciones (Fig. 3.3). Como se puede ver, en este caso la disminución brusca del error transcurre en las primeras 500 iteraciones. El error medio cuadrático normalizado final fue 0,0864.

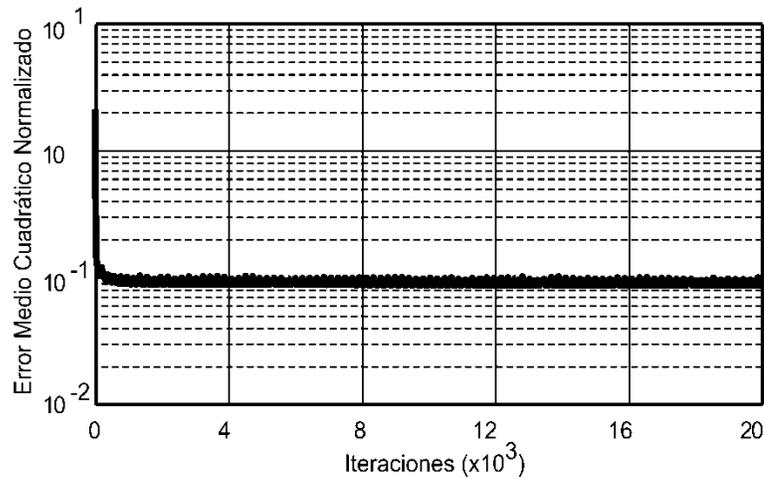


Figura 3.3 Entrenamiento del modelo de la fuerza de corte

El modelo obtenido para la fuerza de corte, tiene un coeficiente de determinación (R^2) de 0,834 (0,805; ajustado para los grados de libertad del modelo), esto significa que el 83% de la variabilidad en la fuerza de corte es explicada por el modelo. El error medio absoluto y el error estándar de las estimaciones para este modelo son, 0,211 y 0,287, respectivamente. La tabla ANOVA (tabla 3.2) muestra que, como el *p-value* es menor que 0,01, existe una relación estadísticamente significativa entre las variables a un nivel de confiabilidad del 99%.

Tabla 3.2 ANOVA para el modelo de la fuerza de corte

Fuente	Suma de cuadrados	Grados de libertad	Media cuadrática	F-ratio	p-value
Modelo	58,957	20	2,948	30,6	0,000
Residuales	11,763	122	0,096		
Total	70,720	142			

El modelo ajustado (Fig. 3.4a) muestra un incremento de la fuerza de corte con el aumento del avance y la profundidad de corte, mientras que la velocidad de corte no tiene una influencia significativa sobre la fuerza.

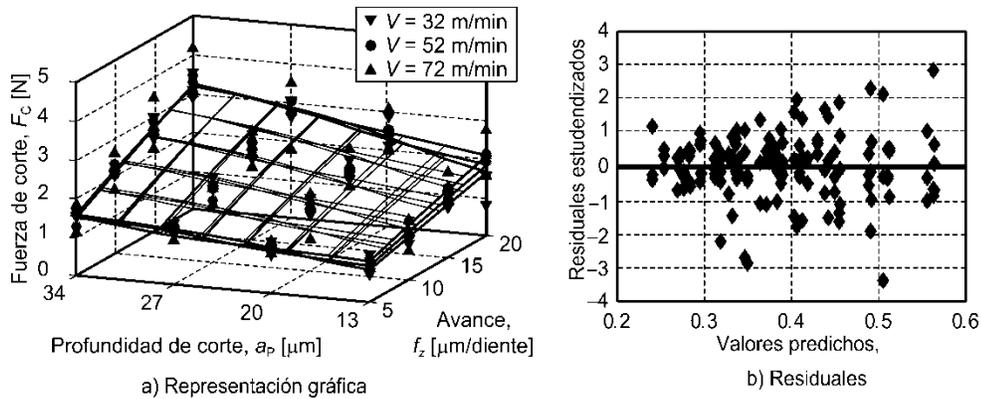


Figura 3.4 Representación del modelo de fuerza de corte

Código 3.2 Implementación en MATLAB de la fuerza de corte

```

function y = FcModel(x)
    n = size(x, 1);
    w1 = [ 1.49744e-01, -3.71014e-01, 5.09598e-01; ...
          -9.87856e-02, -1.43274e-01, -2.38877e-01; ...
          -1.36736e+00, 1.20863e-01, 2.50352e+00; ...
          -2.05817e+00, 7.63430e-01, 1.68368e+00 ];
    w2 = [-7.43646e-01, -1.69709e+00, 1.06216e-01, ...
          6.76285e-02 ];
    b1 = [-8.45899e-01; ...
          2.31059e-01; ...
          -2.23179e-01; ...
          -2.44300e+00 ];
    b2 = [-3.28729e-01 ];
    
```

Continúa...

Código 3.2 Implementación en MATLAB de la fuerza de corte (cont.)

```

xi = [ 3.20000e+01, 7.20000e+01; ...
      5.00000e+00, 2.00000e+01; ...
      1.30000e+01, 3.40000e+01 ];
xo = [-1.00000e+00, 1.00000e+00; ...
      -1.00000e+00, 1.00000e+00; ...
      -1.00000e+00, 1.00000e+00 ];
yi = [-1.00000e+00, 1.00000e+00 ];
yo = [ 6.66834e-01, 4.11275e+00 ];
xi_min = repmat(xi(:, 1), 1, n);
xi_max = repmat(xi(:, 2), 1, n);
xo_min = repmat(xo(:, 1), 1, n);
xo_max = repmat(xo(:, 2), 1, n);
yi_min = repmat(yi(:, 1), 1, n);
yi_max = repmat(yi(:, 2), 1, n);
yo_min = repmat(yo(:, 1), 1, n);
yo_max = repmat(yo(:, 2), 1, n);
x = xo_min + (xo_max - xo_min).* ...
    (x.' - xi_min)./(xi_max - xi_min);
a1 = tansig(w1*x + repmat(b1, 1, n));
a2 = purelin(w2*a1 + repmat(b2, 1, n));
y = (yo_min + (yo_max - yo_min).* ...
    (a2 - yi_min)./(yi_max - yi_min)).';
end

```

El punto 129 del conjunto de entrenamiento fue eliminado del modelo porque su correspondiente residual studentizado (6.72) sugiere que este dato es un valor atípico (*outlier*). Después de esta acción, el resto de los residuales studentizados (excepto uno, con valor de -3,38) se encuentran en el intervalo $[-3, 3]$ (Fig. 3.4b), por lo que no hay una fuerte indicación de ningún otro valor atípico. El Código 3.2 refleja la implementación del modelo de la fuerza de corte como una función de MATLAB.

3.2 Optimización

Los parámetros del algoritmo MOCE+, fueron establecidos por el método de prueba y error, en los siguientes valores: tamaño de la población, $Z = 150$, número de iteraciones,

$N = 100$, límite de convergencia, $\epsilon_{\max} = 10^{-3}$, número máximo de evaluaciones, $S_{\max} = 10^4$, tamaño máximo de la población élite, $Z_{\max}^* = 25$, factor de suavizado, $\alpha = 0,8$; probabilidad de inversión de la frecuencia, $\phi = 0,3$, umbral inicial de la élite, $\lambda_0 = 3,0$; y factor de decrecimiento del umbral, $\kappa = 0,1$. Fueron realizadas 50 réplicas con el objetivo de probar la convergencia del algoritmo.

La Fig. 3.5a representa las soluciones óptimas alcanzadas con el proceso de optimización. Se puede notar que todas estas soluciones corresponden con el nivel alto de la velocidad ($V = 72$ m/min) y cubre un rango de avances desde $5,0 \mu\text{m}/\text{diente}$ hasta $14,5 \mu\text{m}/\text{diente}$ (ver Fig. 3.5b).

El tiempo de ejecución del proceso de optimización fue de $(48,86 \pm 0,09)$ s, lo que corresponde a un coeficiente de variación del 4,8%. Se evaluó la calidad de la frontera obtenida a través del hiperárea, la cual tuvo un valor de $(6,52 \pm 0,0003) \times 10^{-3}$, correspondiente a un coeficiente de variación del 0,11%. Como se puede ver, la variación en ambos parámetros es muy baja, lo que indica la buena convergencia del algoritmo.

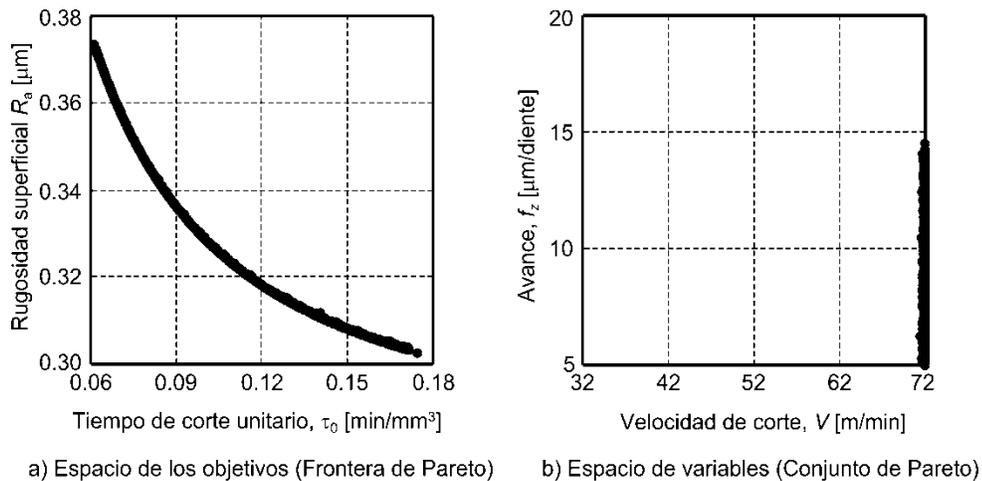


Figura 3.5 Soluciones óptimas

Un resultado similar fue obtenido con el análisis de la variabilidad en el límite inferior y superior de la frontera de Pareto (Tabla 3.3). Cabe destacar que, el coeficiente de variación en todos los extremos es menor que 0,01%. Estos valores tan bajos muestran una buena correspondencia entre la frontera de Pareto y, en consecuencia, es un indicador de la convergencia del algoritmo.

Tabla 3.3 Variabilidad de los extremos de la frontera de Pareto

Variable	Coeficiente de variación	
	Límite inferior	Límite superior
Velocidad de corte, V	0,0045%	0,0058%
Avance, f_z	0,0024%	0,0014%

3.3 Toma de decisiones

Para ilustrar el funcionamiento de la toma de decisiones, se ejecutaron cinco combinaciones diferentes de preferencias de los objetivos, para probar así las respuestas del sistema experto.

Tabla 3.4 Resultados del SE ante diferentes preferencias de los objetivos

Preferencias de los objetivos			Variables de decisión		Objetivos	
P_1	P_2	r	V [m/min]	f_z [$\mu\text{m}/\text{tooth}$]	τ_0 [min/mm ³]	R_a [μm]
0	100	0,00	72	15	0,060	0,376
25	75	0,25	72	9,4	0,093	0,334
50	50	0,50	72	8,8	0,099	0,329
75	25	0,75	72	7,1	0,122	0,317
100	0	1,00	72	5,0	0,175	0,303

La Tabla 3.4 no solo muestra los valores de las funciones objetivos, sino que también recoge los valores correspondientes a las variables de decisión (parámetros de corte) para cada solución.

Evidentemente, la primera solución ($P_1 = 0$ y $P_2 = 100$) corresponde a la solución con menor calidad superficial pero mayor productividad. Por el contrario, la última solución ($P_1 = 100$ y $P_2 = 0$) ofrece baja productividad pero mayor calidad superficial. Finalmente, las otras soluciones son combinaciones que se pueden usar en situaciones intermedias, para balancear la producción.

3.4 Conclusiones parciales del capítulo

Una vez finalizado el presente capítulo, se ha podido arribar a las siguientes conclusiones parciales:

1. Los modelos de redes neuronales han demostrado su eficacia en la representación de la fuerza de corte y la rugosidad superficial del proceso de microfresado de ranuras.
2. El algoritmo de optimización propuesto permite obtener un conjunto de puntos no dominados para aproximar la frontera de Pareto, en la optimización multiobjetivos del proceso de microfresado.
3. A partir de los resultados obtenidos con la optimización, se implementó un sistema experto, que teniendo en cuenta las condiciones específicas de la producción, permite seleccionar la variante más adecuada del régimen de corte a emplear.

CONCLUSIONES

Como resultado final del trabajo desarrollado, se ha podido arribar a las siguientes conclusiones:

1. El sistema experto propuesto permite seleccionar, con rapidez y fiabilidad los parámetros del régimen de corte para el microfresado de ranuras.
2. Los modelos empíricos obtenidos reflejan de manera precisa el comportamiento de las variables en el proceso y las pruebas estadísticas confirman la bondad de ajuste de los mismos.
3. El método de optimización multiobjetivo mejorado basado en entropía cruzada, permite considerar dos objetivos diferentes y mutuamente conflictivos: la rugosidad superficial y el tiempo de corte unitario, realizando la toma de decisiones desde el enfoque *a posteriori*.
4. El sistema para la toma de decisiones implementado, basado en un sistema de inferencia borroso del tipo *Mamdani*, demostró buena aplicabilidad en la selección de las soluciones más adecuadas para cualquier combinación de preferencias de los objetivos suministrada por el usuario.

RECOMENDACIONES

Basadas en las conclusiones obtenidas y para la extensión futura del presente trabajo, se realizan las siguientes recomendaciones:

1. Considerar la omisión de la toma de decisiones para que un usuario experto pueda inferir una solución basándose en su propia experiencia, directamente a partir de los resultados de la optimización.
2. Llevar a cabo otros estudios para evaluar el impacto industrial del sistema propuesto, así como analizar la influencia de la modelación en la robustez del sistema completo.
3. Analizar la aplicación del sistema experto propuesto a otros procesos de corte como el microtaladrado.

REFERENCIAS BIBLIOGRÁFICAS

Abbass, H.A.; Sarker, R. ; Newton, C., 2001. “PDE: A Pareto–frontier differential evolution approach for multi objective optimization problems”. *Congress on Evolutionary Computation*. Piscataway, NJ (U.S.A.), vol. 2, pp. 971-978.

Almeshai, E.A. ; Oraby, S.E., 2003. “An expert system machinability data bank (ESMDB) approach”. *Kuwait Journal of Science and Engineering*, 30 (1), pp. 315-338.

Altintas, Y. ; Jin, X., 2011. “Mechanics of micro-milling with round edge tools”. *CIRP Annals - Manufacturing Technology*, 60 (1), pp. 77-80, DOI: 10.1016/j.cirp.2011.03.084.

Alto, A.; Dassisti, M. ; Galantucci, L.M., 1994. “An Expert System for Reliable Tool Replacement Policies in Metal Cutting ”. *Journal of Engineering for Industry*, 116, pp. 405-406.

Asad, A.; Masaki, T.; Rahman, M.; Lim, H.S. ; Wong, Y.S., 2007. “Tool-based Micro-machining”. *Journal of Materials Processing Technology*, 192–193, pp. 204-211.

Asgharizadeh, E.; Haghnegahdar, E.L. ; Ghorbani, H., 2011. “Reengineering based on using artificial neural networks in manufacturing and production industries”. *World Applied Sciences Journal*, 14 (1515-1522).

Atlas, L.; Ostendorf, M. ; Bernard, G.D., 2000. “Hidden Markov model for monitoring machining tool-wear”. *International Conference on Acoustic, Speech and Signal Processing (ICASSP'2000)*. Istanbul (Turkey).

Azaryoon, A.; Hamidon, M. ; Radwan, A., 2015. “An Expert System Based on A Hybrid Multi-criteria Decision Making Method for Selection of Non-conventional Machining Processes”. *Applied Mechanics and Materials*, 735, pp. 41-49, DOI: 10.4028/AMM.735.41.

Bekker, J. ; Aldrich, C., 2011. “The cross-entropy method in multi-objective optimisation: An assessment”. *European Journal of Operational Research*, 211, pp. 112-121.

Beruvides, G.; Castaño, F.; Quiza, R. ; Haber, R.E., 2016. “Surface roughness modeling and optimization of tungsten–copper alloys in micro-milling processes”. *Measurement*, 86, pp. 246-252, DOI: 10.1016/j.measurement.2016.03.002.

Beruvides, G.; Quiza, R. ; Haber, R.E., 2016. “Multi-objective optimization based on an improved cross-entropy method. A case study of a micro-scale manufacturing process”. *Information Sciences*, 334–335, pp. 161-173, DOI: 10.1016/j.ins.2015.11.040.

Beruvides, G.; Quiza, R. ; Haber, R.E., 2016. “Multiobjective optimization based on an improved cross-entropy method. A case study of a micro-scale manufacturing process”. *Information Sciences*, 334-335, pp. 161-173, DOI: 10.1016/j.ins.2015.11.040.

Beruvides, G.; Quiza, R.; Rivas, M.; Castaño, F. ; Haber, R.E., 2014. “Online detection of run out in microdrilling of tungsten and titanium alloys”. *The International Journal of Advanced Manufacturing Technology*, 74 (9), pp. 1567-1575, DOI: 10.1007/s00170-014-6091-1.

Bhandari, B.; Hong, Y.-S.; Yoon, H.-S.; Moon, J.-S.; Pham, M.-Q.; Lee, G.-B.; Huang, Y.; Linke, B.S.; Dornfeld, D.A. ; Ahn, S.-H., 2014. “Development of a micro-drilling burr-control chart for PCB drilling”. *Precision Engineering*, 38 (1), pp. 221-229, DOI: 10.1016/j.precisioneng.2013.07.010.

Bharathi, R.S. ; Baskar, N., 2010. “Optimization techniques for machining operations: a retrospective research based on various mathematical models”. *International Journal of Advance Manufacturing Technology*, 48 (9-12), pp. 1075-1090, DOI: 10.1007/s00170-009-2351-x.

Bhavsar, S.N.; Aravindan, S. ; Rao, P.V., 2015. “Investigating material removal rate and surface roughness using multi-objective optimization for focused ion beam (FIB) micro-milling of cemented carbide”. *Precision Engineering*, 40, pp. 131-138, DOI: 10.1016/j.precisioneng.2014.10.014.

Cakir, M. ; Cavdar, K., 2006. “Development of a knowledge-based expert system for solving metal cutting problems”. *Materials & Design*, 27 (10), pp. 1027-1034, DOI: 10.1016/j.matdes.2005.01.022.

Cardoso, P. ; Davim, J.P., 2010. “Optimization of surface roughness in micromilling”. *Materials and Manufacturing Processes*, 25 (10), pp. 1115-1119, DOI: 10.1080/10426914.2010.481002.

Coppel, R.; Abellan-Nebot, J.V.; Siller, H.R.; Rodriguez, C.A. ; Guedea, F., 2015. “Adaptive control optimization in micro-milling of hardened steels—evaluation of optimization approaches”. *International Journal of Advance Manufacturing Technology*, pp. 1-20, DOI: 10.1007/s00170-015-7807-6.

Cus, F. ; Balic, J., 2003. “Optimization of cutting process by GA approach”. *Robotics and Computer Integrated Manufacturing*, 19 (1-2), pp. 113-121, DOI: 10.1016/s0736-5845(02)00068-6.

Chandrasekaran, M.; Muralidhar, M.; Krishna, C.M. ; Dixit, U.S., 2010. “Application of soft computing techniques in machining performance prediction and optimization: a literature review”. *International Journal of Advance Manufacturing Technology*, 46, pp. 445-464, DOI: 10.1007/s00170-009-2104-x.

Chandrasekaran, M.; Muralidhar, M.; Krishna, C.M. ; Dixit, U.S., 2010. “Application of soft computing techniques in machining performance prediction and optimization: a literature review”. *The International Journal of Advanced Manufacturing Technology*, 46 (5-8), pp. 445-464, DOI: 10.1007/s00170-009-2104-x.

- Chougule, P.D.; Kumar, S. ; Raval, H.K., 2014 of Conference. “An expert system for selection of carbide cutting tools for turning operations ”. En: (ed.)^(eds.), *All India Manufacturing Technology, Design and Research Conference*. IIT Guwahati, Assam, India, vol. 252, pp. 6.
- Chtourou, H.; Masmoudi, W. ; Maalej, A., 2005. “An expert system for manufacturing systems machine selection”. *Expert Systems with Applications*, 28, pp. 461-467, DOI: 10.1016/j.eswa.2004.12.007.
- D’Addona, D.M.; Ullah, A.M.M.S. ; Matarazzo, D., 2015. “Tool-wear prediction and pattern-recognition using artificial neural network and DNA-based computing”. *Journal of Intelligent Manufacturing*, pp. 1-17, DOI: 10.1007/s10845-015-1155-0.
- Dong, J.; Subrahmanyam, K.V.R.; Wong, Y.S.; Hong, G.S. ; Mohanty, A.R., 2006. “Bayesian-inference-based neural networks for tool wear estimation”. *International Journal of Advanced Manufacturing Technology*, 30 (9-10), pp. 797-807, DOI: 10.1007/s00170-005-0124-8.
- Dweiri, F.; Al-Jarrah, M. ; Al-Wedyan, H., 2003. “Fuzzy surface roughness modeling of CNC down milling of Alomic-79”. *Journal of Materials Processing Technology*, 133 (3), pp. 266-275, DOI: 10.1016/s0924-0136(02)00847-6.
- Fernández-Martínez, J.L. ; García-Gonzalo, E., 2009. “The PSO family: deduction, stochastic analysis and comparison”. *Swarm Intelligence*, 3 (4), pp. 245-273, DOI: 10.1007/s11721-009-0034-8.
- Fu, L.; Ling, S.-F. ; Tseng, C.-H., 2007. “On-line breakage monitoring of small drills with input impedance of driving motor”. *Mechanical Systems and Signal Processing*, 21 (1), pp. 457-465, DOI: 10.1016/j.ymsp.2005.04.004.
- Fu, L.; Ling, S.F. ; Tseng, C.-H., 2007. “On-line breakage monitoring of small drills with input impedance of driving motor”. *Mechanical Systems and Signal Processing*, 21 (1), pp. 457-465, DOI: 10.1016/j.ymsp.2005.04.004.
- Gatton, T.M.; Lawrence, D.J. ; Keamey, F.W., 1990. *Methodology for Development of Expert Systems: Quality Assurance in Construction*.
- Giachetti, R.E., 1998. “A decision support system for material and manufacturing process selection”. *Journal of Intelligent Manufacturing*, 9, pp. 265-276.
- Grafarend, E.W., 2006. “Linear and Nonlinear Models: Fixed Effects, Random Effects, and Mixed Models”. En: Gruyter, W.d. (ed.).
- Hsieh, W.-H.; Lu, M.-C. ; Chiou, S.-J., 2011. “Application of backpropagation neural network for spindle vibration-based tool wear monitoring in micro-milling”. *The International Journal of Advanced Manufacturing Technology*, 61 (1), pp. 53-61, DOI: 10.1007/s00170-011-3703-x.

- Iqbal, A.; He, N.; Li, L. ; Da, N.U., 2007. “A fuzzy expert system for optimizing parameters and predicting performance measures in hard-milling process”. *Expert Systems with Applications*, 32, pp. 1020–1027, DOI: 10.1016/j.eswa.2006.02.003.
- Jang, J.-S.R., 1993. “ANFIS: Adaptive-network-based fuzzy inference system”. *IEEE Transactions on System, Man and Cybernetics*, 23 (3), pp. 665-685.
- Khayyam, H.; Naebe, M.; Zabihi, O.; Zamani, R.; Atkiss, S. ; Fox, B., 2015. “Dynamic Prediction Models and Optimization of Polyacrylonitrile (PAN) Stabilization Processes for Production of Carbon Fiber”. *IEEE Transactions on Industrial Informatics*, 11 (4), pp. 887-896, DOI: 10.1109/tii.2015.2434329.
- Kibria, G.; Doloi, B. ; Bhattacharyya, B., 2012. “Predictive model and process parameters optimization of Nd:YAG laser micro-turning of ceramics”. *International Journal of Advanced Manufacturing Technology*, 65 (1), pp. 213-229, DOI: 10.1007/s00170-012-4161-9.
- Kidd, A.L., 1987. *Knowledge Acquisition for Expert Systems: A Practical Handbook*. New York: Springer US, ISBN 978-1-4612-9019-3.
- Krimpenis, A.A.; Fountas, N.A.; Ntalianis, I. ; Vaxevanidis, N.M., 2014. “CNC micromilling properties and optimization using genetic algorithms”. *International Journal of Advanced Manufacturing Technology*, 70 (1), pp. 157-171, DOI: 10.1007/s00170-013-5248-7.
- Kumar, D., 2015. “Expert systems in manufacturing processes using soft computing”. *International Journal of Advanced Manufacturing Technology*, 81 (5), pp. 887-896, DOI: 10.1007/s00170-015-7285-x.
- Kumar, S.M.; Kannan, T.T.M.; Giridharan, S. ; Kumar, V.P., 2014. “Optimization of micro milling parameters of Al-6082 by ANOVA methodology”. *International Journal of Mechanical Engineering and Robotics Research*, 3, pp. 377-382.
- Kuram, E. ; Ozcelik, B., 2016. “Optimization of machining parameters during micro-milling of Ti6Al4V titanium alloy and Inconel 718 materials using Taguchi method”. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, [in press], DOI: 10.1177/0954405415572662.
- Kussul, E.; Baidyk, T. ; Wunsch, D.C., 2010. “Neural Networks and Micromechanics”. En: Heidelberg, S.B. (ed.), Berlin, pp. 1-5.
- Kwon, Y.; Jeong, M.K. ; Omitaomu, O.A., 2006. “Adaptive support vector regression analysis of closed-loop inspection accuracy”. *International Journal of Machine Tools and Manufacture*, 45 (6), pp. 603-610, DOI: 10.1016/j.ijmactools.2005.07.011.
- Leo, S.P.; Jerald, J. ; Kumanan, S., 2014. “An intelligent process planning system for micro turnmill parts”. *International Journal of Production Research*, 52 (20), pp. 6052–6075, DOI: 10.1080/00207543.2014.910626.

- Li, X.; Tso, S.K. ; Wang, J., 2000. “Real-time tool condition monitoring using wavelet transforms and fuzzy techniques”. *IEEE Transactions on System, Man and Cybernetics*, 30 (3), pp. 352-357.
- Liu, J.; Li, J. ; Xu, C., 2014. “Interaction of the cutting tools and the ceramic-reinforced metal matrix composites during micro-machining: A review”. *CIRP Journal of Manufacturing Science and Technology*, 7 (2), pp. 55-70, DOI: 10.1016/j.cirpj.2014.01.003.
- López-Jaimes, A. ; Coello, C.A., 2014. “Including preferences into a multiobjective evolutionary algorithm to deal with many-objective engineering optimization problems”. *Information Sciences*, 277, pp. 1-20, DOI: 10.1016/j.ins.2014.04.023.
- Mandal, S.; Kumar, A. ; Nagahanumaiah, 2013. “Assessment of micro turning machine stiffness response and material characteristics by fuzzy rule based pattern matching of cutting force plots”. *Journal of Manufacturing Systems*, 32 (1), pp. 228-237, DOI: 10.1016/j.jmsy.2012.11.007.
- Mesina, O.S. ; Langari, R., 2001. “A Neuro-Fuzzy System for Tool Condition Monitoring in Metal Cutting”. *Journal of Manufacturing Science and Engineering*, 123, pp. 312-318, DOI: 10.1115/1.1363599.
- Moorkherjee, R. ; Bhattacharyya, B., 2001. “Development of an expert system for turning and rotating tool selection in a dynamic environment”. *Journals of Materials Processing Technology*, 113, pp. 306-311.
- Naidu, A. ; Asati, S., 2014. “Cutting Tool Condition Monitoring and Validation Using ANN- A Comprehensive Research”. *International Journal of Innovative Research in Science, Engineering and Technology*, 3 (10), pp. 16996-17007, DOI: 10.15680/IJRSET.2014.0310082.
- Natarajan, U.; Periyanan, P. ; Yang, S., 2011. “Multiple response optimization for micro-end milling process using response surface methodology”. *International Journal of Advanced Manufacturing Technology*, 56, pp. 177-185.
- Negnevitsky, M., 2002. *Artificial Intelligence A Guide to Intelligent System*. England: Addison-Wesley, Pearson Education Limited.
- Patel, M. ; Ranganathan, N., 2001. “IDUTC: An Intelligent Decision-Making System for Urban Traffic-Control Applications”. *IEEE TRANSACTIONS ON VEHICULAR TECHNOLOGY*, 50 (3), pp. 816-829.
- Pawar, P.J. ; Venkata Rao , R., 2012. “Parameter optimization of machining processes using teaching–learning-based optimization algorithm”. *International Journal of Advanced Manufacturing Technology*, pp. 12, DOI: 10.1007/s00170-012-4524-2.

- Periyanan, P.; Natarajan, U. ; Yang, S.H., 2011. “A study on the machining parameters optimization of micro-end milling process”. *International Journal of Engineering, Science and Technology*, 3, pp. 237-246.
- Pratap, T.; Patra, K. ; Dyakonov, A.A., 2015. “Modeling cutting force in micro-milling of Ti-6Al-4V titanium alloy”. *Procedia Engineering*, 129, pp. 134-139, DOI: 10.1016/j.proeng.2015.12.021.
- Quiza, R., 2004. *Optimización multiobjetivo del proceso de torneado*. Ph.D. thesis. Matanzas (Cuba): Universidad de Matanzas.
- Quiza, R.; Beruvides, G. ; Davim, J.P., 2014. “Modeling and optimization of mechanical systems and processes”. En: Davim, J.P. (ed.), *Modern mechanical engineering*. Springer Berlin Heidelberg, ISBN 978-3-642-45175-1, pp. 169-198.
- Quiza, R. ; Davim, J.P., 2009. “Computational modeling of machining systems”. En: Özel, T. ; Davim, J.P. (eds.), *Intelligent machining: Modeling and optimization of the machining processes and systems*. London (UK): ISTE, ISBN 9781848211292, pp. 173-213.
- Quiza, R.; López-Armas, O. ; Davim, J.P., 2012. *Hybrid Modeling and Optimization of Manufacturing: Combining Artificial Intelligence and Finite Element Method*. Heidelberg, Berlin: Springer.
- Ramík, J., 2001. *Soft computing: Overview and recent developments in fuzzy optimization*.
- Rao, M.P.; Miller, D.M. ; Lin, B., 2005. “PET: An expert system for productivity analysis”. *Expert Systems with Applications*, 29, pp. 300-309, DOI: 10.1016/j.eswa.2005.04.003.
- Ren, Q.; Balazinski, M.; Jemielniak, K.; Baron, L. ; Achiche, S., 2013. “Experimental and fuzzy modelling analysis on dynamic cutting force in micro milling”. *Soft Computing*, 17 (9), pp. 1687-1697, DOI: 10.1007/s00500-013-0983-0.
- Ross, T.J., 2004. *Fuzzy logic with engineering applications*. 2nd. Ed. Ed. West Sussex (UK): John Wiley & Sons, ISBN 0470860758.
- Rubio, L. ; de la Sen, M., 2008. “An Expert Mill Cutter and Cutting Parameters Selection System incorporating a control strategy ”. *Proceedings of the 17th World Congress of The International Federation of Automatic Control*. Seoul, Korea, pp. 8362-8367.
- Rubio, L.; De la Sen, M.; Longstaff, A.P. ; Fletcher, S., 2013. “Model-based expert system to automatically adapt milling forces in Pareto optimal multi-objective working points”. *Expert Systems with Applications*, 40, pp. 2312-2322, DOI: 10.1016/j.eswa.2012.10.034.

- Saedon, J.B.; Soo, S.L.; Aspinwall, D.K.; Barnacle, A. ; Saad, N.H., 2012. "Prediction and optimization of tool life in micromilling AISI D2 (~62 HRC) hardened steel". *Procedia Engineering*, 41, pp. 1674-1683, DOI: 10.1016/j.proeng.2012.07.367.
- Saklakoglu, I.E. ; Kasman, S., 2010. "Investigation of micro-milling process parameters for surface roughness and milling depth". *International Journal of Advanced Manufacturing Technology*, 54 (5), pp. 567-578, DOI: 10.1007/s00170-010-2953-3.
- Sharma, P. ; Bhargava, M., 2014. "Designing, implementation, evolution and execution of an intelligent manufacturing system". *International Journal of Recent Advances in Mechanical Engineering*, 3 (3), pp. 159-167, DOI: 10.14810/ijmech.2014.3314.
- Sharma, V.S.; Sharma, S.K. ; Sharma, A.K., 2007. "An approach for condition monitoring of a turning tool". *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 221 (4), pp. 635-648, DOI: 10.1243/09544054jem765.
- Shaw, M.C., 1984. *Metal cutting principles*. Oxford (UK): Oxford University Press, ISBN 0198590024.
- Shetty, N.; Herbert, M.A.; Shetty, R.; Shetty, D.S. ; Vijay, G.S., 2016. "Soft computing techniques during drilling of bi-directional carbon fiber reinforced composite". *Applied Soft Computing*, 41, pp. 466-478, DOI: 10.1016/j.asoc.2016.01.016.
- Shi, D. ; Gindy, N.N., 2007. "Tool wear predictive model based on least squares support vector machines". *Mechanical Systems and Signal Processing*, 21 (4), pp. 1799-1814, DOI: 10.1016/j.ymsp.2006.07.016.
- Siler, W. ; Buckley, J.J., 2005. *Fuzzy expert systems and fuzzy reasoning*. Hoboken, NJ (USA): John Wiley & Sons, ISBN 0471388599.
- Silva, R.G.; Wilcox, S.J. ; Reuben, R.L., 2006. "Development of a system for monitoring tool wear using artificial intelligence techniques". *Journal of Engineering Manufacture*, 220 (B), pp. 1333-1346, DOI: 10.1243/09544054JEM328.
- Suhail, A.H.; N. Ismail, N.; Wong, S.V. ; Abdul, N.A., 2011. "Cutting parameters identification using multi adaptive network based Fuzzy inference system: An artificial intelligence approach". *Scientific Research and Essays* 6(1), pp. 187-195, DOI: 10.5897/SRE10.477.
- Surmann, T. ; Krebs, E., 2012. "Optimization of micromilling by adjustment of inclination angles". *Procedia CIRP*, 2, pp. 87-91, DOI: 10.1016/j.procir.2012.05.046.
- Tan, C.F., 2007. "An expert fault diagnosis system for auto wire bond machine". *Journal Teknologi*, 47(A), pp. 55-73.

- Tan, C.F.; Kher, V.K. ; Ismail, N., 2012. “An expert carbide cutting tools selection system for CNC lathe machine”. *International Review of Mechanical Engineering*, 6 (7), pp. 1402-1405.
- Tan, C.F.; Kher, V.K. ; Ismail, N., 2013. “Design of a feature recognition system for CAD/CAM”. *Integration, World Applied Science Journal*, 21 (8), pp. 1162-1166.
- Tansel, I.; Arkan, T.T.; Bao, W.Y.; Mahedrankan, N.; Shisler, B.; Smith, D. ; McCool, M., 2000. “Tool wear estimation in micro-machining. Part I: tool usage - cutting forces relationship”. *International Journal of Machine Tools and Manufacture*, 40 (4), pp. 599-608, DOI: 10.1016/s0890-6955(99)00073-5.
- Tansel, I.; Arkan, T.T.; Bao, W.Y.; Mahedrankan, N.; Shisler, B.; Smith, D. ; McCool, M., 2000. “Tool wear estimation in micro-machining. Part II: neural-network-based periodic inspector for non-metals”. *International Journal of Machine Tools and Manufacture*, 40 (4), pp. 609-620, DOI: 10.1016/s0890-6955(99)00074-7.
- Tolouei-Rad, M. ; Bidhendi, I.M., 1997. “On the optimization of machining parameters for milling operations”. *International Journal of Machine Tools and Manufacture*, 37 (1), pp. 1-16, DOI: 10.1016/S0890-6955(96)00044-2.
- Tsai, J.T.; Lee, K.M. ; Chou, J.H., 2014. “Robust evolutionary optimal tolerance design for machining variables of surface grinding process”. *IEEE Transactions on Industrial Informatics*, 10 (1), pp. 301-312, DOI: 10.1109/tii.2013.2240311.
- Van Veldhuizen, D.A. ; Lamont, G.B., 2000. “Multiobjective evolutionary algorithms: Analyzing the state-of-the-art”. *Evolutionary Computation*, 8 (2), pp. 125-147.
- Vitanov, V.I.; Harrison, D.K.; Mincoff, N.H. ; Vladimirova, T.V., 1995. “An expert system shell for the selection of metal-cutting parameters ”. *Journal of Material Processing Technology*, 55, pp. 111-116.
- Wang, C.; Zhao, W.; Chen, L.; Zhang, K. ; Guo, X., 2014. “Modularized Cutting Tool Selection Expert System”. *The Open Mechanical Engineering Journal*, 8, pp. 892-898.
- Wang, G.; Chen, J.; Zhu, Y.; Huang, J. ; Zhou, D., 2014. “The development and application of expert system about metal cutting burr based on neural network”. *Applied Mechanics and Materials*, 487, pp. 659-663, DOI: 10.4028/AMM.487.659.
- Widodo, A. ; Yang, B.-S., 2007. “Support vector machine in machine condition monitoring and fault diagnosis”. *Mechanical Systems and Signal Processing*, 21 (6), pp. 2560-2574, DOI: 10.1016/j.ymssp.2006.12.007.
- Wong, S.V. ; Hamouda, A.M.S., 2002. “Development of genetic algorithm-based fuzzy rules design for metal cutting data selection”. *Robotics and Computer Integrated Manufacturing*, 18, pp. 1-12.

- Wong, S.V. ; Hamouda, A.M.S., 2003. “The development of an online knowledge-based expert system for machinability data selection”. *Knowledge-Based Systems*, 16, pp. 215-229.
- Wong, S.V.; Hamouda, A.M.S. ; El Baradie, M.A., 1999. “Generalized fuzzy model for metal cutting data selection”. *Journal of Materials Processing Technology*, 89-90, pp. 310-317.
- Xue-bin, L.; Xi-bin, W.; Chong-ning, L. ; San-peng, D., 2013. “The design and implementation of the Expert System for cutting parameters based on CLIPS”. *Applied Mechanics and Materials*, 385-386, pp. 731-734, DOI: 10.4028/AMM.385-386.731.
- Yumak, O. ; Ertunc, H.M., 2006. “Tool wear condition monitoring in drilling processes using fuzzy logic”. En: King, I.; Wang, J.; Chan, L. ; Wang, D. (eds.), *13th International Conference on Neural Information Processing (ICONIP 2006)*. Berlin (Germany), vol. III, pp. 508-517.
- Yusup, N.; Zain, A.M. ; Hashim, S.Z.M., 2012. “Evolutionary techniques in optimizing machining parameters: Review and recent applications (2007–2011)”. *Expert Systems with Applications*, 39, pp. 9909-9927, DOI: 10.1016/j.eswa.2012.02.109.
- Zaquini, L.; Charpy, J.; Bendit, J.P.; Voumard, T.; Mathez, P.E. ; Béguelin, L., 2007 of Conference. “Expert system for the definition of the cutting parameters and machining strategies”. En: *Sixth International Conference on HIGH SPEED MACHINING*. vol., pp. 5.
- Zhou, C. ; Wysk, R.A., 1992. “An integrated system for selecting optimum cutting speeds and tool replacement times”. *International Journal of Machine Tools and Manufacture*, 32 (5), pp. 695-707, DOI: 0.1016/0890-6955(92)90024-B.
- Zhu, K.; Wong, Y.S. ; Hong, G.S., 2009. “Multi-category micro-milling tool wear monitoring with continuous hidden Markov models”. *Mechanical Systems and Signal Processing*, 23 (2), pp. 547-560, DOI: 10.1016/j.ymsp.2008.04.010.
- Zhu, Y.M.; Chen, J.P. ; Zheng, G., 2011. “Application of Neural Network on Burr Expert System in Micromachining”. *International Journal of Intelligent Systems and Applications*, 3 (1), pp. 1-9.