



**VNiVERSiDAD
D SALAMANCA**

UNIVERSIDAD DE SALAMANCA

Departamento de Informática y Automática

**MODELADO Y CONTROL NEUROBORROSO DE
SISTEMAS COMPLEJOS. APLICACIÓN A
PROCESOS DE MECANIZADO DE ALTO
RENDIMIENTO**

TESIS DOCTORAL

AGUSTÍN GAJATE MARTÍN

Directores:

DRA. D.^a PASTORA I. VEGA CRUZ

DR. D. RODOLFO E. HABER GUERRA

Junio 2010



**VNiVERSiDAD
D SALAMANCA**

UNIVERSIDAD DE SALAMANCA

Departamento de Informática y Automática

**MODELADO Y CONTROL NEUROBORROSO DE
SISTEMAS COMPLEJOS. APLICACIÓN A
PROCESOS DE MECANIZADO DE ALTO
RENDIMIENTO**

TESIS DOCTORAL PRESENTADA POR:

D. AGUSTÍN GAJATE MARTÍN

Dirigida por:

DRA. D^a. PASTORA I. VEGA CRUZ

DR. D. RODOLFO E. HABER GUERRA

El doctorando

Salamanca, Junio de 2010

Pastora I. Vega Cruz, *Profesora Catedrática del Departamento de Informática y Automática de la Universidad de Salamanca*, y Rodolfo E. Haber Guerra, *Científico Titular del Centro de Automática y Robótica del Consejo Superior de Investigaciones Científicas*

HACEN CONSTAR: *Que D. Agustín Gajate Martín, Ingeniero Industrial por la Universidad de Salamanca ha realizado bajo nuestra dirección la Memoria que lleva por título “Modelado y control Neuroborroso de sistemas complejos. Aplicación a procesos de mecanizado de alto rendimiento”, con el fin de obtener el grado de Doctor por la Universidad de Salamanca.*

Y para que surta los efectos oportunos firmamos en Salamanca, a tres de Junio de dos mil diez.

Pastora I. Vega Cruz

Rodolfo E. Haber Guerra

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

*A mi hermano,
por ir siempre abriendo caminos,
por ser siempre mi arnés de seguridad.*

“Nunca he encontrado una persona tan ignorante que no pueda aprender algo de ella” (Galileo Galilei)

Agradecimientos

Mi carrera investigadora comienza el 1 de enero de 2007. Supongo que, en cierto sentido, está bien elegido el término “carrera” ya que, hasta la fecha, ha sido un periodo relativamente corto pero muy intenso. Por ello, son muchas las personas a las que tengo que dar las gracias, bien sea en el ámbito profesional o en el personal. Espero no dejarme a nadie en el camino.

Quisiera comenzar por dos personas que han tenido mucho que ver en que esta tesis haya visto la luz. La primera de ellas es Rodolfo Haber. Creo que lo mucho o poco que yo tenga de investigador se lo debo a él. Rodolfo es quién me ha aconsejado, ayudado, apoyado, orientado, dirigido e incluso abroncado durante esta etapa. Gracias a su seriedad, profesionalidad, trabajo y tiempo, las cosas han sido mucho más fáciles y se han podido llevar a cabo gran parte de los retos propuestos. La otra persona es Pastora Vega. Desde el primer momento siempre ha confiado en mi trabajo, siempre se ha mostrado dispuesta a colaborar y siempre ha ofrecido su apoyo a pesar de su complicada agenda. A ambos, muchas gracias por todo.

Por otro lado, sería injusto olvidarme en esta parte de otras dos personas que han sido muy importantes en todo este camino. Por una parte se encuentra José Ramón Alique, del Instituto de Automática Industrial (hoy, Centro de Automática y Robótica). Gracias a él he podido mantenerme trabajando en el IAI. De nuestras conversaciones siempre he sacado ideas muy positivas y, gracias a él, he podido desarrollar otra serie de proyectos que me han permitido trasladar la ciencia a la industria. Por otra parte se encuentra Ángel Luis Sánchez, de la Universidad de Salamanca. Gracias a él he podido matricularme, cursar asignaturas y estudiar en la que yo considero mi universidad, a pesar de todas las restricciones que la distancia nos imponía.

Cierto es también que las victorias se consiguen en equipo, y mi equipo lo han formado mis compañeros del grupo GAMHE del IAI. Gracias a los que están (Maritza, Fernando, Alfonso, Víctor, Raquel, Ángel...) y a los que se fueron (Bruno, Diego, Adriana, Pedro, Michael, Antonio, Miguel...) por toda la ayuda y dedicación prestada (profesional y personal). Mención especial merece Raúl que, además de su ayuda, ha tenido que soportarme durante los últimos meses de dura convivencia. Dentro del IAI, muchas han sido también las personas a las que tengo algo que agradecer: a los chicos de Autopía (Enrique, Joshué, Vicente, Jorges, Javi, Roberto, Eugenio), a los “chicos de Lola” (Nacho*, Ángel, Jesús, Jaime y la susodicha), a Bego... y, en general, a toda la gente que hace que trabajar en el Instituto sea un auténtico lujo (lo siento, tengo que generalizar porque sois muchos).

Resulta también duro comenzar una nueva vida en una ciudad que no es la tuya y, por ello, tengo que agradecer el cariño, apoyo y todos los momentos de distensión que me han brindado amigos como Lupe, Fran, Tello, la gente del *Simposium* y todos mis amigos de Salamanca (vosotros también sois multitud, siento la generalización chic@s). Gracias y perdón, pues os he tenido que desatender en este periodo. Mención especial merece en esta parte Javier Vinuesa ya que, de no ser por él, no me encontraría a día de hoy trabajando en el Instituto.

Finalmente, mi mayor agradecimiento va para mis padres y mi hermano, ya que siempre son ellos los que tienen que aguantar mi mal humor, agravado quizás en los últimos meses. Por último, y no por ello menos importante (más bien todo lo contrario) tengo que agradecer demasiadas cosas a María. Fundamentalmente ha sido mi fuente de energía durante los últimos meses y la persona que más me ha ayudado a seguir para adelante. Ésto, por no hablar de la comprensión que me ha ofrecido, su cariño, su siempre reconfortante sonrisa y por todo lo que le ha tocado vivir en primera persona.

A todos, GRACIAS.

*Gracias por esas charlas de Doctor a doctorando y por la corrección.

Resumen

Este trabajo presenta una metodología para el diseño y la implementación de un sistema de control inteligente y de un sistema de monitorización inteligente. Esta metodología se aplica con éxito a procesos de gran complejidad. Para ello, se propone un procedimiento basado en el modelado neuroborroso del proceso en cuestión. Los modelos se obtienen a través de un proceso de identificación en el cual se utilizan datos entrada-salida representativos del sistema a estudiar. Una vez se han obtenido los modelos que describen la dinámica del proceso, éstos se utilizan como base de los propios sistemas de monitorización y control.

Para el caso del diseño e implementación de sistemas de control neuroborroso se propone un procedimiento para obtener un modelo neuroborroso de la dinámica del proceso (dinámica directa) y un modelo neuroborroso de su dinámica inversa. Estos modelos son utilizados según el paradigma del control por modelo interno para efectuar en último término el control del proceso complejo. De este modo, se diseña e implementa un sistema de control neuroborroso basado en el paradigma del control por modelo interno, para el control de la fuerza de corte en un proceso de taladrado (proceso electromecánico complejo) a través de la modificación de la velocidad de avance de la herramienta.

Por otro lado, para el caso de la monitorización neuroborrosa de sistemas complejos, se plantea un procedimiento para obtener un modelo neuroborroso mediante el cuál se relacionan parámetros del proceso medidos directamente a través de sensores con otra serie de fenómenos de difícil medición *on-line*. De este modo, el sistema de monitorización se implementa sobre la base del modelo neuroborroso obtenido. El procedimiento propuesto para el desarrollo del sistema de monitorización neuroborrosa se ha aplicado a la monitorización del desgaste de la herramienta de corte en un proceso de torneado (proceso físico-mecánico complejo). Mediante la información obtenida a través de los sensores de fuerzas de corte, de aceleración (vibraciones), de emisión acústica y utilizando el propio tiempo de operación se ha desarrollado un modelo neuroborroso para la estimación del desgaste del flanco de la herramienta de corte.

Tanto en el diseño del sistema de monitorización como en el diseño e implementación del sistema de control se han utilizado estrategias de modelado neuroborroso distintas: una estrategia inductiva y otra transductiva. A través de la estrategia inductiva se han obtenido modelos globales que representan toda la dinámica del proceso. Por contra, a través de las estrategias transductivas se han obtenido modelos locales de la situación particular a estudiar. Las estrategias utilizadas han sido ANFIS, TNFIS y TWNFI-i.

El empleo de modelos neuroborrosos (transductivos e inductivos) para el diseño de sistemas de control y monitorización de procesos de mecanizado tiene su origen en la propia naturaleza de estos procesos, es decir, su complejidad. El comportamiento no-lineal y la existencia de ciertas incertidumbres de difícil modelado que se dan tanto en procesos de taladrado como en procesos de torneado abren las puertas a la utilización de estas técnicas. La ventaja del método propuesto es que elimina la necesidad de disponer de un modelo matemático exacto del proceso complejo para el diseño/ajuste del sistema de control y/o monitorización. Los resultados obtenidos con los sistemas de modelado, control y monitorización neuroborrosos han sido muy positivos, y se han sustentado en experimentos reales desarrollados en entornos industriales. Además, desde el punto de vista técnico, se han obtenido importantes ventajas tales como el aumento en la tasa de arranque de material, el aprovechamiento efectivo de la vida útil de la herramienta de corte, un aumento de la seguridad para el proceso (operario, máquina y pieza) y, en general, una disminución de los tiempos de parada debidos a la rotura de la herramienta de corte.

Abstract

This work presents a methodology for the design and implementation of an intelligent control system and an intelligent monitoring system. This methodology is successfully applied to highly complex processes. To that end, it proposes a procedure based on the neurofuzzy modeling of the process in question. The models are obtained through an identification process which uses representative input-output data of the system to be studied. Once models which describe the dynamic process have been obtained, these are used as the basis of the monitoring and control systems.

In the case of design and implementation of neurofuzzy control systems, it proposes a procedure for obtaining a neurofuzzy model of the process dynamics (direct dynamic) and a neurofuzzy model of its inverse dynamics. These models are used according to the internal model control paradigm to control the complex process. Thus, it designs and implements a neurofuzzy control system based on the internal model control paradigm to control the cutting force in a drilling process (complex electrochemical process) by modifying the feed rate of the tool.

Moreover, in the case of neurofuzzy monitoring of complex systems, it proposes a procedure to obtain a neurofuzzy model which relates directly measured process parameters through sensors with a range of phenomena difficult to measure on-line. Thus, the monitoring system is implemented on the basis of the obtained neurofuzzy model. The proposed procedure for developing a neurofuzzy monitoring system, it has been applied to monitoring cutting tool wear in a turning process (complex physical-mechanical process). The information obtained from cutting forces sensors, acceleration (vibration) sensors, acoustic emission sensors and using the operating time, it has developed a neurofuzzy model to estimate the flank wear of the cutting tool.

Both in the monitoring system design and in the design and implementation of the control system, it has used different neurofuzzy modeling strategies: an inductive strategy and another transductive strategy. Through the inductive strategy, it has obtained global models representing the entire dynamic process. Instead, through transductive strategies, it has obtained local models to study the particular situation. The strategies used have been ANFIS, TNFIS and TWNFI-i.

The use of neurofuzzy models (transductive and inductive) to control and monitoring machining processes stems from the nature of these processes, *i.e.*, its complexity. The nonlinear behavior and the presence of uncertainties (difficult to modeling) both in drilling as in turning processes open the door to the use of these techniques. The advantage of the proposed method is that it eliminates the need for an accurate mathematical model of the complex process to design/adjust the control/monitoring system. The results obtained with neurofuzzy modeling, control and monitoring systems have been very significant results and they are based on real experiments carried out in industrial environments. Moreover, from the technical point of view, significant benefits were obtained such as increasing material removal rate, effective utilization of the cutting tool life, increasing safety for the process (operator, machine and workpiece) and better control of downtimes due to breakage of the cutting tool.

Índice general

1. Introducción	1
1.1. Motivación	1
1.2. Descripción del Problema	3
1.2.1. Modelado de Sistemas Complejos	3
1.2.2. Control de Sistemas Complejos	4
1.2.3. Monitorización de Sistemas Complejos	5
1.3. Objetivos	6
1.4. Estructura	7
2. Estado del Arte	11
2.1. Técnicas de Modelado	11
2.1.1. Diferentes Enfoques de Modelado	12
2.1.2. Modelado por Modelos Locales	16
2.2. Técnicas de Control	17
2.2.1. Técnicas de Control Basadas en Modelos	18
2.3. Técnicas de Monitorización	21
2.4. Técnicas de Inteligencia Artificial en el Modelado, la Monitorización y el Control de Procesos	22
2.4.1. Estado del Arte en Sistemas Neuroborrosos	26
2.5. Técnicas de Agrupamiento para Identificación	28
2.6. Monitorización y Control de Sistemas Complejos	30
2.6.1. Estado del Arte en la Monitorización y el Control de Procesos de Mecanizado	30
2.6.1.1. Modelado y Control del Proceso de Taladrado	32
2.6.1.2. Monitorización del Proceso de Torneado	36
3. Sistemas Neuroborrosos	41
3.1. Inteligencia Artificial y Soft Computing	41
3.2. Definición	46
3.3. Inferencia Neuroborrosa	49
3.3.1. Inferencia Inductiva	50
3.3.2. Inferencia Transductiva	53

3.4. Modelado Neuroborroso	61
3.5. Sistemas de Control Neuroborroso	62
3.5.1. Control por Modelo Inverso	63
3.5.2. Control Adaptativo por Modelo de Referencia	64
3.5.3. Control Predictivo Basado en Modelos	65
3.5.4. Control por Modelo Interno	66
4. Sistemas Complejos en Fabricación: Procesos de Mecanizado de Alto Rendimiento	71
4.1. Los Procesos de Mecanizado como Sistemas Complejos	71
4.1.1. Naturaleza del Proceso de Arranque de Viruta	73
4.1.2. El Mecanizado de Alto Rendimiento	78
4.2. El Proceso de Taladrado	80
4.2.1. Parámetros de Corte en el Proceso de Taladrado	82
4.2.2. Enfoque Sistémico del Proceso de Taladrado	85
4.2.3. Modelo (Utilizado en Simulación)	87
4.3. El Proceso de Torneado	88
4.3.1. Parámetros de Corte en el Proceso de Torneado	90
4.3.2. Enfoque Sistémico del Proceso de Torneado	91
4.4. Planteamiento del Problema	92
4.4.1. Planteamiento para el Proceso de Taladrado	93
4.4.2. Planteamiento para el Proceso de Torneado	94
5. Modelado y Control Neuroborroso. Aplicación al Proceso de Taladrado	97
5.1. Plataforma Experimental	97
5.1.1. Arquitectura en Red	102
5.2. Paradigma de Control: El Control por Modelo Interno	105
5.3. Modelado y Control a través de ANFIS	107
5.3.1. Modelado	108
5.3.2. Control	112
5.4. Modelado y Control a través de TNFIS	126
5.4.1. Modelado	127
5.4.2. Control	128

6. Sistema Neuroborroso de Monitorización. Aplicación al Proceso de Torneado	135
6.1. Plataforma Experimental	135
6.2. Monitorización del Proceso de Torneado	137
6.3. Modelado y Monitorización a través de ANFIS	141
6.4. Modelado y Monitorización a través de TWNFI-i	144
7. Conclusiones	155
7.1. Conclusiones	155
7.2. Publicaciones Asociadas	157
7.3. Trabajo Futuro	159
Bibliografía	161

Índice de tablas

Tabla 2.1.	Técnicas de control más utilizadas	17
Tabla 2.2.	Técnicas de Inteligencia Artificial en aplicaciones de modelado, monitorización y control	22
Tabla 5.1.	Errores RMSE de los modelos creados	112
Tabla 5.2.	Resumen de los parámetros de los modelos neuroborrosos	114
Tabla 5.3.	Estudio de los sistemas de control	116
Tabla 5.4.	Condiciones de operación para los materiales estudiados	118
Tabla 5.5.	Cifras de mérito de los experimentos reales con material GGG40 (A395)	119
Tabla 5.6.	Cifras de mérito de los experimentos reales con material GGG40 (A395) - Ethernet	123
Tabla 5.7.	Cifras de mérito de los experimentos reales con material 17-4PH (A564) - Ethernet	123
Tabla 5.8.	Cifras de mérito de los experimentos reales con material GGG40 (A395) - Ethernet	131
Tabla 5.9.	Cifras de mérito de los experimentos reales con material 17-4PH (A564) - Ethernet	131
Tabla 5.10.	Algoritmos neuroborrosos en el paradigma de control por modelo interno	133
Tabla 6.1.	Condiciones de corte de las operaciones de torneado llevadas a cabo	137
Tabla 6.2.	Algoritmos neuroborrosos para el modelado del desgaste de la herramienta	147
Tabla 6.3.	Errores medios de los modelos creados (FG 15)	148
Tabla 6.4.	Errores medios de los modelos creados (En24)	148
Tabla 6.5.	Análisis estadístico de los modelos neuroborrosos (FG 15)	149
Tabla 6.6.	Análisis estadístico de los modelos neuroborrosos (En24)	150

Índice de figuras

Figura 2.1.	Clasificación de modelos utilizados en tareas de monitorización y control	12
Figura 2.2.	Diferentes posibilidades de clases en un espacio de dos dimensiones.....	29
Figura 2.3.	Procesos de taladrado	32
Figura 2.4.	Parámetros geométricos utilizados en el modelo de Elhachimi <i>et al.</i>	33
Figura 2.5.	Diagrama de flujo de la aproximación propuesta por Pirtini y Lazoglu ...	34
Figura 2.6.	Diagrama de bloques de la aproximación adaptativa propuesta por Landers et al.	35
Figura 2.7.	Control PID propuesto por Haber <i>et al.</i>	36
Figura 2.8.	Procesos de torneado	37
Figura 3.1.	Evolución de los sistemas expertos	42
Figura 3.2.	Taxonomía de la inteligencia computacional (<i>soft computing</i>)	46
Figura 3.3.	Partes de un sistema de inferencia borroso	47
Figura 3.4.	Modelado a través de técnicas inductivas	50
Figura 3.5.	Arquitectura del sistema ANFIS	51
Figura 3.6.	Modelado a través de métodos transductivos	53
Figura 3.7.	Ejemplo del algoritmo ECM para simple-entrada/simple-salida y las funciones de pertenencia generadas a partir de sus resultados	56
Figura 3.8.	Arquitectura de TNFIS en un ejemplo de creación de tres <i>clusters</i>	57
Figura 3.9.	Diagrama de bloques del algoritmo TNFIS	57
Figura 3.10.	Diagrama de bloques del algoritmo TWNFI-i	60
Figura 3.11.	Esquema de control por modelo inverso	63
Figura 3.12.	Esquema de control adaptativo por modelo de referencia	64
Figura 3.13.	Estructura básica del control predictivo basado en modelos	66
Figura 3.14.	Esquema de control por modelo interno	67
Figura 4.1.	Procesos de mecanizado	72
Figura 4.2.	Zonas en el proceso de cizalladura	74
Figura 4.3.	Descomposición de las fuerzas y de las velocidades en el modelo de plano de cizalladura	76
Figura 4.4.	Máquina herramienta de Alta Velocidad para procesos de mecanizado ...	80
Figura 4.5.	Detalle del proceso de Taladrado de Alto Rendimiento	82
Figura 4.6.	Velocidades de corte en el Taladrado a Alta Velocidad	82

Figura 4.7.	Posible enfoque sistémico del proceso de taladrado	85
Figura 4.8.	Enfoque sistémico del proceso de taladrado utilizado en este trabajo	86
Figura 4.9.	Torno paralelo y partes que lo constituyen	88
Figura 4.10.	Enfoque sistémico del proceso de torneado utilizado en este trabajo	92
Figura 5.1.	Centro de mecanizado de la plataforma experimental	98
Figura 5.2.	Plataforma experimental	99
Figura 5.3.	Pieza de trabajo fijada a la plataforma dinamométrica	100
Figura 5.4.	Programa de adquisición	101
Figura 5.5.	Niveles de red en la plataforma experimental	103
Figura 5.6.	Distribución estadística de los retardos inducidos por la red obtenida sobre un conjunto de 10000 muestras	104
Figura 5.7.	Aplicación visual para la monitorización del proceso de taladrado	105
Figura 5.8.	Sistema de control por modelo interno a través de Profibus	106
Figura 5.9.	Sistema de control por modelo interno a través de Ethernet	107
Figura 5.10.	Estructura del modelo directo neuroborroso ANFIS	108
Figura 5.11.	Funciones de pertenencia y reglas del modelo directo ANFIS	109
Figura 5.12.	Respuesta del modelo directo neuroborroso ANFIS	110
Figura 5.13.	Estructura de modelo inverso neuroborroso ANFIS	110
Figura 5.14.	Funciones de pertenencia y reglas del modelo inverso ANFIS	111
Figura 5.15.	Respuesta del modelo inverso neuroborroso ANFIS	112
Figura 5.16.	Simulación del control neuroborroso por modelo interno del proceso de taladrado	113
Figura 5.17.	Simulación con un regulador PID	115
Figura 5.18.	Simulación del sistema: a) respuesta del sistema ante un escalón y b) acción de control correspondiente	116
Figura 5.19.	Relación entre el error <i>ITAE</i> del sistema de control ANFIS-CMI ante simulaciones con distinto retardo	117
Figura 5.20.	Respuesta del sistema con el menor y con el mayor de los retardos simulados	117
Figura 5.21.	a) Comportamiento de la fuerza de corte y b) Acción de control en el taladrado del material GGG40	120
Figura 5.22.	a) Comportamiento de la fuerza de corte y b) Acción de control en el taladrado del material 17-4PH	121
Figura 5.23.	Control del proceso de taladrado a través del controlador borroso optimizado por Nelder-Mead	122

Figura 5.24.	a) Comportamiento de la fuerza de corte y b) Acción de control en el taladrado del material GGG40 (Ethernet)	124
Figura 5.25.	a) Comportamiento de la fuerza de corte y b) Acción de control en el taladrado del material 17-4PH (Ethernet)	125
Figura 5.26.	Modelos a) directo e b) inverso del proceso de taladrado obtenidos por TNFIS	128
Figura 5.27.	Esquema de control por modelo interno basado en modelos TNFIS	129
Figura 5.28.	a) Respuesta del sistema real y b) acción de control en operaciones con GGG40	130
Figura 5.29	a) Respuesta del sistema real y b) acción de control en operaciones con 17-4PH	132
Figura 6.1.	Plataforma experimental empleada en la monitorización neuroborrosa	136
Figura 6.2.	Datos obtenidos en operaciones de torneado del FG 15	138
Figura 6.3.	Datos obtenidos en operaciones de torneado del En24	138
Figura 6.4.	Fuerzas de corte en una operación de torneado	140
Figura 6.5.	Modelo del desgaste de la herramienta a través de ANFIS	141
Figura 6.6.	Arquitectura de ANFIS para el modelado del desgaste	142
Figura 6.7.	Funciones de pertenencia del modelo neuroborroso ANFIS propuesto	144
Figura 6.8.	Arquitectura de TWNFI-i para el modelado del desgaste	145
Figura 6.9.	Funciones de pertenencia del modelo neuroborroso TWNFI-i propuesto	146
Figura 6.10.	Resultados obtenidos por los modelos neuroborrosos para el desgaste de herramienta (caso del FG15)	151
Figura 6.11.	Resultados obtenidos por los modelos neuroborrosos para el desgaste de herramienta (caso del En24)	153

Capítulo 1

Introducción

Este capítulo presenta las bases sobre las que se ha desarrollado el presente trabajo de investigación. Para ello, en la primera parte de este capítulo se hace una breve introducción en la cual se presentan las motivaciones del trabajo. Posteriormente se presentan a grandes rasgos los problemas fundamentales a los que se ha tratado de dar solución en esta tesis doctoral: el modelado, el control y la monitorización de sistemas complejos. Una vez se han definido los problemas, se exponen detalladamente los objetivos del trabajo. Por último, en la parte final del capítulo se presenta la estructura general de esta disertación.

1.1. Motivación

La obtención de un modelo matemático que sea capaz de representar un sistema real es un tema fundamental en multitud de áreas relacionadas con la ingeniería y la ciencia. Los modelos pueden ser utilizados para realizar simulaciones, para analizar el comportamiento del sistema, para entender mejor los mecanismos subyacentes del sistema, para diseñar nuevos procesos, o para monitorizar, supervisar y controlar los propios sistemas. En otras palabras, el hecho de contar con un modelo de un sistema proporciona una herramienta potencial para la mejora y optimización del mismo.

El desarrollo de un modelo debe conducir a una representación adecuada de la realidad a través de ecuaciones matemáticas (ecuaciones diferenciales, ecuaciones integrales, etc.). Ciertamente no se trata de una tarea sencilla y tiene una importancia vital para el cumplimiento de objetivos posteriores. Si el modelo no es lo suficientemente preciso, los subsecuentes pasos de análisis, predicción, control, etc., no se desarrollarán correctamente. Sin embargo, existe un compromiso obvio entre la exactitud necesaria de un modelo y su complejidad. Los modelos deben proporcionar información al nivel de precisión más relevante, suprimiendo los detalles innecesarios. Si el modelo es demasiado simple, no representará adecuadamente las características objeto de estudio del sistema y, por tanto, el modelo no cumplirá su propósito. Por el contrario, el modelo no debe ser excesivamente complejo ya que su utilidad práctica sería muy limitada.

En el campo de la ingeniería de control, el modelado y la identificación son pasos muy importantes en el diseño de sistemas de control, sistemas de supervisión, sistemas de monitorización y sistemas de detección de fallos. Los modernos métodos de producción y fabricación industriales, junto con la creciente demanda de mejores productos, bienes y servicios, la calidad, la flexibilidad de la producción, y la seguridad, han incrementado los requisitos impuestos a los sistemas de control. La producción está a menudo caracterizada por frecuentes cambios en los puntos de operación y en las condiciones de operación. Para satisfacer los estrictos requisitos de calidad, los sistemas de control deben garantizar un buen funcionamiento sobre todo el amplio rango de condiciones de operación. Bajo estas condiciones, frecuentemente el modelado de procesos constituye el principal cuello de botella en la aplicación de técnicas avanzadas de control basadas en modelo [1].

Muchos sistemas no son susceptibles de ser modelados a través de técnicas tradicionales debido a la pérdida de precisión, a la falta de un conocimiento técnico exacto acerca del sistema, al comportamiento fuertemente no lineal, al alto grado de incertidumbre y a las características

variantes en el tiempo del proceso en cuestión [2]. Existen ejemplos muy variados de estos sistemas en la industria de procesos, en la industria manufacturera, en el sector aeronáutico y aeroespacial, en el campo de la bioingeniería, etc. En un primer análisis de todos y cada uno de estos campos, se puede considerar que desarrollan un proceso en común: los procesos de mecanizado.

Los procesos de mecanizado tienen una gran importancia dentro de los sectores anteriormente citados. Estos procesos involucran maquinaria y materiales muy costosos así como operadores expertos. De ahí que cualquier modelo que sea capaz de describir de forma eficiente los procesos físicos que tienen lugar en ellos, es esencial para la mejora y optimización de estos sistemas. Ciertamente la maximización de la productividad y la minimización de los fallos y los riesgos de rotura de máquinas y herramientas son tareas muy difíciles de llevar a cabo sin modelos. Por otra parte, la fuerte competencia a nivel internacional en el sector del mecanizado obliga a desarrollar e implantar sistemas de monitorización, supervisión y control que mejoren los procesos productivos en todas sus facetas (aumentar las tasas de arranque del material, disminuir los tiempos de parada, mejorar la calidad superficial, mejorar la calidad dimensional, proteger la herramienta de corte, conservar la mecánica de la máquina, etc.) [3].

Los procesos de mecanizado entran en la categoría de procesos de difícil modelado a través de técnicas clásicas. La razón fundamental es que son procesos extremadamente complejos, fuertemente no-lineales, cargados de incertidumbre y con comportamientos imposibles de describir exactamente por herramientas de modelado convencionales. En este caso, las aproximaciones basadas en técnicas de Inteligencia Artificial (IA) constituyen una alternativa útil y viable para tratar con estos problemas [4]. Prueba de ello es que los últimos años se han caracterizado por el desarrollo de nuevos paradigmas en el campo de la Inteligencia Artificial para dar solución a las problemáticas existentes. El uso masivo de las técnicas de IA en el modelado de procesos, y sobre todo en la monitorización y el control, ha sido consecuencia de que, en buena medida, las técnicas clásicas no han producido, en algunos casos, los resultados deseados y se han mostrado efectivas sólo en las condiciones teóricas de diseño. Además, las prestaciones de los reguladores clásicos se deterioran considerablemente en presencia de incertidumbre y de no linealidades. Sin embargo, no solo basta con desarrollar métodos que aprovechen las ventajas de las técnicas de Inteligencia Artificial, sino que hay que aprovechar la sinergia entre éstas, los métodos computacionales avanzados, los progresos en software para tiempo real y las nuevas herramientas de comunicación. De este modo se pueden alcanzar diseños de sistemas de control, supervisión y monitorización cualitativamente superiores y aplicarlos a la mejora de procesos productivos, en este caso, a los procesos de mecanizado, dando lugar así a los procesos de mecanizado de alto rendimiento.

Por todas estas razones, el presente trabajo trata de modelizar, a través de técnicas de Inteligencia Artificial, dos de las dinámicas más frecuentes, a la par que complejas, de dos de las operaciones de mecanizado más comunes. Por una parte la dinámica del proceso de taladrado, la cual ha recibido poca atención por parte de la comunidad científica. Por otra parte la dinámica del desgaste de la herramienta en operaciones de torneado. Una vez se hayan modelado estos procesos, se procederá en el caso del taladrado a controlar el proceso utilizando estrategias de control que incluyan controladores neuroborrosos con el objetivo de mejorar la eficiencia del proceso alcanzando mayores tasa de arranque de material (disminución del tiempo de producción) y considerando la vida útil de la herramienta de corte. Para el caso del desgaste de la herramienta en operaciones de torneado se utilizarán los modelos para diseñar un sistema de monitorización neuroborrosa con el objetivo de controlar y evitar posibles fallos catastróficos de la herramienta debidos a un desgaste excesivo.

En resumen lo que se pretende es mejorar la eficiencia de procesos complejos con un fuerte impacto en el sector de la fabricación a través de la reducción de los tiempos de ciclo, la prevención de fallos y la reducción de costes a través de la hibridación de técnicas de Inteligencia Artificial.

1.2. Descripción del Problema

Los procesos de fabricación constituyen por su variedad y complejidad un sector industrial con un gran impacto en el PIB de las naciones desarrolladas. El futuro de este sector pasa por la aplicación de nuevos conceptos, modelos, metodologías y tecnologías de la información, con el objetivo de preparar a las empresas manufactureras para ser más competitivas en un entorno global muy masificado [5]. Por tanto, una característica fundamental para el diseño de sistemas de fabricación futuros será su capacidad para adaptarse a entornos y condiciones cambiantes [6]. Estos condicionantes implican la necesidad de construir una máquina inteligente para la consecución de objetivos y para mantener un rendimiento adecuado bajo condiciones de procesos completamente variables. El sistema inteligente a diseñar debe tener características y capacidades tales como percepción sensorial, aprendizaje y adquisición de conocimientos, inferencia a partir de información incompleta, y adaptación.

Sin embargo, los procesos de fabricación constituyen claros ejemplos de sistemas complejos con lo cual, las dinámicas existentes en dichos procesos desempeñan un papel muy importante a la hora de diseñar cualquier sistema para optimizar y/o mejorar el proceso productivo en tiempo real y bajo un entorno cambiante. De entre las posibles vías para la obtención de una mayor ventaja competitiva se encuentran el control y la monitorización de procesos. La obtención de un modelo del sistema objeto de estudio, constituye un elemento común en ambas vías de solución.

Como la monitorización, el control y el modelado de estos sistemas complejos traen aparejados retos diferentes, se detallan a continuación los problemas particulares de cada una de estas facetas.

1.2.1. Modelado de Sistemas Complejos

Buena parte de las dificultades en la introducción de sistemas de control y monitorización “inteligentes” provienen de la falta de modelos adecuados y de técnicas que permitan obtenerlos fácilmente [7]. Los sistemas complejos exhiben generalmente fuertes no linealidades y un comportamiento no estacionario. Por estas razones, los modelos existentes acerca de un sistema complejo son aproximaciones al problema, centrados en ocasiones en regiones de operación muy concretas. Es bastante común que representen el comportamiento del sistema únicamente bajo condiciones teóricas o en un rango muy reducido de la dinámica real del proceso. En general, no suelen ser modelos válidos en todas las condiciones de trabajo.

Algunas de las técnicas utilizadas en los últimos años para modelizar sistemas complejos se basan en la descripción mediante ecuaciones diferenciales, mediante representaciones en variables de estado, mediante matrices de transferencia (continuas o discretas), etc. Sin embargo, existen muchos procesos en los cuáles no resulta sencillo obtener estas ecuaciones y, si es posible, su validez suele ser muy limitada.

Tal y como se ha mencionado anteriormente, el modelo obtenido tiene que servir de soporte a las funciones de diseño integrado del sistema de control, a la monitorización, al entrenamiento de personal, a la planificación, a la simulación predictiva para sistemas de ayuda a la decisión en línea, etc. Por consiguiente, la tarea de modelado requiere una investigación profunda y un esfuerzo importante. No en vano, el desarrollo de métodos para modelizar sistemas complejos sentará en buena medida las bases para la implantación de sistemas de control y monitorización inteligentes en la industria. Además, la mejora del rendimiento en un proceso productivo, la calidad del producto final, el aumento de la productividad y la disminución de costes dependerán de la calidad del modelo obtenido.

1.2.2. Control de Sistemas Complejos

Los modernos métodos de producción y fabricación demandan de los sistemas de control un buen comportamiento en una amplia gama de condiciones de trabajo. Gran parte de este hecho es debido a la necesaria flexibilidad, cambios de producto, regímenes de trabajo, etc. Todas ellas son las condiciones a las que se encuentra sometido hoy en día el sector industrial. En tales circunstancias existe un gran número de procesos que exhiben fuertes no linealidades y un comportamiento no estacionario, y por tanto, existe una notable incertidumbre sobre el proceso en cuestión [8].

Los controladores clásicos y adaptativos han probado su validez en el ambiente industrial, siempre que todas las condiciones teóricas (requisitos *a priori* de diseño) hayan sido cumplimentadas y los parámetros de diseños hayan sido escogidos convenientemente. No obstante, en la práctica muchos de estos requisitos no se cumplen y algunos parámetros de diseño no son los más apropiados, lo que repercute en un pobre funcionamiento del sistema de control. Todas estas circunstancias han motivado que en la actualidad la optimización de muchos procesos industriales, sea un problema sólo resuelto parcialmente. En la mejoría de la eficiencia del proceso productivo influye de manera significativa el hecho de que no se pueden alcanzar incrementos significativos de la productividad a partir de los esquemas de control clásicos instalados. Dos caminos interesantes para abordar la optimización son la introducción de sistemas de monitorización y control inteligentes en los cuales se aproveche la sinergia de técnicas de Inteligencia Artificial.

Sin embargo, no solo basta con aplicar paradigmas emergentes dentro de la Inteligencia Artificial. Los retos anteriormente expuestos hacen necesario el empleo de técnicas capaces de dar respuesta a la interacción de procesos, a dinámicas complejas, a la presencia de incertidumbre. Además, tal y como se ha visto en el apartado anterior, un control adecuado de estos sistemas complejos requiere del uso de modelos más allá de los lineales al uso.

La combinación de esquemas de control, técnicas de Inteligencia Artificial y modelos de sistemas complejos deben conducir incuestionablemente a sistemas de control con garantías de estabilidad y robustez [9, 10]. Este es el único modo en el cual el control inteligente pueda contar con un alto grado de aceptación en la industria. Aunque en ciertos tipo de procesos complejos, como por ejemplo los procesos químicos, se han alcanzado esquemas de control inteligentes con muy buenos resultados [11-13], existen sistemas igualmente importantes pero que no han recibido la misma atención en la literatura de control. Entre ello se encuentran los procesos de mecanizado.

Los procesos de mecanizado son no-lineales y altamente variables debido a múltiples factores (por ejemplo, el desgaste de la herramienta de corte, las vibraciones y otra serie de alteraciones). Estas características conducen a problemas asociados a la estimación de estados y adaptación de modelos en línea, a los métodos de optimización, a la búsqueda de dinámicas eficaces en tiempo y precisión, etc. En este sentido, cabe además mencionar las problemáticas que se plantean a la hora de implementar sistemas de control inteligente en tiempo real en procesos rápidos, aunque algunas de estas técnicas hayan sido implantadas con éxito en procesos lentos.

Los problemas se incrementan aún más cuando se tratan de aplicar sistemas de control a procesos de mecanizado de alta velocidad. El mecanizado de alta velocidad define nuevos conceptos y estrategias en el diseño mecánico, así como en el diseño de sistemas de monitorización y control para procesos de mecanizado.

Por otra parte, la selección de los parámetros óptimos de mecanizado es otro problema importante en el funcionamiento de estos procesos de mecanizado de alta velocidad. Por lo general, en un centro de mecanizado equipado con control numérico por computador (CNC) se realiza la selección de los parámetros de corte óptimo (velocidad de corte, tasa de avance,

profundidad de corte, entre otros). De esta elección depende la calidad y los costes del producto. En la actualidad, en el mecanizado convencional existe suficiente información (bases de datos de mecanizado, manuales) para seleccionar los parámetros adecuados de corte para una combinación de herramienta de corte y material de la pieza dados. Sin embargo, el *know-how* para mecanizados de alta velocidad no está suficientemente desarrollado o accesible y a día de hoy la selección de los parámetros de corte se hace en la mayoría de los casos recurriendo a la heurística, es decir, aprovechando la experiencia del operador humano.

1.2.3. Monitorización de Sistemas Complejos

Buena parte de las posibilidades de implementación de sistemas de control y optimización inteligentes, y su extensión a nuevos campos, se basan en la disponibilidad de una mejor información del proceso. En parte, los nuevos sensores y sistemas de instrumentación de alta tecnología proporcionarán nuevas medidas, pero para traducir los datos en información útil para el control y otros niveles de decisión se necesita un procesamiento de señal más sofisticado. Por ello, es necesario avanzar en temas como estimación de variables no medidas usando el denominado “sensor software”, elaborando de este modo índices de rendimiento y comportamiento dinámico de la planta en línea [7].

Por otra parte, el correcto funcionamiento de los sistemas de control depende en gran medida de la habilidad para conocer el estado real de funcionamiento del proceso, bien en su operación normal, o bien en su funcionamiento degradado debido a la aparición de fallos o cambios de estado interno. Los modernos sistemas basados en buses de campo facilitan alguna de estas tareas al ofrecer diagnósticos automáticos de la instrumentación, pero eso es solo una parte del diagnóstico. Los puntos fuertes acerca de posibles fallos son el propio proceso y el sistema de control. Conviene además no perder de vista en este sentido, los estados o cambios del proceso que pongan en peligro el producto, el propio proceso, el equipamiento y maquinaria o, fundamentalmente, la seguridad de los operarios.

Nuevamente, el modelado, y en ocasiones las técnicas estadísticas, juegan un papel determinante en el diseño e implementación de sistemas de monitorización. La problemática en este caso tiene relación con la obtención de modelos del funcionamiento conjunto de las funciones y elementos del sistema complejo, en lugar de desarrollar un modelado aislado. A este reto hay que añadir las posibilidades que ofrece la utilización de técnicas de aprendizaje automático para la obtención de reglas de funcionamiento en sistemas de monitorización.

Considerando una vez más los procesos de mecanizado como caso de estudio de sistemas complejos, el problema de la monitorización se centra en uno de los problemas fundamentales del proceso: encontrar una solución de compromiso apropiada entre el desgaste de la herramienta de corte, la calidad superficial y la productividad, teniendo en cuenta el coste de la herramienta, el coste de su reposición, el coste de inactividad de la máquina, por solo citar las cuestiones más relevantes. Pese a que la literatura especializada refleja cientos de aproximaciones para el modelado del desgaste de la herramienta, los sistemas de monitorización del desgaste no han alcanzado aún los resultados esperados. Por tanto, sigue siendo hoy en día un problema no resuelto (o resuelto solo parcialmente) lo que constituye, a su vez, una gran oportunidad: desarrollar sistemas de monitorización inteligentes que permitan mantener la misma calidad del producto (o superior) con una reducción de costes operativos. No en vano, ciertos trabajos estiman que el tiempo de inactividad debido a la rotura de la herramienta de corte en una máquina herramienta representa, como valor promedio, entre un 6,8% y un 20% [14]. La complejidad del problema puede aumentar aún más cuando se trata con procesos de mecanizado de alta velocidad y en mecanizados de precisión o en micro-mecanizados.

Sin embargo, aunque no se alcance el estado de rotura, el empleo de herramientas desgastadas o con falta de filo puede conducir a mayores esfuerzos en la máquina herramienta y puede causar una pérdida de calidad en la pieza debido, por ejemplo, a las vibraciones

ocasionadas. Por ello, existen trabajos que también afirman que el empleo de sistemas de monitorización eficaces puede conducir a una disminución en el tiempo de mecanizado de entre un 10% y un 65% [15].

1.3. Objetivos

El trabajo presentado en esta tesis se enmarca en el área de los sistemas inteligentes y la automatización de procesos. La idea fundamental es aplicar al control de sistemas complejos técnicas y esquemas no combinados anteriormente para mejorar el comportamiento de esta serie de procesos. El desarrollo de un método integrador de paradigmas de control, sistemas borrosos, sistemas neuronales, técnicas de razonamiento y técnicas de agrupamiento propiciará potencialidades y sinergias no reportadas anteriormente en el campo del control.

Por ello se plantea como objetivo general del trabajo diseñar e implementar un sistema de control inteligente y un sistema de monitorización inteligente a sistemas complejos. Para ello se propondrá una metodología y un procedimiento basado en el modelado neuroborroso del proceso a optimizar, combinando el conocimiento humano del sistema borroso con la capacidad de aprendizaje de las redes neuronales. De este modo se pretende diseñar e implementar un sistema de control neuroborroso basado en el paradigma del control por modelo interno para el control de la fuerza de corte en un proceso de taladrado (proceso electromecánico complejo). Además, se pretende diseñar un sistema de monitorización neuroborrosa para el desgaste de la herramienta de corte en un proceso de torneado (proceso físico-mecánico complejo).

Los objetivos del planteamiento científico y técnico propuesto en este trabajo se resumen en los siguientes:

Objetivos Científicos:

- 1) Estudiar, analizar y verificar el comportamiento de varios sistemas neuroborrosos en el modelado, monitorización y control de procesos complejos, y en cuestiones específicas tales como:
 - a) El modelado de dinámicas de procesos electromecánicos y físico-mecánicos complejos
 - b) La eficiencia computacional y la viabilidad de aplicación en tiempo real de los algoritmos que implementan los sistemas
 - c) La complejidad de la topología de los sistemas
- 2) Estudiar y verificar las ventajas y desventajas de diversos métodos de inferencia en el modelado de sistemas complejos por medio de estudios comparativos sustentados no solo en simulaciones, sino en experimentos y ensayos en procesos industriales reales
- 3) Desarrollar un método para el control de procesos complejos que combine las propiedades más avanzadas de los sistemas neuroborrosos (inductivas-transductivas, borrosas y neuronales) con paradigmas del control como el control por modelo interno.
- 4) Desarrollar un método para la monitorización de procesos complejos que combine las sinergias de la hibridación neuroborrosa con las distintas técnicas de extracción de conocimiento y la información procedente de la fusión sensorial.

Objetivos Técnicos:

- 5) Desarrollar e implementar algoritmos de monitorización y control que incorporen capacidades y potencialidades más allá de las que en la actualidad aportan algunas de las redes neuronales artificiales más avanzadas, intentando aprovechar mediante hibridación las excelentes propiedades y características que aportan los sistemas borrosos, inductivos y transductivos a estas topologías.
- 6) Mejorar la eficiencia de procesos complejos y con un gran impacto económico (taladrado y torneado) mediante:
 - a) El incremento en la tasa de arranque del material junto con la protección de la vida útil de la herramienta en procesos de taladrado.
 - b) La reducción de riesgos, prevención de fallos, así como el aumento de la producción, de la seguridad y de la calidad en procesos de torneado.

1.4. Estructura

El presente trabajo de investigación se estructura en siete capítulos. En este capítulo (Capítulo 1) se han presentado las bases sobre las que se ha desarrollado la disertación. Primeramente se han mostrado las motivaciones y después se han mostrado a grandes rasgos los problemas fundamentales del modelado, control y la monitorización de sistemas complejos. Una vez se definieron los problemas, se han expuesto detalladamente los objetivos del trabajo.

En el Capítulo 2 se recoge una revisión de las técnicas utilizadas en el modelado, monitorización y control de procesos complejos, así como las contribuciones realizadas por otros investigadores en la optimización de procesos de mecanizado. Primeramente se presentan las técnicas empleadas para modelizar sistemas complejos y después las técnicas empleadas para el control y la monitorización de dichos sistemas. En el apartado dedicado al control, se hace especial hincapié en las técnicas de control basadas en modelos. Posteriormente se repasan las técnicas de Inteligencia Artificial utilizadas en el modelado, la monitorización y el control de sistemas complejos, centrándonos después el estado del arte en sistemas neuroborrosos. También se resumen después algunas de las técnicas de agrupamiento más empleadas en los sistemas de modelado, control y monitorización. Finalmente se recopilan los trabajos y contribuciones en la optimización de procesos complejos, analizando en profundidad qué se ha hecho en el caso de procesos de mecanizado y, en especial, en el modelado y control del proceso de taladrado así como en el modelado y monitorización del proceso de torneado.

El Capítulo 3 trata los aspectos relacionados con los sistemas neuroborrosos. Esta clase de sistemas se ha desarrollado como un paradigma de computación más dentro de las técnicas de Inteligencia Artificial y, más concretamente, dentro del *Soft Computing*. Por tanto, en la primera parte del capítulo se hace una breve introducción acerca de los orígenes de los sistemas neuroborrosos. Posteriormente se pasa ya a definir específicamente en qué consiste un sistema neuroborroso y las motivaciones que desembocaron en su aparición. Después se pasa a detallar el procedimiento o método de inferencia en esta clase de sistemas, diferenciando entre técnicas de inferencia inductiva y técnicas de inferencia transductiva. Siguiendo con esta clasificación, se presentarán tres casos particulares de sistemas neuroborrosos que utilizan los dos métodos de inferencia anteriormente mencionados: ANFIS, TNFIS y TWNFI-i. Debido a que en este trabajo el fin último de estos sistemas neuroborrosos es modelizar y controlar sistemas complejos, se presentan finalmente diferentes procedimientos para modelizar y controlar procesos por medio de sistemas neuroborrosos.

En el Capítulo 4 se tratan todos los aspectos relacionados con los procesos de mecanizado. Primeramente se estudia la importancia que poseen los procesos de mecanizado dentro de la fabricación industrial para, posteriormente, analizar y fundamentar la complejidad de los mismos. Después se define el concepto de arranque de material, así como el término mecanizado de alto rendimiento. Una vez explicados los procesos de mecanizado de alto rendimiento en general, se hace un análisis en profundidad de dos de los subprocesos que son seleccionados como casos de estudio en este trabajo: el taladrado de alto rendimiento y el torneado de alto rendimiento. Se analizarán sus fundamentos, características, parámetros y enfoques sistémicos para, en último término, plantear los problemas existentes en dichos procesos.

El Capítulo 5 muestra el modelado y control del proceso de taladrado a través de técnicas neuroborrosas. Se trata de modelizar primeramente, a través de datos entrada-salida, tanto la dinámica directa como la dinámica inversa del proceso de taladrado. Posteriormente, a través de una técnica de control basada en modelos, el control por modelo interno, se regulará la fuerza media de corte en un proceso de taladrado por medio de la modificación de la velocidad de avance de la herramienta. Por estas razones, la primera parte del capítulo presenta la plataforma experimental en la que se han adquirido los datos para la creación de los modelos y en la que se ha implementado físicamente el propio sistema de control. En la segunda parte del capítulo se detallan las particularidades del esquema de control por modelo interno del proceso de taladrado basado en dicha plataforma experimental. Una vez mostrados los elementos con los que se cuenta para el modelado y el control, se procede a explicar el procedimiento de modelado y los resultados obtenidos en el posterior control del proceso (tanto en simulación como en experimentos industriales reales) a través del sistema de inferencia neuroborroso ANFIS. La última parte del capítulo muestra también el procedimiento y los resultados obtenidos en el modelado y control del proceso de taladrado a través del sistema de inferencia neuroborroso TNFIS.

El Capítulo 6 trata la importante problemática del desgaste de la herramienta de corte en procesos de torneado. Para hacer frente a esta problemática se propone la utilización de sistemas neuroborrosos con el fin de crear modelos que sirvan de base para monitorizar el proceso de desgaste de herramienta en operaciones de torneado. Nuevamente los modelos se crearán a partir de una serie de datos entrada-salida. Se consideran como entradas al modelo el tiempo, la fuerza de corte, las vibraciones sufridas por la herramienta (aceleraciones) y las señales de emisión acústica del proceso. Como salida del modelo se tendrá del desgaste de la herramienta (desgaste en el flanco). Tanto el conjunto de datos utilizado para crear los modelos, así como el resto de datos utilizados para validar los mismos se han obtenido de una plataforma experimental descrita en la primera parte de este capítulo. Posteriormente se detalla y fundamenta el procedimiento seguido para la monitorización del desgaste de la herramienta basada en modelos. Después se analiza y describe cómo se modela el proceso de desgaste a través de un sistema neuroborroso ANFIS, mostrándose a continuación los resultados obtenidos. Del mismo modo, se propone diseñar otro modelo neuroborroso basado en inferencia transductiva para la monitorización del desgaste de la herramienta. En la última parte del capítulo se muestra la implementación y los resultados ofrecidos por la técnica transductiva elegida: TWNFI-i.

Finalmente, el Capítulo 7 presenta las conclusiones de este trabajo de investigación. En este capítulo se recopilan además algunos de los resultados parciales de este trabajo que han sido divulgados, bien en revistas científicas o bien en congresos. Por último, se recogen también en esta parte algunas de las posibles líneas de investigación que han quedado abiertas y que se abordarán en trabajos futuros.

Capítulo 2

Estado del arte

Este capítulo presenta una revisión de las técnicas utilizadas en el modelado, control y monitorización de procesos complejos, así como las contribuciones realizadas por otros investigadores en la optimización de los procesos de mecanizado. Primeramente se presentan las técnicas empleadas para modelizar sistemas complejos y después las técnicas empleadas para el control y la monitorización de dichos sistemas. En el apartado dedicado al control, se hace especial hincapié en las técnicas de control basadas en modelos. Posteriormente se repasan las técnicas de Inteligencia Artificial utilizadas en el modelado, la monitorización y el control de sistemas complejos, reflejando después el estado del arte en sistemas neuroborrosos. A continuación se resumen también algunas de las técnicas de agrupamiento más empleadas en los sistemas de modelado, control y monitorización. Finalmente se recopilan los trabajos y contribuciones en la optimización de procesos complejos, analizando en profundidad qué se ha hecho en el caso de procesos de mecanizado y, en especial, en el modelado y control del proceso de taladrado así como en el modelado y monitorización del proceso de torneado.

2.1. Técnicas de Modelado

El proceso de modelado matemático e identificación experimental para la representación de sistemas es un tema de gran relevancia en muchas disciplinas de la ciencia y la ingeniería. En general, cualquier descripción de un sistema puede ser considerada como un modelo de dicho sistema [16]. Pese a que la capacidad de encapsular la información dinámica del sistema es importante, algunas técnicas de análisis y diseño requieren únicamente la información de estado estacionario. Sin embargo, la tarea de modelado se vuelve especialmente complicada al tratar con sistemas no lineales [17].

Los modelos, una vez desarrollados, pueden ser usados para la simulación, para el análisis del comportamiento del sistema, para una mejor comprensión de los mecanismos subyacentes del sistema, para diseñar nuevos procesos y para controlar sistemas con el fin de realizar un mejor uso de materiales, energía e información. Ciertamente, el uso de modelos reduce la necesidad de la experimentación real y facilita la consecución de fines muy diferentes a un reducido coste, riesgo y tiempo.

La elección de la precisión con la cual el modelo matemático representa la realidad es una tarea muy importante [1, 18]. Si el modelo no es suficientemente preciso, los estudios de análisis, predicción o cálculo de controladores basados en el modelo obtenido no serán desarrollados de forma adecuada. Además, el modelo más preciso y más complejo (*e.g.*, ecuación diferencial de alto grado) no es siempre el más adecuado desde el punto de vista computacional y práctico. Un modelo adecuado deberá proporcionar información sólo hasta el nivel que ésta sea relevante, eliminando los detalles cuando no sean necesarios. Si el modelo obtenido es demasiado simple, no se podrá representar de forma adecuada las características de interés del proceso físico en estudio. Por otra parte, un modelo nunca deberá ser tan complejo como para impedir su uso práctico [19].

En términos de sistemas de monitorización y control, el principal requisito del modelo es que debe contener información que permita la predicción del comportamiento del proceso ante cambios en sus condiciones de funcionamiento [20]. En este contexto, un modelo bien podría

ser una descripción matemática o estadística de los aspectos específicos del proceso. También puede estar representado en forma de descripciones cualitativas del comportamiento del proceso. La Figura 2.1 muestra una clasificación no exhaustiva de los modelos según su representación. Dependiendo de la tarea a realizar, se pueden emplear distintos tipos de modelo.

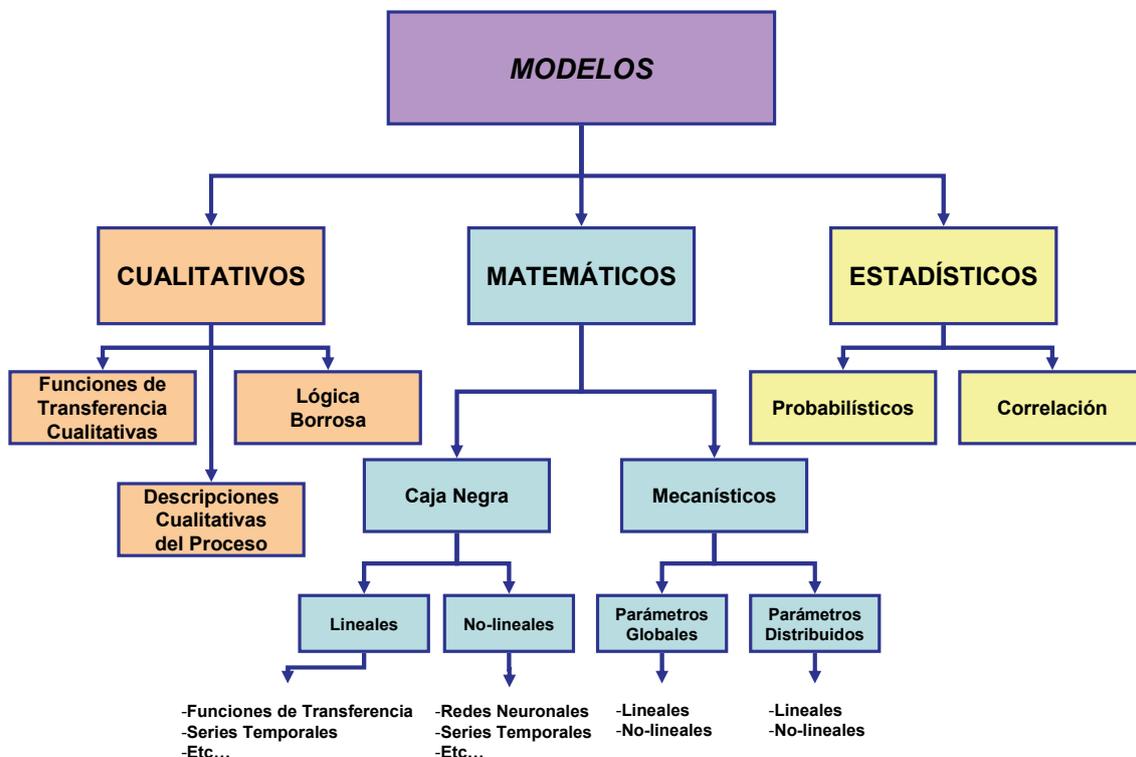


Figura 2.1. Clasificación de modelos utilizados en tareas de monitorización y control

2.1.1. Diferentes Enfoques de Modelado

Aunque existen una gran variedad de clasificaciones de modelos según su representación, en este trabajo de investigación se tratarán los enfoques de inspiración física o mecanísticos (caja blanca), de caja negra, cualitativo, estadístico e híbrido, ya que son los más empleados en el campo de la automatización de los procesos de mecanizado.

Modelos de Inspiración Física

Si se tiene un profundo conocimiento sobre el proceso a estudiar y sus características están bien definidas, entonces se pueden utilizar un conjunto de ecuaciones matemáticas (*e.g.*, ecuaciones diferenciales) para describir el comportamiento dinámico del proceso. Esta aproximación se conoce con el nombre de modelo mecanístico o, en determinadas ocasiones, modelo “caja blanca” (del inglés *white-box*). Este tipo de representación constituye el enfoque tradicional del modelado.

El modelo mecanístico se deriva generalmente de la física, la mecánica y la química que rigen el proceso [21]. Dependiendo del sistema, la estructura final del modelo podrá ser de parámetros globales o bien una representación de parámetros distribuidos. Los modelos de parámetros globales son descritos generalmente por ecuaciones diferenciales ordinarias, mientras que la representación de sistemas por parámetros distribuidos requiere el uso de ecuaciones en derivadas parciales. Obviamente, un modelo de parámetros distribuidos es más

complejo y, por lo tanto, más difícil de desarrollar. Más importante aún es que la solución de las ecuaciones en derivadas parciales también es menos directa.

Tanto los modelos de parámetros globales como los modelos de parámetros distribuidos se utilizan para representar sistemas lineales y no lineales. Por lo general, en la representación de sistemas no lineales, las ecuaciones diferenciales se han linealizado para facilitar el análisis [22].

Ciertamente, la necesidad de una muy buena comprensión de los conceptos físicos relacionados con el sistema hace que la realización y aplicación de este tipo de modelos sea muy limitada, sobretodo en el caso de tratar con sistemas no lineales. Los problemas habituales de los modelos de caja blanca vienen por: una falta de comprensión de los fenómenos físicos en los que se basa el funcionamiento del sistema, por valores inadecuados de los parámetros del sistema o por la propia complejidad del modelo resultante. La comprensión completa de los mecanismos que hay tras un sistema real es prácticamente imposible y tener los conocimientos necesarios para la realización de un modelo físico es difícil, caro y requiere mucho tiempo. Aun en el caso de obtener el modelo, es necesario determinar los valores precisos de una serie de parámetros. La estimación de estos parámetros a través de datos experimentales se realiza con la identificación de sistemas, existiendo una gran variedad de métodos especialmente para sistemas lineales. Sin embargo, la mayoría de procesos reales son no lineales y pueden ser aproximados tan solo localmente por modelos lineales [23, 24].

Ya que este tipo de aproximación representa el enfoque tradicional del modelado, existe una amplia bibliografía acerca de la teoría y aplicación de modelos mecánico. De entre ella podemos destacar los trabajos [17, 21, 25-27], por solo citar algunos. No obstante, en la mayoría de los casos, debido generalmente a limitaciones económicas y de tiempo, el desarrollo de un modelo mecánico no es factible en la práctica. Esto es particularmente cierto cuando el conocimiento del proceso es inicialmente vago o bien si el proceso es tan complejo que las ecuaciones resultantes no pueden ser resueltas.

Modelos Caja Negra

Otro enfoque del modelado asume que el proceso en estudio puede ser aproximado por una estructura de “caja negra” (del inglés *black-box*), que no es más que un *aproximador* de funciones como, por ejemplo, los tratados en [27] y [17]. En este caso, el problema del modelado se reduce a dar una estructura adecuada al *aproximador* para que capture correctamente la dinámica y la posible no linealidad del sistema. La identificación en este caso consiste en estimar los parámetros del modelo a través de datos experimentales [28].

Por tanto, los modelos caja negra se limitan a describir las relaciones entre las entradas y las salidas del sistema. Los parámetros obtenidos no tienen ningún significado físico en términos de equivalencia a parámetros del proceso tales como calor, coeficientes de transferencia de masa, cinética de reacción, etc. Tampoco la estructura del modelo aporta ningún significado. Estas son las principales desventajas de esta clase de modelos en comparación con los modelos de caja blanca. Sin embargo, si el único objetivo es representar fielmente sólo algunas de las tendencias en el comportamiento del proceso, entonces el enfoque de modelado caja negra resulta igual de eficaz. Además, el coste de la modelización es varios órdenes de magnitud menor que el asociado al desarrollo de modelos mecánicos [29]. Por contra, estos modelos no pueden usarse para analizar el comportamiento del sistema en otras condiciones de operación ya que no son escalables ni válidos para procesos similares. Por esta razón, su aplicación industrial puede llegar a ser menor que en el caso de modelos mecánicos.

Como se muestra en la Figura 2.1, los modelos de caja negra pueden ser clasificados en lineales y no lineales. En la categoría lineal, predomina el uso de funciones de transferencia y de modelos de series temporales. Trabajando con conjuntos de datos muestreados, esta delimitación es, en cierto sentido, arbitraria. El único factor que distingue ambos conjuntos es

que en los modelos de series temporales las variables se tratan como variables aleatorias. En ausencia de efectos aleatorios, la función de transferencia y los modelos de series temporales son equivalentes. En esencia, dado un conjunto de datos relevantes, se pueden utilizar una amplia variedad de técnicas para determinar los parámetros de los modelos lineales de caja negra [25]. Las técnicas más utilizadas son los algoritmos basados en mínimos cuadrados.

En la categoría no lineal, aparecen de nuevo los modelos de series temporales junto con los modelos basados en redes neuronales. En las series temporales no lineales, el comportamiento no lineal del proceso es modelado por las combinaciones de productos cruzados ponderados y cuadrados de las variables utilizadas en la representación. Los parámetros de las funciones siguen siendo lineales y, por tanto, facilitan la identificación mediante técnicas basadas en mínimos cuadrados. Por otra parte, las redes neuronales artificiales aparecieron desde sus orígenes como paradigmas de modelado de sistemas no lineales (ver Apartado 2.4). Desde sus comienzos a mediados de los años cuarenta, muchos han sido los trabajos de modelado utilizando las redes neuronales artificiales. Por solo citar algunos, se pueden destacar los trabajos [30-35].

Los trabajos [1, 26, 28, 29, 32-34, 36, 37] resumen buena parte de las técnicas utilizadas en el enfoque caja negra, tanto para procesos lineales como no lineales.

Modelos Cualitativos

Hay casos en los que la naturaleza del proceso puede impedir una descripción matemática del mismo. Por ejemplo, cuando en el proceso se opera a distintas regiones de operación o cuando existen límites físicos. Estas situaciones dan lugar a discontinuidades que no son susceptibles de modelarse matemáticamente. En esta serie de casos, la utilización de modelos cualitativos resulta una solución eficaz. La forma más simple de modelo cualitativo es el modelo basado en reglas que hace uso de los constructores *If-Then-Else* para describir el comportamiento del proceso. Estas reglas son obtenidas a través de operadores expertos. Alternativamente, el empleo de algoritmos de optimización (*e.g.*, algoritmos genéticos) o de técnicas de inducción puede utilizarse para el procesamiento de los datos y para la obtención de las reglas descriptivas más adecuadas [38] (ver Apartado 2.4). Algunas aproximaciones emplean también sofisticadas técnicas de Teoría de la Física Cualitativa y sus variantes [39, 40]. Estos últimos métodos pretenden corregir las desventajas de los modelos basados exclusivamente en reglas a través del empleo de algún tipo de álgebra, obteniendo así una mayor precisión.

De entre los distintos tipos de modelos cualitativos, las funciones de transferencia cualitativas [41] son un método para modelizar adecuadamente el proceso apuntando hacia posteriores diseños de sistemas de control. Este tipo de aproximación conserva muchas de las cualidades de las funciones de transferencia cuantitativas, las cuales describen la relación entre una variable de entrada y una de salida. En particular, conservan la capacidad para incorporar los aspectos temporales del comportamiento del proceso. Como ya se mencionó, esta técnica ha sido concebida para aplicaciones en el ámbito de control de procesos. Dentro de este marco, se construye un modelo para un pequeño subsistema y se conectan todos entre sí mediante un grafo dirigido. Cada nodo del gráfico representa una variable y los arcos que conectan los nodos describen la influencia o relación entre los nodos. En general, el comportamiento del sistema se obtiene recorriendo la gráfica de principio a fin.

Ciertamente, los modelos obtenidos a través del uso de la teoría de conjuntos borrosos también se pueden clasificar como modelos cualitativos. Propuesta por Zadeh a finales de los sesenta [42, 43], la teoría de conjuntos borrosos contiene un álgebra y un conjunto de lingüística que facilita la descripción de los sistemas complejos y con incertidumbre (ver Apartado 2.4). El modelo borroso combina, por tanto, elementos de los modelos basados en reglas, aproximaciones probabilísticas y conjuntos de símbolos. Hoy en día, los modelos borrosos se utilizan en la vida cotidiana sin que seamos conscientes de su presencia (lavadoras, cámaras de

enfoque automático, etc.). Por otra parte, es comúnmente aceptado el hecho de que estas aproximaciones se corresponden también con el enfoque de modelado “caja blanca”.

Dos revisiones interesantes acerca de la teoría y práctica de los modelos cualitativos son [44] y [45].

Modelos Estadísticos

La descripción del comportamiento de los procesos en términos estadísticos proporciona otra técnica de modelado. El enfoque estadístico se hace necesario por la incertidumbre existente en torno a algunos procesos. Las técnicas de modelado estadístico tienen sus raíces en el análisis de datos estadísticos, en la Teoría de la Información, la Teoría de Juegos y en la Teoría de los Sistemas de Decisión [46, 47].

Los modelos probabilísticos están basados en funciones de densidad de probabilidad de las variables. Una de las más comunes es la distribución normal, la cual proporciona información sobre la probabilidad de que una variable tome un determinado valor. Los modelos de correlación surgen por la cuantificación del grado de similitud entre dos variables mediante la observación de sus variaciones. Ésta es una técnica bastante popular y está implícita cuando las asociaciones entre variables se analizan mediante técnicas de regresión [48-50].

La dinámica de sistemas no es captada a través de las técnicas de modelado estadísticas. Sin embargo, en las prácticas de control moderno, los modelos estadísticos juegan un papel muy importante, en particular, para ayudar en la toma de decisiones de alto nivel, en la monitorización de procesos, en el análisis de datos y, obviamente, en el control estadístico de procesos [51].

De entre las distintas técnicas de modelado estadístico destacan los modelos ocultos de Markov [52-54] y las redes Bayesianas [55, 56].

Modelos Híbridos

A lo largo de los años, se han desarrollado una serie de técnicas de modelado que intentan combinar las ventajas de los enfoques de caja blanca y de caja negra, en las que las partes bien conocidas del sistema se modelan usando el conocimiento físico y las partes con incertidumbre se modelan con técnicas de caja negra. Estos enfoques son los llamados híbridos o de caja gris (del inglés *grey-box*).

Por ejemplo, algunas propuestas de identificación de sistemas no lineales se han desarrollado partiendo de estructuras simples como modelos de Hammerstein o de Wiener [57], consistiendo en bloques lineales dinámicos y no lineales estáticos habitualmente descritos por polinomios. Estas propuestas se han extendido a estructuras polinómicas más generales basadas en las series de Volterra o polinomios de Kolmogorov [26]. La tendencia que se ha seguido desde entonces es emplear redes neuronales o modelos borrosos, incrementándose así la universalidad de los modelos [58].

Otro enfoque muy interesante para el modelado de sistemas no lineales es el que recurre a su descomposición en un conjunto más o menos grande de submodelos con un rango de validez limitado [59], a los que podemos denominar modelos locales (ver Apartado 2.1.2). Cada uno de estos submodelos puede tener, a su vez, una estructura distinta (caja negra, caja blanca, caja gris) y el modelo global del sistema se obtendrá a través de la integración de los modelos locales.

Una de las tendencias actuales es integrar técnicas de modelado con técnicas de Inteligencia Artificial (ver Apartado 2.4), permitiendo así la incorporación de conocimiento humano en los modelos. Ejemplos de ello son el modelado borroso, el modelado a través de redes neuronales, o el modelado neuroborroso (ver Capítulo 3). La ventaja en la utilización de las dos últimas es que realizan un aprendizaje y adaptación imitando el funcionamiento de los sistemas neuronales biológicos a un nivel muy simplificado.

Lo cierto es que el empleo de técnicas “inteligentes” en general y de modelos neuroborrosos en particular, representa una alternativa para aquellas partes del modelo donde se vaya a emplear una caja negra (gracias a la propiedad de los sistemas borrosos de ser *aproximadores* universales de funciones [60]) y puede ayudar a una mejor comprensión del proceso por el paralelismo de estos modelos borrosos con los procesos de razonamiento humano. De este modo se consigue que el modelo de caja negra se acerque a un modelo de caja gris [61].

Tal y como se ha mencionado, el modelado neuroborroso ha sido ampliamente estudiado en esta Tesis, mientras que el resto de modelos híbridos están fuera del alcance de este trabajo. Únicamente mencionaremos los trabajos [62-67], en los cuales pueden encontrarse distintas aproximaciones de sistemas para el modelado híbrido.

2.1.2. Modelado por Modelos Locales

Dentro de cada una de las clasificaciones anteriores, nos podemos encontrar con otra subclasificación que se correspondería con dos distintos enfoques: las técnicas de modelado para la obtención de un modelo general (global) y las técnicas de modelado para obtener modelos locales. La idea del modelo global es la que se ha venido exponiendo en el apartado anterior. Pasamos a continuación a detallar las singularidades del modelado local.

La estrategia que propone el modelado (y control) basado en modelos locales [59] consiste en dividir un sistema complejo en subsistemas más sencillos que puedan ser analizados de forma individual. La clave, por tanto, consiste en la elección de aquellos parámetros adecuados que permitan realizar dicha partición. Esta partición se puede realizar, si es posible, en base a diferentes criterios [68]:

- Descomposición basada en componentes físicos, en donde el problema complejo se descompone en sus componentes y el problema de modelado se resuelve uniendo las partes del sistema.
- Descomposición basada en fenómenos relevantes, cuando el modelo global se obtiene por la descripción que las leyes físicas dan del comportamiento del sistema (por ejemplo, en un sistema termoeléctrico se separa el modelado de la parte eléctrica y la térmica).
- Descomposición basada en objetivos, ya que un sistema complejo suele deber satisfacer numerosos requisitos.
- Descomposición basada en expansión en series, que es la base de la identificación por caja negra y donde se supone la existencia de una relación funcional entre las variables del sistema.

Por otra parte, se hace necesario un elemento supervisor que sea de algún modo capaz de integrar de nuevo todos estos subsistemas en un sistema global. Si se eligen modelos lineales como modelos locales (todos ellos con la misma estructura, manteniéndose así las variables de estado), la integración de todos ellos nos lleva a un modelo lineal de parámetros variables LPV (*linear parameter-varying*), los cuales son la base de las técnicas clásicas para el desarrollo de controladores por planificación de ganancia y que se revisan, por ejemplo, en [69-71].

La idea de utilizar modelos precisos a nivel local se describe primeramente en la literatura estadística [72], donde los modelos locales lineales o cuadráticos son ponderados por funciones de suavizado. Más adelante, en el trabajo de Atkenson [73], se hace una revisión de la literatura de aprendizaje local hasta el año 1990, con ejemplos de trabajos estadísticos que se remontan al año 1912. Posteriormente, dos de los principales investigadores del enfoque de modelado por modelos locales son Johansen y Foss, los cuales en la década de los noventa aplicaron modelos locales en ciertos sistemas de monitorización y control [74-77]. También se describe el uso de modelos dinámicos locales para tareas de modelado y control en [78], utilizando funciones

definidas por intervalos según los rangos de operación. Los métodos de Takagi y Sugeno [79] para sistemas borrosos son también modelos con funciones definidas por intervalos, con interpolación borrosa entre modelos proporcionadas por las funciones de pertenencia. Aplicaciones similares también se reflejan en [80-83] y [77].

Como se puede observar, la idea de utilizar modelos locales tiene generalmente, como último objetivo, el control del proceso objeto de estudio. En el campo de las redes neuronales utilizadas para el control se han producido interesantes resultados mediante la utilización de modelos locales. Prueba de ello son los trabajos [84-87].

En cuestión de revisiones y discusiones acerca del uso de modelos locales, destaca el trabajo [88], en el que se sugiere una utilización adecuada de los métodos locales y globales.

2.2. Técnicas de Control

El control de sistemas en general, y el de procesos industriales en particular, constituyen un área de trabajo que no ha dejado de evolucionar en los últimos 50 años. A lo largo de esta evolución, muchas han sido las estrategias y técnicas desarrolladas, aceptándose a día de hoy por muchos autores la existencia de tres grandes grupos de técnicas de control: las técnicas de control clásicas o convencionales (1940-1960), las técnicas de control avanzadas o control moderno (1960-1980) y el denominado control inteligente (1980-actualidad). La Tabla 2.1 engloba de forma general las principales técnicas existentes en cada grupo.

Tabla 2.1. Técnicas de control más utilizadas

<i>Control Convencional</i>	<i>Control Avanzado</i>	<i>Control Inteligente</i>
<ul style="list-style-type: none"> - PID - Autómatas -Redes de Petri - Etc. 	<ul style="list-style-type: none"> - Control Adaptativo - Control Robusto - Control Óptimo - Control Predictivo - Control Basado en Eventos - Etc. 	<ul style="list-style-type: none"> - Control Neuronal - Control Borroso - Sistemas Expertos - Control con Aprendizaje - Algoritmos Genéticos para ajuste de Controladores - Etc.

Los controladores basados en técnicas "clásicas" llevan mucho tiempo funcionando en la industria, lo que constituye una prueba evidente de su capacidad y fiabilidad. Ejemplos de las técnicas de control "clásicas" más usuales son el control PID en sus diversas formas (ajuste manual o automático), sistemas de adelanto-atraso (*Lead-Lag*) por asignación de polos y ceros, control digital discreto (autómatas programables), entre otros.

En general, estas estrategias pueden denominarse de "parámetros óptimos" ya que, partiendo de una estructura algorítmica fija, se modifican sus parámetros con el objeto de lograr la respuesta del proceso que mejor cumpla con las especificaciones del mismo, conforme a un criterio de optimización fácil de entender y manejar por un operador de planta. Esta forma de operar tiene, entre sus ventajas principales, que puede ser fácilmente implantada con circuitos electrónicos analógicos y/o digitales, pudiendo construirse controladores PID en aparatos compactos y comercializarse individualmente como tal.

Asimismo, la simpleza de la programación de un algoritmo PID digital ha posibilitado que la mayor parte de las empresas fabricantes de equipos de automatización (autómatas programables, sistemas de adquisición de datos o sistemas de control distribuido) incorporen módulos de control PID dentro de sus productos. Por lo general, este tipo de control presenta

buenas condiciones de desempeño para la mayoría de los procesos industriales tradicionales, lo que prácticamente asegura su permanencia en el tiempo.

La literatura existente sobre técnicas de control clásico es amplia y extensa, por lo que solo destacaremos aquí algunos trabajos [89-92] por su alta trascendencia. Sin embargo, estas técnicas, en las que a menudo es necesario disponer de un modelo preciso del proceso a controlar para diseñar el controlador, muestran sus limitaciones cuando se abordan problemas de control con determinadas características frecuentes en los procesos industriales. Entre ellas destacan la imprecisión del modelo disponible, ya sea por motivos de incertidumbre o de complejidad, el incumplimiento de ciertas premisas impuestas por las técnicas "clásicas" de diseño de controladores, como la linealidad, y muy habitualmente la variación en el tiempo de la dinámica del proceso.

Posteriormente, se han venido desarrollando diferentes técnicas capaces de afrontar este tipo de problemas. Muchas de ellas se podrían considerar ya técnicas clásicas también, puesto que llevan tiempo dando buenos resultados en la industria, aunque aquí las clasificamos como control avanzado o control moderno. Por tanto, cuando se hace referencia a control avanzado se quiere indicar la aplicación de estrategias de control automático que trascienden las que usualmente se aplicaban en control de procesos hasta los años sesenta y que requieren aplicar técnicas de control avanzadas para alcanzar las prestaciones deseadas. Cabe destacar los métodos de control no lineal, el control óptimo, el control robusto y el control adaptativo, capaces de solucionar parte de los problemas planteados, y con ciertas limitaciones en su utilización (ver apartado 2.2.1).

Sin embargo, la complejidad de los sistemas a controlar es cada vez mayor, las especificaciones de diseño impuestas al comportamiento del sistema de control son más exigentes, el conocimiento previo de la planta y su entorno es cada vez más impreciso, y el grado de incertidumbre es cada vez mayor. Estas circunstancias llevaron a un replanteamiento de las técnicas de control existentes hasta la década de los ochenta y a la aparición de otras, nuevas en este campo, que podrían enmarcarse dentro del llamado control inteligente.

Sin entrar en la polémica de las características que debe o no presentar un controlador inteligente, lo que es indiscutible es la necesidad de un alto grado de autonomía en los controladores que vayan a enfrentarse a procesos complejos, y esto significa que hay que dotar a los controladores de la facultad de adaptarse sobre la marcha y, sobretodo, de la capacidad de aprender y de nutrirse de la experiencia de operadores expertos.

Entre las técnicas que se han situado habitualmente en el campo del control inteligente encontramos los sistemas expertos, el control borroso, el control basado en algoritmos genéticos y las redes neuronales. Los dos primeros no presentan en sí las características de autonomía y capacidad de aprendizaje citadas, aunque últimamente las técnicas de control borroso se han combinado con las redes neuronales o los algoritmos genéticos para diseñar controladores híbridos que sí tienen estas características (ver Apartado 2.4 y Capítulo 3).

Ciertamente, tanto la mayor parte de las técnicas de control avanzado como algunas de las técnicas de control inteligente (algunas incluso hibridan técnicas avanzadas con técnicas de Inteligencia Artificial) requieren de una representación (modelo) de los sistemas a controlar. Por ello se consideran técnicas de control basadas en modelos y se resumen a continuación. Las técnicas clásicas se encuentran, en su mayoría, basadas en modelos pero quedan fuera del ámbito de esta revisión.

2.2.1. Técnicas de Control Basadas en Modelos

El objetivo de las técnicas de control basadas en modelos es incorporar conocimiento sobre el proceso al método de cálculo de la señal de control. Al igual que las técnicas de modelado, las técnicas de control basadas en modelo también dependen de la utilización de modelos

matemáticos (conocimiento analítico), de un conjunto de reglas (conocimiento experto heurístico), de modelos caja negra, etc.

En general, todas las técnicas de control basadas en modelos están sustentadas en un conocimiento más o menos acabado del sistema a controlar (tanto de su fenomenología como de sus condiciones de operación) a través de un modelo matemático que lo describa en forma bastante aproximada, en todo su rango de operación y para cualquier instante de tiempo. Este modelo se usa tanto como parte integrante del sistema de control, como para evaluar el desempeño del sistema a través de técnicas de simulación. Por lo general, ninguna de estas técnicas de control pueden considerarse de “parámetros optimizados” sino que responden más bien a estrategias de “estructura optimizada”, ya que su estructura depende del sistema particular a controlar.

A continuación, se hace referencia a las técnicas de control basadas en modelo más relevantes, partiendo de aquellas que han cruzado al umbral de la aplicación industrial con excelentes resultados [93]. Las técnicas de control basadas en modelo que utilizan técnicas de Inteligencia Artificial se mostrarán en apartados posteriores (ver Apartado 2.4).

Control Óptimo/Predictivo

Este control se basa en la definición de una función que, por lo general, incluye el error de control y la acción de control y/o sus desviaciones, con ponderaciones que permiten “pesar” en forma relativa cada una de ellas, estableciendo un criterio de optimización sobre dicha función que se ajuste a los objetivos del control. Además, pueden incluirse también las restricciones de la misma (rangos de operación de variables, de las acciones de control y del sistema), produciendo una acción de control óptima según el criterio establecido, sujeta a las restricciones presentes en el proceso. Este último aspecto es su principal fortaleza frente a controladores convencionales como el PID. Una definición del tema más extensa se encuentra en [94].

El mejor representante de este tipo de control, por la gran aceptación que ha tenido en el campo del control de procesos, es el Control Predictivo basado en Modelo (*Model Predictive Control*). El sistema utiliza un modelo matemático del proceso para predecir el comportamiento del sistema en el futuro frente a posibles acciones de control a aplicar (puede verse mayor información en el Capítulo 3). Se define un “horizonte de predicción” (tiempo sobre el cual se evalúan las posibles respuestas del sistema) y un “horizonte de control” (tiempo sobre el que las acciones de control pueden variar y después del cual se mantienen constantes). Se determina la acción de control óptima a aplicar al sistema para lograr la respuesta deseada del sistema dentro del horizonte de predicción previsto, tanto para la acción de control en el instante presente como en los futuros instantes de muestreo. A pesar de definirse varias acciones de control (actual y futuras) solamente se aplica la actual, ya que en el próximo intervalo de control se vuelve a repetir el mismo cálculo. El sistema más difundido es el que usa un modelo lineal para el sistema (*Linear Model Predictive Control*), tanto por la facilidad de implantación como por la posibilidad de ajustar el modelo en distintos instantes del proceso usando cualquiera de los métodos de identificación de sistemas conocidos. La teoría y aplicaciones industriales de esta técnica de control pueden encontrarse en [95-97].

Control Robusto

Consiste en definir una estructura de control que tenga un desempeño acorde a las especificaciones del sistema, independientemente de las perturbaciones a las que esté expuesto. A nivel académico, los mayores desarrollos en torno a este tema tienen relación con el Control Óptimo H_∞ [98]. Sin embargo, otro buen ejemplo que sí ha sido aplicado a nivel industrial es el Control por Modelo Interno (*Internal Model Control*) [99, 100]. Este sistema de control también ha tenido buena aceptación industrial, debido a que el controlador resultante puede asimilarse a un control PID (puede verse mayor información en el Capítulo 3). Tal como en el Control Predictivo basado en Modelo, este control incorpora un modelo matemático de la planta, pero en

este caso se usa para compensar la dinámica modelable y no modelable de planta. Aunque las acciones de control que pueden lograrse con sistemas de control robusto son más cautelosas que las que resultan de otros sistemas, con un buen ajuste del controlador se pueden lograr sistemas que cumplan ambas prestaciones [101, 102].

Control Adaptivo, Adaptativo o Adaptable (*Adaptive Control*)

Este sistema de control es apropiado para sistemas que sean variantes en el tiempo. Aunque dentro de esta categoría podrían colocarse los “PID autoajustables”, el concepto es mucho más amplio, ya que suelen incorporar técnicas de identificación de parámetros por mínimos cuadrados u otras técnicas. Una de las estrategias de control más conocidas dentro de este tipo de control es el Control Adaptativo por Modelo de Referencia (*Reference Model Adaptive Control*) [103].

Se define un modelo con una dinámica como la que se desea que tenga el sistema (puede verse mayor información en el Capítulo 3). El objetivo del sistema de control es disponer de un sistema de lazo cerrado cuyos parámetros puedan ajustarse para establecer el tipo deseado de respuesta del sistema (la que se tendría si el sistema fuese igual al modelo de referencia) [104].

Por otra parte, si se desea explotar el sentido físico de los modelos lineales como linealizaciones del proceso, se pueden emplear las mismas técnicas de control que se basan en representar sistemas no lineales por un modelo linealizado que lo aproxime y diseñar un controlador para él. La restricción de que dicho modelo solo puede hacer una representación local del comportamiento del sistema, tradicionalmente se elimina diseñando diferentes controladores para diferentes modelos lineales en diferentes puntos de operación e interpolando estos controladores, con lo que se llega a un controlador no lineal global. A grandes rasgos, esto es lo que se conoce como control por planificación de ganancia.

La planificación de ganancia es una de las técnicas más habituales para el control de procesos no lineales y ha sido empleada satisfactoriamente desde hace años [105, 106] en aplicaciones que van desde la ingeniería aeroespacial al control de procesos. Sin embargo, hasta los años noventa es raro encontrar un tratamiento teórico de la planificación de ganancia [69-71]. Algunas revisiones interesantes sobre este tipo de técnica se encuentran también en [107, 108].

Control basado en Modelos Locales

Aunque no se trata de una técnica de control basada en modelos como tal, sino que en este apartado caben perfectamente las técnicas mostradas anteriormente, existen algunos trabajos de control destacables en este campo.

Una de las opciones más utilizadas para el desarrollo de controladores basados en modelos locales [109, 110] es la que emplea la resolución de “LMIs” (*Linear Matrix Inequalities*). Esta técnica tiene la ventaja de asegurar la estabilidad del sistema [111] independientemente de la idoneidad de las linealizaciones, pero da resultados muy conservadores que pueden llevar a que un conjunto de controladores apropiados no satisfagan las condiciones de estabilidad. Además, convierten el problema del diseño del control en una resolución matemática de ecuaciones, con lo que el Ingeniero de Control pierde la capacidad de emplear su conocimiento de experto para mejorar el comportamiento de los controladores locales así diseñados.

Otras aproximaciones muy interesantes que combinan sistemas de control adaptativos y sistemas de control robusto con modelos locales son las propuestas de K.S. Narendra en [81, 83] y C.G. Atkeson en [112].

2.3. Técnicas de Monitorización

Actualmente, según la complejidad del proceso de estudio, se puede combinar el sistema de control diseñado con un sistema de monitorización, o bien, se puede únicamente implantar un sistema de monitorización cuando el control del proceso no sea posible por las especificaciones técnicas y/o las restricciones económicas. Los sistemas de monitorización permiten un diálogo con el operador humano por medio de representaciones gráficas, números y símbolos ofreciendo información relativa al estado del proceso o máquina en tiempo real. Sin embargo, la tendencia actual muestra la necesidad de introducir aspectos que no son únicamente cuantitativos, o que están expresados en forma simbólica. Esta necesidad aparece a causa de la dificultad de tratar numéricamente la complejidad y la incertidumbre que acompañan al proceso objeto de estudio [113, 114].

Lógicamente, cualquier sistema de monitorización depende en gran medida de la habilidad para conocer el estado real de funcionamiento del proceso, bien en su operación normal, o bien en su funcionamiento degradado debido a la aparición de fallos o cambios de estado interno. Ciertamente, el único modo de obtener dicha información es a través de sensores. Hoy en día, una gran parte de los sistemas de monitorización se basan en la fusión sensorial, la cual representa una estrategia de integración de una variedad de sensores con la expectativa de aumentar la precisión y eliminar ambigüedades sobre el conocimiento del entorno [115]. Existe únicamente una tendencia distinta a la obtención de información a través de sensores, y es la técnica denominada monitorización sin sensor o *sensorless*. El principio de este tipo de técnica se basa en la obtención de información a través de las señales internas de las máquinas (potencia, posición, par, etc.) [116, 117].

Independientemente del modo de obtención de información en el sistema de monitorización, se necesita traducir las señales obtenidas (vía sensores o señales internas) en información útil para la representación del estado del proceso. Este procesamiento de la señal se puede llevar a cabo a través de métodos directos y métodos indirectos [118]. Los métodos directos miden los valores reales de las variables objeto de estudio, mientras que los métodos indirectos miden variables del proceso que se correlacionan con las variables objeto de estudio.

Bien sea por métodos directos o indirectos, el sistema de monitorización debe extraer conclusiones a través de un modelo matemático o empírico del problema a estudiar. Por ello, de todas las estrategias disponibles para la monitorización de los procesos industriales, los métodos basados en modelos se consideran unos de los más usados [119]. La comparación entre la respuesta del proceso real con la estimación realizada por el modelo del proceso y la generación de los correspondientes residuos constituyen el sustento de estos métodos.

La monitorización basada en modelo tiene muchas ventajas sobre el resto de los métodos. Primeramente, las salidas son comparadas con los valores esperados en base a las condiciones reales del proceso. Esto significa que los umbrales de detección se pueden fijar más cercanos a la realidad del proceso en cuestión, y la probabilidad de identificar errores o fallos en el proceso en una etapa temprana se incrementa substancialmente. Además, un simple fallo a menudo se propaga a más de una variable y causa que sea necesario algo más que verificar la activación de un valor límite (superación de un umbral). Es difícil aislar los fallos en tales situaciones sin la disponibilidad de modelos matemáticos. Asimismo, el uso de un modelo permite una insensibilidad del sistema de monitorización ante las perturbaciones no medidas. La desventaja principal del enfoque basado en modelos es, sin embargo, el incremento de la complejidad del esquema de tomas de decisiones y la necesidad de un modelo matemático [120, 121].

Por tanto, la problemática en este caso sigue estando relacionada con la obtención de modelos del proceso y, por ende, con todo lo visto anteriormente en relación a las técnicas de modelado (mecánico, caja negra, etc.).

2.4. Técnicas de Inteligencia Artificial en el Modelado, la Monitorización y el Control de Procesos

La línea de investigación en Control Inteligente (que también abarca el modelado y la monitorización de procesos) nace hace cuatro décadas, alrededor del año 1975, con la intención de aplicar a los sistemas de monitorización y control las técnicas de Inteligencia Artificial, las cuales comenzaban a despuntar por las posibilidades que ofrecían para incorporar el conocimiento de operadores expertos (ver Capítulo 3).

El empleo de técnicas de Inteligencia Artificial en el modelado, la monitorización y el control ha sido consecuencia, en buena medida, de que las técnicas clásicas y avanzadas no han producido en algunos casos los resultados deseados y se han mostrado efectivas sólo en las condiciones teóricas de diseño. Generalmente, las prestaciones que nos ofrece el uso de técnicas clásicas y avanzadas se deterioran considerablemente en presencia de incertidumbre y de no linealidades. Por contra, las técnicas de Inteligencia Artificial poseen teóricamente la capacidad o habilidad para actuar de forma apropiada en presencia de incertidumbre, imprecisión, variación en el tiempo, etc. Por ello, los sistemas de modelado, monitorización y control han aprovechado las posibilidades que nos ofrecen esta clase de técnicas. Algunos de los resultados más destacables en la utilización de técnicas de Inteligencia Artificial para aplicaciones de modelado, monitorización y control se resumen en la Tabla 2.2. A continuación se hace una pequeña descripción de las técnicas más empleadas y de las que mejores resultados han aportado en este tipo de aplicaciones.

Tabla 2.2. Técnicas de Inteligencia Artificial en aplicaciones de modelado, monitorización y control

Técnicas	<i>Modelado</i>	<i>Monitorización</i>	<i>Control</i>
Inteligencia Artificial Convencional (Sist. Expertos, Sist. basados en Reglas, etc.)	[51, 122]	[51, 123]	[122, 124]
Redes Neuronales	[34, 125-127]	[118, 128, 129]	[31, 84, 130, 131]
Lógica Borrosa	[20, 77, 79, 132-134]	[135, 136]	[20, 79, 137-141]
Computación Evolutiva	[142, 143]	[135, 144]	[142, 145, 146]
Swarm Intelligence	[147, 148]	[149, 150]	[151, 152]
Sistemas Inmunes Artificiales	[153, 154]	[155, 156]	[157-159]

Razonamiento basado en Casos

La técnica de razonamiento basado en casos es una técnica perteneciente al grupo de los Sistemas Expertos dentro de la Inteligencia Artificial Convencional (consultar Capítulo 3). Su principio se basa en la resolución de un problema a través de los recuerdos que posee de problemas anteriores que son similares, asumiendo que ambos tienen soluciones similares. El razonamiento basado en casos necesita, por tanto, numerosos casos anteriores para adaptar sus soluciones o métodos al nuevo problema. Esta técnica reconoce que los problemas son más fáciles de resolver gracias a los repetidos intentos que posee, procedentes de su aprendizaje [160].

El razonamiento basado en casos generalmente realiza cuatro pasos básicos: recuperar los casos anteriores más relevantes de la base de datos, utilizar el caso recuperado para proporcionar una solución al nuevo problema, revisar la solución propuesta mediante simulación y/o ejecución de prueba y, finalmente, guardado de la solución para un uso futuro si ha resultado una adaptación exitosa.

El proceso de recuperación puede reconocer sintácticamente (estructura gramatical) o semánticamente (significado) la similitud con el nuevo caso. Las búsquedas sintácticas de acuerdo al contexto son utilizadas por técnicas avanzadas de razonamientos basados en casos. Los principales métodos de recuperación son: los métodos de vecinos más próximos, los métodos inductivos y las búsquedas basadas en conocimiento [160].

La recuperación a través de métodos de vecinos más próximos encuentra los casos pasados que comparten la mayoría de las características con el nuevo caso, ponderando éstos según su importancia. Precisamente la determinación de esta importancia (búsqueda del peso) es la mayor dificultad de estas técnicas [161]. Sin embargo, este método obvia las relaciones entre características. Por el contrario, los métodos inductivos deciden qué características discriminan mejor los casos [161]. Sin embargo, el método exige una base de datos de un tamaño razonable y de calidad. Las búsquedas basadas en conocimiento aplican conocimientos existentes para identificar las características más importantes en cada caso, evaluando todos los casos de forma independiente. Es un método computacionalmente muy pesado para grandes bases de datos y por tanto, poco utilizado en la práctica.

Después de la recuperación, el razonamiento basado en casos adapta las soluciones del pasado al nuevo problema. Esta adaptación puede ser de carácter estructural o derivacional [161]. Las adaptaciones estructurales ofrecen una solución al problema a través de la modificación de soluciones de casos pasados. Por su parte, la adaptación derivacional aplica algoritmos, métodos o reglas utilizadas en casos pasados al nuevo caso.

Sistemas basados en Reglas

Los sistemas basados en reglas pertenecen, al igual que el razonamiento basado en casos, a la rama de la Inteligencia Artificial Convencional (ver Capítulo 3). Estos sistemas resuelven problemas a través de la aplicación de reglas obtenidas a partir del conocimiento experto [122]. Las reglas contienen antecedentes y consecuentes, alimentándose a través de un motor de inferencia. Este último posee cierta memoria acerca de información ocurrida en el pasado, un buscador de patrones y un ejecutor de reglas. El patrón de búsqueda rastrea la información almacenada en la memoria para decidir cuáles son las reglas adecuadas y, posteriormente, el ejecutor de reglas decide qué norma aplicar. La nueva información creada por la nueva acción se agrega a la información almacenada (memoria). El ciclo de búsqueda-selección-ejecución entre el problema a resolver y la base de conocimiento se repite hasta que no se encuentren normas más relevantes [122].

Los hechos a manejar y las reglas a utilizar son imprecisos. Por tanto, se suelen incorporar técnicas de manejo de incertidumbre a los sistemas basados en reglas como, por ejemplo, enfoques de probabilidad subjetiva, teoría de Dempster-Shafer, teorías posibilísticas, métodos Bayesianos, enfoques cualitativos, etc. [122, 162]. Estas técnicas son capaces de incorporar valores de incertidumbre (probabilidad, confianza, pertenencia) a los hechos y a las reglas, gracias al conocimiento humano.

Existen dos sistemas de reglas según el encadenamiento de las mismas, los sistemas de razonamiento hacia adelante y los de razonamiento hacia atrás [167]. Los sistemas basados en reglas de encadenamiento o propagación hacia adelante valoran los hechos iniciales para extraer conclusiones a partir de las reglas. Por el contrario, los sistemas de reglas con encadenamiento o propagación hacia atrás parten de una hipótesis, obteniendo posteriormente las reglas que la hagan sostenible. Es otras palabras, el encadenamiento hacia adelante descubre lo que puede

deducirse de los datos, mientras que el encadenamiento hacia atrás busca la justificación de las decisiones [163].

Redes Neuronales Artificiales

Las Redes Neuronales Artificiales son estructuras matemáticas que procuran representar la información en forma similar a como se estructura en nuestro cerebro. Inspirados por los sistemas nerviosos biológicos, muchos investigadores, especialmente los relacionados con la neurociencia y las ciencias de la computación, han estado explorando las redes neuronales artificiales creando, a día de hoy, un sistema poderosísimo de procesamiento de información no algorítmico.

El objetivo del uso de redes neuronales es disponer de un sistema que se comporte como una “caja negra” pudiendo emular el comportamiento de un sistema. A través de estas arquitecturas conexionistas se espera imitar los mecanismos del cerebro para simular el comportamiento inteligente. Para ello, se requiere de una etapa de entrenamiento (donde se ingresa información disponible del sistema procurando que la red aprenda lo que se le quiere enseñar) y una de validación (donde se contrasta el aprendizaje de la red con otros datos disponibles del sistema que no se utilizan para el entrenamiento). Cuando la red ha aprendido, se la puede utilizar tal como si se operara con el sistema real.

Incorporando la información deseada al aprendizaje de la red, podría lograrse que el sistema emule tales condiciones. La utilización de las redes neuronales requiere que el proceso de entrenamiento incluya todo el espectro posible de situaciones a las que podría estar expuesto el sistema, ya que si se llegase presentar una condición que no fue considerada durante la etapa de entrenamiento, no puede asegurarse que el sistema responda en la forma esperada. Por tanto, la parte más crítica es la selección de datos adecuados para el entrenamiento de la red. Hoy en día, en esta etapa se pueden encontrar redes neuronales combinadas con otras técnicas, como es el caso de los sistemas neuroborrosos (ver Capítulo 3), los cuales emplean lógica borrosa para poder establecer la selección de datos a utilizar en el entrenamiento.

La bibliografía acerca de redes neuronales es muy amplia y extensa, por la que solamente se mencionan aquí los trabajos [130, 131, 164-167] por ser algunos de los más representativos. La revisión extensa de este campo está fuera de los objetivos de esta Tesis Doctoral.

Lógica Borrosa

El cerebro humano interpreta la información sensorial imprecisa e incompleta facilitada por los órganos perceptivos. La teoría de conjuntos borrosos proporciona un cálculo sistemático para hacer frente a dicha información lingüística, y realiza cálculos numéricos mediante el uso de etiquetas lingüísticas establecidas por funciones de pertenencia. Por otra parte, una selección de reglas borrosas “*if-then*” constituyen el componente clave del sistema de inferencia borroso (*Fuzzy Inference System*), que efectivamente puede modelizar la experiencia humana en una aplicación específica.

Aunque los sistemas de inferencia borrosos tienen una representación del conocimiento estructurado en forma de reglas borrosas, carecen de la capacidad de adaptación para hacer frente a los cambios del entorno externo. Por lo tanto, a lo largo de su historia se han incorporado mecanismos adaptativos u otra serie de técnicas, como por ejemplo las redes neuronales. La incorporación de esta últimas da lugar a los sistemas neuroborrosos (ver Capítulo 3).

Quizás la información aportada en este apartado no sea muy extensa, pero se ha resumido ya que se van a tratar en el Capítulo 3 conceptos de la lógica borrosa y de los sistemas borrosos en general. No obstante, la bibliografía en el campo de la lógica borrosa también es muy extensa, destacando en este apartado la importancia de los trabajos [42, 79, 80, 134, 139-141, 168-175]. Nuevamente, la revisión extensa de este campo está fuera del ámbito de esta Tesis.

Computación Evolutiva

La inteligencia natural es el producto de millones de años de evolución biológica. Del mismo modo, la simulación de complejos procesos de evolución biológica puede llevarnos a descubrir cómo la evolución impulsa a los sistemas vivos hacia un nivel de inteligencia mayor. Por esta razón, los últimos años se han caracterizado por un gran interés en el estudio de las técnicas de computación evolutiva como, por ejemplo, los algoritmos genéticos. Éstos se basan en el principio de selección natural. El modelado de sistemas inmunes y vida artificial son disciplinas similares y ambas se basan en la suposición de que las leyes físicas y químicas son capaces de explicar la vida inteligente. En particular, la vida artificial es un paradigma integrador que trata de recrear comportamientos inteligentes imitando los procesos que ocurren en el desarrollo y/o la mecánica de la vida [176].

Las técnicas de búsqueda de información heurística se emplean en muchas aplicaciones de Inteligencia Artificial. Cuando un espacio de búsqueda es demasiado grande para una búsqueda exhaustiva y es difícil identificar el conocimiento que se pueden aplicar (para reducir el espacio de búsqueda), no tenemos más remedio que utilizar otras técnicas de búsqueda más eficientes para encontrar soluciones cercanas a la óptima. El método de algoritmos genéticos es una técnica candidata para este fin, ya que ofrece la capacidad de búsquedas aleatorias sistemáticas basadas en poblaciones. El temple simulado y la búsqueda aleatoria son otros de los candidatos que exploran el espacio de búsqueda de forma estocástica. Los métodos de optimización utilizados en computación evolutiva se discuten en [177-181].

Swarm Intelligence (Inteligencia de Enjambre)

La inteligencia de enjambre o *swarm intelligence* es una forma de modelado basada en agentes e inspirada en las colonias de animales sociales como las hormigas, las abejas o los bancos de peces [147]. Mientras que los agentes individuales son simples, actuando como un enjambre exhiben una inteligencia superior. La auto-organización es un elemento clave ya que a través de la cual los patrones globales surgen de las interacciones locales, sin necesidad de un control centralizado o de un modelo global. Estas interacciones pueden ocurrir a través de comunicación directa (agente a agente) o indirecta (a través del medio ambiente).

Por ejemplo, el comportamiento de las hormigas es la base del algoritmo de optimización de colonia de hormigas (*Ant Colony Optimization*), el cual es uno de los principales algoritmos de la inteligencia de enjambre. Las hormigas aisladas se mueven al azar hasta que encuentran un rastro de feromonas, los cuales son propensos a seguir y posteriormente reforzar con sus propias feromonas. Las hormigas tienden a elegir caminos con concentraciones de feromona más fuertes, lo que resulta en el comportamiento auto-catalizador: cuanto más tráfico recibe un sendero, más atractivo se convierte [148]. Los caminos más cortos entre destinos requieren menos tiempo de tránsito y se convierten en dominantes, ya que se refuerzan con más feromona. A través de un comportamiento auto-catalizador, todas las hormigas finalmente eligen el camino más corto [148]. La descomposición de feromonas en el tiempo conduce al azar o a recorridos menos transitados (más largos) conduciendo a concentraciones próximas a cero, de forma análoga a la pérdida gradual de la memoria.

Otro algoritmo de optimización perteneciente a la inteligencia de enjambre está inspirado en la sincronía de las bandadas de aves y de peces. Se denomina optimización por enjambre de partículas (*Particle Swarm Optimisation*). La idea es que el sistema se inicializa con una población al azar de posibles soluciones o partículas, las cuales "vuelan" a través del espacio del problema N-dimensional [182], en el que cada solución es un punto. En cada iteración, las partículas evalúan su adecuación (posiciones respecto a la meta) y comparten los recuerdos de sus mejores puestos en el enjambre.

Algunas revisiones interesantes en las técnicas de inteligencia de enjambre se pueden encontrar en [183-185].

Sistemas Inmunes Artificiales

Tal y como se ha mencionado anteriormente, los sistemas bio-inspirados han llamado durante la última década la atención de muchos investigadores. Entre algunos de los sistemas bio-inspirados se encuentran los sistemas inmunes, sistemas muy complejos con varios mecanismos de defensa contra organismos patógenos. El principal propósito de los sistemas inmunes es reconocer a todas las células dentro del cuerpo y categorizarlas con el objeto de inducir un mecanismo de defensa apropiado. El sistema inmune aprende a través de la evolución para poder distinguir entre los antígenos externos peligrosos (por ejemplo, bacterias, virus, etc.) de las células propias del cuerpo.

Los sistemas inmunes tienen varias propiedades atractivas desde el punto de vista computacional ya que es difícil encontrar otro sistema biológico que reúna tantas características poderosas y diversas. Algunas de ellas son: reconocimiento de patrones, unicidad, auto-identificación, diversidad, ninguna célula es indispensable para el funcionamiento del sistema inmune, autonomía, múltiples capas de diferentes mecanismos actúan en forma cooperativa, detección de anomalías, tolerancia a las fallos, sistema distribuido, robustez, aprendizaje y memoria, auto-organización e integración con otros sistemas. Estas características junto con un buen conocimiento de cómo trabaja el sistema inmune, son excelentes motivaciones para desarrollar un sistema inmune artificial.

Algunos de los modelos basados en principios de sistemas inmunes, tales como la Teoría de la Selección Clonal [186], el Modelo de Red Inmune, o el Algoritmo de Selección Negativa han incrementado sus aplicaciones en el campo de la ciencia e ingeniería [186], en aplicaciones tales como: seguridad, detección de virus, monitorización de procesos, reconocimiento de patrones, optimización numérica, etc.

Algunas revisiones interesantes acerca de los sistemas inmunes artificiales son [153, 187, 188].

Sistemas Híbridos

Los sistemas híbridos combinan dos o más técnicas de Inteligencia Artificial para beneficiarse de las fortalezas de cada una y superar asimismo las deficiencias individuales. Existen tres tipos principales de sistemas híbridos de acuerdo a cómo se combinan las técnicas: secuenciales, auxiliares e integrados (embebidos). En un sistema híbrido secuencial, el primer paradigma pasa su salida a la segunda técnica para generar la salida. En un sistema híbrido auxiliar, el primer paradigma obtiene alguna información de la segunda técnica para generar la salida. En sistema un híbrido integrado, los dos paradigmas están contenidos unos dentro de otros.

El más común de todos los sistemas híbridos es el sistemas neuroborroso, que combina redes neuronales y sistemas borrosos (ver Capítulo 3). Los sistemas neuroborrosos son rápidos, eficientes y de fácil diseño, implementación y entendimiento [49]. El resto de sistemas híbridos están fuera del alcance de este trabajo. Algunos de ellos pueden encontrarse en [189, 190]. A continuación se hace una revisión al estado del arte en sistemas neuroborrosos.

2.4.1. Estado del Arte en Sistemas Neuroborrosos

Los sistemas neuroborrosos son una integración inteligente de las ventajas inherentes a los enfoques de redes neuronales artificiales y lógica borrosa, permitiendo construir sistemas de toma de decisiones aún más inteligentes.

A finales de la década de los noventa, ya se habían desarrollado varios sistemas híbridos neuroborrosos que podemos separar en dos grandes grupos: redes neuronales dotadas con la capacidad de manejar información borrosa [*fuzzy-neural networks* (FNN)] y sistemas borrosos combinados con redes neuronales para mejorar algunas de sus características [*neural-fuzzy systems* (NFS)].

En un sistema FNN, bien las señales de entrada, los pesos de las conexiones y/o las salidas son subconjuntos borrosos o conjuntos de valores de pertenencia de conjuntos borrosos como sucede, por ejemplo, en [191-194]. Por lo general, estas variables se modelizan empleando valores lingüísticos tales como “bajo”, “medio” y “alto”, o números difusos o intervalos. Las redes neuronales con neuronas borrosas también se denominan FNN ya que son capaces de procesar información borrosa.

Por el contrario, un sistema neuroborroso del tipo NFS está diseñado para realizar el proceso de razonamiento borroso y, en él, los pesos de conexión de la red se corresponden con los parámetros de razonamiento borroso. Un ejemplo de estos sistemas se puede encontrar en [195-200]. El uso de algoritmos de aprendizaje del tipo propagación hacia atrás (*backpropagation*) hace que los sistemas NFS puedan identificar reglas borrosas y aprender funciones de pertenencia del razonamiento borroso. Normalmente, para un sistema NFS es fácil establecer una correspondencia individualizada entre la red neuronal y el sistema borroso. En otras palabras, la arquitectura del sistema NFS tiene nodos diferentes en las cláusulas antecedentes, en los operadores de relación, y en las cláusulas consecuentes. Un sistema de control borroso también puede ser denominado sistema NFS.

Un sistema del tipo NFS debe ser capaz de aprender las reglas lingüísticas y/o funciones de pertenencia, u optimizar las existentes. Existen tres posibilidades [195]:

- 1) El sistema se inicia sin reglas, creándose nuevas reglas hasta que el problema de aprendizaje queda resuelto. La creación de una nueva regla se producirá por la entrada al sistema de un patrón de entrenamiento que no está suficientemente cubierto por la base de reglas actual.
- 2) El sistema se inicia con todas las reglas, las cuales pueden ser creadas por partición de variables y eliminadas de la base de reglas gracias a una evaluación del desempeño de las mismas.
- 3) El sistema se inicia con una base de reglas con un número fijo de reglas. Durante el aprendizaje, las reglas se sustituyen a través de un proceso de optimización.

El estado de la técnica para las diferentes técnicas de combinación neuroborrosa evoluciona constantemente y cada día se están desarrollando nuevos tipos de hibridaciones que implican síntesis a distintos niveles. Sin embargo, todas estas metodologías pueden clasificarse dentro de alguno de los grupos que se muestran a continuación [201]. Hay que tener en cuenta que las categorías a), c), d) y e) se refieren a sistemas FNN, mientras que la categoría b) se refiere a sistemas NFS.

- a) Incorporación de incertidumbre y borrosidad (*fuzziness*) en el marco de una red neuronal: emborronado de los datos de entrada, asignación de etiquetas borrosas para las muestras de entrenamiento, posible emborronado en el procedimiento de aprendizaje, obtención de productos de redes neuronales en términos de conjuntos borrosos, etc. [191, 193, 194, 202, 203].
- b) Diseño de redes neuronales guiadas por el formalismo de lógica borrosa: diseño de redes neuronales para implementar lógica borrosa y toma de decisiones borrosas, creación de funciones de pertenencia que representen conjuntos borrosos, etc. [195, 196, 198-200].
- c) Cambio en las características básicas de las neuronas: neuronas diseñadas para realizar diversas acciones utilizando la teoría de conjuntos borrosos (tales como unión, intersección y/o agregación borrosa) en lugar de operaciones estándar (multiplicación, suma, etc.) [204-206].
- d) Uso de medidas borrosas para errores e inestabilidades de la red neuronal: las medidas de incertidumbre de un conjunto borroso son utilizadas para modelizar el error, la

inestabilidad y/o las funciones de energía de sistemas basados en redes neuronales [207].

- e) Creación de neuronas borrosas individuales: la entrada y salida de las neuronas son conjuntos borrosos, siendo también un proceso borroso la actividad de las redes que involucran neuronas borrosas [192].

Existen también en la literatura otros tipos de clasificaciones para los sistemas neuroborrosos [195, 208]. Por ejemplo, Buckley y Hayashi [208] han clasificado las redes neuronales borrosas de la siguiente manera. Las redes pueden tener: 1) Números reales como entradas, salidas borrosas y pesos borrosos; 2) Entradas borrosas, salidas borrosas y números reales como pesos; 3) Entradas borrosas, salidas borrosas, y pesos borrosos. Este tipo de clasificación deja sin embargo fuera a sistemas neuroborrosos como el de Hayashi *et al.* [205], los cuales “emborronaron” la regla delta para el perceptrón multicapa (MLP) usando números borrosos. Tampoco estaría clara la aproximación neuroborrosa de Ishibuchi *et al.* [209], que incorpora números borrosos en los pesos. Por el contrario, ambos sistemas neuroborrosos si estarían recogidos entre los apartados a) y c) de la clasificación mostrada anteriormente.

Las aproximaciones de Nauck *et al.* [195] son también interesantes ya que tienen que ver principalmente con el control neuroborroso. Estos autores sugirieron lo siguiente. Crean un sistema de cooperación donde la red neuronal y el sistema borroso trabajan independientemente el uno del otro, encontrándose la combinación en la determinación de ciertos parámetros del sistema borroso mediante la red neuronal. También proponen un sistema híbrido neuroborroso que implementa un sistema borroso con una red neuronal, generando en este caso una entidad homogénea que no se puede dividir en un sistema borroso o en una red neuronal. Ambas combinaciones se enmarcarían en el punto b) de la clasificación mostrada anteriormente (sistema NFS).

La tendencia actual es desarrollar sistemas neuroborrosos evolutivos (*evolving neuro-fuzzy systems*). En este tipo de sistemas neuroborrosos la estructura de los mismos va cambiando a lo largo del tiempo, a diferencia de los sistemas neuroborrosos anteriores en los cuales solamente se modificaban los parámetros a lo largo del tiempo. Ejemplos de estos sistemas son los trabajos [210-215]. No hay que confundir esta clase de sistemas neuroborrosos con aquellos que modifican sus parámetros a través de computación evolutiva (*e.g.*, algoritmos genéticos), como por ejemplo se hace en [142, 216].

2.5. Técnicas de Agrupamiento para Identificación

Tal y como se ha explicado en el apartado anterior, son muchas las técnicas de Inteligencia Artificial que son utilizadas para modelizar, identificar o extraer conocimiento a partir de conjuntos de datos del sistema objeto de estudio. Algunas de estas técnicas de IA utilizan técnicas de agrupamiento o *clustering* como paso previo a la extracción de conocimiento. Podría decirse que, en el campo de estudio en el cual se centra este trabajo de investigación, las técnicas de agrupamiento se utilizan para procesar los datos que posteriormente serán utilizados en los algoritmos de modelado e identificación basados en técnicas de Inteligencia Artificial.

En esencia, las técnicas de agrupamiento tienen como objetivo la clasificación de objetos de acuerdo con sus similitudes, así como la organización de datos en grupos. En concreto, la propiedad que más interesa en el modelado de procesos complejos, es su facilidad para dividir un conjunto de datos dados en varios grupos, de forma que la similitud entre los elementos dentro de un grupo es mayor que con los de otros grupos.

Por lo tanto, un *cluster* (grupo, clase) no es más que un grupo de objetos que son más similares entre ellos que a miembros de otros grupos. El término similitud debe ser entendido matemáticamente, medible de alguna forma bien definida. En los espacios métricos, la similitud suele ser definida mediante una norma o distancia. Esta distancia puede estar medida entre

vectores de datos, o como distancia a unos vectores de datos prototipo de la clase. Estos prototipos no suelen ser conocidos *a priori*, sino que los propios algoritmos de agrupamiento los van definiendo a la vez que realizan la partición de los datos.

El aspecto geométrico de las clases puede ser muy variado en cuanto a formas, tamaños y densidades, como se muestra en la Figura 2.2 para dos dimensiones. Las clases pueden ser lineales (2.2.a), esféricas (2.2.b) o incluso huecas como en (2.2.c) y (2.2.d). El mejor o peor comportamiento de la mayoría de algoritmos de agrupamiento se ve fuertemente influenciado por la forma y densidad de la clase, así como por la relación espacial y distancia entre ellas.

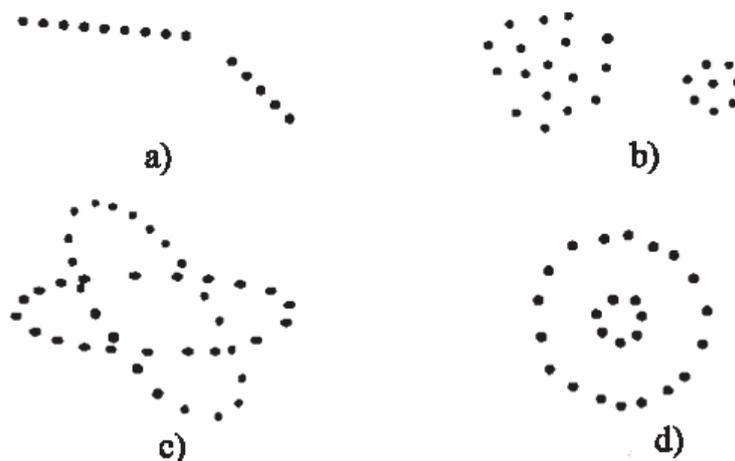


Figura 2.2. Diferentes posibilidades de clases en un espacio de dos dimensiones

Existe una gran diversidad de métodos de agrupamiento en la literatura. Como las clases pueden ser vistas como subconjuntos del conjunto de datos, una primera clasificación podría ser la que tuviese en cuenta si los subconjuntos son clásicos o borrosos. Los métodos de agrupamiento clásicos se basan en la teoría clásica de conjuntos y requieren que un objeto pertenezca o no a un conjunto. El método clásico de agrupamiento aplicado a un conjunto de datos Z significa dividir los datos en un número c determinado de subconjuntos mutuamente excluyentes. Los métodos de agrupamiento borrosos permiten a los objetos pertenecer a diferentes clases simultáneamente, con diferentes grados de pertenencia, siendo c el número total de subconjuntos borrosos definidos.

Otra posible clasificación de los métodos de agrupamiento podría hacerse con respecto al tipo de algoritmo que el método proponga. Los métodos jerárquicos utilizan técnicas de aglomeración y división de los subconjuntos creados, atendiendo a alguna medida de similitud. La mayor ventaja de estos métodos es su sencillez y rapidez. En los métodos basados en la teoría de grafos, el conjunto de datos Z se toma como un conjunto de nodos. Los enlaces indican similitud entre nodos y existe la posibilidad de dividir el grafo en subgrafos. El tercer tipo de algoritmos de agrupamiento emplea una función objetivo para medir la adecuación de las particiones, minimizando una función objetivo global.

Son varios también los trabajos que hacen una revisión de las distintas técnicas de agrupamiento, bien sean borrosas, clásicas, híbridas, etc. De entre esta serie de trabajos destacan [217-219].

2.6. Monitorización y Control de Sistemas Complejos

Se entiende aquí como optimización de sistemas complejos la incorporación de sistemas de monitorización y/o control para maximizar o minimizar un determinado índice de comportamiento o cifra de mérito en determinados procesos productivos. La fuerte competencia global existente en torno a los mercados productivos, a los mercados financieros, al campo de la investigación e incluso al sector servicios, obliga cada vez más a cualquier proceso complejo a ser más competitivo (bien aumentando su productividad, calidades u otra serie de características).

Sin embargo, las dinámicas existentes en los procesos complejos¹ desempeñan un papel muy importante a la hora de diseñar cualquier sistema para optimizar y/o mejorar el propio proceso. Sobre todo, cuando el proceso complejo se desarrolla en tiempo real y bajo un entorno cambiante. De entre las posibles vías para la obtención de una mayor ventaja competitiva se encuentran el control y la monitorización de procesos. No obstante, ambas vías requieren la obtención de un modelo preciso del sistema objeto de estudio. La incorporación de los sistemas de monitorización y/o control ayudarán a la consecución de objetivos y al mantenimiento de un rendimiento adecuado bajo condiciones de procesos completamente variables en el tiempo.

Por esta razón, se trata de hacer a continuación una pequeña revisión en el estado del arte de los sistemas de modelado, monitorización y/o control de procesos complejos. Pese a que existen multitud de sistemas o procesos complejos (sistemas financieros, grandes plantas industriales, estimación de consumos eléctricos, etc.) en este trabajo de investigación nos centraremos en los procesos de mecanizado como ejemplos de procesos complejos (ver Capítulo 4).

2.6.1. Estado del Arte en la Monitorización y el Control de Procesos de Mecanizado

La optimización de procesos de mecanizado vía la aplicación de sistemas de monitorización y control basadas en técnicas clásicas y modernas queda fuera del ámbito de este trabajo. Únicamente se estudiarán algunos de estos sistemas en los casos particulares de optimización de procesos de taladrado y optimización de procesos de torneado. De este modo, nos centraremos en este apartado en la aplicación de sistemas de control inteligente.

Desde la aparición de las primeras técnicas de Inteligencia Artificial aplicadas al campo del control de procesos, surgió la necesidad de aplicar las mismas a los procesos de mecanizado debido a sus complejas características (ver Capítulo 4). Si bien es cierto que uno de los principales objetos de estudio de este trabajo es el control inteligente, no siempre se han podido aplicar las técnicas de IA directamente al control. Sin embargo, a lo largo de los últimos años se han llevado a cabo diversas técnicas de optimización (ajuste de parámetros, monitorización, supervisión, control, etc.) en procesos de corte basadas en técnicas de Inteligencia Artificial, las cuales han producido resultados extraordinarios.

Los métodos de control inteligente en procesos de mecanizado son considerados una herramienta vital para la continua mejora de productos, de procesos de modelado, de procesos productivos, de técnicas de control. Entre los diversos métodos de optimización existentes, los que se centran en los parámetros de corte han sido los más estudiados y los que mejores resultados han aportado. A su vez, dentro de este grupo se pueden diferenciar la optimización de parámetros a la hora de modelizar relaciones entrada-salida y parámetros en proceso, y la determinación de condiciones de corte óptimas o cuasi-óptimas.

¹ La definición de “sistema complejo” aparece en el Capítulo 4 (Apartado 4.1)

Las técnicas de Inteligencia Artificial más empleadas en la optimización de parámetros han sido las redes neuronales artificiales y la lógica borrosa. Debido a la capacidad de aprendizaje de relaciones no-lineales, las redes neuronales artificiales han atraído a multitud de investigadores para modelizar procesos de corte [220, 221]. Coit *et al.* consideraron los aspectos prácticos de la construcción y validación de modelos neuronales [125], y Viharos *et al.* mostraron el control y la monitorización de procesos de mecanizado con redes neuronales artificiales [222]. Diversas aplicaciones de modelado de procesos de mecanizado a través de redes neuronales artificiales basadas en relaciones entrada-salida han sido reportadas en la literatura. El perceptrón multicapa ha sido satisfactoriamente aplicado por Sathyanarayanan *et al.*, por Jain *et al.*, y por Feng *et al.* para modelizar el lijado de super-aleaciones, para la predicción de la tasa de arranque de material y el acabado superficial de un mecanizado abrasivo y para el tallado de cilindros para motores, respectivamente [126, 127, 223]. Grzesik y Brol mostraron la utilidad del modelado y el control neuronal de ciertas características del acabado superficial en procesos de mecanizado multietapa [224]. Algunos de los inconvenientes de las redes neuronales artificiales son que los parámetros del modelado no pueden ser interpretados, que son dependientes de grandes conjuntos de datos de entrenamiento, que ciertas configuraciones de las redes producen sobre-entrenamiento y que, en ocasiones, el entrenamiento acaba sin que se hayan alcanzado soluciones óptimas.

Por otro lado, la lógica borrosa también ha jugado un papel muy importante en el modelado de procesos de mecanizado basado en relaciones entrada-salida. La técnica de modelado fundamentada en la teoría de conjuntos borrosos es generalmente utilizada cuando existe conocimiento subjetivo del proceso u opiniones de operadores expertos, las cuales desempeñan un papel fundamental en la definición de funciones objetivo y variables de decisión. Shin y Vishnupad observaron que el modelado basado en lógica borrosa y redes neuronales podría ser una manera efectiva de controlar el proceso de pulido [225]. Kuo y Cohen enfatizaron la importancia de la integración entre redes neuronales y lógica borrosa para el control efectivo de procesos de fabricación [226]. Cabe destacar también en este campo el trabajo de Kamatala *et al.*, en el cual se desarrolla un sistema basado en lógica borrosa para predecir la rugosidad superficial en procesos de torneado [136]. Chen y Kumara usaron una aproximación híbrida de lógica borrosa y redes neuronales para diseñar y controlar un proceso de pulido [227]. Hashmi *et al.* utilizaron por primera vez la lógica borrosa para seleccionar condiciones de corte en operaciones de fresado [228]. En el mismo año, W.L.R. Ip adoptó una estrategia de control basada en lógica borrosa para la regulación de la velocidad de avance en el fresado de un acero templado, obteniendo una mayor eficiencia de corte y un mayor aprovechamiento de la vida útil de la herramienta [229]. Lee *et al.* usaron la teoría de conjuntos borrosos para obtener un modelo no-lineal del proceso de torneado, mostrando de este modo una herramienta más efectiva que las técnicas de modelado matemático para el caso en el que exista cierta “vaguedad” en la variables de control del proceso [230]. Al-Wedyan *et al.*, ya en el año 2001, usaron técnicas de modelado borroso para operaciones de fresado [132]. A pesar de todas las aplicaciones desarrolladas, el empleo aislado de reglas borrosas elaboradas a partir de operadores expertos no resulta adecuado para modelizar los cambios dinámicos subyacentes en cualquier proceso de mecanizado. Debido a ésta y otras razones, es más común el empleo de técnicas neuroborrosas para tratar con este tipo de procesos. Pese a que se han encontrado en la literatura aplicaciones de control neuroborroso para ciertas operaciones de corte de metales, no se han encontrado aplicaciones de esta técnica en el taladrado. Alguna técnica neuroborrosa sí se aplica en la monitorización del desgaste de la herramienta en procesos de torneado.

A continuación se hace una revisión del estado del arte en la optimización de ambos procesos por separado. Solamente se estudiarán el modelado y posterior control en operaciones de taladrado, y la monitorización del desgaste de la herramienta de corte en procesos de torneado, por ser las áreas en las cuáles se desarrolla este trabajo de investigación.

2.6.1.1. Modelado y Control del Proceso de Taladrado

En la revisión de métodos de modelado y control del proceso de taladrado se van a distinguir dos posibles vías. Por una parte se analizará el estado del arte en cuanto a modelos del proceso de taladrado existentes. Una vez se hayan visto los modelos, se pasarán a ver distintos sistemas de control aplicados a procesos de taladrado.

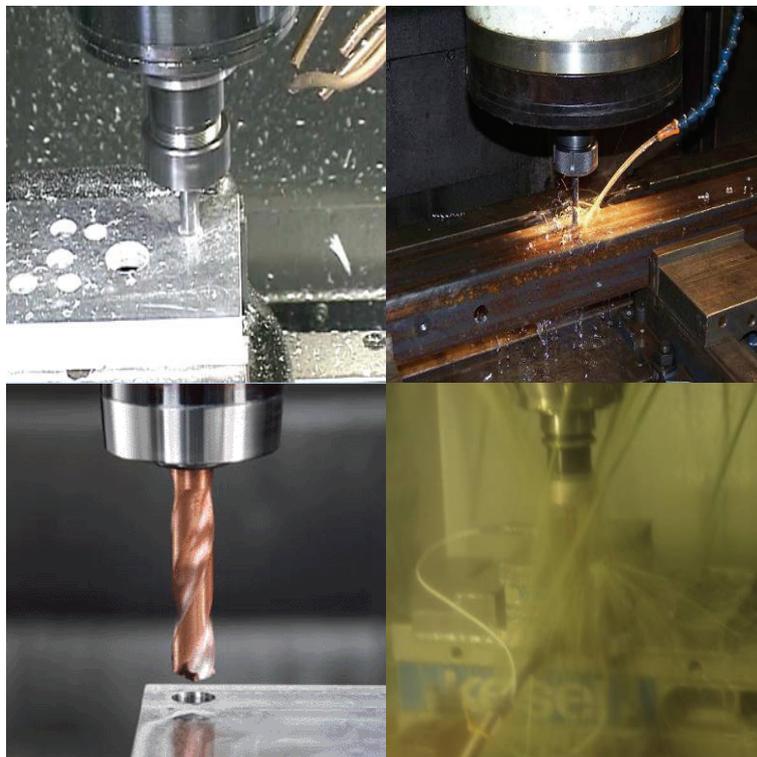


Figura 2.3. Procesos de taladrado

Modelado

Con respecto al modelado hay que decir que las operaciones de corte de metales, de las cuales el taladrado es un subconjunto, han sido modeladas de diversas maneras. Muchas aproximaciones modelan explícitamente la fuerza de corte a través de la geometría o de las variables del proceso (velocidad de giro, velocidad de avance, profundidad de corte). En el trabajo de Landers *et al.*, se proporciona una buena visión general en la que se discuten las aplicaciones y la robustez de los controles en mecanizado que utilizan modelos basados en fuerzas [231]. Para el proceso de taladrado en particular, Kim *et al.*, analizan la fuerza de empuje y la velocidad de avance de una operación de taladrado en una máquina herramienta con CNC [232], creando un sistema lineal y de primer orden (2.1). Cada material puede tener sus propias ganancias y constantes de tiempo, pero para solventar estas incertidumbres, se suelen utilizar controles adaptativos para ajustar estos parámetros.

$$G_p(s) = \frac{F(s)}{f(s)} = \frac{K}{\tau s + 1} \quad (2.1)$$

donde $F(s)$ es la fuerza de empuje, $f(s)$ es la velocidad de avance, s es el operador de Laplace, K es la ganancia y τ es la constante de tiempo. En el Capítulo 4 se estudiarán más detalladamente cada una de estas variables y su importancia dentro del proceso de taladrado.

Elhachimi *et al.* expandieron este trabajo, presentando un modelo puramente geométrico de fuerzas de empuje y de corte para un determinado tipo de broca, proporcionando a su vez una validación de este modelo con resultados experimentales en el taladrado de medio carbono- acero [233, 234]. Hay que mencionar también que la herramienta de taladrado, la broca en sí misma ha sido evaluada usando un modelado en elementos finitos para, entre otras funciones, predecir la respuesta del sistema.

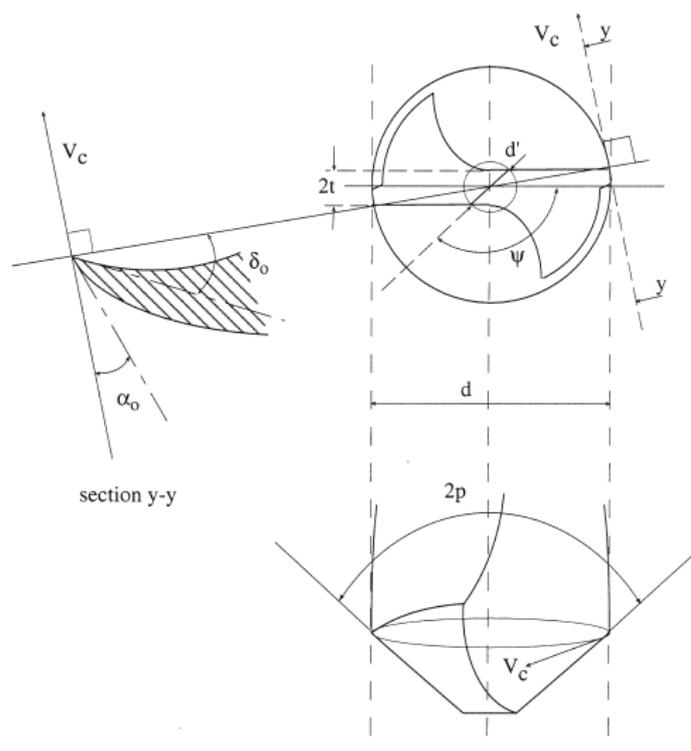


Figura 2.4. Parámetros geométricos utilizados en el modelo de Elhachimi *et al.* (imagen tomada de [233])

Centrándonos ahora en modelos que han sido utilizados para el control del taladrado, existen investigaciones de controles basados en modelos de par para reducir el desgaste en la herramienta utilizando una generalización de un sistema de segundo orden. Furness *et al.* modelaron el par de corte frente a la velocidad de avance comandada como un sistema de tercer orden con un retardo fijo [235]. Un modelo similar de tercer orden pero sin retardo fue implementado en conjunción con un controlador Proporcional-Integral-Derivativo (PID) para el control del par [236]. En este trabajo, Oh *et al.* modelan el proceso de taladrado como un sistema de segundo orden subamortiguado. Posteriormente, este modelo es combinado con un modelo de primer orden del propio cabezal, dando lugar al modelo resultante de tercer orden (2.2).

$$G_p(s) = \frac{T(s)}{f(s)} = \frac{K_c K_s}{(\tau_{fc1}s + 1)(\tau_{fc2}s + 1)(\tau_s s + 1)} \quad (2.2)$$

donde $T(s)$ es el par de corte, $f(s)$ es la velocidad de avance, s es el operador de Laplace, K_c es la ganancia correspondiente al proceso de corte, K_s es la ganancia relacionada con el cabezal, τ_{fc1} y τ_{fc2} son las constantes de tiempo correspondientes al conjunto proceso-cabezal, y τ_s es la constante de tiempo relacionada con el cabezal.

Claramente existen algunas variaciones en el orden de los modelos presentados en la literatura para el taladrado de alto rendimiento. Un estudio muy completo acerca de qué orden puede ser el más adecuado aparece en el trabajo de Del Toro *et al.* en el cual se evalúan sistemas de primer, segundo y tercer orden como modelos de simple entrada - simple salida [237]. (Ver Apartado 4.2.3).

Por otra parte, una aproximación completamente diferente para el modelado de operaciones de taladrado de alto rendimiento se puede realizar vía el golpeo de la herramienta de corte mientras permanece fija en el cabezal del centro de mecanizado con un martillo. Dicho martillo se encuentra calibrado y se utiliza para obtener la dinámica del sistema a través de su respuesta al impulso. Estos modelos han sido verificados representando la fuerza frente a la profundidad de corte en una operación de taladrado y comparando ésta con la repuesta dinámica estimada del sistema [238].

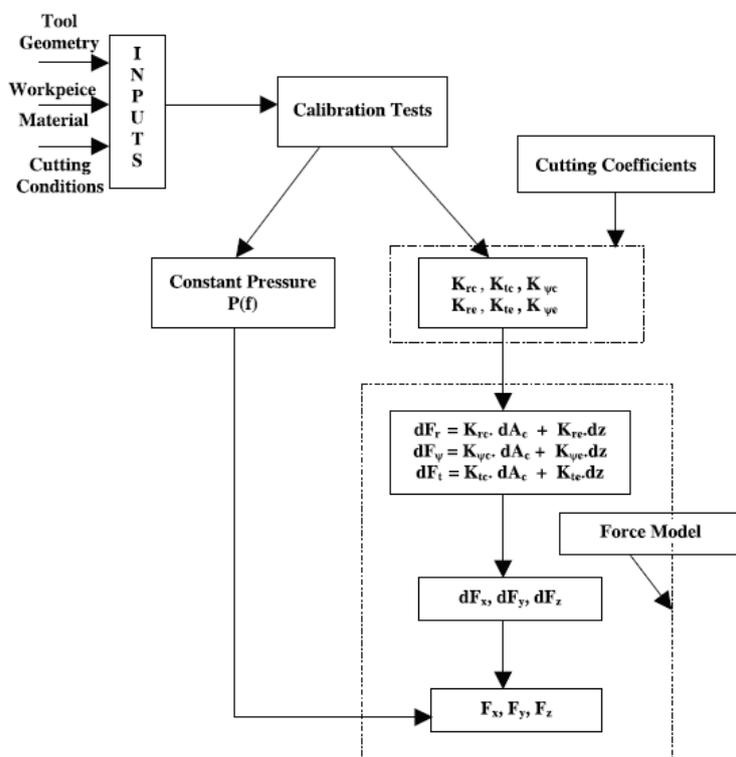


Figura 2.5. Diagrama de flujo de la aproximación propuesta por Pirtini y Lazoglu (imagen tomada de [238])

Las técnicas de identificación presentadas en esta revisión representan un sistema de reducida complejidad dentro de la ardua tarea que supone el modelado del proceso. Esta pequeña revisión de la bibliografía se ha incorporado al trabajo con el objeto de mostrar modelos lineales que suponen una aproximación al proceso de taladrado. Sin embargo, es necesario aclarar que los modelos lineales obtenidos son aproximaciones imprecisas dado que existen no linealidades y comportamientos variantes en el tiempo del proceso (desgaste de herramienta, etc.) que no reflejan esta serie de modelos (ver Capítulo 4). También es necesario mencionar que se han realizado controles en base a alguna de estas aproximaciones lineales, pero precisamente no han aportado los resultados esperados (dado que el proceso es no lineal). Este es el motivo fundamental de emplear técnicas neuroborrosas para el modelado del proceso de taladrado.

Control

El control de la fuerza de corte en lazo cerrado ha sido ampliamente estudiado en multitud de operaciones de mecanizado. En uno de los estudios más amplios que ha sido recientemente publicado, Landers *et al.* tratan el problema del control de fuerzas de corte en procesos de fresado usando un modelo estático, es decir, abandonando la dinámica del proceso [231]. Los autores utilizan cinco aproximaciones distintas en el diseño del controlador: la propuesta de linealización por realimentación, la propuesta de transformada logarítmica, la aproximación no lineal, la aproximación robusta y la aproximación adaptativa. Todas han sido analíticamente estudiadas y simuladas. En el estudio también se proporciona la validación experimental en el fresado de aluminios, incluyendo análisis comparativos.

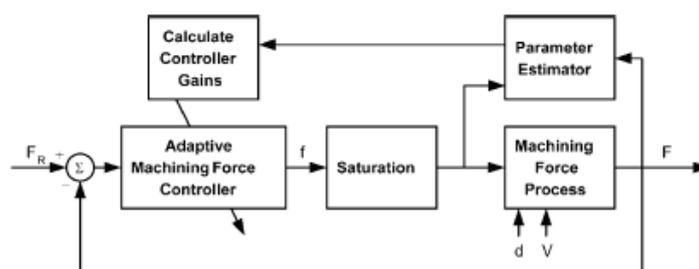


Figura 2.6. Diagrama de bloques de la aproximación adaptativa propuesta por Landers *et al.* (imagen tomada de [231])

Aunque no ha sido tan estudiado como el proceso de fresado, también existen investigaciones en el control del proceso de taladrado, entre las cuales se encuentra el trabajo pionero de Kim *et al.* En dicho trabajo, se diseña un controlador de la fuerza de empuje (predominantemente la componente axial de la fuerza de corte) mediante una aproximación lineal a un modelo de primer orden (abandonando la dinámica de las transmisiones) [232]. Después se introdujo un control adaptativo por modelo de referencia que inicialmente se verifica a través de simulación. El éxito obtenido en este trabajo se demostró a través de la realización de experimentos de taladrado llevados a cabo en piezas multicapa, creándose de este modo cambios (saltos) en las condiciones de corte.

Las investigaciones en el control del proceso de taladrado se han intensificado en los últimos años. Furness *et al.*, en otro trabajo seminal, presentan el modelado de la dinámica y el control en tiempo real del proceso de taladrado con herramientas de distinta clase [235]. Los autores identifican un modelo lineal de tercer orden con retardo (con diversas ganancias según la clase de herramienta) que usan en conjunción con un controlador con colocación de polos (basado en relaciones entrada-salida con esquema de ganancia) para el control del proceso en tiempo real. Los resultados de los experimentos realizados en este trabajo muestran una regulación efectiva del par de corte (evitando la rotura de la herramienta) manipulando automáticamente la velocidad de avance de la herramienta durante el mecanizado. Sheng *et al.* presentan también interesantes resultados concernientes al modelado dinámico y al control adaptativo-predictivo del taladrado de materiales compuestos, obteniendo una mejora en la calidad del acabado digna de mención [4].

Oh *et al.*, hacen una propuesta basada en un diseño clásico para implementar un sistema de control del proceso de taladrado [236]. Mediante identificación experimental, crean un modelo lineal de tercer orden a través de la respuesta de la fuerza de corte tras introducir en el sistema un salto en la velocidad de avance como entrada. Después diseñan un controlador PID a través del procedimiento de diseño (ajuste) de Ziegler-Nichols. Finalmente, la ganancia del controlador es reajustada usando el método del lugar de las raíces (*root-locus*), con el fin de

eliminar la respuesta con sobrepaso (*overshoot*). Típicamente, el sobrepaso provoca inestabilidad cuando se taladran profundidades que exceden de 3 a 4 veces el diámetro de la herramienta. Un trabajo similar de los mismos autores, evalúa el comportamiento del control del proceso de taladrado en términos del desgaste de la herramienta. Un procedimiento de prueba y error es usado para ajustar el controlador en su segunda versión.

Del mismo modo, y desde el punto de vista de las técnicas clásicas, en el trabajo de Haber *et al.*, se diseña e implementa un controlador PID para el control del proceso de taladrado de alto rendimiento [239]. Por medio de la utilización de un modelo lineal y experimental de una determinada región de operación del proceso de taladrado, estos autores consiguen diseñar un regulador PID clásico para el control de la fuerza de corte. Posteriormente, el controlador es ajustado en base a las restricciones tecnológicas que tiene el taladrado de alto rendimiento.

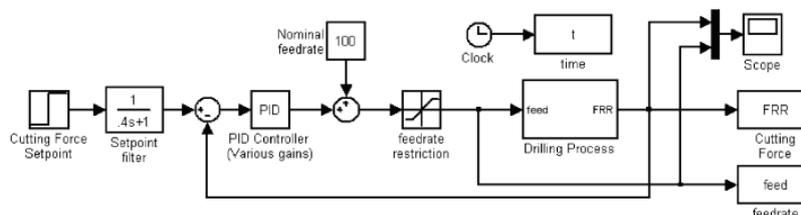


Figura 2.7. Control PID propuesto por Haber *et al.* (imagen tomada de [239])

2.6.1.2. Monitorización del Proceso de Torneado

Las operaciones de torneado son a menudo utilizadas como base para las investigaciones de monitorización del estado de la herramienta en procesos de corte. Existen diversas razones para ello. Primeramente, el proceso de arranque de viruta en operaciones de torneado es más sencillo de describir ya que, en este tipo de operaciones, se producen únicamente cortes ortogonales y oblicuos. Estos dos tipos de corte, a diferencia de otras operaciones, pueden ser descritos en dos direcciones (en un único plano). Por ello, esta simplicidad ha convertido al proceso de torneado en la base de la mecánica del corte. No obstante, el proceso de torneado tiene también otra ventaja añadida, y es que en esta operación la herramienta de corte no gira, razón por la cual la herramienta es más fácil de instrumentar. Además, el procesamiento de las señales procedentes de los sensores también es más sencillo (no hay necesidad de procesar señales de un objeto girando a cientos de revoluciones por minuto).

Como resultado de la sencillez en la instrumentación y en el estudio de su naturaleza, las operaciones de torneado han sido objeto de considerables estudios a lo largo de la historia. Uno de los métodos más populares para detectar el desgaste y la rotura de la herramienta en operaciones de torneado es a través de las fuerzas de corte del proceso. En multitud de casos, las medidas de fuerza se hacen a través de una plataforma dinamoétrica [129, 240-242], mientras que en otros casos las fuerzas de corte se determinan mediante parámetros del cabezal tales como tensión, intensidad o velocidad [243, 244].

Otro método bastante común para la medida del desgaste de la herramienta en operaciones de torneado, es la utilización de señales de emisión acústica. Las emisiones acústicas se recogen usando micrófonos altamente direccionales, aunque acústicamente limitados con películas de sensores piezoeléctricos capaces de medir y transmitir ondas acústicas que viajan a través de la superficie de la pieza de trabajo y la estructura de la máquina herramienta [245-247]. Desafortunadamente, existen muy pocos micrófonos lo suficientemente robustos para operar en un entorno industrial tan hostil como el que se produce en operaciones de torneado. Debido a esta razón, la elección de sensores es muy limitada [248]. Además, si los micrófonos no son lo suficientemente direccionales, a menudo pueden recoger el ruido ambiente, lo que puede reducir

la relación señal-ruido de los datos medidos. Para evitar esta situación, el micrófono debe ser colocado tan cerca del punto de corte como sea lo posible. Sin embargo, esta localización puede llevar a que las virutas y el líquido refrigerante penetren en él.

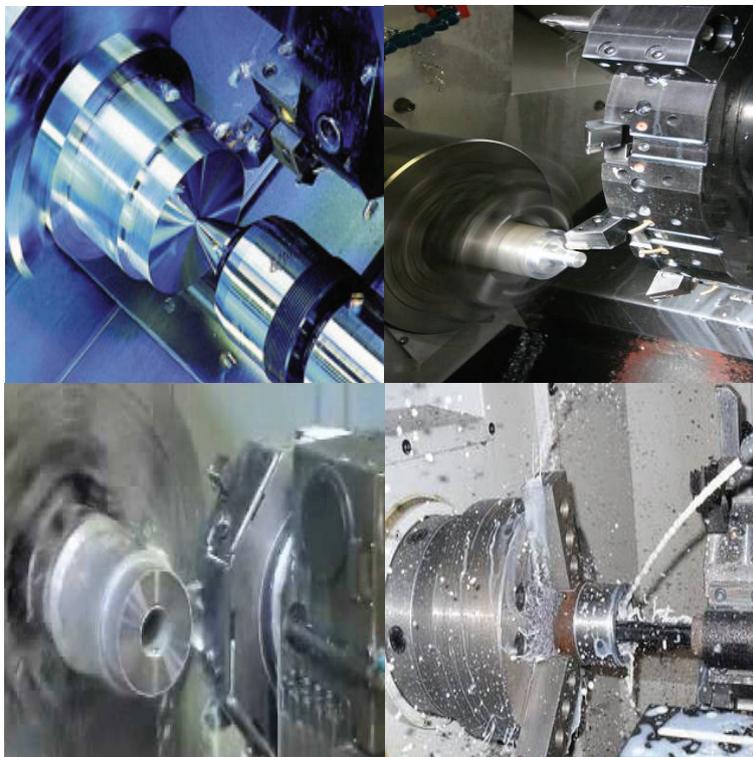


Figura 2.8. Procesos de torneado

A pesar de estos inconvenientes, se sigue utilizando el valor eficaz de la señal de emisión acústica como valor más efectivo para la detección de roturas en herramientas de corte en operaciones de torneado [249]. La razón fundamental de utilizar el valor eficaz de la señal es que resulta muy difícil separar el ruido de fondo del ruido producido por la rotura de un diente o de la herramienta en el procesamiento de señales de emisión acústica crudas. De este modo también se pueden modificar los umbrales de detección para adaptarse al ruido producido por herramientas usadas (con un mayor desgaste), evitando así un número importante de falsas alarmas. Uno de los diversos trabajos que utilizan el valor eficaz de las señales de emisión acústica para detectar las roturas en operaciones de torneado es [242]. En él se concluye que el valor eficaz puede cambiar como resultado del desgaste y que su nivel se relaciona con el área de la rotura de la herramienta.

Las vibraciones y la emisión de ultrasonidos se examinan en [243] como otro posible método para la monitorización del desgaste de la herramienta de corte. Los autores proponen primeramente una recopilación de datos para conformar lo que ellos denominan como “matriz de influencias multi-valoradas”. Dicha matriz contiene dos columnas de parámetros que representan una herramienta “saludable” y una herramienta “gastada”. Posteriormente, las mediciones realizadas en línea se comparan con los datos almacenados en la matriz y se toma una decisión basada en la distancia matemática entre el vector de medición y los vectores “saludable” y “gastada” almacenados en la matriz. Si únicamente se utiliza la señal de ultrasonidos como único indicador de rotura se tienden a producir falsas alarmas [243]. Las vibraciones también se utilizan en [250] junto con transformadas *wavelet* para crear modelos

ocultos de Markov. En [251] se mejora el método anterior mediante la utilización de métodos estadísticos de procesamiento de señales

Tanto las señales de vibración como las de emisión acústica se utilizan también para determinar los efectos del desgaste de la herramienta en el acabado superficial en procesos de torneado [252]. Este estudio utiliza "modelos de monitorización multigrado", que poseen la rapidez de los criterios de modo simple, pero la exactitud de los modelos de modos combinados. Otro enfoque interesante es el adoptado en [240], donde se investigan ciertos parámetros de las virutas producidas durante el giro para determinar el desgaste del flanco de la herramienta. Por ejemplo, se concluye que el color final y la superficie de reflexión de las virutas producidas se encuentran relacionadas con la temperatura y ésta, a su vez, está directamente relacionada con la fricción en el corte y por tanto, con el desgaste de la herramienta. Estos parámetros se utilizan, junto con las fuerzas de corte, para conformar una red neuronal artificial. Sin embargo, el principal problema de esta aproximación es que las medidas de reflexión no se pueden hacer en línea y, por tanto, no se puede utilizar para aplicaciones en tiempo real.

A pesar de las limitaciones en los métodos descritos hasta ahora, las redes neuronales artificiales, así como otros algoritmos de aprendizaje, son los métodos más utilizados y los que mejores resultados han aportado en la monitorización del estado de la herramienta en operaciones de torneado, al menos a escala de laboratorio. Las redes neuronales supervisadas y no supervisadas son comparadas, en términos de capacidad y rendimiento, en la detección de roturas en herramientas de corte en [241]. Por ejemplo, las redes de Kohonen (un tipo de algoritmo supervisado de propagación hacia atrás) son capaces de modificar sus valores prototipo, pero son incapaces de trabajar en línea. Sin embargo, un clasificador no supervisado de categorías simples es capaz de aumentar la fiabilidad de la detección al 92%. Además, no requiere extensos entrenamientos *off-line* con datos de herramientas "saludables" y "gastadas" (como sí sucede en las redes de Kohonen). La ventaja es que sólo necesita ser entrenado con datos de la categoría normal, pudiendo detectar la rotura sobre la base de la desviación de ésta [241]. El trabajo concluye que, por tanto, los algoritmos no supervisados pueden resultar significativamente mejores que los supervisados.

Las redes de Kohonen también pueden ser emparejadas con métodos frecuenciales tal y como se demuestra en [129]. En este caso, se utilizan *wavelets* para descomponer las fuerzas de corte. La descomposición permite analizar la media y la varianza de los máximos y mínimos locales a partir del valor absoluto de la señal decompuesta, siendo estas características las entradas de la red de Kohonen. El trabajo encuentra que cuando el número de características independientes es grande, el éxito de este enfoque es del 91%. Sin embargo, como se indica en [241], la red de Kohonen no puede reconocer la rotura en condiciones que no se hayan utilizado en su entrenamiento.

Por otra parte, existen aproximaciones que mejoran el desempeño de las redes neuronales, reduciendo también su dependencia al entrenamiento específico utilizado [128]. Esto se puede lograr mediante la elección de ciertos parámetros del proceso como entradas a la red neuronal. Esta configuración resulta muy útil ya que se amplía el rango de condiciones de corte que se pueden monitorizar, aumentando la flexibilidad del sistema y su capacidad para detectar el desgaste de la herramienta a través de fuerza indirectas y señales de vibración.

Existen también aproximaciones muy interesantes que utilizan técnicas neuroborrosas para modelizar el desgaste de la herramienta, creando después un sistema de monitorización sobre la base de este modelo [253, 254]. Sin embargo, no se detallan aquí los pormenores de estos enfoques, ya que serán ampliamente tratados en el Capítulo 6.

Capítulo 3

Sistemas Neuroborrosos

Este capítulo trata los aspectos relacionados con los sistemas neuroborrosos. Esta clase de sistemas se ha desarrollado como un paradigma de computación más dentro de las técnicas de Inteligencia Artificial y, más concretamente, dentro del *Soft Computing*. Por tanto, en la primera parte del capítulo se hace una breve introducción acerca de los orígenes de los sistemas neuroborrosos. Posteriormente se pasa ya a definir específicamente en qué consiste un sistema neuroborroso y las motivaciones que desembocaron en su aparición. Después se pasa a detallar el método de inferencia en esta clase de sistemas, diferenciando entre técnicas de inferencia inductiva y técnicas de inferencia transductiva. Siguiendo con esta clasificación, se presentarán tres casos particulares de sistemas neuroborrosos que utilizan los dos métodos de inferencia mencionados anteriormente. Debido a que en este trabajo el fin último de estos sistemas neuroborrosos es modelizar y controlar sistemas complejos, se presentan finalmente diferentes procedimientos para modelizar y controlar procesos por medio de sistemas neuroborrosos.

3.1. Inteligencia Artificial y Soft Computing

Las ideas más básicas acerca de los primeros estudios en Inteligencia Artificial (IA) se remontan a la época de los griegos. Aristóteles (384-322 a.C.) fue el primero en describir un conjunto de reglas que describen una parte del funcionamiento de la mente para obtener conclusiones racionales. El hecho es que los humanos usualmente emplean el lenguaje natural en el razonamiento y en la obtención de conclusiones. En base a esta consideración, las primeras investigaciones en Inteligencia Artificial se centran en intentar imitar el comportamiento inteligente humano mediante su expresión en forma de lenguaje o reglas simbólicas. Según esta primera aproximación, la Inteligencia Artificial básicamente manipula “símbolos” suponiendo que el comportamiento inteligente humano (inteligencia) puede ser almacenado en bases de conocimiento estructuradas simbólicamente. Los sistemas simbólicos constituyen una buena base para modelizar la experiencia de los humanos en limitadas áreas del problema si existe un conocimiento explícito disponible. Dentro del área de sistemas simbólicos de IA, el sistema basado en conocimientos o sistema experto es la herramienta desarrollada más exitosa (ver Figura 3.1).

Sin embargo, en la práctica se ha demostrado que la manipulación simbólica marca el límite de la aplicabilidad de la IA, ya que la adquisición y representación del conocimiento son tareas muy arduas y difíciles. Por otro lado, el objetivo último de la IA es la comprensión, creación e implementación de máquinas inteligentes. En vista de la aparición de estas dualidades, la IA se divide en dos escuelas de pensamiento: la Inteligencia Artificial convencional y la Inteligencia (Artificial) computacional.

La Inteligencia Artificial convencional es, por así decirlo, la rama más teórica de la IA, conociéndose también en algunos casos como IA simbólico-deductiva. Está basada en el análisis formal y estadístico del comportamiento humano ante diferentes problemas, dando lugar al razonamiento basado en casos, a los sistemas expertos, a las redes bayesianas (soluciones mediante inferencia estadística), a la IA basada en comportamientos, etc. La literatura en Inteligencia Artificial convencional refleja generalmente los trabajos previos a lo que hoy conocemos por “Sistema Inteligente”. Sin embargo, muchos precursores de la IA

definen la Inteligencia Artificial convencional en base a su propia filosofía [176]. Esta rama de la IA queda fuera del ámbito de este trabajo.

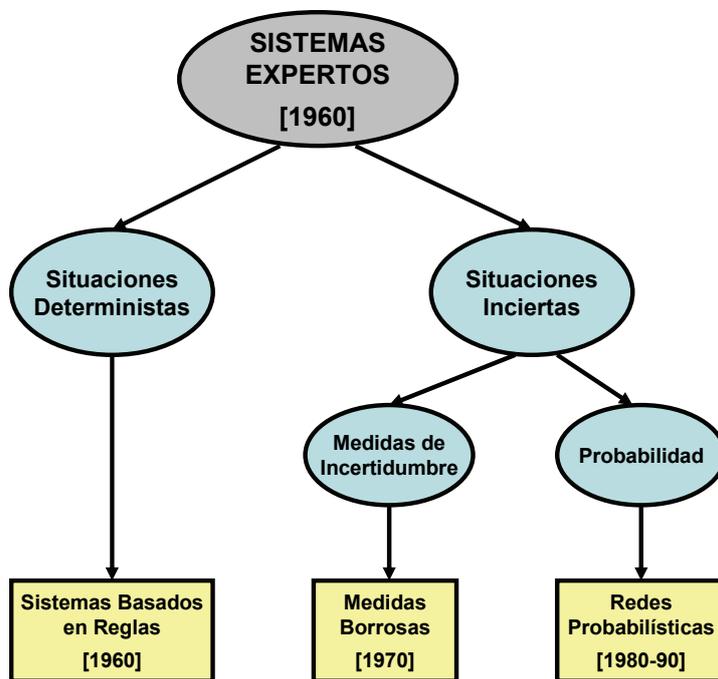


Figura 3.1. Evolución de los sistemas expertos

Por otra parte, la Inteligencia Artificial computacional o Inteligencia Computacional se centra en el estudio de mecanismos adaptativos para permitir el comportamiento inteligente de sistemas complejos y cambiantes, tratando de no confiar en algoritmos heurísticos tan habituales en la Inteligencia Artificial más tradicional. Dentro de la Inteligencia Computacional podemos encontrar una gran riqueza de técnicas como las redes neuronales artificiales, los sistemas borrosos, la computación evolutiva, *swarm intelligence*, los sistemas inmunes artificiales, etc.

La Inteligencia Computacional combina elementos de aprendizaje, adaptación, evolución y lógica borrosa para crear sistemas que son, en cierta manera, “inteligentes”. La investigación en Inteligencia Computacional no rechaza los métodos estadísticos, pero muy a menudo aporta una visión complementaria.

Las técnicas de Inteligencia Artificial, y más concretamente las de Inteligencia Computacional, ofrecen herramientas muy poderosas que pueden ser aplicadas a multitud de campos. Dado que este trabajo se enmarca en el campo de la Automática y el Control de procesos, nos centraremos de aquí en adelante en la aplicación de técnicas de inteligencia Artificial al control de procesos, dando lugar al denominado “Control Inteligente”. Por lo tanto, definiremos ahora más concretamente la Inteligencia Artificial desde la perspectiva de la Automática como la disciplina que se encarga de construir sistemas artificiales que, al ser ejecutados sobre una arquitectura física, producen acciones o resultados que optimizan una medida de rendimiento determinada, basándose en la secuencia de entradas percibidas y en el conocimiento almacenado en tal arquitectura. Anteriormente las percepciones y las acciones se referían únicamente a las de un ser humano. Sin embargo, en el Control Inteligente, las percepciones y las acciones pueden ser obtenidas y producidas, respectivamente, por sensores físicos y actuadores mecánicos en máquinas, por pulsos eléctricos en computadoras, y por entradas y salidas digitales en un entorno software.

La línea de investigación en Control Inteligente (que también abarca el modelado y la monitorización de procesos) nace hace cuatro décadas, alrededor del año 1975, con la intención de aplicar al control las técnicas de Inteligencia Artificial, las cuales comenzaban a despuntar por las posibilidades que ofrecían para incorporar el conocimiento de operadores expertos. Tal y como se ha mencionado anteriormente, la Inteligencia Artificial en sí misma es un campo muy amplio ya que abarca lógica, optimización, probabilidad, percepción, razonamiento, toma de decisiones y aprendizaje. Por su parte, el objetivo del Control Inteligente es integrar agentes inteligentes o sistemas inteligentes en los sistemas de control. El término "Sistemas Inteligentes" se utiliza para describir sistemas y métodos que emulan aspectos del comportamiento inteligente, con la intención final de aprender de la naturaleza y del comportamiento de los seres vivos para poder diseñar y construir sistemas computacionales más potentes. En palabras de M. Minsky, consiste en "el estudio de cómo programar computadoras que posean la facultad de hacer aquello que la mente humana puede realizar", en otras palabras, sustituir a la mente humana en la toma de decisiones, planificación y aprendizaje [255]. En definitiva se trata de que el sistema artificial sea capaz de emular el comportamiento de algunos de sus elementos o algunas de las cualidades sociocognitivas del comportamiento humano (o de los seres vivos en general), como el aprendizaje, el razonamiento simbólico, la planificación o la adaptación a un medio cambiante.

De forma un tanto recíproca, la Teoría de Sistemas Lineales y No Lineales, y específicamente, la Teoría de Control ha tenido influencia en el desarrollo de la investigación en Inteligencia Artificial (el concepto de "agente" es muy similar al de "regulador"). Así, desde unos comienzos basados en sistemas expertos con reglas intuitivas y métodos de aprendizaje de redes neuronales, en la actualidad el control inteligente se nutre de las teorías de sistemas adaptativos, no lineales, de modelos locales y de la planificación de ganancia (desigualdades matriciales lineales). Asimismo, los investigadores en Inteligencia Artificial utilizan resultados de control y "cibernética", en particular optimización de índices de coste y programación dinámica y el concepto de estado de sistema dinámico y filtrado de Kalman.

A través de los estudios en control inteligente se pone de manifiesto que las técnicas de Inteligencia Artificial y los métodos de inspiración biológica y física son capaces de influir de forma decisiva en los caminos utilizados para diseñar e implementar nuevos sistemas para el modelado, la monitorización y el control de procesos complejos. Estos temas han recibido, por separado, un impulso extraordinario en los últimos años. Sin embargo, es necesario desarrollar métodos que aprovechen la sinergia entre técnicas de Inteligencia Artificial, métodos computacionales avanzados, software para tiempo real y comunicaciones. De este modo se pueden diseñar sistemas para el modelado, monitorización y control cualitativamente superiores y aplicarlos a la mejora de procesos de gran complejidad.

El uso masivo de las técnicas de IA en el modelado, la monitorización y el control ha sido consecuencia, en buena medida, de que las técnicas clásicas no han producido en algunos casos los resultados deseados y se han mostrado efectivas sólo en las condiciones teóricas de diseño. Además, las prestaciones de los reguladores clásicos se deterioran considerablemente en presencia de incertidumbre y de no linealidades. La razón fundamental es que el control clásico o control convencional utiliza teorías y métodos que se basan en la representación del conocimiento acerca de los procesos por medio de ecuaciones diferenciales, en representaciones en variables de estado, en matrices de transferencia (continuas o discretas), etc. Sin embargo, existen muchos procesos en los cuáles no resulta sencillo ni barato obtener estas representaciones. En otros casos, la validez de estas representaciones es muy reducida y acotada a condiciones de operación muy particulares, por lo que conducen a diseños poco eficientes y robustos desde el punto de vista práctico. Por contra, los sistemas inteligentes poseen la capacidad o habilidad para actuar de forma apropiada en presencia de incertidumbre.

Debido a estas características, las principales motivaciones para el uso de sistemas inteligentes (como, por ejemplo, los sistemas neuroborrosos) en el modelado, monitorización y

control han sido: la naturaleza compleja de muchos procesos físicos, biológicos y sociales (en los que las estrategias clásicas de control no han ofrecido los resultados de exactitud, precisión y estabilidad esperados), la existencia de sistemas donde se requiere aumentar la seguridad de funcionamiento, la presencia de procesos donde es necesario aumentar la calidad de los productos, por solo mencionar algunos ejemplos.

Los desarrollos producidos dentro del campo del control inteligente en todos estos años pueden dividirse, mayoritariamente, en tres grandes grupos o categorías [256]:

- Sistemas basados en conocimiento: sistemas expertos, sistemas basados en reglas, sistemas basados en marcos y objetos, etc.
- Sistemas de inteligencia computacional: redes neuronales, algoritmos genéticos, etc.
- Sistemas híbridos: sistemas basados en lógica borrosa, etc.

Las dos últimas categorías constituyen lo que se ha denominado computación “*soft*”, y es donde se enmarcan las técnicas neuroborrosas.

Una de las definiciones de *soft computing* la aporta el Profesor Lofti Zadeh en 1994, presentándolo como un sistema que: “[...] *aprovecha la tolerancia ante la imprecisión, la incertidumbre, y la veracidad parcial de los hechos con vistas a lograr un manejo adecuado, robustez, una solución de bajo coste y una mejor afinidad con la realidad*” [168]. Más tarde, en el año 1998, el propio Zadeh amplía esta definición afirmando que el *soft computing* es el lugar donde convergen todas las tecnologías emergentes del razonamiento [257]. Ya en torno al año 2000, Bonissone *et al.* actualizan la definición de *soft computing* como el conjunto de metodologías computacionales que tiene entre sus principales miembros la lógica borrosa, la neurocomputación, la computación evolutiva y la computación probabilística [258].

Teniendo en cuenta las definiciones anteriores como base, las características y ventajas de las técnicas de *soft computing* pueden resumirse en las siguientes [176]:

- Experiencia humana (*human expertise*): el *soft computing* utiliza razonamiento humano en forma de reglas borrosas *if-then*, así como representaciones convencionales del conocimiento, para resolver problemas prácticos.
- Modelos computacionales inspirados biológicamente: inspiradas en las redes neuronales biológicas, las redes neuronales artificiales se emplean intensamente en el *soft computing* para tratar con la percepción, el reconocimiento de patrones, la regresión no lineal y distintos problemas de clasificación.
- Nuevas técnicas de optimización: el *soft computing* aplica métodos de optimización innovadores de diversas naturalezas e inspiración. Éstas pueden ser tanto algoritmos genéticos (inspirados en la evolución y en procesos selectivos), como temple simulado (motivado por la termodinámica), métodos de búsqueda aleatorios, así como el algoritmo de Nelder-Mead. Estos métodos de optimización no siempre requieren el vector de gradientes de una función objetivo, ya que son más flexibles en el trato con problemas de optimización complejos.
- Computación numérica (*numerical computation*): a diferencia de la Inteligencia Artificial simbólica o convencional, el *soft computing* cuenta con computación numérica. La incorporación de técnicas simbólicas en el *soft computing* es un área de investigación muy activa dentro de este campo.
- Nuevos dominios de aplicación: debido a la computación numérica, el *soft computing* ha encontrado una gama amplia de dominios de aplicación, además de aproximaciones en Inteligencia Artificial. Estos dominios de aplicación son computacionalmente más costosos e incluyen procesamiento de señal adaptativo,

control adaptativo, identificación de sistemas no lineales, regresión no lineal y reconocimiento de patrones.

- Aprendizaje no dependiente de modelo (*model free learning*): las redes neuronales y los sistemas de inferencia borrosos tienen la habilidad de construir modelos usando solo conjuntos de datos (*data samples*). El entendimiento de los subprocesos que se desarrollan dentro del sistema objetivo ayuda a configurar la estructura inicial del modelo, pero no es obligatoria.
- Computación intensiva (*intensive computation*): sin la necesidad de asumir demasiado conocimiento de fondo acerca del problema a resolver, los sistemas neuroborrosos y las técnicas de *soft computing* dependen fuertemente de la computación de alta velocidad ya que se deben realizar múltiples cálculos para encontrar reglas o regularidad en los conjuntos de datos. Esta es una característica común a todas las áreas de inteligencia computacional.
- Tolerancia a fallos: tanto las redes neuronales artificiales como los sistemas de inferencia borrosos, exhiben cierta tolerancia a fallos. La eliminación de una neurona en una red neuronal, o la eliminación de una regla en un conjunto de reglas borrosas, no destruyen el sistema necesariamente. Al contrario, el sistema continúa modelando y/o controlando ya que cuenta con una arquitectura redundante y paralela, aunque indudablemente la calidad del desarrollo se deteriora gradualmente.
- Características basadas en objetivo (*goal-driven characteristics*): los sistemas neuroborrosos y el *soft computing* se guían por objetivos. El camino a recorrer desde el estado actual hasta la solución del problema no tiene porque ser tan larga como en los sistemas más clásicos. Esto es particularmente cierto cuando se usa esquemas de optimización que no requieren el uso del gradiente (*derivative-free*), tales como algoritmos genéticos, temple simulado y métodos de búsqueda aleatoria. Sin embargo, el dominio específico del conocimiento ayuda a reducir la cantidad de computación y el tiempo de búsqueda pero, por contra, no es un requerimiento.
- Aplicaciones del mundo real: muchos problemas del mundo real son a gran escala e inevitablemente están contruidos sobre la base de una gran incertidumbre. Estas características se descartan cuando se utilizan aproximaciones convencionales que requieren la descripción de todos los detalles para que el problema sea resuelto eficientemente. A diferencia de las técnicas clásicas, las técnicas de *soft computing* son una aproximación integrada para construir soluciones generalmente satisfactorias para los problemas del mundo real.

Ciertamente, el *soft computing* pretende ser una aproximación innovadora para la construcción de sistemas inteligentes. Hoy en día, los complejos problemas del mundo real requieren sistemas inteligentes que combinen conocimiento, técnicas y metodologías de varias fuentes para tratar el problema en todas sus vertientes. Estos sistemas inteligentes poseen la habilidad de “humanizar” un dominio específico ya que son capaces de adaptarse a cada situación, aprenden a hacer lo mejor en entornos cambiantes y, además, tienen la habilidad de explicar cómo toman las decisiones o las acciones. Frecuentemente los problemas de computación del mundo real se resuelven a través de alguna de las técnicas mencionadas con anterioridad. Sin embargo, resulta más ventajoso usar diversas técnicas que desarrollen sinergias y complementariedades, obteniéndose los denominados sistemas inteligentes híbridos. Una gran parte de los sistemas inteligentes híbridos utilizan la computación neuroborrosa: redes neuronales artificiales que reconocen patrones y se adaptan en entornos cambiantes, junto con sistemas de inferencia borrosos que incorporan conocimiento humano y desarrollan la toma de decisiones. La integración de estas dos aproximaciones complementarias, conducen a una nueva disciplina conocida como “sistemas neuroborrosos”.

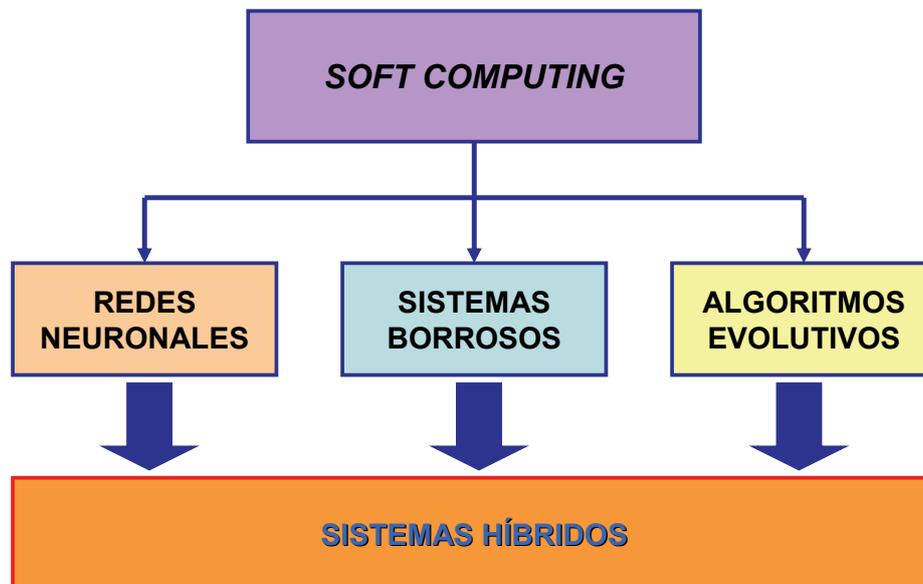


Figura 3.2. Taxonomía de la inteligencia computacional (*soft computing*)

3.2. Definición

El campo del *soft computing* ha evolucionado desde su aparición de un modo vertiginoso. Continuamente se están proponiendo nuevas técnicas, métodos y nuevas aplicaciones para hacer frente a problemas reales de alta complejidad. De entre todas las técnicas existentes y emergentes, la fusión de las redes neuronales artificiales (ANN – *Artificial Neural Networks*) y los sistemas de inferencia borrosos (FIS – *Fuzzy Inference System*) han atraído un creciente interés de los investigadores en diversas áreas científicas y de la ingeniería, debido fundamentalmente a la creciente necesidad de desarrollar sistemas inteligentes adaptativos para solucionar problemas del mundo real [259]. En el campo de la Inteligencia Artificial y el *soft computing*, los sistemas neuroborrosos se refieren a la combinación de las redes neuronales artificiales y la lógica borrosa.

Por un parte, las redes neuronales artificiales permiten obtener y ajustar modelos de manera sencilla. La principal ventaja es que las redes neuronales aprenden “desde cero” a través del ajuste de las interconexiones entre sus distintas capas. En otras palabras, las redes neuronales artificiales tienen una alta capacidad de aprendizaje. Sin embargo, uno de los mayores problemas de estas técnicas es que el conocimiento aparece de forma implícita (valores numéricos sin un significado fácilmente reconocible) en forma de “caja negra” y suelen fallar cuando se producen comportamientos fuera de la región de entrenamiento. Por otra parte, los sistemas de inferencia borrosos proporcionan un entorno o marco eficiente de computación basado en el concepto de la teoría de conjuntos borrosos, en reglas borrosas *if-then* y en razonamiento borroso (formación de base de reglas lingüística). Un sistema de inferencia borroso puede utilizar el conocimiento humano mediante el almacenamiento de sus componentes esenciales en forma de bases de reglas y conjuntos de datos, realizando posteriormente razonamientos borrosos para inferir el valor de salida. Estas técnicas permiten expresar incertidumbre en los sistemas basados en reglas y poseen además robustez intrínseca. Sin embargo, la obtención de las reglas borrosas (*if-then*) y de las funciones de pertenencia correspondientes depende en gran medida del conocimiento que se tenga *a priori* del sistema objeto de estudio. Esto se plasma, entre otros factores, en la dificultad que existe para ajustar los parámetros de las funciones de pertenencia de manera óptima. Lo cierto es que no existen

métodos universales para transformar el conocimiento humano en reglas borrosas. Por contra, estos sistemas han dado muy buenos resultados prácticos en el campo del modelado y control desde mediados de la década de los ochenta [260].

Los sistemas neuroborrosos surgen de la mano de J.S.R. Jang a principios de los noventa combinando las ventajas de las redes neuronales artificiales y de los sistemas de inferencia borrosos [199]. En este trabajo de investigación se toma la siguiente definición de sistema neuroborroso:

Un sistema neuroborroso es aquel sistema borroso cuyas reglas “if-then” se encuentran representadas en una estructura de red, a través de la cual se aplican algoritmos de aprendizaje derivados del área de las redes neuronales artificiales.

De este modo, la hibridación neuroborrosa resulta en un sistema inteligente híbrido que explota la sinergia de estas dos técnicas, combinando el razonamiento humano de los sistemas borrosos con el aprendizaje y la estructura conexionista de las redes neuronales. La hibridación neuroborrosa es ampliamente denominada en la literatura como *Fuzzy Neural Network* (FNN) o como *Neuro-Fuzzy System* (NFS), pudiéndose traducir al castellano como sistemas neuroborrosos o sistemas neurodifusos. La diferenciación entre las dos nomenclaturas inglesas proviene del origen de los sistemas neuroborrosos en el cual surgieron dos vertientes (ver Capítulo 2): redes neuronales dotadas con la capacidad de manejar información borrosa [*Fuzzy-Neural Networks* (FNN)] y sistemas borrosos combinados con redes neuronales para mejorar algunas de sus características [*Neural-Fuzzy Systems* (NFS)] [261].

Independientemente de las distintas tendencias en los orígenes de los sistemas neuroborrosos, la motivación para su aparición es común. Pese a que los sistemas de inferencia borrosos se habían postulado como sistemas que manejaban correctamente el conocimiento humano, existían todavía dos problemas básicos e importantes para la preparación y manipulación del conocimiento:

- No existía una manera sistemática para transformar la experiencia o el conocimiento humano en una base de conocimiento de un sistema de inferencia borroso.
- Existía una necesidad de adaptabilidad o de algoritmos de aprendizaje para ajustar las funciones de pertenencia con el objetivo de minimizar la discrepancia entre la salida del modelo (calculado) y la salida deseada.

Estos dos problemas restringían fuertemente los dominios de aplicación de los sistemas de inferencia borrosa, ya fuera como sistema de control o como sistema experto.

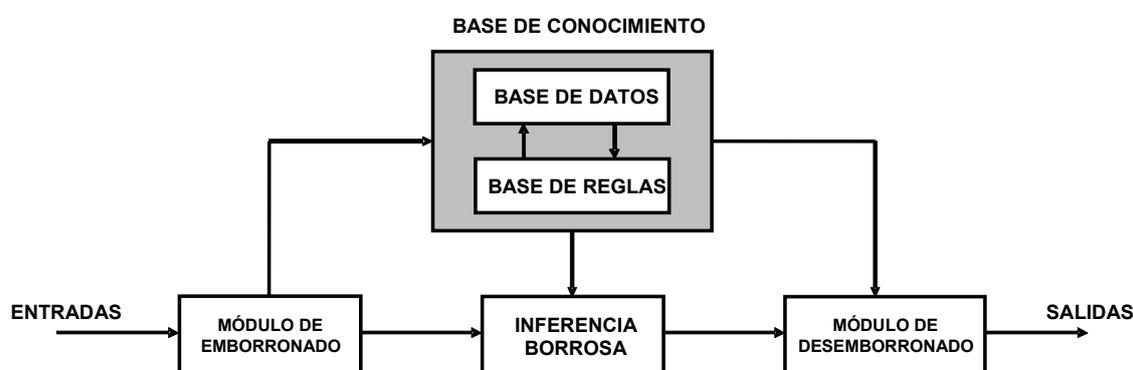


Figura 3.3. Partes de un sistema de inferencia borroso

Por otra parte, el modelado a través de redes neuronales no se basa en la experiencia humana. Contrariamente, emplean un procedimiento de aprendizaje y un conjunto dado de datos de entrenamiento para desarrollar un conjunto de parámetros (pesos) de tal manera que se logre el comportamiento funcional requerido. Debido a la estructura homogénea de la red neuronal, es difícil extraer el conocimiento estructurado de cualquiera de los pesos o de la propia configuración de la red neuronal. En determinados casos, ciertos autores destacan que los pesos en una red neuronal tienen significados físicos [36]: los pesos de un determinado nodo representan los coeficientes del hiperplano (o de la función discriminante) que dividen el espacio de entrada en dos regiones con diferentes valores de salida. Sin embargo, esta interpretación acerca de los pesos resulta ser poco útil ya que sólo es válida en redes que usen limitadores duros como funciones de activación (y la mayoría usan funciones sigmoidales o tangentes hiperbólicas) y cuando el conocimiento se encuentre en la forma de estructura hiperplana (y en los sistemas reales no sucede así).

En gran medida, las desventajas relativas a estos dos enfoques parecen complementarias. Por lo tanto, parece natural considerar la construcción de un sistema que integre y combine los conceptos de modelado de la lógica borrosa y de las redes neuronales. En otras palabras, el enfoque integrado (sistema neuroborroso) debe incorporar tres importantes características:

1. Representación concisa y significativa del conocimiento estructurado.
2. Capacidad de aprendizaje eficaz para la identificación de parámetros.
3. Mapeo claro entre los parámetros y el conocimiento estructurado.

Las ventajas de la combinación de las redes neuronales artificiales y los sistemas de inferencia borrosos a través de los sistemas neuroborrosos son obvias. La hibridación de estos dos paradigmas permite aprovechar las ventajas de ambos, consiguiendo la sencillez de ajuste de las redes neuronales y a la vez disponiendo de conocimiento explícito expresado en un conjunto de reglas *if-then*. Por contra, la principal fortaleza de los sistemas neuroborrosos implica dos exigencias contradictorias en los sistemas de inferencia borrosos: *interpretabilidad* frente a precisión. En la práctica, una de las dos propiedades prevalece. Por ejemplo, en el campo del modelado neuroborroso se distinguen dos áreas de investigación: el modelado borroso lingüístico que se centra en la *interpretabilidad* (principalmente en el modelo de Mamdani), y el modelado borroso preciso que, como su propio nombre indica, se centra en la precisión (generalmente en el modelo Takagi-Sugeno-Kang) [262].

Aunque generalmente el término “sistema neuroborroso” supone la realización de un sistema borroso a través de redes conexionistas, hoy en día este término se utiliza también para describir algunas otras configuraciones que incluyen:

- Obtención de reglas borrosas a través de redes RBF entrenadas.
- Ajuste de parámetros de redes neuronales basado en lógica difusa.
- Utilización de criterios de lógica borrosa para aumentar el tamaño de redes neuronales.
- Creación de funciones de pertenencia borrosas a través de algoritmos de agrupamiento (aprendizaje no-supervisado) en redes neuronales y redes SOM.
- Emborronado (*fuzzification*²) y desemborronado (*defuzzification*³) a través de redes conexionistas multicapa.

² *Fuzzification*: término inglés referido a la acción de convertir datos nítidos en borrosos. Usualmente se han aceptado los términos “emborronado” y “borrosificación” para referirse a esta acción, aunque no se encuentran recogidos por la RAE.

³ *Defuzzification*: término inglés que representa la acción contraria a la *fuzzification*, es decir, convierte valores borrosos en datos nítidos. Comúnmente se utilizan los términos “desemborronado” o “desborrosificación” para su uso en castellano.

Existen múltiples aproximaciones para integrar redes neuronales artificiales y sistemas de inferencia borrosos que, a menudo, dependen de su aplicación. La revisión de todas las propuestas que aparecen en la literatura en este campo está fuera del ámbito de este trabajo. En el Capítulo 2 se han mostrado las características más importantes de algunas de ellas. En el próximo apartado, trataremos de hacer un estudio más profundo acerca de dos sistemas neuroborrosos concretos con distintos tipos de inferencia.

3.3. Inferencia Neuroborrosa

Según la RAE, la inferencia se define como la acción y efecto de inferir, es decir, sacar una consecuencia o deducir algo de otra cosa. En términos más amplios, una inferencia es una evaluación que realiza la mente entre conceptos que, al interactuar, muestran sus propiedades de forma discreta, necesitando utilizar la abstracción para lograr entender las unidades que componen el problema, creando un punto axiomático o circunstancial, que nos permitirá trazar una línea lógica de causa-efecto, entre los diferentes puntos inferidos en la resolución del problema.

Ciertamente, la inferencia es un proceso intrínseco al razonamiento humano. Inferir es concluir o decidir a partir de algo conocido o asumido (llegar a una conclusión). A su vez, razonar es pensar coherente y lógicamente, en otras palabras, establecer inferencias o conclusiones a partir de hechos conocidos o asumidos. El proceso de razonamiento, por lo tanto, involucra la realización de inferencias, a partir de hechos conocidos. Realizar inferencias significa derivar nuevos hechos a partir de un conjunto de hechos conocidos como verdaderos.

Por otra parte, el fin último de los sistemas inteligentes, entre los cuáles se encuentran los sistemas neuroborrosos, es emular aspectos del comportamiento inteligente: representar un conocimiento y razonar sobre él, aprender, planificar, actuar, etc. Sin embargo, en un sistema inteligente (sistema neuroborroso), el conjunto de hechos conocidos sobre el cuál se infiere es un conjunto de datos. Por tanto, la extracción de conocimiento a partir del conjunto de datos disponible constituye una tarea fundamental en los sistemas neuroborrosos.

Las principales características de esta “extracción del conocimiento” o método de inferencia es que debe ser automática, simple, veloz y eficaz. Tampoco hay que olvidar que la información almacenada del sistema neuroborroso es uno de los recursos más importantes con los que se cuenta a la hora de obtener buenos resultados.

Los sistemas neuroborrosos, por definición, emplean la lógica borrosa para inferir resultados. Sin embargo, dentro de la propia inferencia borrosa se puede hablar de distintos tipos de inferencia tal y como sucede en el razonamiento humano.

Según la psicología [263], se define el razonamiento como: “[...] una operación lógica mediante la cual, partiendo de uno o más juicios, se deriva la validez, la posibilidad o la falsedad de otro juicio distinto. Por lo general, los juicios en que se basa un razonamiento expresan conocimientos ya adquiridos, o por lo menos, postulados como hipótesis. Cuando la operación se realiza rigurosamente y el juicio derivado se desprende con necesidad lógica de los juicios antecedentes, el razonamiento recibe nombre de inferencia. Los juicios sirven como punto de partida son denominados premisas y desempeñan la función de ser las condiciones de la inferencia. El resultado que se obtiene, o sea, el juicio inferido como consecuencia es llamado conclusión.

La inferencia permite extraer de los conocimientos ya establecidos, otro conocimiento que se encuentra implícito en las premisas o que resulte posible de acuerdo a ellas. Cuando en la conclusión se llega a un conocimiento menos general que el expresado en las premisas, se habrá efectuado una inferencia deductiva. Cuando la conclusión constituye una síntesis de las premisas y, por consiguiente, un conocimiento de mayor generalidad, se habrá practicado una inferencia inductiva. Y, cuando la conclusión tiene el mismo grado de generalidad o de

particularidad que las premisas, entonces se habrá ejecutado una inferencia transductiva. La ejecución de las inferencias se realiza conforme a ciertas reglas que han sido dilucidadas en la experiencia y formuladas de un modo estricto por la lógica [...]”.

Por tanto, al igual que en psicología, dentro del campo de los sistemas neuroborrosos también podemos distinguir entre inferencia inductiva e inferencia transductiva. A grandes rasgos, un sistema neuroborroso con inferencia inductiva trata de obtener un modelo general (función) a partir de todo el conjunto de datos entrada-salida representativos del sistema a estudiar. Por contra, un sistema neuroborroso con inferencia transductiva genera un modelo en un único punto del espacio de trabajo partiendo, únicamente, de la información más relacionada con el punto del espacio a estudiar. En los siguientes puntos pasamos a definir cada una de estas inferencias, detallando a su vez un ejemplo de sistema neuroborroso que utilice dicha inferencia.

3.3.1. Inferencia Inductiva

La mayoría de los modelos de aprendizaje existentes en los sistemas de Inteligencia Artificial desarrollados y aplicados hasta ahora, especialmente en el ámbito del *soft computing* y particularmente en los sistemas de razonamiento neuroborrosos, están basados en métodos de inferencia inductivos. Estos métodos de inferencia obtienen un modelo general (una función) a partir del conjunto de datos que representa el espacio del problema, aplicando posteriormente este modelo a los nuevos datos a procesar o utilizando dicho modelo como base para el diseño de sistemas de control. En otras palabras, el aprendizaje inductivo realiza una extrapolación, a partir de un determinado conjunto de ejemplos, para que se puedan hacer predicciones exactas sobre ejemplos futuros.

Por ejemplo, dado un conjunto de entrenamiento de ejemplos positivos y negativos de un concepto, la inferencia inductiva trata de construir una descripción que clasifique con precisión si los ejemplos futuros son positivos o negativos. Es decir, aprende una buena estimación de una función f dado un conjunto de entrenamiento $[(\vec{x}_1, y_1), (\vec{x}_2, y_2), \dots, (\vec{x}_n, y_n)]$ donde cada y_i es ó + (positivo) ó - (negativo).

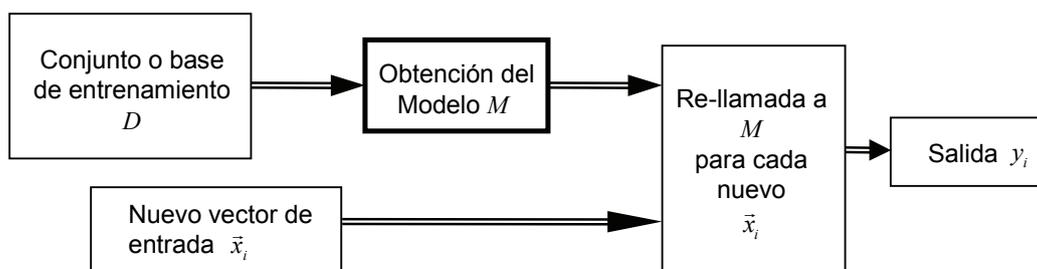


Figura 3.4. Modelado a través de técnicas inductivas

El modelo obtenido a través de técnicas inductivas generalmente se crea sin tener en cuenta cualquier información particular acerca de un determinado nuevo vector de datos (datos de prueba). Si se utiliza, sin embargo, una medida de error para estimar cómo de bien se ajustan los nuevos datos al modelo. Los modelos obtenidos por inferencia inductiva son, en la mayoría de los casos, modelos globales que abarcan enteramente el espacio del problema. Estos modelos son por ejemplo: funciones de regresión, la red neuronal perceptrón multicapa (MLP) o el sistema neuroborroso ANFIS [199].

Los enfoques de aprendizaje e inferencia inductivos son especialmente útiles cuando se necesita una representación global del problema (perspectiva amplia/visión de amplio alcance) incluso en su forma más aproximada. En algunos modelos inductivos (e.g., a través de sistemas

neuroborroso evolutivos), es posible aplicar aprendizaje incremental en línea para ajustar el modelo con nuevos datos y facilitar su evolución.

A continuación se presenta el primer sistema neuroborroso inductivo que, a su vez, es el más utilizado tanto en modelado no convencional como en control de procesos. Su amplia utilización responde en gran parte a su sencillez y a su viabilidad computacional para aplicaciones de tiempo real (rapidez).

ANFIS

El sistema neuroborroso tomado como ejemplo de sistema neuroborroso inductivo es el conocido como *Adaptive Network based Fuzzy Inference System* (ANFIS), en el que las reglas borrosas se obtienen a partir de datos del propio proceso [199]. El sistema ANFIS es uno de los primeros sistemas neuroborrosos conocidos. Su principio se basa en la extracción de reglas borrosas a través de una estrategia descomposicional, donde las reglas son extraídas en cada nivel de una red neuronal. Una vez obtenidas las reglas, éstas deben proporcionar la información necesaria del comportamiento global del proceso.

Como todo sistema de inferencia borroso, el sistema neuroborroso ANFIS desarrollará los siguientes pasos: emborronado de las entradas en forma de variables físicas del sistema, computación del grado de satisfacción de cada regla lingüística, conjunción de las diferentes premisas o antecedentes y desemborronado. Todo este proceso se realiza en las distintas capas secuenciales de la red neuronal.

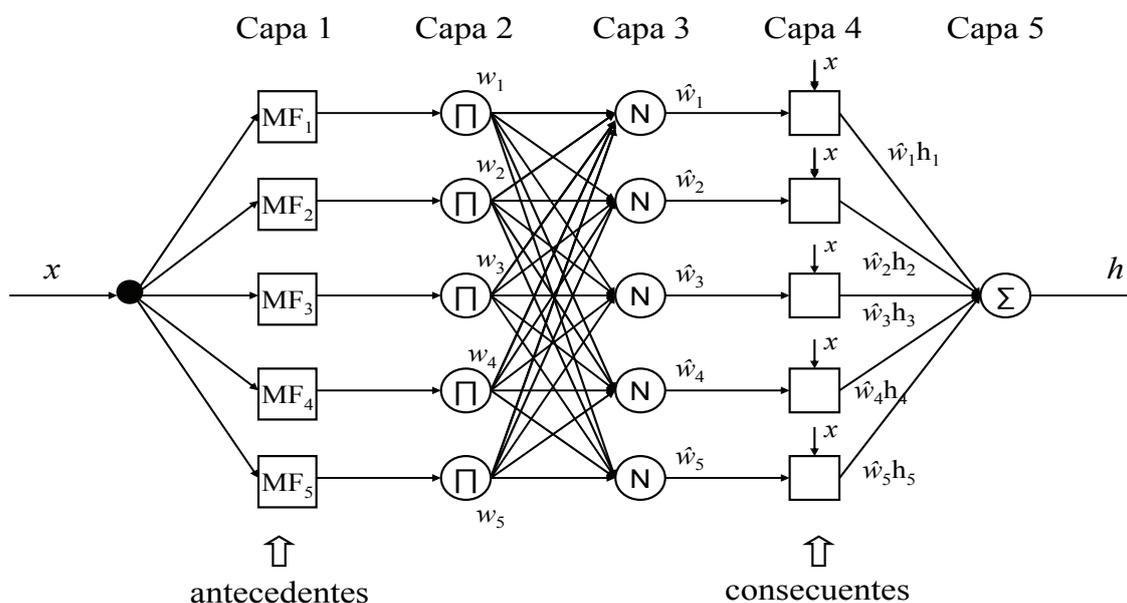


Figura 3.5. Arquitectura del sistema ANFIS

ANFIS implementa el modelo de Takagi-Sugeno para la estructura de las reglas *if-then* del sistema borroso. La arquitectura de ANFIS dispone de cinco capas, tal y como se muestra en la Figura 3.5. En esta arquitectura, todos los nodos de una misma capa tienen la misma función. Los nodos representados con cuadrados son nodos cuyos parámetros son ajustables, mientras que los nodos representados por círculos son nodos fijos. Las funciones de cada capa son las siguientes:

- La primera capa representa las funciones de pertenencia del sistema borroso.
- La segunda y la tercera capa contienen los nodos que forman el antecedente de cada regla borrosa.
- La cuarta capa calcula la función de Takagi-Sugeno para cada regla borrosa.
- La quinta capa es la capa de salida y calcula el peso global de la salida del sistema.

A continuación se presenta ANFIS para el caso particular de un sistema de una entrada y una salida [264].

En la primera capa se produce el emborronado (3.1). La salida de cada nodo se representa por $O_{1,i}$, donde i es el i -ésimo nodo de la capa l .

$$O_{1,i} = \mu_{A_i}(x) \quad (3.1)$$

donde x es la variable de entrada al nodo y A_i es el conjunto borroso asociado al nodo. Si utilizamos una función *Gaussiana* como función de pertenencia borrosa obtendríamos la siguiente expresión, donde a_i , b_i y d_i son los parámetros antecedentes ajustables:

$$\mu_{A_i}(x) = \frac{1}{1 + [((x - d_i) / a_i)^2]^{b_i}} \quad (3.2)$$

En la segunda capa se multiplican las señales de entrada. La salida de esta capa es el resultado de aplicar la regla del máximo. La tercera capa normaliza la importancia de cada regla.

$$O_{2,i} = w_i = \mu_{A_i}(x) \quad (3.3)$$

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad (3.4)$$

La cuarta capa calcula el consecuente, es decir, la función de Takagi-Sugeno para cada regla borrosa, donde m_i y c_i son los parámetros consecuentes.

$$O_{4,i} = \bar{w}_i h_i = \bar{w}_i (m_i x + c_i) \quad (3.5)$$

Por último, la quinta capa realiza el desemborronado como sigue:

$$O_{5,1} = \sum_i \bar{w}_i h_i = \frac{\sum_i w_i h_i}{\sum_i w_i} \quad (3.6)$$

ANFIS utiliza como estrategia de aprendizaje la retropropagación o propagación hacia atrás de los errores para determinar el antecedente de las reglas. El consecuente de la regla se estima por medio del método de los mínimos cuadrados. En el primer paso o “paso hacia delante”, los modelos de entrada son propagados y los consecuentes óptimos son estimados por un procedimiento iterativo de mínimos cuadrados, mientras que los antecedentes permanecen fijos. En el segundo paso o “paso hacia atrás” se utiliza el procedimiento de retropropagación de errores para modificar los antecedentes mientras los consecuentes permanecen constantes. Este procedimiento se repite hasta que se alcanza la condición de parada (criterio de error).

Cuando los valores de los antecedentes son fijos, la salida general del sistema puede expresarse como una combinación lineal de los consecuentes (3.7). Por otra parte, los

antecedentes son actualizados por un criterio de “gradiente-descendente” (3.9), siendo η la tasa de aprendizaje para a_{ij} .

$$h = \begin{bmatrix} \bar{w}_1 x & \bar{w}_1 & \bar{w}_2 x & \bar{w}_2 \end{bmatrix} \cdot \begin{bmatrix} m_1 \\ c_1 \\ m_2 \\ c_2 \end{bmatrix} = \bar{X} \cdot \bar{W} \quad (3.7)$$

Si \bar{X} es una matriz invertible

$$\bar{W} = \bar{X}^{-1} \cdot h \quad (3.8)$$

$$a_{ij}(t+1) = a_{ij}(t) - \eta \frac{\partial E}{\partial a_{ij}} \quad (3.9)$$

3.3.2. Inferencia Transductiva

En contraste con las estrategias inductivas, existen métodos de inferencia o modelado transductivos. Desde la perspectiva de la psicología y la medicina (pediatría), en el razonamiento transductivo se utiliza un elemento particular o detalle de un acontecimiento para juzgar o anticipar un segundo elemento o suceso. Desde el punto de vista de la Teoría de Sistemas y el modelado de sistemas, los métodos transductivos generan un modelo en un único punto del espacio de trabajo. Para cada nuevo dato que tenga que ser procesado, se buscan los ejemplos más cercanos entre los datos conocidos, con el objetivo de crear un nuevo modelo local que dinámicamente se aproxime lo más fielmente posible al proceso en el nuevo estado. Se trata, por tanto, de darle más importancia a la información específica relacionada con el dato a procesar que a la información general aportada por todo el conjunto de entrenamiento [265].

De este modo, cuando hablamos de aprendizaje transductivo nos referimos a la estimación de una función en un solo punto del espacio de trabajo: por cada nuevo vector de entrada \bar{x}_i , un nuevo modelo M_i es creado dinámicamente a partir de ciertas muestras para aproximar la función en la localidad de punto \bar{x}_i .

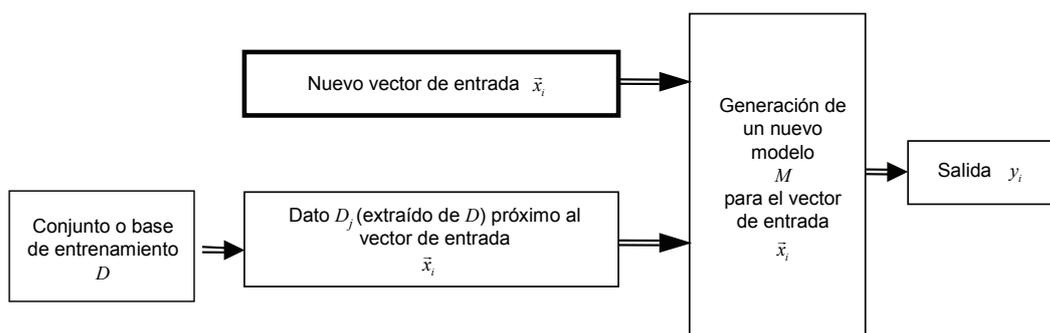


Figura 3.6. Modelado a través de métodos transductivos

Los métodos transductivos tienen algunas ventajas sobre los inductivos ya que, en ocasiones, crear un modelo válido para todo el espacio o región de operación es una tarea difícil y en algunos casos el resultado es insuficiente. Además, el proceso de inferencia inductivo puede conducir a percepciones creativas o divergentes del entorno, y en algunos casos puede producir a una generalización excesiva. Por contra, la generación dinámica de modelos locales

personalizados permite la ampliación del conocimiento (representado como el conjunto de datos conocidos) de manera sencilla, permitiendo un aprendizaje incremental *on-line*. En comparación con el aprendizaje inductivo, el aprendizaje transductivo tiene especialmente en cuenta tanto los datos catalogados como los datos no catalogados previamente (los modelos inductivos son difíciles de actualizar con nuevos datos sin la utilización de datos anteriores, previamente utilizados para obtener los propios modelos). Además, las estrategias transductivas tienen capacidad de funcionar correctamente con un conjunto de entrenamiento reducido.

A continuación se presentan dos sistemas neuroborrosos transductivos: TNFIS y TWNFI-i. Los dos están inspirados en dos sistemas neuroborrosos transductivos desarrollados en los últimos años ([212] y [211], respectivamente) que han sido mejorados en esta Tesis Doctoral. Dichas mejoras y su posterior aplicación a la optimización de procesos de alta complejidad constituyen algunas de las aportaciones de este trabajo.

Ambos métodos transductivos responden en esencia a la misma idea de modelado, sin embargo, el sistema TWNFI-i es más acorde para temas de monitorización y TNFIS es más acorde para tareas de control (más rápido computacionalmente hablando).

TNFIS

El sistema de inferencia neuroborroso transductivo TNFIS (*Transductive Neuro-Fuzzy Inference System*), inspirado en la aproximación NFI propuesta por Song y Kasabov en el año 2005 [212], implica la creación de modelos locales (particulares) para cada sub-espacio del problema, utilizando la distancia euclídea. La distancia euclídea se selecciona de entre otros posibles métodos (*e.g.*, distancia de Mahalanobis, correlación de Pearson, *et.*) con el objetivo de obtener un tiempo de respuesta rápido con una carga computacional mínima [217]. Sin embargo, las ventajas que nos aportarían estos otros métodos (*e.g.*, Mahalanobis: determinar la similitud entre dos variables aleatorias multidimensionales) se consigue a través de una normalización de datos (diferente a la del trabajo original de Song y Kasabov) en la que se tienen en cuenta las varianzas.

TNFIS utiliza el método de inferencia tipo Mamdani y las funciones de pertenencia empleadas son *Gaussianas*, tanto en los antecedentes como en los consecuentes de las reglas *if-then*. Este tipo de función de pertenencia es derivable, permitiendo así el uso de algoritmos de aprendizaje supervisado tales como el algoritmo de retropropagación de errores (*backpropagation*).

Pasamos a describir a continuación los diferentes pasos del algoritmo de inferencia transductivo TNFIS para la obtención de modelos. Primeramente, las entradas a este sistema neuroborroso se pueden expresar en distintas unidades de medida. Por ello, se recomienda la normalización de los datos. Cabe destacar que existen varios métodos de normalización⁴. El procedimiento de normalización aquí propuesto está basado en la utilización de la media y la desviación estándar del conjunto de datos, a diferencia de la normalización en el intervalo [0,1] propuesta en NFI. Por tanto, en TNFIS cada dato de entrada (x_j') es normalizado de acuerdo a:

$$x_j = \frac{x_j' - \mu_j}{\sigma_j} \quad (3.10)$$

donde μ_j es la media y σ_j es la desviación estándar del conjunto de datos conocidos o conjunto de entrenamiento.

⁴ El estudio y evaluación de métodos de normalización está fuera del ámbito de este trabajo de investigación.

Una vez que se ha realizado la normalización (x_j), los diferentes modelos locales se crean a partir de los datos del conjunto de entrenamiento más cercanos a cada nuevo dato de entrada. La distancia euclídea (3.11) se utiliza para seleccionar este subconjunto de datos, en otras palabras, los “vecinos” más cercanos. El tamaño de este subconjunto (N_q) es un parámetro de diseño del algoritmo. Cuando los vecinos han sido seleccionados, el algoritmo también calcula la importancia o peso de cada distancia previamente calculada (3.12).

$$\|\bar{x} - \bar{k}\| = \left[\frac{1}{P} \sum_{j=1}^P |x_j - k_j|^2 \right]^{\frac{1}{2}} \quad (3.11)$$

$$v_i = 1 - (d_i - \min(\bar{d})) \quad (3.12)$$

donde P es el número de elementos del vector de entrada, \bar{x} es el vector de entrada, \bar{k} es cada uno de los vectores o datos del conjunto de entrenamiento, $\min(\bar{d})$ es el elemento mínimo en el vector de distancias $\bar{d} = [d_1, d_2, \dots, d_{N_q}]$, e $i = 1, 2, \dots, N_q$ es el índice que representa el número de vecinos.

Una vez que el subconjunto de datos ha sido elegido y que la importancia de las distancias ha sido calculada, las reglas borrosas y las funciones de pertenencia (con sus parámetros iniciales) de cada modelo local son construidas iterativamente en base al subconjunto de datos más cercano (de cada vector de entrada).

El siguiente paso de TNFIS es el uso del algoritmo de agrupamiento (*clustering*) denominado ECM (*Evolving Clustering Algorithm*) [210] para la creación de estos modelos neuroborrosos locales. Se trata de un algoritmo de una iteración para el agrupamiento dinámico *on-line* de un conjunto de datos, comenzando con un conjunto inicial para el primer dato. Para los siguientes datos, el algoritmo decide, a partir de las distancias euclídeas y del valor umbral de agrupamiento (D_{thr}), añadir el dato a un conjunto existente (actualizando el centro y el radio del mismo) o crear un nuevo conjunto. Los grupos o *clusters* resultantes son circulares y se utilizan para crear las funciones de pertenencia gaussianas. Para ello, el centro del conjunto se toma como centro de la función gaussiana, y el radio como anchura. El número total de grupos no es constante, obteniéndose un número apropiado de *clusters* en cada iteración. La Figura 3.7 representa una iteración en particular del algoritmo ECM en una situación simple-entrada (X) / simple-salida (Y).

Si consideramos que el sistema tiene P entradas, una salida y M reglas borrosas definidas inicialmente a través del algoritmo de agrupamiento, la l -ésima regla tiene la forma:

$$R_l: \quad \text{If } x_1 \text{ is } \Phi_{1l} \text{ and } x_2 \text{ is } \Phi_{2l} \text{ and } \dots x_P \text{ is } \Phi_{Pl}, \text{ then } y \text{ is } \Gamma_l. \text{ (Cluster } l) \quad (3.13)$$

$$\Phi_{lj} = \alpha_{lj} \exp \left[-\frac{(x_{ij} - m_{lj})^2}{2a_{lj}^2} \right] \quad (3.14)$$

$$\Gamma_l = \exp \left[-\frac{(y - n_l)^2}{2\delta_l^2} \right] \quad (3.15)$$

donde m y n son los centros de las funciones gaussianas para las entradas y salidas, a y δ son las anchuras, $i = 1, 2, \dots, N_q$ es el índice que representa el número de vecinos más cercanos, $j = 1, 2, \dots, P$ representa el número de variables de entrada, y $l = 1, 2, \dots, M$ representa el número de reglas borrosas.

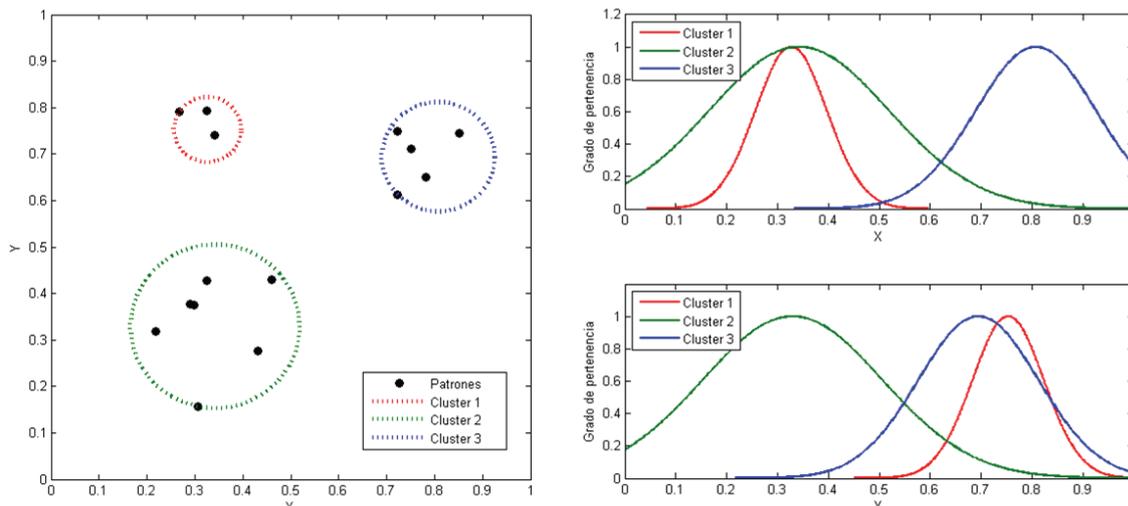


Figura 3.7. Ejemplo del algoritmo ECM para simple-entrada/simple-salida y las funciones de pertenencia generadas a partir de sus resultados

Los centros m y n , así como las anchuras a y δ , se obtienen como resultado del algoritmo de agrupamiento ECM, mientras que el parámetro α_{ij} se elige por diseño (inicialmente con un valor unitario) y representa el peso cada una de las funciones de pertenencia a la entrada. Todos estos parámetros son ajustados posteriormente con el algoritmo de propagación hacia atrás de los errores.

Usando el método del centro del área modificado como método de desemborronado, el valor de salida del sistema TNFIS para un vector de entrada $\bar{x}_i = [x_1, x_2, \dots, x_p]$ se calcula del siguiente modo:

$$O(\bar{x}_i) = \frac{\sum_{l=1}^M \frac{n_l}{\delta_l^2} \prod_{j=1}^P \alpha_{lj} \exp \left[-\frac{(x_{ij} - m_{lj})^2}{2a_{lj}^2} \right]}{\sum_{l=1}^M \frac{1}{\delta_l^2} \prod_{j=1}^P \alpha_{lj} \exp \left[-\frac{(x_{ij} - m_{lj})^2}{2a_{lj}^2} \right]} \quad (3.16)$$

La función de error resultante se expresa como una función de error cuadrática ponderada que es derivable (3.17). El sistema utiliza datos de entrada / salida de los datos más cercanos de entrenamiento $[\bar{x}_i, Y_i]$ y el objetivo es minimizar la función objetivo:

$$E = \frac{1}{2} v_i [O(\bar{x}_i) - Y_i]^2 \quad (3.17)$$

donde v_i , con $i = 1, 2, \dots, N_q$, indica la importancia de las distancias (la proximidad de cada vecino a la salida deseada) calculada en el primer paso, $O(\bar{x}_i)$ es la función de desemborronado que ofrece TNFIS, e Y_i es la salida deseada.

La Figura 3.8 muestra la arquitectura del sistema neuroborroso TNFIS para el supuesto de un sistema tres-entradas/simple-salida y suponiendo una determinada iteración en la que se han creado tres *clusters*. En la Figura 3.9 se pueden observar con más detalle todos los distintos pasos que sigue TNFIS para la creación de cada uno de los modelos locales.

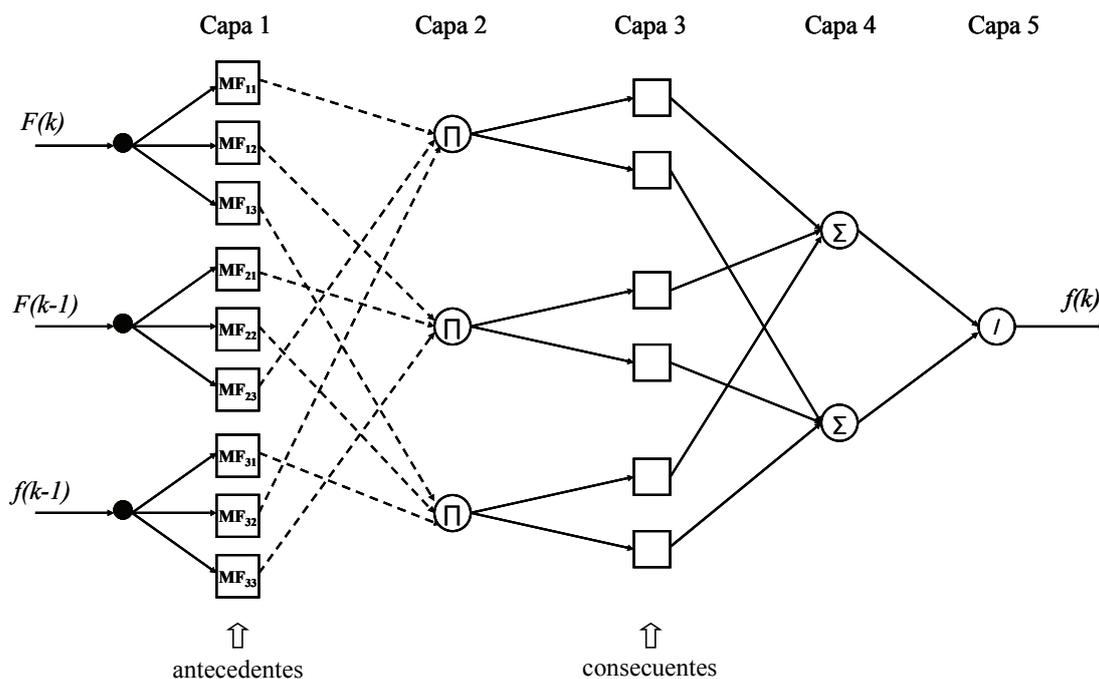


Figura 3.8. Arquitectura de TNFIS en un ejemplo de creación de tres *clusters* (las conexiones entre las capas 1 y 2 depende de los *clusters* creados)

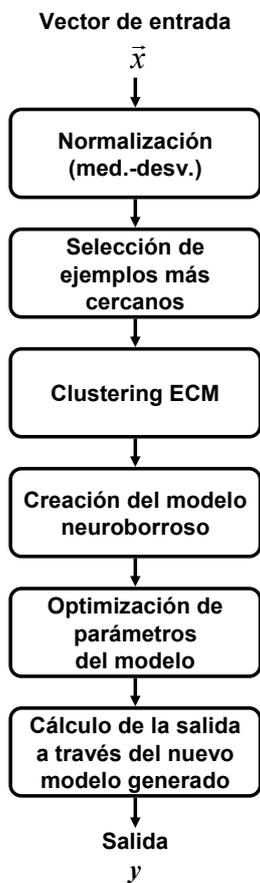


Figura 3.9. Diagrama de bloques del algoritmo TNFIS

En la práctica se pueden aplicar a esta técnica varios algoritmos de aprendizaje y de agrupamiento. Sin embargo, el sistema TNFIS presentado en este trabajo se basa únicamente en ECM y en retropropagación de errores debido principalmente a las velocidades de convergencia que ofrecen y la sencillez de ambos métodos (ya que son algunas de las limitaciones a tener en cuenta en aplicaciones de tiempo real).

TWNFI-i

El sistema de inferencia neuroborroso transductivo TWNFI-i (*Transductive Weighted Neuro-Fuzzy Inference system-improved*) se encuentra inspirado en la aproximación TWNFI propuesta por Song y Kasabov en el año 2006 [211], la cuál es perfeccionada (mejorada) mediante la utilización de otro método de agrupamiento y de otro método de normalización distintos de los utilizados en la aproximación original. Tanto TWNFI-i como TWNFI comparten los mismos principios que TNFIS y NFI, sin embargo, las dos primeras estrategias (a diferencia de las dos últimas) utilizan una modificación de la distancia euclídea para la creación de cada modelo local. En esta modificación (distancia euclídea ponderada) se considera la importancia de cada variable de entrada. La importancia se ajusta a lo largo del proceso de creación de modelo. Por este motivo, en TWNFI-i, se debe volver a comprobar que los vecinos más próximos al dato de entrada no han cambiado (debido al ajuste del nivel de importancia de cada variable) antes de que el modelo local pueda ofrecer una salida.

Pese a que el algoritmo que implementa el sistema TWNFI-i comparte la mayor parte de los pasos anteriormente explicados en TNFIS, se vuelven a mostrar a continuación haciendo especial énfasis en las diferencias entre ambos métodos.

Nuevamente, para poder determinar la similitud entre variables aleatorias multidimensionales se vuelve a utilizar la normalización basada en media y desviación estándar (utilizada en TNFIS) en vez de utilizar la normalización [0,1] utilizada en TWNFI.

$$x_j = \frac{x_j' - \mu_j}{\sigma_j} \quad (3.18)$$

Una vez se ha llevado a cabo la normalización, el modelo local personalizado se crea a partir de los datos del conjunto de entrenamiento más cercanos a cada nuevo dato de entrada. Para la selección de este subconjunto de datos se utiliza la distancia euclídea ponderada (3.19). El tamaño de este subconjunto (N_q) es un parámetro del algoritmo. Los pesos (w_j) de cada componente del vector de entrada (cuyos valores están entre 0 y 1) se obtienen en un proceso posterior de ajuste del modelo y reflejan la importancia de cada variable. Inicialmente todos tienen como valor la unidad.

$$\|\bar{x} - \bar{k}\| = \left[\frac{1}{P} \sum_{j=1}^P w_j |x_j - k_j|^2 \right]^{\frac{1}{2}} \quad (3.19)$$

Cuando los ejemplos más cercanos ya se han seleccionado, se procede a crear el modelo personalizado. El sistema de inferencia neuroborroso utilizado por TWNFI-i emplea un motor de inferencia tipo Mamdani cuyas funciones de pertenencia borrosas son gaussianas, tanto en los antecedentes como en los consecuentes de las reglas neuroborrosas.

Para crear las funciones de pertenencia y las reglas neuroborrosas de cada modelo local se utiliza un algoritmo de agrupamiento distinto de ECM (utilizado tanto en TNFIS como en TWNFI). En esta ocasión se ha elegido un algoritmo de agrupamiento dinámico para un conjunto de datos denominado *Quality Cluster Algorithm* (QT_{Clust}) [266]. Este algoritmo toma

como parámetros un umbral de calidad (que indica el radio máximo de los grupos de datos) y un tamaño mínimo de grupo (mínimo número de datos en un grupo).

En primer lugar, el algoritmo de agrupamiento genera un grupo o cluster provisional centrado en el primer dato. El resto de elementos (datos) son añadidos de forma iterativa sin exceder el diámetro máximo. El segundo grupo provisional se forma a partir del segundo dato repitiéndose el mismo procedimiento. En una primera aproximación, el número de grupos provisionales es igual al número de vecinos más cercanos. En este punto, se selecciona el grupo provisional que contiene más datos y se guarda como definitivo. Los datos incluidos en este grupo se extraen del conjunto de datos (no se consideran) y todo el procedimiento anterior se repite en el subconjunto de datos resultante. La iteración termina cuando todos los datos están en un grupo definitivo o cuando el mayor grupo generado en una iteración tiene menos elementos que el tamaño mínimo indicado como parámetro. Los conjuntos resultantes son elipsoidales y se utilizan para crear las funciones de pertenencia gaussianas. Para ello, el centro del conjunto se toma como centro de la gaussiana, y el radio como anchura.

La elección de este algoritmo de agrupamiento es porque resulta más acorde a las características de los procesos a modelizar (ver Capítulo 4). Además, el algoritmo QT_{Clust} garantiza la calidad de los grupos, encontrando solamente grandes grupos cuyo diámetro no sea superior al que el usuario determina como umbral. Este método evita que los datos de diferentes grupos estén incluidos en un mismo cluster y garantiza a su vez la creación exclusiva de grupos de buena calidad.

Al igual que en TNFIS, en TWNFI-i cada regla difusa se crea sobre la base de un grupo o *cluster*:

$$R_l: \quad \text{If } x_1 \text{ is } \Phi_{1l} \text{ and } x_2 \text{ is } \Phi_{2l} \text{ and } \dots x_P \text{ is } \Phi_{Pl}, \text{ then } y \text{ is } \Gamma_l. \text{ (Cluster } l) \quad (3.20)$$

$$\Phi_{lj} = \alpha_{lj} \exp \left[-\frac{(x_{ij} - m_{lj})^2}{2a_{lj}^2} \right] \quad (3.21)$$

$$\Gamma_l = \exp \left[-\frac{(y - n_l)^2}{2\delta_l^2} \right] \quad (3.22)$$

donde m y n son los centros de las funciones gaussianas para las entradas y salidas, a y δ son las anchuras, $i = 1, 2, \dots, N_q$ es el índice que representa el número de vecinos más cercanos, $j = 1, 2, \dots, P$ representa el número de variables de entrada, y $l = 1, 2, \dots, M$ representa el número de reglas borrosas.

Usando el método del centro del área modificado como método de desemborronado, el valor de salida del sistema TWNFI-i para un vector de entrada $\bar{x}_i = [x_1, x_2, \dots, x_p]$ se calcula del siguiente modo:

$$O(\bar{x}_i) = \frac{\sum_{l=1}^M \frac{n_l}{\delta_l^2} \prod_{j=1}^P \alpha_{lj} \exp \left[-\frac{w_j^2 (x_{ij} - m_{lj})^2}{2a_{lj}^2} \right]}{\sum_{l=1}^M \frac{1}{\delta_l^2} \prod_{j=1}^P \alpha_{lj} \exp \left[-\frac{w_j^2 (x_{ij} - m_{lj})^2}{2a_{lj}^2} \right]} \quad (3.23)$$

donde w_j representa el peso o importancia de cada variable de entrada.

Una vez obtenidas las funciones de pertenencia y las reglas neuroborrosas, se aplica el algoritmo de descenso por gradiente para optimizar los pesos y los parámetros de las reglas

neuroborrosas. Para ello se utiliza como conjunto de entrenamiento el formado por los ejemplos cercanos anteriormente seleccionados.

$$E = \frac{1}{2} v_i [O(\bar{x}_i) - Y_i]^2 \quad (3.24)$$

Como ejemplo de fórmula de optimización de parámetros se muestra a continuación la actualización del parámetro m_{ij} (centro de función de pertenencia de entrada) (3.25). Del mismo modo se procedería en TWNFI-i para n_l , a_{ij} , δ_l , α_{ij} y w_j a partir de (3.24).

$$m_{ij}(k+1) = m_{ij}(k) - \frac{\eta_m w_j^2(k) v_i \theta(\bar{x}_i)}{\delta_l^2(k) a_{ij}^2(k)} [O^{(k)}(\bar{x}_i) - Y_i] \times [n_l(k) - O^{(k)}(\bar{x}_i)] [x_{ij} - m_{ij}(k)] \quad (3.25)$$

donde η_m es la tasa de aprendizaje para el parámetro m , k es el número de iteración y donde

$$\theta(\bar{x}_i) = \frac{\prod_{j=1}^P \alpha_{lj} \exp \left\{ -\frac{w_j^2(k) [x_{ij} - m_{lj}(k)]^2}{2a_{lj}^2(k)} \right\}}{\sum_{l=1}^M \frac{1}{\delta_l^2} \prod_{j=1}^P \alpha_{lj} \exp \left\{ -\frac{w_j^2(k) [x_{ij} - m_{lj}(k)]^2}{2a_{lj}^2(k)} \right\}} \quad (3.26)$$

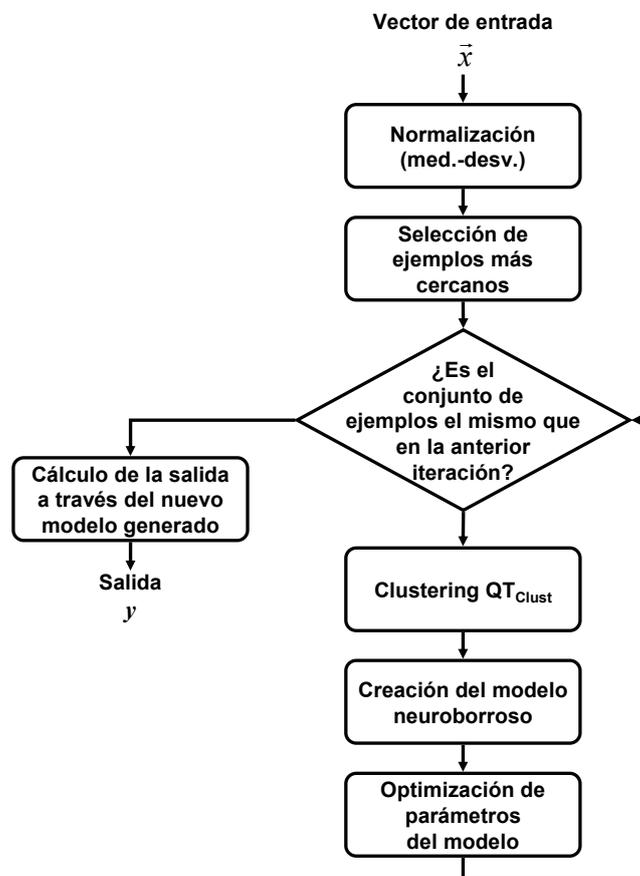


Figura 3.10. Diagrama de bloques del algoritmo TWNFI-i

Tras realizar todos estos pasos, se comprueba que el conjunto de vecinos más cercano no haya cambiado debido a los nuevos pesos de las variables. Si eso ocurre, se vuelve a crear un modelo para ese nuevo conjunto tomando como pesos de partida los obtenidos en la iteración anterior. Si no, el modelo se usa para predecir la salida correspondiente al vector de entrada. De esta manera se optimiza el peso de cada variable en función de su importancia dentro del subespacio en el que se aproxima la función.

En la Figura 3.10 se pueden observar con más detalle el diagrama de bloques del algoritmo, así como los distintos pasos que sigue TWNFI-i para la creación de cada uno de los modelos locales. La arquitectura neuroborrosa es igual que la mostrada en la Figura 3.9 con la única diferencia de añadir un peso w_j en cada una de las entradas.

3.4. Modelado Neuroborroso

Tradicionalmente, y tal y como se ha visto en el Capítulo 2, el modelado es visto como la conjunción de un conocimiento profundo acerca de la naturaleza del sistema y de un conocimiento profundo acerca de su comportamiento. En base a estos profundos conocimientos y mediante un adecuado tratamiento matemático se obtiene un modelo útil que representa al sistema objeto de estudio. Este enfoque suele denominarse "caja blanca" (del inglés *white-box*) y en él se desarrollan modelos matemáticos, físicos, mecánicos, etc., representados a través de ecuaciones matemáticas (e.g., ecuaciones diferenciales). Este tipo de modelado se basa en el supuesto de que los sistemas a estudiar pueden ser completamente descritos mediante las citadas ecuaciones matemáticas que, a su vez, representan todas las correspondientes leyes (físicas, mecánicas) del sistema [1]. Sin embargo, el hecho de requerir una buena comprensión de los fenómenos físicos que se producen en el problema en cuestión, resulta ser un factor muy limitante en la práctica, ya que los sistemas en consideración suelen ser sistemas complejos y poco conocidos (comprendidos). Evidentemente, las dificultades encontradas en el modelado convencional (caja blanca) pueden surgir, por ejemplo, de la escasa comprensión de los fenómenos subyacentes, de los valores inexactos de diversos parámetros del proceso, o de la complejidad del modelo resultante. En la mayoría de los sistemas reales es prácticamente imposible tener una comprensión completa del mecanismo subyacente. Por otra parte, la recopilación de un grado aceptable de conocimientos necesarios para el modelado físico puede ser una tarea muy costosa, muy difícil y que puede consumir bastante tiempo. Incluso en los casos en los cuales se consigue determinar la estructura del modelo, el problema se mantiene debido a la dificultad existente para obtener los valores precisos de los parámetros del modelo. La identificación de sistemas surge para tratar de estimar los parámetros a través de datos medidos en el sistema. Sin embargo, los métodos de identificación se han desarrollado básicamente para tratar únicamente con sistemas lineales. Con todo, la mayoría de los procesos reales son no lineales y pueden ser aproximados por modelos lineales solamente a nivel local [20].

Un enfoque diferente dentro del proceso de modelado supone que el proceso en estudio puede ser aproximado mediante el uso de algunas estructuras generales denominadas "cajas negras" (*black-box*) que se utilizan como un *aproximador* general (función). El problema de modelado se reduce entonces a postular una estructura adecuada del *aproximador*, con el fin de capturar correctamente la dinámica y la no linealidad del sistema. En el modelado "caja negra" la estructura del modelo no se encuentra en relación con la estructura del sistema real. Si existen datos representativos del proceso a disposición del usuario, los modelos "caja negra" se pueden desarrollar, por lo general, con bastante facilidad, sin necesidad de poseer un conocimiento específico del proceso. Sin embargo, un grave inconveniente de este enfoque es que generalmente la estructura y los parámetros de estos modelos no tienen ningún significado físico. Por esta razón, estos modelos no se pueden utilizar para analizar el comportamiento del sistema de no ser que únicamente se requiera una simulación numérica (carente de significado).

Además, estos modelos tampoco se pueden escalar cuando en el proceso real pasa de una escala a otra, y por lo tanto son menos útiles para la práctica industrial [267].

En vista de que ninguna de las anteriores estrategias resulta ideal para modelizar sistemas reales y observando la complementariedad de las mismas, surge una corriente de modelado que establece la combinación de ambos enfoques como mejor estrategia para tratar con el modelado de procesos complejos. De esta manera, las dinámicas del proceso que son bien conocidas pueden representarse utilizando la física y la ingeniería del conocimiento, y las características menos conocidas se pueden describir o aproximar a través del método “caja negra”, utilizando datos del propio proceso. Este nuevo enfoque se conoce como modelado híbrido o “caja gris” (del inglés *grey box*) [268].

La utilización de sistemas neuroborrosos para el modelado e identificación de sistemas responde a la mencionada aproximación híbrida. Ciertamente, las herramientas de modelado convencionales no siempre son adecuadas para hacer frente a la complejidad y a las incertidumbres de los procesos. En estas situaciones, la Inteligencia Artificial proporciona técnicas como el modelado a través de la lógica borrosa o través de las redes neuronales artificiales para hacer frente a estos problemas. Sin embargo, la utilización de estas técnicas por separado sigue mostrando carencias ya que el modelado a través de redes neuronales nos proporciona un modelo “caja negra” y el desarrollo de un modelo con lógica borrosa obliga a disponer de conocimientos acerca del proceso, al igual que en la aproximación “caja blanca”. Por otra parte ambas técnicas comparten algunas características comunes, como puede ser cierta capacidad de tolerancia a fallos, necesaria en modelos que posteriormente sean utilizados en labores de control. Por todas estas razones, el modelado neuroborroso se postula como una técnica adecuada para modelizar sistemas complejos ya que utiliza el enfoque *grey box* y explota las ventajosas características que aportan al modelado tanto la lógica borrosa como las redes neuronales artificiales.

La manera más fácil y simple de obtener un modelo neuroborroso es crear su base de conocimientos utilizando técnicas de verbalización. Sin embargo, la elaboración de una descripción verbal completa de cómo se comporta un proceso complejo es generalmente muy difícil de obtener. En dichas situaciones, es obligatorio desarrollar un procedimiento basado en la identificación a través de datos entrada-salida. Por tanto, un modelo neuroborroso se puede construir a partir de datos entrada-salida del proceso (caja negra), utilizando a su vez la ingeniería del conocimiento para el establecimiento de variables del proceso, objetivos y perturbaciones (caja blanca), y aplicando técnicas de identificación recursiva para el ajuste de parámetros del modelo (retropropagación de error, mínimos cuadrados, descomposición de valor singular, etc.).

3.5. Sistemas de Control Neuroborroso

Un gran número de procesos industriales están caracterizados por un comportamiento no-lineal y por la existencia de importantes perturbaciones no medidas que modifican las condiciones de operación. Para estos procesos se han desarrollado diversas técnicas de control tales como control adaptativo, control robusto, control inteligente, etc. Mediante la simulación de estas técnicas, se ha comprobado que muestran un muy buen comportamiento. Sin embargo, a nivel práctico (nivel industrial), solamente las soluciones con controladores PID, con controles expertos y con controles predictivos lineales han tenido una mayor repercusión en el campo de las realizaciones prácticas a gran escala.

Hoy en día, gracias al desarrollo computacional que han sufrido los dispositivos digitales, el control inteligente se está convirtiendo en una alternativa viable a las estrategias convencionales de control. En ciertas situaciones los esquemas son completamente novedosos y, en otras, los esquemas clásicos son complementados con técnicas de Inteligencia Artificial. La principal razón por la que resultan más adecuadas estas técnicas es porque la lógica borrosa, las

redes neuronales y los propios sistemas neuroborrosos, tratan con la incertidumbre y/o con las desconocidas variaciones (perturbaciones) en los parámetros de la planta y la estructura. Por ello, pueden manejar de un modo más efectivo estas características y mejorar la robustez del sistema de control.

Los sistemas neuroborrosos desempeñan un papel fundamental dentro de los sistemas de control inteligente debido fundamentalmente a que son capaces de modelizar cualquier sistema complejo, tal y como se ha visto en el anterior apartado. Una vez que se ha obtenido un modelo neuroborroso del proceso, éste se puede utilizar para analizar el propio proceso, para mejorar el entendimiento sobre el mismo, para mejorar la operación, para monitorizarla, como herramienta de diagnosis o bien se puede incorporar el modelo neuroborroso obtenido a un sistema de control en tiempo real. Este es el principio de los sistemas de control basados en modelo.

La aplicación al control de los modelos neuroborrosos pasa necesariamente por la utilización de un método de diseño que satisfaga los requisitos del mismo. Varios han sido los esquemas de control que han utilizado modelos neuroborrosos en su estructura (ver Capítulo 2).

A continuación se analizan aquellos esquemas de control en los que se han utilizado más intensamente las técnicas neuroborrosas o aquellos que han reportado importantes ventajas a la hora de controlar de un modo más eficiente, y sobre todo más robusto, los procesos objeto de estudio.

3.5.1. Control por Modelo Inverso

Una manera sencilla de diseñar un controlador para un proceso no lineal es invertir el modelo del proceso. A esta técnica se la conoce con el nombre de control por modelo inverso o control basado en modelo inverso. Es el método más simple para diseñar un controlador basado en la adaptación de parámetros a partir de datos de entrada-salida, a pesar de ello, es muy utilizado para crear todo tipo de estructuras de control. El principal objetivo de esta serie de técnicas es buscar qué entradas aplicar al sistema en cuestión para llevarlo al estado deseado buscando, del mismo modo, qué estado proporciona los mejores objetivos de control.

El empleo de modelos neuroborrosos en este tipo de control se debe fundamentalmente a dos razones. Por una parte, los modelos neuroborrosos son sistemas capaces de representar las no linealidades de los procesos, obteniéndose de este modo controladores no lineales (basados en modelos neuroborrosos). En presencia de fuertes no linealidades, los controladores no lineales pueden ofrecer ventajas significativas sobre las técnicas de control lineal, y en muchas ocasiones pueden ser la única solución para desarrollar un control aceptable. La otra razón es que a través de los modelos neuroborrosos se puede modelizar la dinámica inversa de los procesos (a través de datos entrada-salida) sin necesidad de realizar una inversión del modelo (tarea difícil y no siempre posible).

Una vez que se dispone de un modelo neuroborroso razonablemente preciso, se puede utilizar *off-line* para diseñar un controlador no lineal para dicho proceso, o bien puede formar parte de un esquema de control basado en modelos [269].

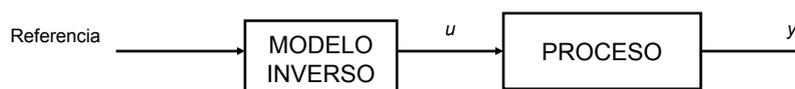


Figura 3.11. Esquema de control por modelo inverso

El control por modelo inverso puede ser aplicado a sistemas que son estables a lazo abierto (o que son estabilizados por realimentación) y cuyo modelo inverso también es estable, es decir, si el sistema no exhibe comportamientos de fase no-mínima. En la teoría, el uso del control por modelo inverso posee las ventajas del control a lazo abierto: estabilidad inherente y control sin errores en las respuestas transitoria y permanente. Además, el uso de modelos neuroborrosos incorpora las saturaciones inherentes a las entradas del modelo y a otras variables del proceso, proporcionando un sistema de control capaz de controlar un sistema no lineal en todo el rango de operación. En la práctica, sin embargo, los sistemas de control tienen que tratar con errores de modelado y con perturbaciones (no contempladas por este esquema de control) y, por tanto, se hace necesario incorporar nuevos elementos al esquema de control basado en modelo inverso para tratar con sistemas complejos (e.g., control por modelo interno).

3.5.2. Control Adaptativo por Modelo de Referencia

Los sistemas adaptativos por modelo de referencia fueron diseñados primeramente para sistemas continuos con la finalidad de minimizar un índice de actuación, siendo dicho índice la integral del error al cuadrado [270]. Esta regla de diseño fue la propuesta inicialmente por Whitaker en el año 1958 [271], sin embargo los sistemas fueron evolucionando creándose nuevos índices de referencia.

En cuanto a las configuraciones posibles como modelo de referencia, la más usual es utilizar un modelo paralelo (Figura 3.12), aunque son posibles otras configuraciones como modelo serie, serie-paralelo, etc.

Existe una dualidad entre los sistemas de control adaptativo por modelo de referencia y el problema de identificación con un modelo ajustable, siendo en este caso el modelo de referencia la planta a identificar.

Dado un modelo de referencia y un sistema ajustable, la minimización del error ha sido la regla más popular debido a su simplicidad. Sin embargo, para el caso de ajuste de varios parámetros requiere un número elevado de funciones de sensibilidad (tantas como parámetros). Por otro lado, la ganancia de adaptación gobierna la velocidad de respuesta, si ésta es muy grande el sistema puede ser inestable y si es muy pequeña la velocidad será muy lenta. Para obtener un buen compromiso entre velocidad de respuesta y estabilidad es necesario un laborioso estudio de simulación.

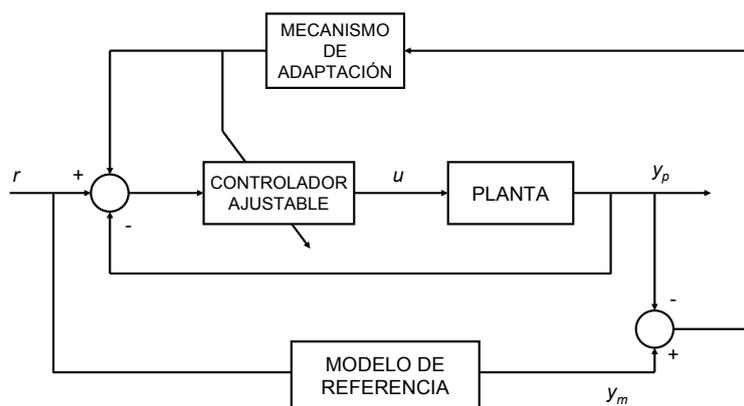


Figura 3.12. Esquema de control adaptativo por modelo de referencia

Para solventar estos inconvenientes surgieron técnicas de diseño fundamentadas en la utilización del segundo método de Lyapunov. Este método tiene la ventaja de asegurar la estabilidad global para cualquier valor de la ganancia de adaptación y cualquier tipo de entrada. La principal desventaja de este método es que se requiere el conocimiento del vector de estado, que no siempre es accesible. Otra desventaja es que no es aplicable a los casos donde los parámetros del conjunto planta más controlador no pueden ser modificados directamente.

Landau propone otra técnica de diseño en el año 1981 basada en el concepto de hiperestabilidad y en la teoría de estabilidad de Popov [272]. El concepto de *hiperestabilidad* está relacionado con la estabilidad de una clase de sistemas, tales que pueden ser separados en dos bloques: parte lineal e invariante en el tiempo y parte no-lineal y/o variable en el tiempo. Una discusión extensa de esta técnica puede encontrarse en dicho trabajo, resultando en casos particulares que la ley de adaptación es de la forma “proporcional + integral” o “proporcional + integral + derivada”. Con esta técnica se garantiza la estabilidad del conjunto, siendo su principal desventaja que a menudo son necesarios una serie de diferenciadores.

Sin embargo, con la aparición de los sistemas neuroborrosos, se deciden implantar métodos de diseño que incluyen modelos neuroborrosos como modelos de referencia y, en algunos casos, controladores neuroborrosos autoajustables o con autosintonía. El empleo de estos sistemas elimina alguna de las barreras planteadas en estructuras anteriores. En este campo destacan los trabajos de Shahri *et al.* por ser uno de los primeros [273], y el trabajo de Liu *et al.* por ser uno de los más citados en su ámbito [274].

3.5.3. Control Predictivo Basado en Modelos

El control predictivo basado en modelos es un método avanzado de control de procesos que ha sido utilizado en industrias de procesos, tales como plantas químicas o refinerías, desde los años ochenta. Los controladores predictivos basados en modelos cuentan con modelos dinámicos del proceso, generalmente modelos lineales empíricos obtenidos por identificación de sistemas. La obtención de estos modelos no es tarea fácil ya que deben describir lo más fielmente posible el comportamiento de sistemas dinámicos complejos. A su vez, los modelos deberían compensar el impacto de las no linealidades en las variables [275].

En consecuencia, los modelos son usados para predecir el comportamiento de las variables dependientes (salidas) de la dinámica del sistema con respecto a los cambios en las variables independientes del modelo (entradas). En la industria química, las variables independientes son generalmente puntos de referencia o valores de control-regulación que gobiernan el movimiento de las válvulas. Por contra, las variables dependientes son generalmente restricciones en el proceso (pureza del producto, seguridad en los equipos o límites de operación) [96].

El control predictivo basado en modelos utiliza los modelos y las medidas actuales del proceso para calcular los futuros cambios en las variables independientes que cumplan con las pertinentes restricciones (tanto de variables dependientes como independientes). El control predictivo enviará entonces el correspondiente movimiento a los actuadores para implementar el punto de operación calculado.

A pesar de que para la mayoría de los procesos industriales reales es posible obtener aproximaciones lineales válidas solamente en una limitada zona de operación, las aproximaciones del control predictivo por modelo lineal son usadas en la mayoría de las aplicaciones. Además se utiliza un mecanismo de retroalimentación para compensar los errores en la predicción debidos tanto a la propia estructura, como al modelo y al mismo proceso. En los controladores predictivos por modelos que cuentan únicamente con modelos lineales, se puede aplicar el principio de superposición del álgebra lineal para efectuar cambios en múltiples variables independientes. De este modo se añade la respuesta de las variables dependientes junto

a la predicción. Este hecho simplifica el problema del control al cálculo de series de matrices algebraicas que, además, es mucho más rápido y robusto.

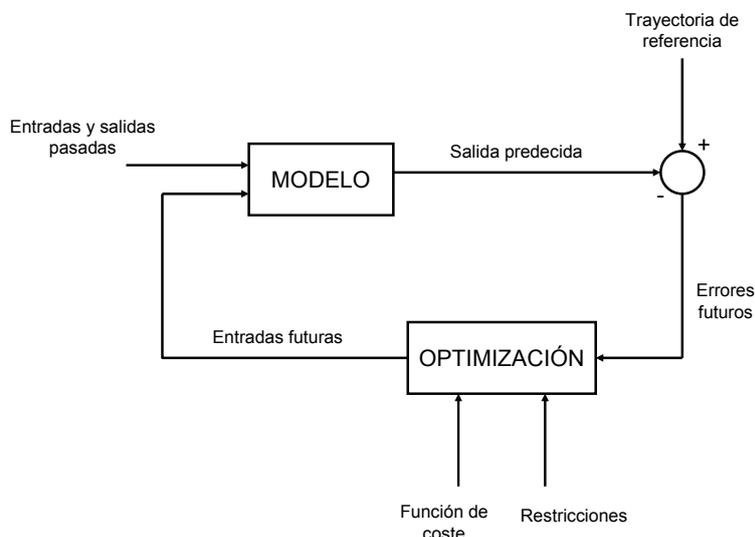


Figura 3.13. Estructura básica del control predictivo basado en modelos

Cuando los modelos lineales no son lo suficientemente precisos (debido en gran parte a las no linealidades del proceso), el proceso puede ser controlado mediante la utilización de modelos predictivos no lineales. Los modelos no lineales se pueden obtener a través de la utilización de datos empíricos (de ahí la utilización de sistemas neuroborrosos) o del modelado de alta fidelidad basado en fundamentos tales como masa, balances de energía, etc. No obstante, el modelo no lineal puede ser linealizado para derivar en un filtro de Kalman o un modelo específico para el control predictivo lineal.

La utilización de un modelo no lineal fiable es el núcleo central en las operaciones de simulación, estimación y control. De ello se dieron cuenta multitud de autores que solventaron las dificultades del control predictivo basado en modelos a través de modelos neuroborrosos del proceso. Por ejemplo, Esgañó *et al.* deciden modelizar primero y controlar después un autoclave industrial a través de sistemas neuroborroso [276]. También nos encontramos con el trabajo de Hernández *et al.* que hacen lo propio con una unidad termoeléctrica [277].

3.5.4. Control por Modelo Interno

El esquema de control por modelo interno (*Internal Model Control*) es uno de los paradigmas de la teoría de control que incluye la utilización explícita de modelos, y que surge a principios de los años ochenta de la mano de Morari [99]. Es en sí mismo el padre del control predictivo actual, pero su contemporaneidad ha permanecido intacta en la última década. Este paradigma se concreta en un esquema de control en lazo cerrado en el que intervienen tanto un modelo directo (G_M) del proceso a controlar (G_P) situado en paralelo con éste, así como un modelo inverso (G_M^{-1}) del mismo. Desde un punto de vista general, podríamos decir que el modelo directo del proceso actúa como un *predictor*, mientras que el modelo inverso hace la función de controlador. Las perturbaciones externas al proceso vienen representadas por d en la Figura 3.14.

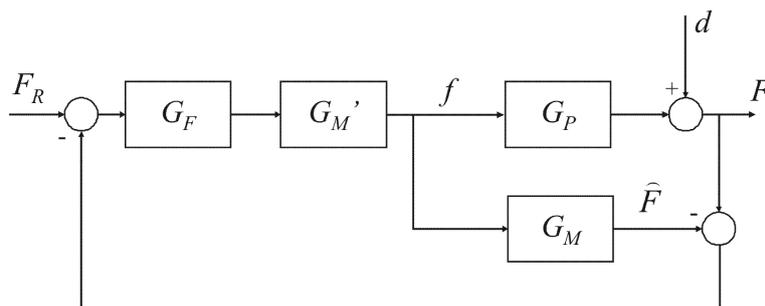


Figura 3.14. Esquema de control por modelo interno

El control por modelo interno (IMC) ha tenido gran aceptación desde sus orígenes debido a su capacidad para hacer frente a las perturbaciones y su comportamiento robusto. Además, este paradigma constituye un enfoque bien establecido para el diseño de controladores. El diseño del controlador es sencillo y su ajuste simple, además, se encuentra bien fundamentado a través de diversos trabajos teóricos para sistemas lineales. En la práctica, sin embargo, la mayoría de los sistemas presentan algún tipo de no linealidad, razón por la que surge la necesidad de extender el IMC a sistemas no lineales [278]. Uno de los mayores problemas aparece debido a que, en general, la inversión de modelos no lineales no es una tarea fácil, y pueden no existir soluciones analíticas, de modo que las soluciones tienen que calcularse numéricamente. Otro problema es que la inversión del modelo del proceso puede conducir a controladores inestables [279].

Para solventar este tipo de dificultades se combina este tipo de esquema de control con técnicas de modelado no lineales. Algunas técnicas ampliamente utilizadas para obtener representaciones de sistemas no lineales son las redes neuronales y los sistemas borrosos. Varios son los trabajos que relacionan el control por modelo interno con estas técnicas. De ahí que este tipo de paradigma pueda ser combinado con modelos neuroborrosos (como modelos directo e inverso) tal y como se propone y aplica en este trabajo.

Las principales propiedades del esquema de control por modelo interno se encuentran relacionadas con la estabilidad del sistema. La primera de ellas afirma que si el modelo inverso y la planta o proceso son estables, y además el modelo directo del proceso es una representación perfecta del mismo, entonces el sistema es estable a lazo cerrado. En esta situación estamos suponiendo que el modelo directo es una representación perfecta de la planta, con lo cual la señal realimentada es igual a la influencia de las perturbaciones y no está afectada por la acción de las variables manipuladas. Por esta razón puede afirmarse que el sistema está en lazo abierto y, por lo tanto, no aparece ninguna de las cuestiones de estabilidad asociadas a la realimentación.

La segunda de las propiedades establece que si existe la inversa del modelo que describe a la planta, dicha inversa se utilizará como controlador y el sistema en lazo cerrado será estable con dicho controlador. Entonces el control será perfecto. Bajo estas condiciones se obtiene un control sin error estacionario siempre y cuando las entradas sean asintóticamente constantes.

De acuerdo con estas propiedades, siempre que se consiga un modelo perfecto del proceso será posible obtener un seguimiento exacto de la referencia aun a pesar de la existencia de perturbaciones no medibles. Por todas estas razones, la utilización del paradigma de control por modelo interno garantiza teóricamente la robustez y estabilidad del sistema de control en presencia de perturbaciones externas.

Sin embargo, la práctica nos demuestra que el modelo directo del proceso no siempre representa exactamente el comportamiento dinámico de la planta. Entonces, la señal realimentada representa a la vez la influencia de las perturbaciones, tanto medibles como no medibles, y el efecto del error de modelado. El error de modelado puede hacer crecer la señal de

realimentación y originar problemas de estabilidad. Por esta razón se introduce el filtro del sistema (G_F). Mediante un diseño adecuado, el filtro se puede elegir de manera que se reduzca la ganancia del sistema realimentado y de la referencia. También sirve para suavizar los cambios rápidos y bruscos en las señales. De este modo el filtro mejora la respuesta del controlador, reduce la ganancia de alta frecuencia y mejora la robustez del sistema. Un estudio completo de la robustez y del diseño de los filtros puede encontrarse en [99].

$$G_F(z) = \frac{1-k_2}{z-k_1} \quad (3.27)$$

donde k_1 y k_2 son parámetros de diseño y usualmente $k_1 = k_2$.

Sistemas Complejos en Fabricación: Procesos de Mecanizado de Alto Rendimiento

En este capítulo se tratan todos los aspectos relacionados con los procesos de mecanizado. Primeramente se estudia la importancia que poseen los procesos de mecanizado dentro de la fabricación industrial para, posteriormente, analizar y fundamentar la complejidad de los mismos. Después se define el concepto de arranque de material, así como el término mecanizado de alto rendimiento. Una vez explicados los procesos de mecanizado de alto rendimiento en general, se hace un análisis en profundidad de dos de los subprocesos que son seleccionados como casos de estudio en este trabajo: el taladrado de alto rendimiento y el torneado de alto rendimiento. Se analizarán sus fundamentos, características, parámetros y enfoques sistémicos para, en último término, plantear los problemas existentes en dichos procesos.

4.1. Los Procesos de Mecanizado como Sistemas Complejos

Los procesos de fabricación constituyen por su variedad y complejidad un sector industrial con un gran impacto en el PIB de las naciones desarrolladas. La actividad de fabricación en Europa representa aproximadamente el 22% del Producto Interior Bruto (PIB). Se estima además que un 70% del empleo a nivel europeo está relacionado con la fabricación [280]. Entre las tareas básicas de estos procesos de fabricación están las de arranque de material, conformado, soldado y ensamblado.

Los procesos de mecanizado forman parte del proceso de fabricación y abarcan un conjunto de operaciones de conformación de piezas o componentes mediante la deformación y eliminación o remoción de material (ya sea por arranque de viruta o por abrasión) y que, además, se desarrollan en una máquina herramienta. Los procesos de mecanizado se realizan partiendo de productos semielaborados como lingotes, tochos u otras piezas previamente conformadas por otros procesos como, por ejemplo, el moldeo o la forja. Los productos obtenidos a partir de los procesos de mecanizado pueden ser finales o semielaborados, los cuáles requieren operaciones posteriores. Tanto en el mecanizado tradicional como en el mecanizado de alto rendimiento (que se definirá más adelante), un proceso de mecanizado está compuesto por procesos tales como taladrado (30%), torneado (20%), fresado (16%), roscado (15%), grabado (6%) y otra serie de procesos (13%) [281]. Tanto el taladrado como el torneado son los dos procesos que mayor porcentaje representan dentro del conjunto de procesos de mecanizado y, por ello, pueden considerarse como los procesos de mayor importancia. Por esta razón, han sido también los dos procesos escogidos como casos de estudio en este trabajo.

Los procesos de mecanizado tienen una gran importancia dentro de los sectores de fabricación industrial. Estos procesos involucran maquinaria y materiales muy costosos así como operadores expertos. Además, la fuerte competencia a nivel internacional en el sector del mecanizado obliga a desarrollar e implantar sistemas de control que mejoren los procesos productivos en todas sus facetas (aumentar las tasas de arranque del material, disminuir los tiempos de parada, mejorar la calidad superficial, mejorar la calidad dimensional, proteger la herramienta de corte, conservar la mecánica de la máquina, etc.) [3]. Sin embargo, esta tarea no es sencilla ya que los procesos de mecanizado se enmarcan dentro del grupo de “sistemas complejos”.

Según la literatura en el campo del control, se entiende por sistema complejo aquel que presenta dificultades con su modelado formal y/o con su simulación. Ciertamente, la complejidad de un sistema no se mide en función del número de componentes (o subsistemas) que lo integran, ni tampoco en función del número de ecuaciones necesarias para describir su comportamiento. Tampoco puede llegar a entenderse como una propiedad inherente al comportamiento del sistema. La complejidad se define como una falta de metodología y de herramientas que permitan especificar y formalizar el conocimiento que se tiene del sistema, con el objetivo de desarrollar un modelo que presente un comportamiento similar al del sistema real. Además, la ocurrencia de un cierto evento (como podría ser una perturbación) en un sistema complejo, hace que se desconozcan las consecuencias del mismo, así como la influencia que provocaría sobre el rendimiento global del proceso [282].

Los procesos de mecanizado cumplen con todas estas características, considerándose procesos muy complejos. La razón fundamental es que son procesos fuertemente no lineales, están cargados de incertidumbre y poseen comportamientos imposibles de describir exactamente por herramientas de modelado convencionales. Por ello, las aproximaciones basadas en técnicas de Inteligencia Artificial (IA) constituyen una alternativa útil y viable para tratar con estos problemas [4]. A lo largo de este capítulo se irá fundamentando la complejidad de los procesos de mecanizando, haciendo primeramente un estudio en profundidad acerca del proceso de arranque de viruta en general (proceso común a todos los procesos de mecanizado), y, posteriormente, de los procesos de taladrado y de torneado en particular.

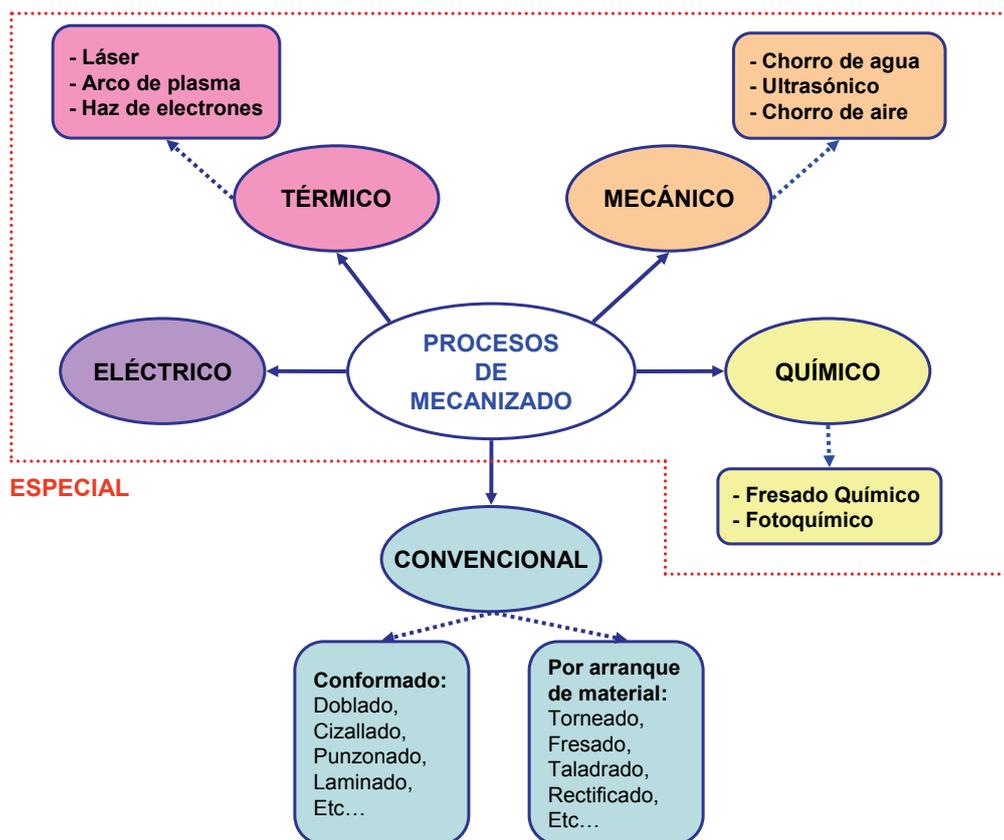


Figura 4.1. Procesos de mecanizado

Haciendo una primera aproximación y desde un punto de vista técnico, el proceso de mecanizado es un proceso electromecánico en el cuál, mediante corte (arranque) o abrasión, se

retira material de un bloque para producir o conformar una pieza con una determinada forma geométrica y con una superficie de acabado establecida. La parte eléctrica está representada por el conjunto de accionamientos, actuadores y elementos de cómputo necesarios. Aunque el término mecanizado se podría emplear para el procesamiento de cualquier sólido, se suele aplicar más frecuentemente para el procesado de metales y aleaciones. Es menos frecuente para plásticos y madera y, muy raramente, para otro tipo de materiales.

Dejando a un lado el mecanizado por abrasión y centrándonos ahora exclusivamente en el mecanizado por corte, hay que especificar que el material es arrancado o cortado con una herramienta dando lugar a un desperdicio o viruta. De ahí el sobrenombre de mecanizado por arranque de viruta. La herramienta de corte consta, generalmente, de uno o varios filos o cuchillas que separan la viruta de la pieza en cada pasada. Sin embargo, existen evidentes limitaciones físicas ya que no se puede eliminar todo el material que se quiera porque llega un momento en que el esfuerzo para apretar la herramienta contra la pieza es tan liviano que la herramienta no penetra y no se llega a extraer viruta. Dentro del mecanizado por arranque de viruta se pueden distinguir los procesos de desbaste (eliminación de mucho material con poca precisión - proceso intermedio) y procesos de acabado (eliminación de poco material con mucha precisión - proceso final).

Comparada con las dimensiones de la pieza, la pequeña deformación volumétrica que da origen a la formación de viruta es una de las características fundamentales del proceso. En esta pequeña deformación volumétrica se produce una gran transformación de energía pues el trabajo mecánico realizado por los motores de la máquina herramienta, es casi completamente transformado en calor cuando se genera la viruta. Este proceso de transformación energética da lugar a la formación de una nueva superficie en la pieza trabajada. El próximo apartado trata de explicar en mayor profundidad la naturaleza de este proceso.

Sin embargo, también es necesario decir que otro de los rasgos distintivos de los procesos de mecanizado, es que muchas de las operaciones de mecanizado son bastante complejas en cuanto a la forma de la herramienta y a los requisitos especiales de elaboración de las piezas, tales como roscas, taladros y cantos vivos. Sin embargo, este y otros problemas pueden minimizarse mediante la elección de unos adecuados parámetros de corte. La selección de las condiciones óptimas de mecanizado es un factor clave y fundamental para la obtención de procesos de mecanizado más eficientes (lo cuál es el objetivo primordial de cualquier sistema de control). Tal y como se ha visto en el Capítulo 2, la mayoría de las investigaciones en el campo del control del mecanizado se centran en el diseño y la implementación de procesos de control eficientes para operaciones de corte a través de la optimización de los parámetros de corte. Algunos de estos sistemas se basan en la emulación del comportamiento de los operarios, los cuales deben buscar un compromiso entre calidad y coste en cada etapa de la operación para asegurar una mejora y tener, a su vez, una garantía contra el fallo en la operación o los defectos en el producto.

4.1.1. Naturaleza del Proceso de Arranque de Viruta

Primeramente, es necesario explicar que el estudio acerca de los procesos de mecanizado en general, y del proceso de arranque de viruta en particular, no es un tema nuevo. Existen actualmente millones de libros, artículos y congresos que explican su naturaleza, datándose los primeros del año 1900 aproximadamente. Dado que el objeto de este trabajo no es profundizar en los conocimientos del proceso, sino únicamente sentar las bases para estudiar posteriormente cómo mejorarlo, la mayoría de las explicaciones y definiciones de este capítulo se extraen de [283], cuyo primer autor es un estudioso de este campo en España. No obstante, se ha revisado una amplia bibliografía, completándose las definiciones con las aportadas por otros autores cuando ha sido necesario.

En los procesos de mecanizado se arranca material de la superficie de las piezas a trabajar produciendo viruta. El arranque se produce como consecuencia del movimiento relativo entre la herramienta de corte y la pieza. Para ello, la herramienta debe situarse a una determinada profundidad dentro de la pieza y la pieza (o la herramienta en algunos casos) deben moverse en cada ciclo de arranque de viruta con una determinada velocidad, llamada de avance y otra que produce el arranque efectivo de la viruta conocida como velocidad de corte.

En todo proceso de mecanizado y, por tanto, en todo proceso de arranque de viruta podemos identificar una serie de elementos fundamentales como son la herramienta de corte, la máquina-herramienta (que produce el movimiento relativo entre pieza y herramienta para que haya arranque de viruta) y los fluidos de corte. La herramienta de corte es el útil que permitirá mecanizar el material que deseamos conformar. Los materiales de los que está hecha son muy variados, si bien se debe verificar siempre que el material de la herramienta es más duro que el material a mecanizar. Dependiendo del material, el filo y el mango de la herramienta estarán hechos del mismo material o diferente, en cuyo caso, el filo o filos de material más duro, se encuentran insertos en una plaquita. El soporte de la plaquita será de otro material que aporta generalmente resistencia y tenacidad a la herramienta.

El origen de las cargas que soporta el filo de la herramienta en el proceso de arranque de viruta es de dos tipos [283]:

- *Mecánico*: El material presenta resistencia a ser cortado y se producen fuerzas de reacción entre el filo y la pieza. Estas fuerzas son los diferentes componentes de la fuerza de corte.
- *Térmico*: Durante el proceso de cizalladura del material se produce una gran cantidad de energía que se transforma casi íntegramente en calor. Este produce el calentamiento de la propia viruta y de la herramienta que se encuentra en contacto con ella.

A estos efectos principales se suma el posible ataque químico que puede originarse por la existencia de algún tipo de reactivo en el conjunto pieza/herramienta/ambiente, que si bien no es frecuente, cuando aparece puede ser muy peligroso para la integridad de la herramienta.

En el proceso de generación de la viruta existen una serie de zonas diferenciadas, que se muestran en la Figura 4.2. En ella se presenta una fotografía de una viruta y el resultado de la simulación por elementos finitos de un corte ortogonal (la velocidad de corte es perpendicular al filo de la herramienta). En este caso se muestra la deformación equivalente unitaria ϵ , que es hasta cuatro veces la longitud inicial. En las imágenes se distinguen tres zonas:

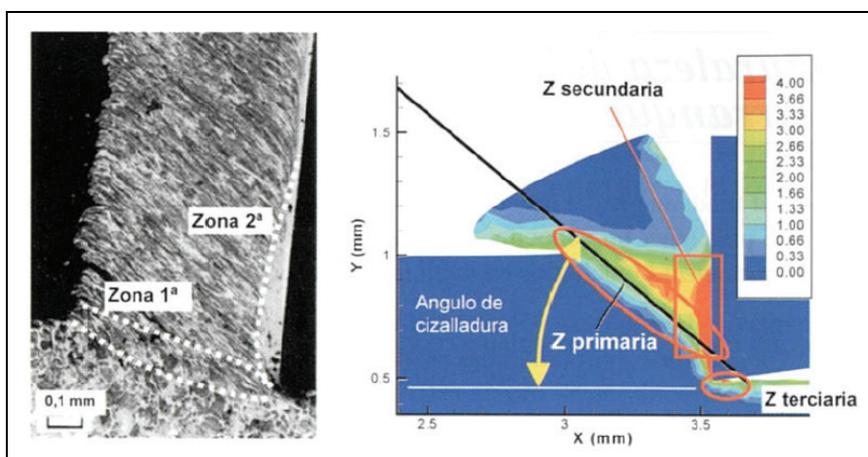


Figura 4.2. Zonas en el proceso de cizalladura (imagen tomada de [283])

- *Zona de cizalladura primaria*, situada delante del filo y con una orientación de Φ grados sobre la superficie mecanizada. En esta zona se produce un cizallamiento severo del material, que sale en forma de viruta deslizándose a lo largo de la cara de desprendimiento. Puede aproximarse a un plano aunque es todo un volumen. La deformación de material en esta zona se traduce en una enorme energía de deformación que se convierte en calor.
- *Zona de cizalladura secundaria*, situada en la zona de la viruta sobre la cara de desprendimiento de la herramienta. En esta zona se produce un gran rozamiento entre viruta y herramienta debido a la presión y temperaturas alcanzadas, que llega incluso en algunos casos a los 1.200 °C. Por este motivo el material se deforma en planos paralelos a la dirección de la salida de la viruta.
- *Zona de cizalladura terciaria*, en esta región de dimensiones reducidas se produce una deformación de la superficie de la pieza similar a una laminación. El aplastamiento generalmente provoca que la rugosidad superficial disminuya respecto a la teórica, y puede inducir tensiones residuales en la superficie mecanizada.

Los fenómenos que suceden en estas tres zonas generan calor pudiéndose hacer la siguiente aproximación según su procedencia:

- El 80% es generado en la deformación del material en la *zona primaria*.
- El 18% se genera en la deformación de la *zona secundaria* y por la fricción de la viruta con la herramienta en esta zona.
- El 2% se genera por el rozamiento de la punta de corte sobre la superficie de la zona.

A velocidades de corte moderadas parte del calor se transmite a la superficie de la herramienta, provocándose el aumento de la temperatura del filo y del cuerpo de la herramienta. Este hecho está basado en los primeros estudios de Taylor, el cual relacionaba la vida de la herramienta con la velocidad de corte. A medida que la velocidad crecía, Taylor demostró que la vida de la herramienta disminuía [284]. Lo más tradicional para combatir el calentamiento es utilizar condiciones de corte moderadas y refrigerar exteriormente el sistema con líquidos refrigerantes/lubricantes, que pueden ser aceite de corte o en la mayor parte de los casos taladrina (emulsión de aceite, 5-10%, en agua). Otra solución es dotar a la herramienta de una gran resistencia térmica, bien porque el material base posee gran resistencia o bien porque se le ha dotado de un recubrimiento superficial que se aplica sobre el acero HSS (*High Speed Steel* - herramientas de acero rápido) o metal duro.

Volviendo nuevamente al proceso y analizándolo desde el punto de vista físico, aunque el proceso tiene lugar solamente en una pequeña porción del metal que se está trabajando, es un proceso bastante complejo de modelizar. El proceso de arranque es un proceso de deformación. A lo largo del siglo XX se ha intentado crear un modelo adecuado que explique el fenómeno y permita predecir tres aspectos fundamentales: la forma de la viruta, las fuerzas existentes y las temperaturas en el corte. Sin embargo, a fecha de hoy no existe un modelo totalmente aceptado y que describa el fenómeno en su totalidad. Incluso en libro aparecidos en 1999 [285] se duda de algunas ideas tomadas como ciertas por autores previos.

El modelo básico de formación de la viruta fue primeramente planteado por Usachev [286], aunque fue retomado más tarde por Merchant [287] y con ese nombre suele conocerse. Este modelo considera que la cizalladura del material se ubica en un plano, denominado *plano de cizalladura*. Este plano se encuentra inclinado un ángulo Φ respecto a la línea de corte, denominado *ángulo de cizalladura*. Evidentemente no puede ser un plano, pues de ser así en él se produciría una velocidad de cizallamiento infinita, pero puede considerarse una zona muy estrecha.

En la Figura 4.3 se observan las dos representaciones gráficas principales del modelo, la de la izquierda es denominada círculo de Merchant.

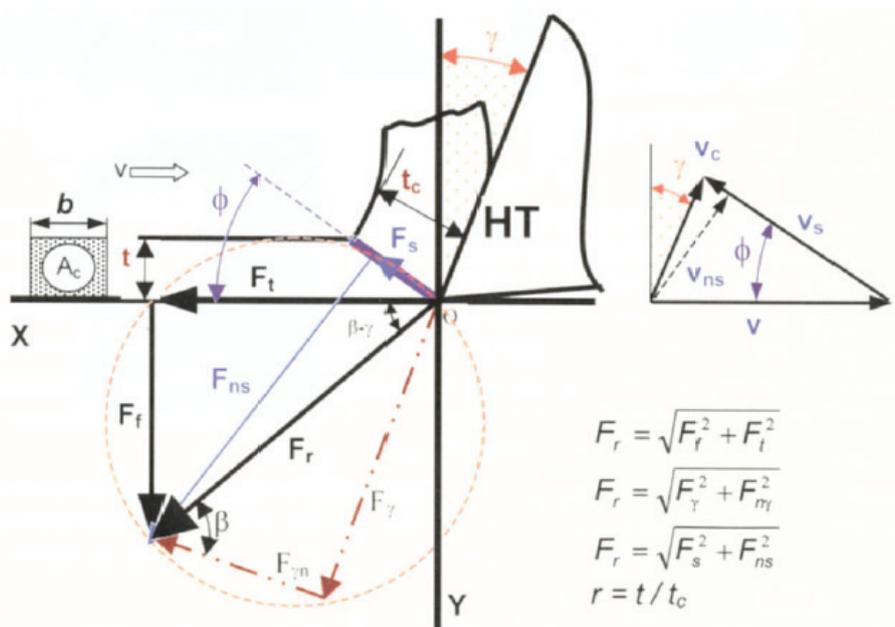


Figura 4.3. Descomposición de las fuerzas y de las velocidades en el modelo de plano de cizalladura (imagen tomada de [283])

La fuerza surgida en el proceso F_r se puede descomponer en varias direcciones perpendiculares, que dan lugar a las siguientes componentes de fuerza:

- F_t : fuerza de corte o fuerza tangencial, en la dirección de la velocidad de corte (v). De disponer de un sistema experimental de medida se obtendría directamente, de ahí su importancia.
- F_f : fuerza de avance, en la dirección de la profundidad de corte (t). También fácilmente medible.
- F_r : fuerza total ejercida entre herramienta y pieza.

Si la fuerza se descompone en la dirección de la cara de desprendimiento y su perpendicular, se tienen:

- $F_{n\gamma}$: fuerza normal a la cara de desprendimiento, que origina una compresión sobre la herramienta.
- F_γ : fuerza de fricción.

Por último, si la fuerza se descompone en el plano de cizalladura y el normal a éste, se tienen:

- F_s : fuerza de cizalladura.
- F_{ns} : fuerza normal al plano de cizalladura.

La velocidad de corte (v) se puede descomponer en la velocidad de la viruta (v_c) y la velocidad de cizalladura (v_s), tal como se observa en la figura anterior. Así:

$$v_s = (\cos \gamma / \cos(\Phi - \gamma))v \tag{4.1}$$

$$v_c = (\text{sen}\Phi / \cos(\Phi - \gamma))v = v \cdot r \quad (4.2)$$

Ciertamente, el símbolo de la velocidad de corte es v , no v_c que es la velocidad de salida de la viruta. Sin embargo, cuando se habla de procesos pero no se entra en detalle de la microgeometría del corte, v_c haces siempre referencia a la velocidad de corte. Así se considerará de aquí en adelante.

La deformación por cizalladura ocurrida en el plano se obtiene como resultado de

$$\varepsilon_r = v_s / v_{ns} = \cos \gamma / (\text{sen}\Phi \cos(\Phi - \gamma)) \quad (4.3)$$

Tal y como se ha podido observar, debido a la complejidad del proceso, se efectúan importantes simplificaciones del mismo que lo hacen manejable computacionalmente, con el objetivo de proveer una base de ingeniería para su control y explotación. El proceso puede ser representado en términos simples como una fuerza producida en la superficie de la pieza que se está cortando. Tomando como referencia la pieza, esta fuerza y sus componentes cambian en el tiempo y en el espacio. Por lo tanto, es interesante analizar como las componentes de la fuerza de corte varían con el resto de variables y parámetros del proceso. De este modo, otro enfoque posible para la caracterización y construcción de un modelo busca relaciones del tipo:

$$F_t = K_t \cdot t \cdot b \quad (4.4)$$

donde K_t es un coeficiente que depende del materia, herramienta y de la profundidad de corte. Este coeficiente en procesos sencillos suele denominarse p_s , *fuerza específica de corte* o *potencia específica de corte*. La razón de denominarle *fuerza específica* es que indica la fuerza necesaria para arrancar una unidad de sección de material. Y *potencia* porque si multiplicamos la anterior expresión por la velocidad v , surge:

$$P = F_t \cdot v = K_t \cdot t \cdot b \cdot v = K_t V / \text{tiempo} \quad (4.5)$$

donde V es el volumen de material arrancado, y por tanto K_t es la energía necesaria para arrancar una unidad de volumen de material. Es decir, la misma magnitud empleando unidades coherentes.

La componente de la fuerza F_t se obtiene mediante otro coeficiente K_f , que presenta la misma dependencia del material, herramienta y de la profundidad de corte que K_t .

Como se ha indicado, estos coeficientes empíricos K no son constantes, aunque se pueden encontrar en la literatura valores de los mismos para diversos materiales [283]. También existen en la bibliografía leyes obtenidas por experimentación que permiten determinar aproximadamente el valor de K para otros espesores y ángulos de desprendimiento.

Toda la bibliografía referente a los modelos de procesos de arranque de viruta considera también importantísimas variables como la temperatura en el proceso, así como los temas relacionados con el contacto de la viruta y la herramienta, y las diversos tipos de viruta que se pueden formar. Sin embargo, todos estos temas están fuera del alcance de este trabajo, pudiéndose ampliar información acerca de los mismos en cualquier bibliografía acerca del proceso de arranque de viruta.

El objetivo de este apartado ha sido fundamentar la complejidad de los procesos de mecanizado y comprobar como, en la mayoría de los trabajo se realizan ciertas simplificaciones del proceso. Pese a estas simplificaciones y puesto que el mecanizado es un componente importante dentro del conjunto de las actividades de fabricación, muchas de las características del proceso han sido y todavía siguen siendo muy estudiadas. Por ejemplo, existen multitud de trabajos que tratan el fenómeno de las vibraciones (forzadas y autoexcitadas) que aparecen en virtud de la variabilidad de las componentes de la fuerza de corte en función de la carga de la

viruta y de la velocidad. Estos estudios se realizan debido a que la aparición de estas vibraciones resulta muy nociva para la vida de la herramienta, para la geometría y el acabado de la pieza y, también, para la propia máquina herramienta. El control de la viruta y las medidas para reducir el desgaste de la herramienta, por diseño o por el uso de fluidos de corte, son también áreas de investigación y desarrollo muy activas [288]. Para una mayor información acerca de las nuevas áreas de estudio, consultar el Capítulo 2.

4.1.2. El Mecanizado de Alto Rendimiento

La bibliografía existente acerca de los procesos de eliminación de material y sus fundamentos (en los aspectos más tradicionales del mecanizado) es abundante y de calidad. Sin embargo, en lo que se refiere a *Mecanizado de Alto Rendimiento* la bibliografía existente es escasa y, en ciertos casos, errónea en sus términos. La principal causa es que parte de la bibliografía en castellano a hecho una traducción no muy correcta de los términos empleados en la bibliografía de habla inglesa. Nuevamente, en este trabajo se vuelven a tomar las bases de los conceptos aportados en [283].

A grandes rasgos, el *Mecanizado de Alto Rendimiento (MAR)* se puede entender como todo aquello que aporta mejoras sustanciales, respecto de los procesos de mecanizado tradicionales, aumentando el valor añadido del proceso. Usualmente el concepto de mecanizado de alto rendimiento se confunde con el término *Mecanizado a Alta Velocidad*. La razón es que tradicionalmente, y así se recoge en los libros anteriores a 1980, el *Mecanizado de Alto Rendimiento* hacía referencia a aquel que aplica simultáneamente grandes avances y profundidades de corte, pero manteniendo las velocidades de corte consideradas convencionales. Con estas condiciones de operación surgen virutas de gran tamaño. Este proceso debe de ejecutarse en máquinas-herramienta con cabezales de gran potencia y estructura rígida. En inglés se denomina *High Removal Rate Machining*, un término más específico y descriptivo que lo entendible en el más vago de “alto rendimiento”, aunque diversos autores utilizan también el término *High Performance Machining Process*.

Aplicando grandes avances y con elevadas profundidades de corte se generan espesores de viruta muy superiores al caso convencional (las fuerzas de corte crecen casi en proporción directa a la sección de viruta). Por tanto, en este planteamiento nos acercamos a dos tipos de problemas: el posible fallo catastrófico de las herramientas (*rotura*) debido a las elevadas fuerzas de corte o las roturas de filos en múltiples puntos (*chipping*). Por este motivo este tipo de mecanizado solo es aplicable a materiales blandos, como es el caso de las aleaciones ligeras, aceros de baja resistencia o aceros antes del endurecimiento por tratamiento de temple.

Hoy en día, y en nuestro contexto, el concepto *MAR (Mecanizado de Alto Rendimiento)* es mucho más general, refiriéndose a toda tecnología de arranque de viruta que mejore sustancialmente dos aspectos del proceso [283]:

- La **productividad**, medida como tasa de arranque, es decir, cantidad de material eliminado por unidad de tiempo. También debe procurarse mecanizar en condiciones que induzcan un desgaste no excesivo de las herramientas.
- La **calidad**, en cuanto a una mayor precisión dimensional y una menor rugosidad de las superficies.

Ha existido en los últimos 15 años una pequeña revolución referente a la mejora de los procesos y al aumento del conocimiento de los mismos. Las razones pueden ser diversas:

- Los materiales constitutivos de los componentes fabricados poseen mayores prestaciones mecánicas, lo que conlleva casi siempre una menor maquinabilidad. Un buen ejemplo es el creciente uso de las aleaciones de titanio, aleaciones de níquel y cobalto (termorresistentes), composites infiltrados de *CSi*, etc.

- Las herramientas de corte han mejorado mucho en los últimos 15 años, han aparecido nuevas calidades de metal duro, se han perfeccionado los materiales extraduros (Nitruro de Boro Cúbico Policristalino, *PCBN*, y Diamante Policristalino, *PCD*). Las herramientas tienden a especializarse cada vez más en una aplicación, abandonando su propósito de ser de aplicación en muchos grupos de materiales.
- A la mejora del rendimiento de las herramientas ha contribuido decisivamente el desarrollo de nuevos recubrimientos, cada vez más duros y resistentes a elevadas temperaturas. El recubrimiento de *TiAlN* aplicado por tecnología *PVD* (*Physical Vapor Deposition*) ha sido de enorme importancia.
- Se ha comprobado que el conocimiento en detalle de los procesos y su modelización contribuye a ganar dinero. Es decir, se saca valor del conocimiento pese a que éste todavía puede ser limitado. Un ejemplo es la predicción de las condiciones de estabilidad del fresado.
- En Europa y en España, el sector de la máquina-herramienta y de fabricación por mecanizado es de gran importancia, por lo que a él se han destinado recursos de investigación por parte de empresas y administraciones. No olvidemos que los procesos de mecanizado son considerados como estratégicos en los sectores de automoción, aeronáutico, de máquina-herramienta, y de fabricantes de moldes y matrices (sectores todos ellos de gran peso en la economía de una sociedad industrializada). Además, la mejora de la máquina y su proceso preocupa tanto a los constructores y suministradores de máquina herramienta como a los usuarios de las mismas.
- Las nuevas generaciones de máquinas herramienta son capaces de interactuar con su entorno, sin embargo, existe un gran vacío en las tecnologías necesarias y en la inteligencia incorporada (a través de sistemas basados en técnicas de IA) para alcanzar un nivel cualitativamente superior de productividad. Es por ello que se requiere continuar aumentando la tasa de utilización de las máquinas herramienta, su precisión y, al mismo tiempo, disminuir los tiempos de producción.

La industria de los países desarrollados tiende a producir cada vez más componentes de mayor valor añadido. El término *rendimiento elevado* se refiere a todo aquello que contribuye a aumentar este valor, bien porque disminuye los tiempos de producción y costes o porque aumenta la calidad de lo fabricado.

Por tanto, hoy en día se entiende como *Mecanizado de Alto Rendimiento* todo aquel que incorpora una mejora notable respecto a la forma tradicional de mecanizar, aumentando el valor añadido del proceso tanto en productividad como en calidad. *Los procesos de Mecanizado de Alto Rendimiento* imponen nuevos conceptos y estrategias de diseño mecánico en los elementos de la máquina herramienta, así como en el rediseño drástico de todos los esquemas relacionados con los sistemas de monitorización, control y supervisión de los procesos [289]. La complejidad de los procesos de mecanizado, no-lineales, no-estacionarios y de naturaleza multivariable, se hace aún más patente en el nuevo concepto de *Mecanizado de Alto Rendimiento*.

Por contra, en el *Mecanizado de Alta Velocidad* la idea es contraria al concepto tradicional anteriormente mencionado. Entenderemos ahora como proceso de *Mecanizado de Alta Velocidad* a aquel proceso en el que se mantiene la sección de viruta, es decir el avance por diente y las condiciones de inmersión (profundidad de pasada), e incluso se reducen en gran medida, pero se eleva la velocidad de corte sobre lo habitual. No existe un valor exacto acerca de cuánto se eleva, pero se entiende que la velocidad de corte es sensiblemente mayor a la “tradicional” (x10, x20,...). Estos valores dependen también en gran parte de la combinación entre los materiales mecanizados y las herramientas utilizadas para hacerlo.



Figura 4.4. Máquina herramienta de Alta Velocidad para procesos de mecanizado

4.2. El Proceso de Taladrado

El taladrado representa uno de las operaciones de mecanizado más comunes en la industria manufacturera. En algunos países existen informes que afirman que las operaciones de taladrado representan cerca del 50% de las operaciones de mecanizado. Se llama taladrar a la operación de mecanizado que tiene por objeto producir agujeros cilíndricos en una pieza cualquiera, utilizando como herramienta una broca. La operación de taladrar se puede hacer con un taladro portátil, con una máquina taladradora o en un centro de mecanizado equipado con CNC (*Computerized Numerical Control* – Control Numérico Computerizado) [290]. Esta última opción es la más contemporánea y, además, es la opción utilizada en este trabajo.

El taladrado es un término que cubre todos los métodos para producir agujeros cilíndricos en una pieza con herramientas de arranque de viruta. Además del taladrado de agujeros cortos y largos, también cubre el trepanado y los mecanizados posteriores tales como escariado, mandrinado, roscado y brochado (en el presente trabajo nos centraremos en la propia operación de taladrado). La diferencia entre taladrado corto y taladrado profundo consiste en que el taladrado profundo es una técnica específica diferente que se utiliza para mecanizar agujeros donde su longitud es varias veces más larga (entre 8-9 veces) que su diámetro.

Con el desarrollo de las brocas basadas en nuevo materiales, el proceso de taladrado ha cambiado de manera drástica ya que con esta serie de brocas se consigue que un taladro macizo de diámetro grande se pueda realizar en una sola operación, sin necesidad de un agujero previo, ni de agujero guía. Además, producen mejores calidades del mecanizado y mayor exactitud del agujero que evita la operación posterior de escariado.

Como todo proceso de mecanizado por arranque de viruta, la evacuación de la misma se torna crítica cuando el agujero es bastante profundo. Por eso, el taladrado está restringido según sean las características del mismo. Cuanto mayor sea su profundidad, más importante es el control del proceso, el fluido refrigerante y la evacuación de la viruta. Estos factores son muy importantes en el proceso de taladrado. La generación de formas y tamaños de viruta adecuados, además de su evacuación, es vital para realizar correctamente cualquier operación de taladrado. Si el proceso no es correcto, cualquier broca dejará de cortar después de poco tiempo porque la

viruta se quedará atascada en el agujero. Con las brocas modernas las velocidades de perforación son muy elevadas, pero éstas solo han sido posibles gracias a la evacuación eficaz de la viruta mediante el fluido de corte. Todas las brocas helicoidales disponen de canales para evacuar la viruta. Durante el mecanizado se inyecta fluido de corte en la punta de la broca para lubricarla y para evacuar la viruta por los canales. La formación de la viruta está determinada por el material de la pieza, la geometría de la herramienta, la velocidad de corte y en cierta medida por el tipo de lubricante que se utilice. La forma y longitud de la viruta son aceptables siempre que permitan su evacuación de manera fiable.

Al igual que en los procesos de mecanizado en general, en el proceso de taladrado, el término “alta velocidad” se refiere a operaciones de taladrado que utilizan parámetros de corte (velocidades y avances) muy superiores a los utilizados convencionalmente. Sin embargo, no existe una velocidad determinada como umbral, sino que consiste en una determinada combinación de pieza, máquina herramienta, herramienta y velocidades óptimas de corte. Mediante una adecuada elección de estos parámetros, conseguiremos la deseada reducción de tiempos de mecanizado y una muy buena precisión, tanto dimensional como geométrica.

El *Taladrado de Alto Rendimiento*, que se encuentra un paso por encima del *Taladrado de Alta Velocidad*, ofrece otra serie de ventajas sobre el taladrado convencional como, entre otras:

- Altos caudales de viruta (cantidades de virutas cortadas en la unidad de tiempo) y, como consecuencia, importantes reducciones de tiempos de mecanizado que se traducen en menores tiempos de fabricación y reducción de costes.
- Obtención de formas críticas a causa de la reducción de fuerzas y esfuerzos de corte (reducción de deformaciones sobre la pieza).
- Mecanizado de materiales tratados de alta dureza.

Como contrapartida, el *Taladrado de Alto Rendimiento* requiere disponer de una serie de condiciones específicas en lo que se refiere principalmente a:

- Características de la propia máquina herramienta y sus complementos (utillaje de fijación de pieza, porta-herramientas, etc.).
- Características de la herramienta de corte (material del substrato, configuración, calidad geométrico-dimensional y de acabado superficial, etc.).
- Diseños de proceso optimizados (condiciones de corte, secuencias de movimientos, recorridos, trayectorias).
- Sistemas de seguridad y protección adecuados ante potenciales riesgos de incidentes. En todo momento resulta imprescindible considerar las características de la pieza a mecanizar, material, morfología, exigencias en cuanto a calidades geométrica-dimensional y de acabado superficial, etc.

En términos generales, cuando nos referimos específicamente al proceso de *Taladrado de Alto Rendimiento*, debemos considerar como cuestiones fundamentales e importantes la velocidad de la operación, la eficiencia del sistema y la estabilidad-repetibilidad del proceso. Posteriormente y a la hora de controlar el proceso habrá que hacer hincapié en la productividad, en la calidad dimensional y superficial, sin olvidar el respeto al medioambiente.

A continuación se tratará de aportar una visión más amplia acerca de los parámetros de corte envueltos en una operación de taladrado y de los fenómenos que ocurren durante la misma.



Figura 4.5. Detalle del proceso de Taladrado de Alto Rendimiento

4.2.1. Parámetros de Corte en el Proceso de Taladrado

Cabe destacar una vez más, que se trata de un proceso de *Taladrado de Alto Rendimiento* cuando aumenta el valor añadido del proceso tanto en productividad como en calidad. Por contra, el *Taladrado a Alta Velocidad* se trabaja a altas velocidades de corte considerando las restricciones del material (dureza), la herramienta y la propia máquina herramienta. No obstante, a la hora de explicar los parámetros de corte en el proceso de taladrado, no existen distinciones en la definición de los parámetros para todos los tipos de operaciones (taladrado convencional, de alta velocidad y de alto rendimiento).

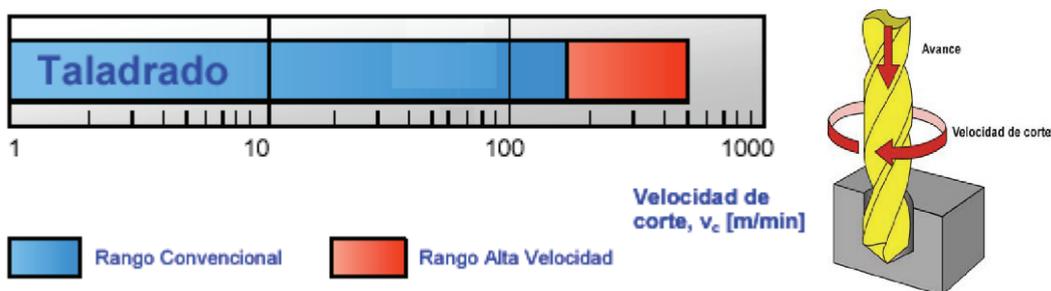


Figura 4.6. Velocidades de corte en el Taladrado a Alta Velocidad

Pese a que ya se han mencionado algunos parámetros de corte en el proceso de arranque de viruta, los parámetros de corte fundamentales, así como otra serie de parámetros y variables que hay que considerar en el proceso de taladrado son los siguientes:

- Elección del tipo de broca más adecuado
- Sistema de fijación de la pieza
- Velocidad de corte de la broca

- Diámetro exterior de la broca
- Revoluciones por minuto del husillo portabrocas
- Avance de la broca
- Profundidad del agujero
- Esfuerzos de corte (fuerzas y pares)
- Tipo de taladradora y accesorios adecuados (refrigeración, etc.)

Muchos de estos parámetros y variables dependen exclusivamente de la broca o de la máquina elegida en función del material que se quiera taladrar o, simplemente, de la infraestructura de la que se disponga. En este trabajo nos vamos a centrar directamente en los parámetros de corte que tienen lugar en el proceso, una vez que ya se han fijado ciertos parámetros a partir de la información proporcionada en manuales de usuarios y en el conocimiento de operadores expertos.

Velocidad de Corte

Se define como *Velocidad de corte* (v_c) la velocidad lineal de la periferia de la broca u otra herramienta que se utilice en la taladradora (escariador, macho de roscar, etc.). La velocidad de corte, que se expresa normalmente en metros por minuto (m/min), tiene que ser elegida antes de iniciar el mecanizado y su valor adecuado depende de muchos factores, especialmente de la calidad y tipo de broca que se utilice, de la dureza y la maquinabilidad que tenga el material que se mecanice, y de la velocidad de avance empleada. Las limitaciones principales de la máquina son su gama de velocidades, la potencia de los motores y la rigidez de la fijación de la pieza y de la herramienta.

A partir de la determinación de la velocidad de corte se puede determinar las revoluciones por minuto que tendrá el husillo portabrocas según la siguiente fórmula:

$$v_c = \frac{N \cdot \pi \cdot D_c}{1000} \quad (4.6)$$

donde v_c es la velocidad de corte (usualmente en m/min), N es la velocidad de rotación de la herramienta en (usualmente en min^{-1}) y D_c es el diámetro de la herramienta (normalmente en mm).

La velocidad de corte es uno de los factores principales que determinan la duración de la herramienta. Una alta velocidad de corte permite realizar el mecanizado en menos tiempo pero acelera el desgaste de la herramienta. Los fabricantes de herramientas y proutuarios de mecanizado, ofrecen datos orientativos sobre la velocidad de corte adecuada de las herramientas para una duración determinada de la herramienta, por ejemplo, quince minutos. En ocasiones, es deseable ajustar la velocidad de corte para una duración diferente de la herramienta, para lo cual, los valores de la velocidad de corte se multiplican por un factor de corrección. La relación entre este factor de corrección y la duración de la herramienta en operación de corte no es lineal.

En resumen, una velocidad de corte excesiva puede dar lugar a: un desgaste muy rápido del filo de corte de la herramienta, una deformación plástica del filo de corte con pérdida de tolerancia del mecanizado, o una calidad del mecanizado deficiente. Por contra, una velocidad de corte demasiado baja puede dar lugar a: una formación de filo de aportación en la herramienta, un efecto negativo sobre la evacuación de viruta, una baja productividad y un coste elevado del mecanizado.

Velocidad de Rotación de la Broca

La *Velocidad de rotación* del husillo portabrocas (N) se expresa habitualmente en revoluciones por minuto (rpm). En las taladradoras convencionales hay una gama limitada de velocidades, que dependen de la velocidad de giro del motor principal y del número de velocidades de la caja de cambios de la máquina. En las taladradoras de control numérico, esta velocidad es controlada con un sistema de realimentación que habitualmente utiliza un variador de frecuencia y puede seleccionarse una velocidad cualquiera dentro de un rango de velocidades, hasta una determinada velocidad máxima.

La velocidad de rotación de la herramienta es directamente proporcional a la velocidad de corte y al diámetro de la herramienta.

$$N = \frac{v_c \cdot 1000}{\pi \cdot D_c} \quad (4.7)$$

Velocidad de Avance

El avance o *Velocidad de avance* (f) en el taladrado es la velocidad relativa entre la pieza y la herramienta, es decir, la velocidad con la que progresa el corte. El avance de la herramienta de corte es un factor muy importante en el proceso de taladrado.

Cada broca puede cortar adecuadamente en un rango de velocidades de avance por cada revolución de la herramienta, denominado *Avance por revolución* (f_z). Este rango depende fundamentalmente del diámetro de la broca, de la profundidad del agujero, además del tipo de material de la pieza y de la calidad de la broca. Este rango de velocidades se determina experimentalmente y se encuentra en los catálogos de los fabricantes de brocas. Además esta velocidad está limitada por las rigideces de las sujeciones de la pieza y de la herramienta, y por la potencia del motor de avance de la máquina. El grosor máximo de viruta en milímetros es el indicador de limitación más importante para una broca. El filo de corte de las herramientas se prueba para que tenga un valor determinado entre un mínimo y un máximo de grosor de la viruta.

La velocidad de avance es el producto del avance por revolución por la velocidad de rotación de la herramienta.

$$f = N \times f_z \quad (4.8)$$

Al igual que con la velocidad de rotación de la herramienta, en las taladradoras convencionales la velocidad de avance se selecciona de una gama de velocidades disponibles, mientras que las taladradoras de control numérico pueden trabajar con cualquier velocidad de avance hasta la máxima velocidad de avance de la máquina.

Los principales efectos de la velocidad de avance son que resulta decisiva para la formación de viruta, que afecta al consumo de potencia de la máquina y que, además, contribuye a la tensión mecánica y térmica.

La elección de una elevada velocidad de avance da lugar a un buen control de viruta, un menor tiempo de corte, un menor desgaste de la herramienta, un riesgo más alto de rotura de la herramienta y una elevada rugosidad superficial del mecanizado. Por contra, la elección de una velocidad de avance baja produce una viruta más larga, una mejor calidad del mecanizado, un desgaste acelerado de la herramienta, una mayor duración del tiempo de mecanizado y en general, un mayor coste del mecanizado.

Tiempo de Mecanizado

Para poder calcular el *Tiempo de mecanizado* (T) de un taladro hay que tener en cuenta la longitud de aproximación y salida de la broca de la pieza que se mecaniza. La longitud de

aproximación depende del diámetro de la broca. Normalmente las longitudes se expresan en milímetros y el tiempo de mecanizado en minutos

$$T = \frac{L_{acercamiento} + L_{taladrar}}{f} \quad (4.9)$$

4.2.2. Enfoque Sistémico del Proceso de Taladrado

Hasta ahora se ha venido estudiando el proceso de taladrado desde un punto de vista mecánico. Sin embargo, no hay que olvidar que el fin último de este trabajo de investigación es desarrollar un sistema de control y, para ello, es necesario tratar al proceso de taladrado desde la Teoría de Sistemas. En el apartado anterior se han analizado algunos de los parámetros del proceso (mecánicamente hablando) pero, llegados a este punto, se debe reelaborar esta información del proceso de taladrado dándole un enfoque orientado hacia el control. En este sentido, ya no cabe hablar únicamente de parámetros del proceso sino que hemos de diferenciar entre entradas al proceso, salidas, perturbaciones y parámetros. La Figura 4.7 trata de dar respuesta a esta cuestión. En ella se pueden observar algunas de las posibles entradas, salidas, perturbaciones y parámetros del proceso.



Figura 4.7. Posible enfoque sistémico del proceso de taladrado

Tal y como dicta la Teoría de Control, entenderemos de aquí en adelante como variable aquella que cambia a lo largo del tiempo de duración del proceso, y como parámetro aquella variable que, pudiendo tomar distintos valores, se fija como constante al comienzo de cada operación.

Bajo este nuevo enfoque, nos encontramos ahora con que el proceso de taladrado tiene como posibles variables de entrada, variables de salida, parámetros y perturbaciones las reflejadas en la Figura 4.7. Sin embargo, como se puede observar existen ciertas variables que se pueden tomar como parámetros o ciertos parámetros que se pueden tomar como perturbaciones. Tal es el caso de, por ejemplo, el desgaste de la herramienta o la dureza del material a taladrar.

Por tanto, es necesario aclarar si ciertas características se toman como variables de entrada o salida, como perturbaciones no medibles, etc. Además, es necesario también reducir la complejidad del problema. De este modo, se decide aportar el siguiente enfoque sistémico, resumido en la Figura 4.8, que es el que se utilizará a lo largo de este trabajo de investigación para el proceso de taladrado.

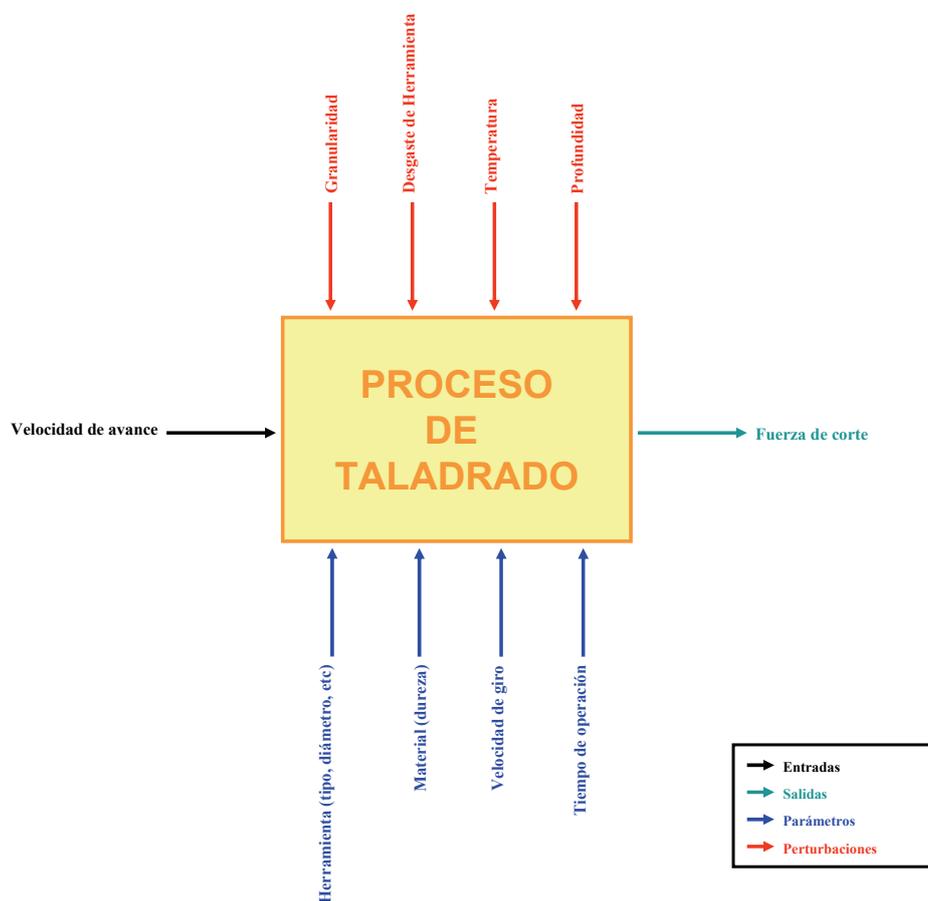


Figura 4.8. Enfoque sistémico del proceso de taladrado utilizado en este trabajo

Así, se decide reducir el sistema a una entrada y una salida, siendo la velocidad de avance de la herramienta de corte (f) la variable de entrada y la fuerza media de corte (F) la variable de salida. Como parámetros del proceso se fijan la velocidad de giro de la herramienta, el diámetro de la herramienta de corte y la velocidad de avance inicial. De este modo, quedan entonces como perturbaciones no medibles ni estimables el desgaste de la herramienta de corte, la

granularidad del material a mecanizar y las posibles variaciones en la profundidad de corte. El resto de variables no recogidas en este enfoque quedan también como perturbaciones al proceso.

4.2.3. Modelo (Utilizado en Simulación)

Tal y como se ha podido ver a lo largo de este capítulo, el proceso de taladrado, al igual que el resto de procesos de mecanizado, es un proceso complejo, fuertemente no-lineal, cargado de incertidumbre y que, además, posee un comportamiento imposible de describir exactamente por herramientas de modelado convencionales. Por consiguiente, no existe un modelo completamente válido que sea capaz de representar el proceso de taladrado en su totalidad. Precisamente por ese motivo, este trabajo utiliza técnicas de Inteligencia Artificial para tratar con este problema (ver Capítulo 5). Sin embargo, para demostrar la validez del modelado y control del proceso de taladrado de alto rendimiento mediante técnicas neuroborrosas que plantea este trabajo, se hace necesaria la realización de ciertas simulaciones antes de llevar a cabo el control en tiempo real sobre el proceso industrial. Para una mayor comprensión del proceso y para el desarrollo de estas simulaciones se necesita utilizar uno de los múltiples modelos vistos en la literatura (ver Capítulo 2).

Por estos motivos, se decide utilizar uno de los modelos obtenidos por Del Toro *et al.* debido a su afinidad con las características del proceso que en último término deseamos controlar [237]. Al igual que en la mayoría de modelos que nos ofrece la literatura en este campo (ver Capítulo 2), se considera el sistema de una entrada y una salida. Esta elección se hace a partir del análisis sistémico del proceso y del conocimiento técnico del mismo. Como entrada se tiene la *velocidad de avance* de la herramienta de corte (f), y como salida, la *fuerza media de corte* (F) cuya importancia ya fue explicada.

El proceso de taladrado está considerado un proceso no lineal. Sin embargo, la representación mediante un modelo lineal proporciona una descripción aproximada del proceso, que ayuda a investigar y analizar las posibles vías de mejoras mediante sistemas de control. En este trabajo se ha utilizado como base un modelo lineal representado por una función de transferencia de tercer orden [237]:

$$G_p(s) = \frac{F(s)}{f(s)} = \frac{10.26}{0.005241s^3 + 0.09376s^2 + 0.5414s + 1} e^{-0.4s} \quad (4.10)$$

donde $f(s)$ es la velocidad de avance, $F(s)$ es la fuerza de corte y $G_p(s)$ es la función de transferencia del proceso en el dominio de Laplace.

En dicho trabajo se comprobó experimentalmente que la fuerza de corte tiene una relación directa con la velocidad de avance. El modelo lineal representado describe de forma aproximada el comportamiento dinámico del proceso de taladrado para una condición de operación determinada y considerando una profundidad de corte pequeña (menor que un quinto del diámetro de la broca).

Tal y como se aprecia en (4.10), el modelo contiene un retardo. Este retardo incluye tanto el tiempo muerto del proceso como los retardos inducidos por las redes de comunicaciones asumiendo, como veremos más adelante, que el conjunto “Proceso+CNC” está conectado a través de una red Profibus. En el Capítulo 5 de este trabajo se detallará y explicará más en profundidad el origen y la duración del retardo (sección 5.1.1).

Nuevamente es necesario aclarar que la ecuación (4.10) se ha incorporado al trabajo con el objeto de mostrar modelos lineales que suponen una aproximación al proceso de taladrado. Este modelo solo representa una aproximación a la dinámica real del proceso de taladrado en unas condiciones de operación ideales. Cualquier conclusión obtenida a partir de la simulación ó

implementación basada en ese modelo, al igual que cualquier diseño de sistema de control basado en el mismo, tienen una utilidad práctica muy restringida.

A pesar de estas restricciones, gracias al modelado lineal del proceso se ha podido comprobar que la reducción del tiempo de producción en un proceso de taladrado está relacionada directamente con una mayor tasa de arranque de material, con un aprovechamiento de toda la vida útil la herramienta de corte (minimizando rotura o aceleración del desgaste) y con la obtención de la calidad requerida en el acabado. No obstante, no son las únicas variables que influyen en la operación de taladrado.

4.3. El Proceso de Torneado

Se llama torneado a la operación de mecanizado que se realiza en cualquiera de los tipos de torno que existen. El proceso de torneado consiste en las operaciones de mecanizado que se realizan en los ejes de revolución u otros componentes que tengan mecanizados cilíndricos concéntricos (tanto exteriores como interiores) o perpendiculares a un eje de rotación. Para efectuar el proceso de torneado, los tornos disponen de accesorios adecuados para fijar las piezas en la máquina y de las herramientas adecuadas que permiten realizar todas las operaciones de torneado que cada pieza requiera.

Hoy por hoy, los mecanizados complejos y de precisión se realizan en tornos dotados de CNC, y las series grandes de piezas se realizan en torno automático. Sin embargo, aún quedan muchos mecanizados que se realizan en torno paralelo donde se requiere una buena pericia y profesionalidad de parte de los operarios que los manejan [291].

En un torno paralelo universal se pueden realizar las siguientes operaciones de torneado:

- *Torneado exterior*: cilindrado, refrentado, ranurado, roscado, moleteado, cilindrado cónico, cilindrado esférico, segado, chaflanado.
- *Torneado interior*: taladrado, mandrinado, ranurado interior, mandrinado cónico, mandrinado esférico, roscado interior, refrentado interior, chaflanado interior.

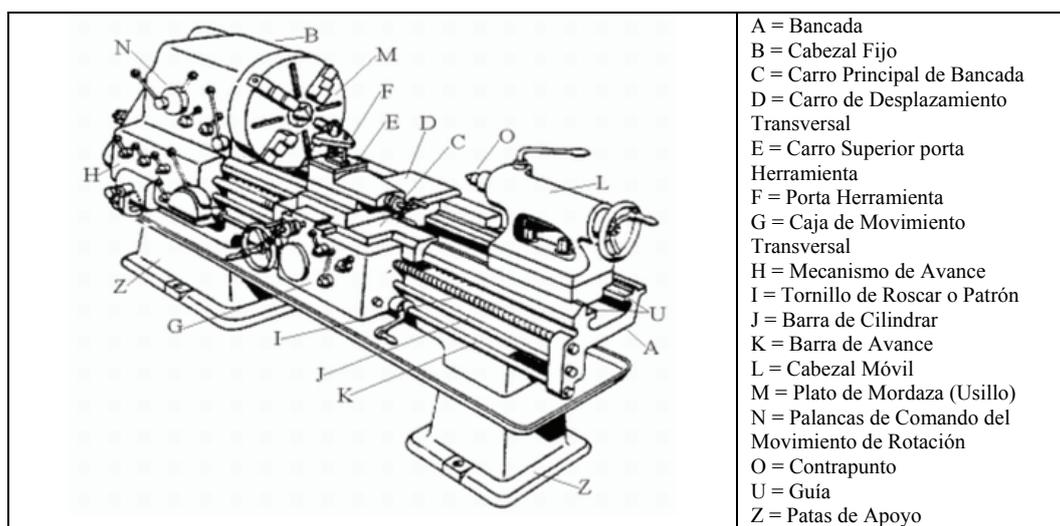


Figura 4.9. Torno paralelo y partes que lo constituyen

Hoy en día, en todas las operaciones de mecanizado, y particularmente en el proceso de torneado, es de vital importancia hacer una selección adecuada de las herramientas que permita realizar los mecanizados en el menor tiempo posible y en las condiciones de precisión y calidad

requeridas. La razón fundamental de esta cuidadosa selección es el alto coste que tiene el tiempo de mecanizado. Los principales factores a la hora de elegir una herramienta u otra se resumen en los siguientes:

- El diseño y las limitaciones de la pieza: tamaño, tolerancias del torneado, tendencia a vibraciones, sistemas de sujeción, acabado superficial, etc.
- Las operaciones de torneado a realizar: cilindrados exteriores o interiores, refrentados, ranurados, desbaste, acabados, optimización para realizar varias operaciones de forma simultánea, etc.
- La estabilidad y las condiciones de mecanizado: cortes intermitente, voladizo de la pieza, forma y estado de la pieza, estado, potencia y accionamiento de la máquina, etc.
- La disponibilidad y la selección del tipo de torno: posibilidad de automatizar el mecanizado, poder realizar varias operaciones de forma simultánea, serie de piezas a mecanizar, calidad y cantidad del refrigerante, etc.
- El material de la pieza: dureza, estado, resistencia, maquinabilidad, barra, fundición, forja, mecanizado en seco o con refrigerante, etc.
- La disponibilidad de herramientas: calidad de las herramientas, sistema de sujeción de la herramienta, acceso al distribuidor de herramientas, servicio técnico de herramientas, asesoramiento técnico.
- Los aspectos económicos del mecanizado: Optimización del mecanizado, duración de la herramienta, precio de la herramienta, precio del tiempo de mecanizado

En cierta serie de operaciones de torneado, como por ejemplo para mandrinar, es necesario contar con algunos requisitos especiales. Por ejemplo, se debe seleccionar el mayor diámetro de la barra posible y asegurar una buena evacuación de la viruta. También se debe seleccionar el menor voladizo posible de la barra y, a su vez, seleccionar herramientas de la mayor tenacidad posible

El proceso de torneado ha evolucionado tanto que ya no se trata tan solo de arrancar material a gran velocidad, sino que los parámetros que componen el proceso tienen que estar estrechamente controlados para asegurar los resultados finales de economía calidad y precisión [292].

La forma de tratar la viruta se convierte en un proceso complejo, donde intervienen todos los componentes tecnológicos del mecanizado, para que pueda tener el tamaño y la forma que no perturbe el proceso de trabajo. Si no fuera así, se acumularían rápidamente masas de virutas largas y fibrosas en el área de mecanizado que formarían madejas enmarañadas e incontrolables. La forma que toma la viruta se debe principalmente al material que se está cortando. El avance con el que se trabaje y la profundidad de pasada, son bastante responsables de la forma de viruta. Cuando no se puede controlar con estas variables hay que recurrir a elegir la herramienta que lleve incorporado un rompevirutas eficaz.

La evacuación de la viruta en el proceso de torneado puede ser problemática cuando se mecanizan piezas de acero, sobretodo si no se utiliza la herramienta adecuada con los ángulos de corte de acuerdo al material que se mecaniza (en función de la profundidad de pasada que tenga y del avance). Cuando se trabaja con las herramientas de metal duro, las velocidades de corte y avance son muy elevadas. En estos casos, la temperatura en el filo de la herramienta es muy alta y para prevenir un desgaste inmediato de la herramienta, o incluso su rotura, se hace necesario refrigerar la zona de corte con un bombeo abundante de aceite de corte o taladrina.

4.3.1. Parámetros de Corte en el Proceso de Torneado

En los procesos de torneado existen tres parámetros de corte claves: la velocidad de corte, el avance y la profundidad de pasada. Con ellos y el diámetro de la pieza se calculan los parámetros de máquina, que son la velocidad del cabezal y el avance lineal. Además se pueden también calcular otros valores secundarios como son la sección de viruta, caudal, etc., que son útiles para evaluar el rendimiento del proceso.

Velocidad de Corte

La *Velocidad de corte* (v ó v_c) es la velocidad periférica asociada a la rotación de la pieza. Define la velocidad relativa entre el filo de la herramienta y la pieza. Su elección viene determinada por el material de la herramienta, el tipo de material de la pieza y las características de la máquina. Una velocidad alta de corte permite realizar el mecanizado en menos tiempo, pero acelera el desgaste de la herramienta. La velocidad de corte se suele expresar generalmente en metros por minuto (m/min).

La velocidad de corte se calcula numéricamente por medio de la siguiente fórmula:

$$v_c = \frac{n \cdot \pi \cdot D}{1000} \quad (4.11)$$

donde v_c es la velocidad de corte (usualmente en m/min), N es igual a las revoluciones del motor principal (normalmente en rpm) y D representa el diámetro de la pieza en (generalmente en mm). En ocasiones, las revoluciones del motor también se denotan como S .

Avance

El *Avance* (f) es la distancia que recorre la herramienta por cada revolución de la pieza. Generalmente se mide en milímetros (mm). Conocido el avance y la velocidad del motor principal o cabezal (N), se obtiene la *Velocidad de avance* (v_f) mediante la expresión:

$$v_f = N \cdot f \quad (4.12)$$

donde v_f indica la velocidad de avance (usualmente en mm/min), f es el avance (usualmente en mm/rev) y N es igual a las revoluciones del motor principal (usualmente en rpm). En ocasiones, la velocidad de avance también se denota como F .

Generalmente, la velocidad de corte óptima de cada herramienta y el avance de la misma vienen indicados en el catálogo del fabricante de la herramienta o, en su defecto, en los prontuarios técnicos de mecanizado.

Profundidad de Pasada

Se define la *Profundidad de pasada* (a_p) como la distancia que penetra la herramienta en la dirección perpendicular a la velocidad de avance. Generalmente se mide en milímetros (mm).

Sección de Viruta y Espesor de Corte

Durante una operación de torneado, la herramienta está en contacto con una cantidad determinada del material. El área de contacto entre la cara de desprendimiento de la herramienta y la pieza se define como *Sección de viruta* (A_c).

La sección de viruta se puede obtener en función del avance y de la profundidad de pasada mediante la expresión:

$$A_c = f \cdot a_p \quad (4.13)$$

donde A_c es la sección de viruta (generalmente medida en mm), f es el avance (en mm/rev) y a_p es la profundidad de pasada

Aplicando esta expresión se comete un pequeño error, ya que la sección de viruta no es perfectamente trapezoidal. A efectos de cálculo el error cometido es despreciable

Por otro lado, partiendo de la geometría de la sección de viruta, se pueden definir otros dos parámetros: el espesor de viruta y la anchura de viruta. El *Espesor de corte*, también llamado a_c , mide la cantidad de material que está cortando la herramienta en dirección perpendicular al filo. El espesor es una magnitud importante, ya que está directamente relacionada con la fuerza de corte. La *Anchura de viruta* (b) representa la longitud del filo comprometido en el corte.

Tanto la anchura de viruta como el espesor de corte se obtienen a partir de la profundidad de pasada y el avance respectivamente, relacionándolos con el ángulo de posición del filo principal (k_r), que es característico de la forma de la plaquita de corte:

$$a_c = f \cdot \text{sen}(k_r) \quad (4.14)$$

$$b = \frac{a_p}{\text{sen}(k_r)} \quad (4.15)$$

donde a_c es el espesor de viruta (medido en mm), f es el avance (en mm/rev), b es la anchura de viruta (medida en mm), a_p es la profundidad de pasada y k_r es el ángulo de posición del filo principal. Así, la sección de viruta también se puede calcular como $A_c = b \cdot a_c$

Caudal de Viruta

El *Caudal de viruta* (Q) mide el volumen de viruta evacuado por unidad de tiempo, dando una idea de la productividad de la operación. Depende de la velocidad a la que se ejecute la operación y de la sección de viruta. El proceso de torneado es un proceso de corte en continuo y la sección de viruta se mantiene constante. Así, se puede calcular el caudal de viruta mediante la expresión:

$$Q = v_c \cdot A_c = v_c \cdot a_p \cdot f \quad (4.16)$$

donde Q es el caudal de viruta (en mm/min), v_c es la velocidad de corte (medida en mm/min), A_c es la sección de viruta (en mm), a_p es la profundidad de pasada (en mm) y f es el avance (medido en mm/rev).

4.3.2. Enfoque Sistémico del Proceso de Torneado

Al igual que sucedía en el caso del proceso de taladrado, las definiciones vistas hasta ahora para el proceso de torneado poseían un enfoque mecánico. Sin embargo, se deben definir cuáles son las entradas del proceso, sus salidas, cuáles son los parámetros y que se toma como perturbación, en otras palabras, es necesario definir el enfoque sistémico del proceso de torneado.

Nuevamente existen infinidad de combinaciones acerca de qué considerar como entrada, como salida, etc., ya que según el propósito que se desee conseguir, se decidirá tomar unas u otras posibilidades según convenga. Para el caso que nos ocupa, se decide aportar el enfoque sistémico que aparece en la Figura 4.10.

De este modo, quedan como entradas al proceso de torneado la fuerza de corte, la aceleración de la herramienta y el tiempo de la operación. Como salida se tomará el desgaste de la herramienta de corte. Se fijan como parámetros del proceso la profundidad de corte, la velocidad de corte, el avance, el material a tornear y la herramienta para llevar a cabo el

proceso. Como perturbaciones no medibles se tienen las diferencias de temperatura, el tipo de viruta y las no homogeneidades del material (granularidad).

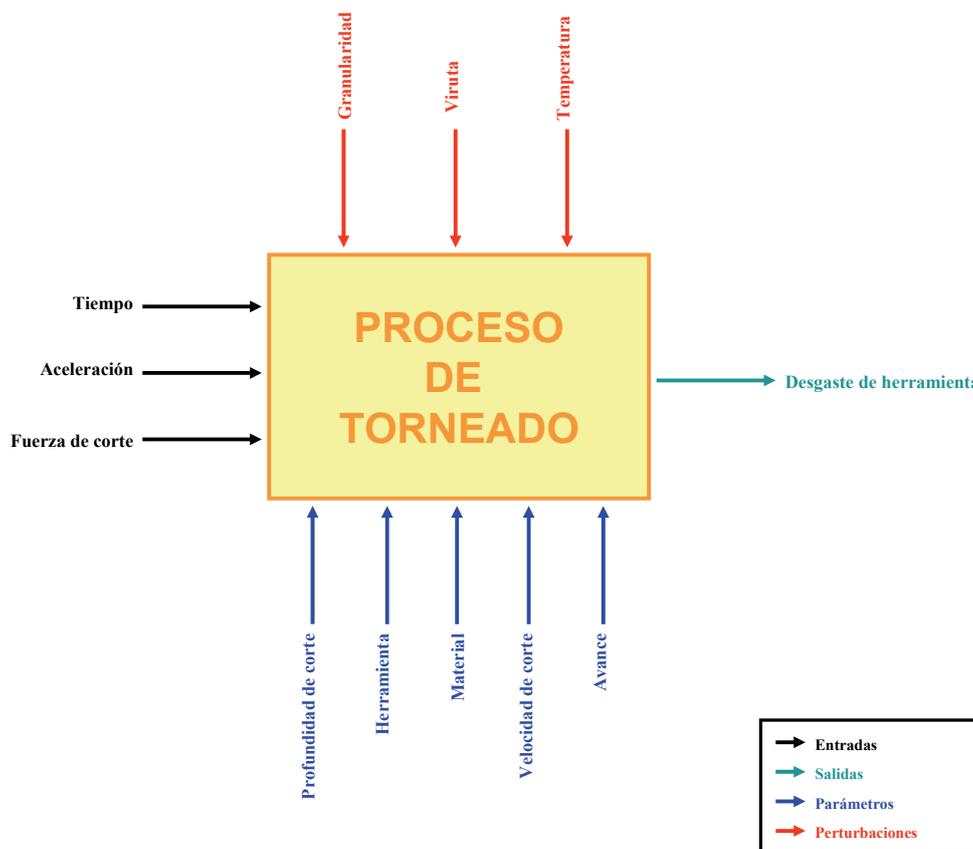


Figura 4.10. Enfoque sistémico del proceso de torneado utilizado en este trabajo

4.4. Planteamiento del Problema

Antes de entrar a detallar el planteamiento del problema, es necesario hacer una serie de aclaraciones. Ciertamente, todos los procesos de mecanizado tienen, por así decirlo, una problemática común. En ella se pueden englobar los temas relacionados con calidad dimensional, calidad superficial, productividad, desgaste de herramienta, etc. Estos problemas se tratan de manera distinta en cada uno de los procesos de mecanizado, debido fundamentalmente a las diferentes características de los propios procesos. Pese a que todos los procesos cuentan con “todos” los problemas, en este trabajo se ha decidido abordar uno de los diversos problemas que ocurren en el mecanizado (productividad) en uno de los procesos de mayor utilización (taladrado), mientras que otro de los problemas (desgaste de herramienta) se ha tratado en otro proceso de mecanizado distinto (torneado). De este modo, se han tomado dos casos de estudio distintos para evaluar el uso de sistemas neuroborrosos en varios problemas en distintos procesos. No obstante, y tal y como se verá a lo largo de la sección, todas las problemáticas se encuentran fuertemente relacionadas ya que, por ejemplo, no se puede aumentar la productividad de un proceso sin cuidar la herramienta de corte.

4.4.1. Planteamiento para el Proceso de Taladrado

El taladrado es uno de los procesos más intensamente utilizados en la fabricación de componentes aeronáuticos, del automóvil y, en general, en la fabricación de moldes y matrices. Debido a la feroz competencia por los mercados, uno de los principales objetivos de las empresas es reducir al máximo los tiempos de fabricación y aumentar la calidad de sus productos. Para llevar a cabo esta serie de objetivos es necesario tener un profundo conocimiento del proceso y además, ser capaz de representarlo de una manera adecuada. La tarea de modelado es la encargada de poder estudiar en detalle las relaciones que se dan entre variables del proceso y, de este modo, poder crear modelos para posteriormente simular el comportamiento del proceso. Gracias a los modelos se pueden realizar simulaciones y, en consecuencia, diseñar controladores que nos permitan optimizar el proceso con el fin de dar un salto cualitativo dentro de la competencia del sector.

Sin embargo, tal y como se ha visto en la descripción del proceso, el primero de los problemas es precisamente modelizar la dinámica de un sistema electromecánico complejo, con un comportamiento no-lineal y que presenta múltiples incertidumbres. Justamente, estas son las causas que han motivado el hecho de que las técnicas de modelado clásicas no hayan aportado los resultados esperados.

Una vez se haya obtenido un modelo del proceso, el segundo paso es dar a ese proceso un mayor valor añadido. Pese a su importancia y sus múltiples estudios, el proceso de taladrado no se ha beneficiado suficientemente de las enormes posibilidades que ofrecen el control y la automatización de procesos en este sentido. Los desarrollos en los procesos de taladrado pueden tener repercusiones muy positivas en la calidad del acabado, en la productividad y en el coste. Examinando las operaciones de taladrado se observa que, tal y como se expuso en secciones anteriores, a medida que la profundidad del taladro aumenta, la viruta ya no se desaloja tan fácilmente del agujero y comienza a causar un incremento en la fricción entre la broca y la pieza. Como resultado, la fuerza de corte y la temperatura de corte aumentan continuamente, y si no existe una acción apropiada, se producen vibraciones en la herramienta, desgaste excesivo, perjudiciales roturas de herramienta y quizás fallos catastróficos en el cabezal. La rotura de herramienta interrumpe la producción y puede suponer daños irreparables en la pieza, con lo cual supone unas pérdidas importantísimas. Todas estas consecuencias son evidentemente muy indeseadas desde cualquier punto de vista productivo. Por ello, el control en tiempo real de la fuerza de corte es una solución adecuada para evitar el incremento indeseado en la fricción pieza-herramienta.

La necesidad de controlar a lazo cerrado los procesos de mecanizado no solamente es válida para minimizar los efectos inadecuados de la evacuación de la viruta, sino también para incrementar la productividad del mecanizado. Típicamente, en un proceso no controlado de taladrado de alto rendimiento, los parámetros de corte (velocidad de avance, velocidad de giro, etc.) se mantienen constantes durante toda la operación a través de servocontroladores. En esta situación, se utilizan normalmente condiciones de corte conservativas para las operaciones de taladrado, debido al deseo del operador de esquivar condiciones de corte adversas. Por ello, el control en tiempo real del proceso de taladrado a través de la modificación en la velocidad de avance de la herramienta puede reducir el tiempo de ciclo así como evitar la rotura de herramientas. Se trata de demostrar de este modo que manipulando los parámetros de corte durante la operación se mejora la eficiencia del proceso y se compensan los efectos impredecibles de las perturbaciones, fundamentalmente a través de la regulación de la fuerza de corte.

Pese a los amplios estudios llevados a cabo en este campo, y a partir de la bibliografía a la que han tenido acceso el autor, no se han encontrado soluciones en este campo que utilicen la sinergia de las redes neuronales y la lógica borrosa para el control del proceso de taladrado.

4.4.2. Planteamiento para el Proceso de Torneado

Al igual que en el resto de procesos de mecanizado, en el proceso de torneado la herramienta está sometida a la acción combinada de grandes esfuerzos mecánicos, elevadas temperaturas y corrosión, producida en parte por los fluidos de corte. Por ello, los filos se van desgastando progresivamente y, en casos extremos, se llega al fallo catastrófico prematuro de los mismos, que puede ser debido a la deformación plástica del mismo, a la fluencia del material a alta temperatura o, simplemente, por fatiga y rotura frágil debida a las tensiones combinadas y a la baja tenacidad de la herramienta.

La rotura de herramienta por fallo catastrófico tiene una serie de riesgos muy importantes tanto para el operario como para el proceso. Los riesgos para el operario cuando una herramienta se rompe son evidentes, ya que en una operación de torneado el filo puede salir disparado a una velocidad muy elevada pudiendo causar daños importantísimos. Por otra parte nos encontramos con posibles daños en la propia pieza a mecanizar así como en la máquina-herramienta. Del mismo modo, el coste productivo que representa la sustitución de la herramienta es elevado.

De hecho, la importancia de maximizar el tiempo de trabajo de una herramienta y hacer todo lo posible para impedir su rotura está directamente relacionada con la optimización del proceso. La cuestión clave es encontrar un equilibrio apropiado entre el desgaste de la herramienta y la productividad, considerando el coste de la herramienta, su coste de reposición, el coste de la cancelación del tiempo de inactividad de la máquina, y así sucesivamente. No obstante, uno de los principales objetivos en los procesos de mecanizado es lograr una duración económica de la herramienta a través de una correcta elección de la velocidad de corte, de la velocidad de avance y de la profundidad de corte.

Por todas estas razones, una de las principales líneas de investigación en el campo de los procesos de mecanizado, y en particular en el proceso de torneado, se centra en evitar el fallo catastrófico de la herramienta de corte. Ya que la rotura por fallos inesperados es casi imposible de detectar, los mayores esfuerzos se centran en evitar la rotura de la herramienta por un excesivo desgaste de la misma.

El desgaste de la herramienta de corte es generalmente causado por una combinación de diversos fenómenos, siendo un hecho intrínseco a los procesos de corte. Sin embargo, el desgaste de la herramienta no es un valor de una variable física fácilmente medible mediante un método específico. Más bien se trata de una estimación subjetiva que un especialista puede hacer, dependiendo de la condición de los bordes de la herramienta y de sus superficies. Dado que no existe un criterio único para decidir cuando una herramienta necesita cambiarse u afilarse, pueden predecirse distintos “tiempos de vida” para una misma herramienta empleada en un mismo proceso. Dos de los criterios generalmente aceptados para decidir la sustitución de la herramienta son el fallo catastrófico y los cambios en la geometría de la herramienta. En algunos casos, se utilizan otra serie de criterios como son el degradado que produce la herramienta sobre la superficie de acabado, la desviación en las fuerzas de corte, la aparición de un mayor consumo de energía, el sobrecalentamiento, las obtención de piezas fuera de las tolerancias, y la aparición de *chattering*.

Como se mencionó anteriormente, el desgaste gradual o progresivo de la herramienta de corte puede producirse por adhesión, por abrasión o por difusión, pudiendo aparecer de dos formas: desgaste en la cara de la herramienta o desgaste en su flanco. El contacto con la viruta produce un cráter en la cara de la herramienta. El desgaste del flanco es debido comúnmente a la fricción entre la herramienta y el material de la pieza a trabajar.

Lo cierto es que el desgaste progresivo de una herramienta de corte no puede ser evitado, pero sí pueden utilizarse herramientas para su control. Ya que el operario es quién en último término toma la decisión acerca de la sustitución de la herramienta, una posible solución al

problema planteado es ofrecer al usuario una herramienta para monitorizar el desgaste de la herramienta en función de las variables que ocurren durante el proceso de torneado. Esta monitorización permitiría a su vez reducir, en un número muy importante, el número de fallos catastróficos.

Pese a que existen multitud de señales del proceso que podrían aportar información acerca del desgaste de la herramienta, diversos trabajos proponen en la literatura la medición de las fuerzas de corte, la medición de las vibraciones en la herramienta y la utilización de sensores de emisión acústica. Distintos autores ya han aportado soluciones empleando técnicas de Inteligencia Artificial, sin embargo, en este trabajo se trata también de aprovechar las ventajas que aportan otras técnicas de inferencia no utilizadas en este campo.

Capítulo 5

Modelado y Control Neuroborroso. Aplicación al Proceso de Taladrado

El presente capítulo muestra el modelado y control del proceso de taladrado a través de técnicas neuroborrosas. El primer paso es modelizar primeramente, a través de datos entrada-salida, tanto la dinámica directa como la dinámica inversa del proceso de taladrado. Posteriormente, a través de una técnica de control basada en modelos, el control por modelo interno, se regulará la fuerza media de corte en un proceso de taladrado por medio de la modificación de la velocidad de avance de la herramienta. Por estas razones, la primera parte del capítulo presenta la plataforma experimental en la que se han adquirido los datos para la creación de los modelos y en la que se ha implementado físicamente el propio sistema de control. En la segunda parte del capítulo se detallan las particularidades del esquema de control por modelo interno del proceso de taladrado basado en dicha plataforma experimental. Una vez mostrados los elementos con los que se cuenta para el modelado y el control, se procede a explicar el procedimiento de modelado y los resultados obtenidos en el posterior control del proceso (tanto en simulación como en experimentos industriales reales) a través del sistema de inferencia neuroborroso ANFIS. La última parte del capítulo muestra también el procedimiento y los resultados obtenidos en el modelado y control del proceso de taladrado a través del sistema de inferencia neuroborroso TNFIS.

5.1. Plataforma Experimental

Tal y como se expuso en el anterior capítulo, la operación de taladrado se puede hacer con un taladro portátil, en una máquina taladradora o en un centro de mecanizado equipado con CNC. Por otra parte, el propósito de este trabajo se centra en el sector industrial, donde los temas de optimización y productividad tienen una mayor relevancia siendo, a su vez, más difíciles de realizar las mejoras conducentes a una mayor eficiencia. En vista de esta serie de premisas, la investigación y experimentación desarrollada en este trabajo está orientada hacia el sector productivo en cual se trabaja con multitud de centros de mecanizado. Por estos motivos, para la adquisición de datos y para la realización de ensayos reales es necesario contar con una infraestructura similar a la de cualquier industria relacionada con el mecanizado. De este modo, se ha decidido realizar la implementación del sistema de control neuroborroso por modelo interno y la toma de datos en uno de los diversos centros de mecanizado del laboratorio que posee el grupo GAMHE (Grupo de Automatización Inteligente de los procesos de Mecanizado de Alto Rendimiento) en el Instituto de Automática Industrial (Consejo Superior de Investigaciones Científicas). En él se ha realizado una parte importante de las actividades de investigación y en él se han alcanzado gran parte de los resultados descritos en esta Tesis Doctoral.

Como parte importante de la plataforma experimental, se ha seleccionado un centro de mecanizado de alta velocidad Kondia HS1000 equipado con un CNC abierto Siemens Sinumerik 840D (Figura 5.1). Se trata de un centro de mecanizado de 3 ejes que cuenta con una potencia de cabezal de 26 kW, una velocidad de giro máxima de 24.000 rpm, una velocidad de avance rápido de 24 m/min y un par máximo disponible 28 Nm (a 6.000 rpm). Por estas características, este centro de mecanizado es capaz de desarrollar operaciones de taladrado (además de otras operaciones de mecanizado) en una gran variedad de materiales y,

dependiendo de las características de estos materiales, se pueden también realizar operaciones de mecanizado de alta velocidad.



Figura 5.1. Centro de mecanizado de la plataforma experimental

A este centro de mecanizado se le han incorporado varios elementos adicionales formando, de este modo, la denominada “plataforma experimental”. Así, la plataforma experimental está compuesta de los siguientes elementos:

1. Centro de mecanizado (máquina + CNC).
2. Sensores instalados en la máquina (plataforma dinamométrica, acelerómetros y emisión acústica).
3. Amplificadores para el acondicionamiento y filtrado de las señales procedentes de los sensores.
4. Sistema de adquisición de datos (incluye tarjetas de adquisición de datos y programa desarrollado en LabView para controlar el sistema de adquisición). Este sistema se encuentra instalado en un ordenador (externo al proceso) y tiene la particularidad de que es capaz de manejar señales internas del CNC como se verá posteriormente.

La Figura 5.2 muestra la arquitectura del sistema en su totalidad. Antes de pasar a detallar los elementos que componen la plataforma experimental, cabe hacer referencia tanto a los materiales a mecanizar como a las herramientas utilizadas en los ensayos experimentales.

Los materiales sobre los cuales se han realizado las operaciones de taladrado han sido la fundición nodular GGG40 (hierro fundido) y la aleación de acero inoxidable 17-4PH (precipitación endurecida). De acuerdo con el estándar internacional de ASTM (*American Society for Testing and Materials*) estos materiales se denominan A395 y A564, respectivamente. La fundición nodular GGG40 (A395) es un material muy popular debido a sus múltiples aplicaciones en ingeniería. La razón fundamental es que posee ciertas ventajas potenciales por su alta resistencia y tenacidad, así como por su buen comportamiento frente a fatiga y su resistencia al desgaste. No en vano, esta fundición es utilizada ampliamente en la industria aeroespacial. Por su parte, el acero inoxidable 17-4PH (A564) es utilizado con

frecuencia en una gran diversidad de aplicaciones, incluyendo piezas para válvulas hidráulicas, equipamiento para procesos químicos, engranajes, aspas de barcos, y otras aplicaciones industriales. Teniendo en cuenta la dureza de ambos material y sus condiciones de corte (que se verán más adelante), se ha seleccionado la broca SANDVIK CoroDrill Delta-C R840-1000-30-AOA para la realización de los taladros. Ésta tiene un diámetro de 10 mm, cuenta con un recubrimiento de TiN/TiAlN multicapa y además permite la utilización de refrigerante externo (emulsión ó aceite de corte).

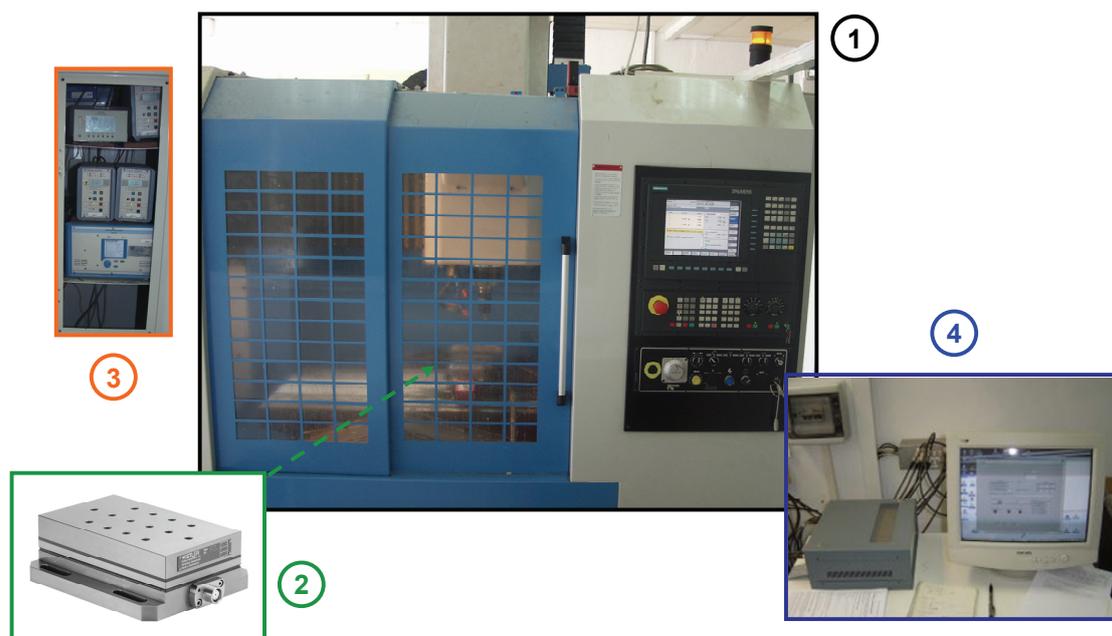


Figura 5.2. Plataforma experimental

Una vez descritos los materiales a taladrar, las herramientas (brocas) seleccionadas, y como ya se ha hablado del centro de mecanizado, pasamos a continuación a detallar el resto de elementos que componen la plataforma experimental.

Sensores

En el campo de la investigación en los procesos de corte es habitual el empleo de diversos sensores y así lo ha reflejado la literatura a lo largo de muchos años [137, 293-296]. Sin embargo, no sólo es importante el uso de sensores, sino que también es fundamental la fusión de la información aportada por los sensores con la información aportada por el propio centro de mecanizado a través de sus señales internas.

Pese a que el centro de mecanizado en el que se va a desarrollar la investigación dispone de varios tipos de sensores (sensores de emisión acústica, acelerómetros), para el modelado y control del proceso de taladrado únicamente será necesario el empleo de la plataforma dinamométrica instalada en la mesa de trabajo del centro de mecanizado.

Se trata de una plataforma dinamométrica o dinamómetro de muy altas prestaciones Kistler modelo 9257B utilizado para entregar señales eléctricas proporcionales a las componentes ortogonales de la fuerza de corte durante una operación de taladrado. Es un dinamómetro universal con 3 componentes de cristal de cuarzo para la medición de las tres componentes ortogonales de una fuerza. El empleo de este dinamómetro impone una restricción en su instalación y es que la pieza en la que se van a realizar los agujeros ha de fijarse a la plataforma dinamométrica, tal y como muestra la Figura 5.3. Las principales características técnicas son:

- Rango de medición: ± 5 kN (F_x, F_y, F_z)
- Sensibilidad: $-7,5$ pC/N (F_x, F_y) / $-3,7$ pC/N (F_z)
- Frecuencia Natural: 2,3 kHz (F_x, F_y) / 3,5 kHz (F_z)
- Temperatura de operación: 0 a 70 °C
- Dimensiones: 170mm \times 100mm \times 60mm (L \times A \times Al)
- Peso: 7,300 kg



Figura 5.3. Pieza de trabajo fijada a la plataforma dinamométrica

Amplificador

Para amplificar las señales de fuerza, se utiliza un amplificador de carga multicanal Kistler tipo 5070A. Los sensores de fuerza piezoeléctricos producen una carga eléctrica que varía en proporción directa a la carga que actúa en el sensor. El amplificador de carga convierte la carga eléctrica en un voltaje proporcional.

Sistema de Adquisición de Datos

El sistema de adquisición de datos está formado por una tarjeta de adquisición de datos y un programa de ordenador que realizará la adquisición.

Las señales de fuerza procedentes del amplificador de carga se adquieren con una tarjeta Iotech DaqBoard-2005 configurada para adquirir señales a una tasa de muestreo de 50 kHz. Esta tarjeta garantiza 16-bits de precisión y una tasa de muestreo de hasta 200 kHz. La tarjeta de adquisición se encuentra conectada a un PC local externo al proceso, denominado PC1 (que cuenta con sistema operativo Windows 2000).

Por otro lado, y en este mismo PC1, se ha diseñado e implementado un programa de adquisición para controlar, monitorizar y almacenar las señales, tanto del sensor de fuerza como las internas del CNC (*e.g.*, velocidad de giro del cabezal, velocidad de avance de la herramienta de corte, posición de la herramienta de corte, etc.). Este programa se ha desarrollado en el

entorno LabView y sus principales funciones son: definir la configuración de cada canal de la tarjeta DaqBoard 2005, controlar el inicio y parada del sistema de adquisición durante el proceso de taladrado, especificar la tasa de muestreo para la tarjeta de adquisición, determinar el número de muestras adquiridas por cada canal y, si se desea, monitorizar gráficamente la señal en tiempo real durante el proceso de taladrado.

Tal y como se ha venido explicando, las componentes ortogonales de la fuerza de corte (F_x , F_y , y F_z) se miden y envían al PC1 (y, por tanto, al programa de adquisición) a través de los sensores, amplificadores y tarjeta de adquisición. Por ello, en este programa de adquisición también se ha desarrollado un pre-procesamiento en la señal de fuerza para determinar la fuerza media o fuerza resultante por revolución (F_M), que será el valor que realmente se utilizará para el modelado y control del proceso.

$$F_M = \frac{1}{N} \sum_{i=1}^N |\vec{F}|_i \quad (5.1)$$

siendo N el número de muestras por revolución y $\vec{F} = (F_x, F_y, F_z)$

Para el diseño e implementación de esta programa de adquisición se han tenido en cuenta los requisitos del sistema de medición tales como: un frecuencia de muestreo de las componentes ortogonales de 50 kHz, un número de canales para la adquisición igual a tres (modo diferencial), un rango de voltaje para la conversión de ± 10 V (bipolar), el escalamiento de las señales, y el pre-procesamiento de las señales para obtener la fuerza media.

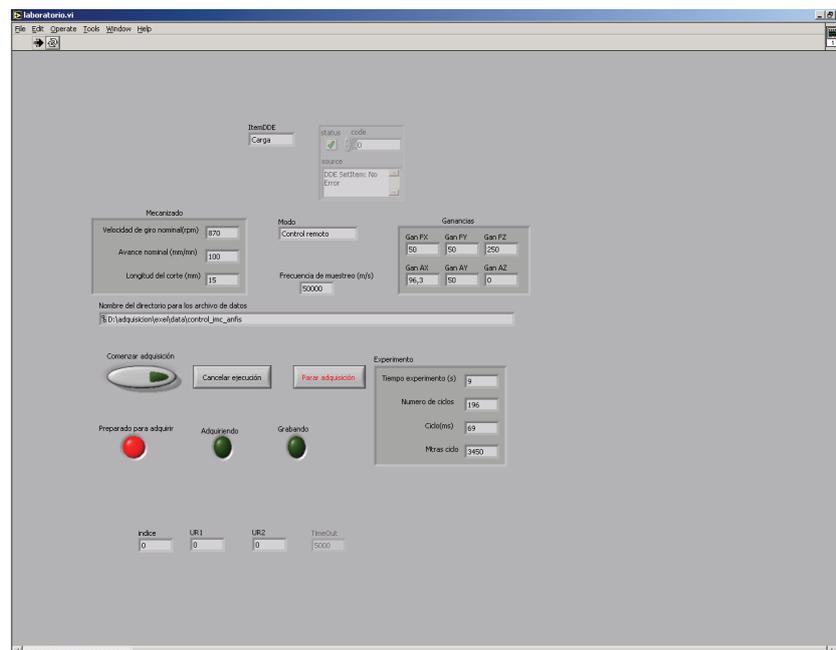


Figura 5.4. Programa de adquisición

Para la lectura y escritura de variables internas del CNC, hay que tener en cuenta que el centro de mecanizado en el que se ha llevado a cabo el estudio utiliza un control numérico Sinumerik 840D, y éste está equipado con un bus de comunicaciones propietario, muy similar al Profibus, conocido como interfaz multipunto (*Multi Point Interface*, MPI). Este bus de comunicaciones permite el intercambio de datos desde el ordenador local externo (PC1), siempre y cuando el ordenador tenga instalada una tarjeta de comunicaciones. El tratamiento de

estas señales internas (lectura y escritura) se hace también a través del programa de adquisición en LabView. Por tanto, la transferencia de información en el programa de adquisición está basada en la tarjeta DaqBoard 2005 anteriormente mencionada y una tarjeta de comunicaciones propietaria (CP5611).

En vista de que las comunicaciones con el CNC pasan obligatoriamente por el uso de una red industrial, con las restricciones que ello conlleva, se pasan a estudiar más en profundidad las características de la arquitectura en red de la plataforma experimental descrita en este apartado.

5.1.1. Arquitectura en Red

Tal y como se ha venido explicando a lo largo de este capítulo, la lectura y escritura de variables internas del CNC y, por tanto, el posterior control neuroborroso del proceso de taladrado, se hace a través de la red. Debido a restricciones del fabricante de CNCs, el único modo de realizar lecturas y escrituras sobre las variables del mismo es a través de un protocolo multipunto (*multipoint interface*). La interfaz física de este protocolo es idéntica a la de Profibus (por ello nos referimos a la red como Profibus) con una velocidad de 187.5 kbits/s. Esta velocidad se puede incrementar hasta 12 MB/s.

Ineludiblemente, para realizar cualquier tipo de control (escritura de variables) se ha de pasar por este nivel de red. La realización de experimentos de control impone la implementación de los controladores (o del sistema de control basado en modelos) en el PC en el que se encuentra el programa de adquisición (PC1). Sin embargo, debido a que es necesario el uso de comunicaciones a través de redes industriales, se decide por restricciones del software y hardware propietario de la máquina herramienta realizar algunas implementaciones utilizando un segundo nivel de red (*i.e.*, Ethernet). De este modo, es posible estudiar el comportamiento dinámico del sistema de control propuesto en presencia de retardos. A continuación pasamos a detallar las características de este segundo nivel.

Ciertamente, los buses de campo dominan actualmente el mercado de las comunicaciones en tiempo real para entornos industriales. Dentro de este amplio espectro existen ciertos estándares, pero no tecnologías unificadas. En realidad, concurren un amplio número de estándares utilizados, como Profibus, CAN, WorldFIP y Foundation Fieldbus. La principal ventaja de estas tecnologías es su buen comportamiento en entornos industriales. Sin embargo, existen también algunas desventajas, como el coste en hardware asociado, su engorrosa integración con otros productos y, en algunos casos, las limitaciones en el ancho de banda.

Con el fin de hacer frente a estos problemas, las tecnologías de redes de ordenadores, y particularmente Ethernet, han sido adaptadas al campo de la automática industrial [297]. Ethernet es una red de bajo coste, simple, disponible (abierto) y con altas tasas de transmisión, características que la hacen muy atractiva para aplicaciones industriales. Se produce sin embargo, una barrera técnica: Ethernet tiene un comportamiento no determinista que la hace inadecuada para tareas de tiempo real.

Una manera de tratar con este comportamiento no determinista es utilizando redes Ethernet conmutadas. En esta configuración, los tradicionales concentradores de red (*hubs*) son reemplazados por puentes Ethernet (comúnmente conocidos como *switches*). Una de las ventajas de los *switches* es que solo envían *frames* a los *link* de destino. El uso de un *switch* para aislar cada parte de un sistema conduce a una subred controlada y sin colisiones, eliminando el principal problema de Ethernet en sistemas de control en red. Además, Ethernet conmutada es compatible con Ethernet tradicional. Estudios teóricos y experimentales acerca de este tema son reportados en [298, 299].

La arquitectura global del control en red a través de Ethernet, incluyendo el centro de mecanizado donde se desarrolla el proceso de taladrado, se muestra en la Figura 5.5. En el apartado anterior ya se hizo mención a las tareas desarrolladas por el PC1. En el control

neuroborroso del proceso de taladrado a través de Ethernet, el PC1 incluirá dos tareas más. Una tarea es comunicar con un segundo ordenador personal, PC2, vía Ethernet con *middleware* Standard CORBA. De este modo la fuerza filtrada F_M , así como otros parámetros y variables (e.g., velocidad de giro, profundidad del agujero) son enviados al PC2. La otra tarea será recibir la señal de control calculada por el PC2 (el sistema de control se desarrolla en este PC para el caso de control a través de Ethernet) mediante la interfaz de datos y sincronizar las tareas a través de Ethernet (a través de la aplicación creada en LabView). Tal y como se ha explicado anteriormente, el PC2 no se puede conectar directamente al CNC debido a las restricciones que impone el fabricante del CNC.

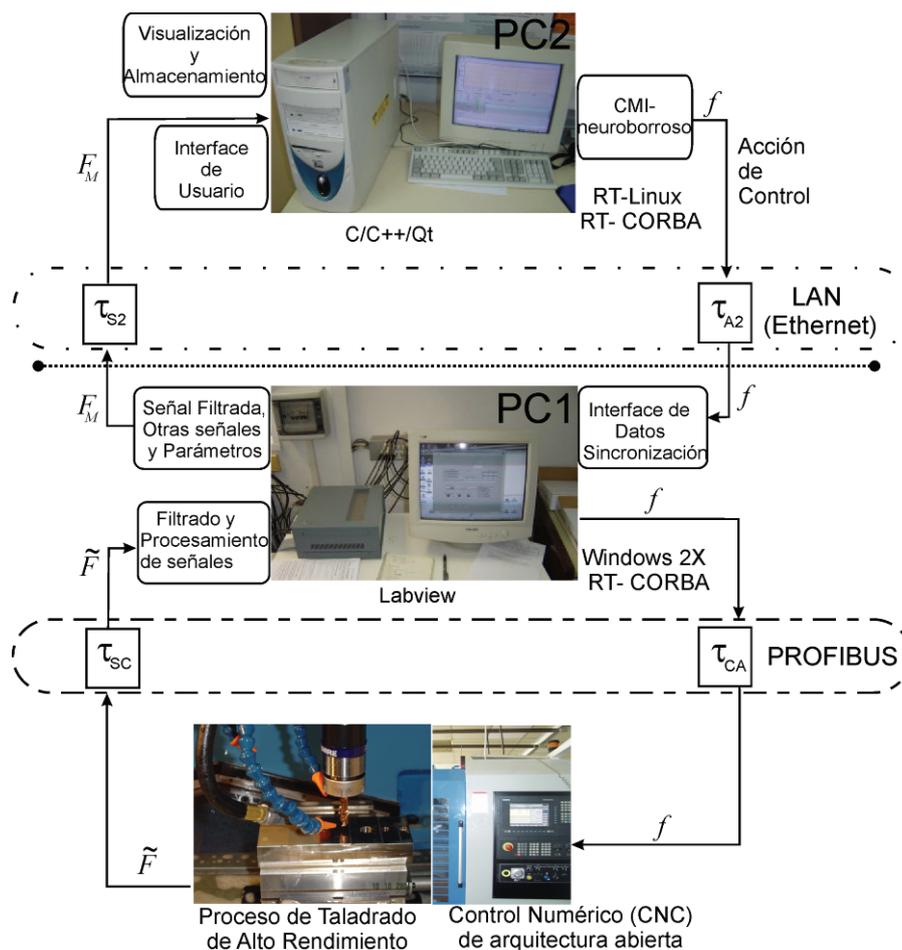


Figura 5.5. Niveles de red en la plataforma experimental

Ciertamente la existencia de diversos niveles de red, más el propio tiempo muerto del proceso, hacen que se produzcan una serie de retardos a la hora de realizar cualquier tipo de control o monitorización. Los retardos inducidos por la red usualmente no son conocidos *a priori* y, en general, son de difícil medición o estimación en línea. Un tratamiento formal acerca de los retardos inducidos por la red y el procedimiento para estimarlos puede ser encontrado en la literatura [300, 301]. El máximo retardo, incluyendo el retardo inducido por la red y el tiempo muerto del proceso puede estimarse del siguiente modo:

$$\left[\tau_{SC} + \tau_{CA} + \tau_p \right]_{MAX} = 0.4 \text{ s} \quad (5.2)$$

donde τ_{SC} es el retardo del sensor dinámico al PC1, τ_{CA} es el retardo del PC1 al CNC y τ_p es el tiempo muerto intrínseco del proceso de taladrado.

Un riguroso estudio acerca de la influencia de los retardos inducidos por la red en procesos de mecanizado donde la máquina herramienta esta conectada a redes locales usando Ethernet (incluyendo resultados experimentales) se muestra en [302]. El comportamiento a ráfagas del tráfico en redes Ethernet convencionales sugiere el uso de funciones de autosimilitud usando el coeficiente de Hurst. Una distribución de Pareto es la que mejor representa la distribución empírica de muestras medidas en tiempo real en este tipo de redes.

Es importante reseñar que el retardo debido a la red Ethernet conmutada no es significativo para aplicaciones de tiempo real, y por tanto constituye una alternativa prometedora para el control de sistemas en red. La Figura 5.6 muestra el análisis estadístico que corrobora un retardo límite inducido por la red. Este análisis está basado en [302]:

$$\tau_{S2} + \tau_{A2} = 0.005 \text{ s} \tag{5.3}$$

donde τ_{S2} es el retardo del PC1 al PC2 y τ_{A2} es el retardo del PC2 al PC1.

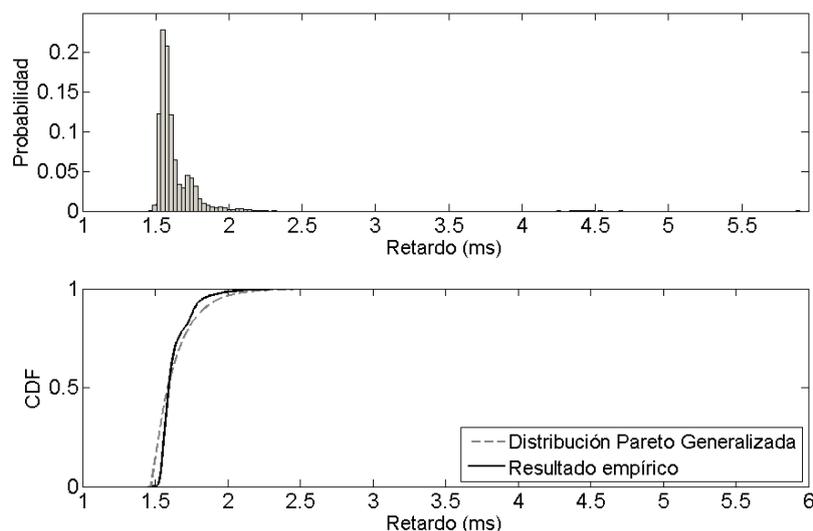


Figura 5.6. Distribución estadística de los retardos inducidos por la red obtenida sobre un conjunto de 10000 muestras

A partir del hecho de que el retardo inducido por la red Ethernet es mucho menor que el retardo inducido por la red Profibus y el propio tiempo muerto del proceso ($0.005 \text{ s} \ll 0.4 \text{ s}$), a lo hora de diseñar, modelizar e implementar el sistema de control neuroborroso consideramos el máximo retardo para ambos niveles de red del mismo valor que el retardo debido a la red Profibus y al tiempo muerto del proceso, es decir, 0.4 segundos.

Para el caso del control en red a través de Ethernet, la interfaz de usuario, la visualización y el almacenamiento de datos, y los sistemas de control por modelo interno basados en modelos neuroborrosos estarán implementados en el PC2. Un software de libre distribución (RTAI-Linux y Qt) es usado en este nivel de la plataforma desarrollada. Para la lectura y escritura de datos a través de la red se desarrolló una aplicación en lenguaje C. En caso de fallo o pérdida de información debido a las comunicaciones, el sistema tiene programado un mecanismo de seguridad en el CNC que mantiene la velocidad de avance constante sobre el proceso.

Cuando el control neuroborroso por modelo interno se efectúa desde el PC2 (Ethernet), ya no se utiliza una herramienta software propietaria para implementar los modelos neuroborrosos y el sistema de control. En este caso se ha implementado todo en código C, elaborando además una aplicación para la visualización y monitorización del proceso de taladrado de alto rendimiento.

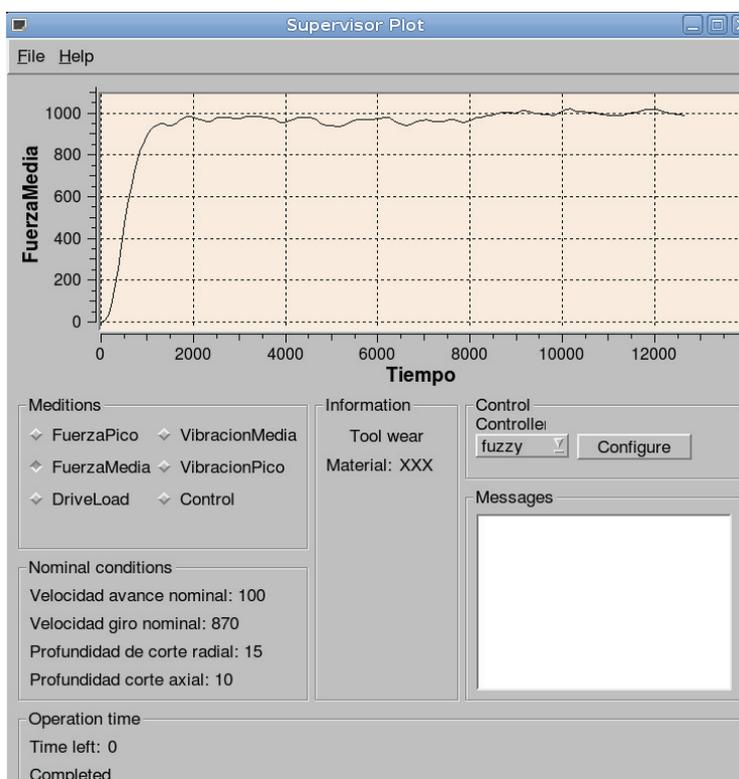


Figura 5.7. Aplicación visual para la monitorización del proceso de taladrado

5.2. Paradigma de Control: El Control por Modelo Interno

Entre los diversos sistemas de control basados en modelos existentes en la literatura (ver Capítulo 2 y Capítulo 3), en este trabajo se decide la utilización del control por modelo interno para el control del proceso de taladrado. El empleo de este paradigma reporta una serie de ventajas como son su capacidad intrínseca para hacer frente a las perturbaciones y la buena respuesta dinámica. Además, este paradigma constituye un enfoque bien establecido para el diseño de controladores ya que en el control por modelo interno el diseño del controlador es sencillo y su ajuste simple.

El esquema de control a nivel teórico ha quedado claramente explicado en el Capítulo 3. Sin embargo, su implementación en la plataforma experimental puede resultar un poco engorrosa, más aún con la existencia de los distintos niveles de red explicados anteriormente. Por ello, se describen a continuación las distintas configuraciones que tiene el sistema de control por modelo interno basado en modelos neuroborrosos según se realice el control a través de Profibus o bien a través de Ethernet.

Cuando nos referimos al control del proceso de taladrado a través de Profibus, nos estamos refiriendo a que la mayor parte de los elementos del esquema de control por modelo interno se encuentran implementados en el PC1. De este modo, tanto el modelo directo del proceso de

taladrado, como el modelo inverso, el filtro y la selección de la fuerza de referencia (con el posterior cálculo del error) se encuentran en el ordenador que está conectado al CNC a través de la red Profibus. En este caso, esta serie de elementos se encuentran implementados en la herramienta de tiempo real *Real-Time Workshop* (RTW) de Matlab/Simulink. Gracias a esta herramienta, la programación del lazo de control se hace sobre la base de Simulink. El programa calcula la acción de control (la velocidad de avance de la herramienta, en nuestro caso particular) y se la envía directamente al CNC a través de Profibus. Por su parte, la lectura de la variable controlada se hace a través de la tarjeta de adquisición de datos, la cuál se comunica también directamente con el programa de Simulink. La Figura 5.8 muestra la implementación de este sistema de control por modelo interno a través de Profibus.

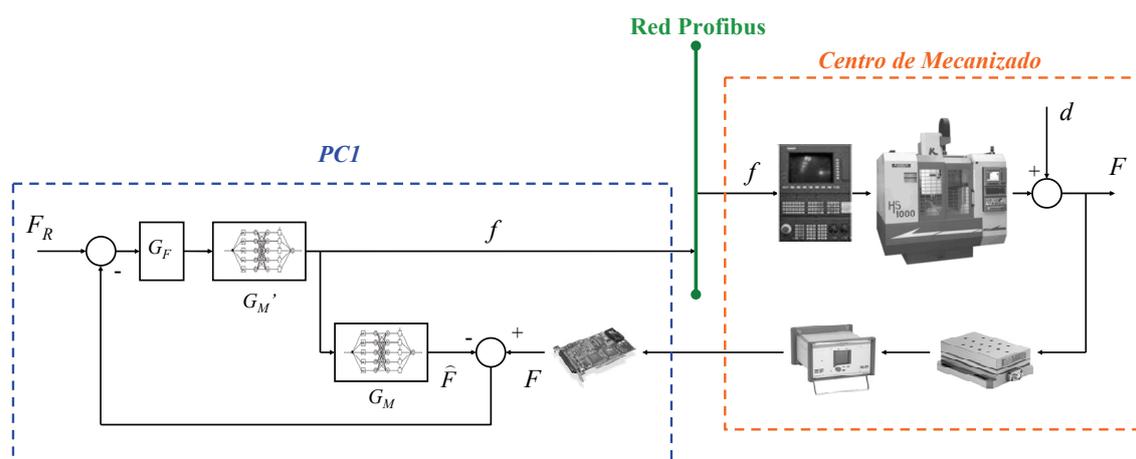


Figura 5.8. Sistema de control por modelo interno a través de Profibus

Por otra parte, cuando nos referimos al control del proceso de taladrado a través de Ethernet, nos estamos refiriendo a que la mayor parte de los elementos del esquema de control por modelo interno se encuentran implementados en el PC2. Así, el modelo directo del proceso de taladrado, el modelo inverso, el filtro y la selección de la fuerza de referencia (con el posterior cálculo del error) se encuentran en el PC2, implementados en este caso en código C. El programa en C es, en este caso, el encargado de calcular la acción de control (velocidad de avance de la herramienta). Una vez se calcula la acción de control, ésta se envía a través de Ethernet al programa de LabView del PC1, el cual es el encargado de modificar la variable correspondiente en el CNC (vía Profibus). Asimismo, el PC1 procesa la variable controlada (fuerza media de corte) a través del programa de LabView (conectado con la tarjeta de adquisición) y la enviará a través de Ethernet al programa en C del PC2. Todo el intercambio de información entre el PC1 y el PC2 se hace a través del middleware CORBA. De este modo, todas las operaciones desarrolladas en el PC2 se hacen a través de un software de libre distribución. La Figura 5.9 muestra la implementación de este sistema de control por modelo interno a través de Ethernet.

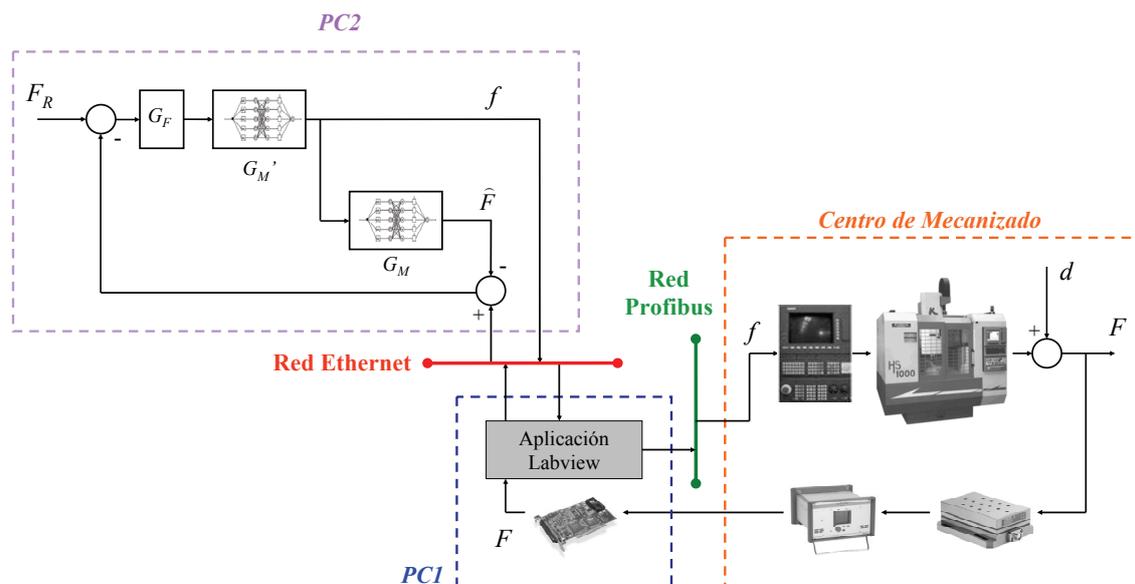


Figura 5.9. Sistema de control por modelo interno a través de Ethernet

5.3. Modelado y Control a través de ANFIS

Para poder llevar a cabo un control adecuado del proceso de taladrado, es necesario tener un profundo conocimiento del proceso y, sobre todo, es preciso representarlo de una manera adecuada. A través del modelado se podrán estudiar en detalle las relaciones que se dan entre las variables del proceso y, posteriormente, se podrá diseñar el sistema de control. Además, se podrá también simular el comportamiento del proceso y del sistema de control antes de tener que implementarlo físicamente.

En base a todo lo expuesto en el Capítulo 3, se puede afirmar que los sistemas neuroborrosos (y particularmente ANFIS) resultan muy adecuados tanto para modelizar procesos complejos con un alto nivel de incertidumbre, como para controlarlos. Por otra parte, y tal y como se expuso en el Capítulo 4, el proceso de taladrado posee una dinámica compleja, fuertemente no lineal, de difícil modelado, y poblada de incertidumbres. Por tanto, parece que el sistema neuroborroso ANFIS puede resultar apropiado para modelizar las dinámicas del proceso de taladrado (directas e inversas). Si además sabemos que el paradigma de control por modelo interno es apropiado para el control de esta serie de procesos, resulta obvio por consiguiente, que el control neuroborroso por modelo interno (basado en modelos ANFIS) puede llegar a controlar el proceso de taladrado de un modo eficaz. A través de este apartado se trata de demostrar esta teoría. Primeramente se explicará el procedimiento utilizado para modelizar la dinámica directa e inversa del proceso de taladrado a través de ANFIS. Después se incorporarán los modelos obtenidos al control del proceso por medio del esquema de control por modelo interno. Antes de presentar los experimentos industriales reales del sistema de control diseñado, se mostrará también el profundo estudio de simulación realizado.

5.3.1. Modelado

En el Capítulo 2 se han mostrado diferentes modelos del proceso de taladrado obtenidos por técnicas clásicas. También, a lo largo de la revisión de la literatura en el modelado del proceso de taladrado, se han encontrado ciertas aproximaciones que emplean técnicas de Inteligencia Artificial. Por ejemplo, se modela la operación de taladrado con redes neuronales para predecir la fuerza presente a la entrada y a la salida de la propia operación [4]. Sin embargo, cabe resaltar nuevamente que, en base a la literatura a la que se ha tenido acceso, no se han encontrado aproximaciones neuroborrosas para representar el proceso de taladrado.

Modelo Directo

Al igual que en los modelos clásicos estudiados, aquí se decide también reducir el sistema a una entrada y una salida, siendo la velocidad de avance de la herramienta de corte (f) la variable de entrada y la fuerza media de corte (F) la variable de salida. A esta representación del sistema se la conoce como modelo directo. Como parámetros del modelo se fijan la velocidad de giro de la herramienta, el diámetro de la herramienta de corte y la velocidad de avance inicial. De este modo, quedan entonces como perturbaciones no medibles ni estimables el desgaste de la herramienta de corte y las posibles variaciones en la profundidad de corte. Una vez definida la estructura del modelo, el sistema neuroborroso ANFIS se entrena para que aprenda la dinámica del proceso por medio de datos entrada-salida. En este trabajo se han utilizado datos reales de fuerza de corte y velocidad de avance obtenidos experimentalmente.

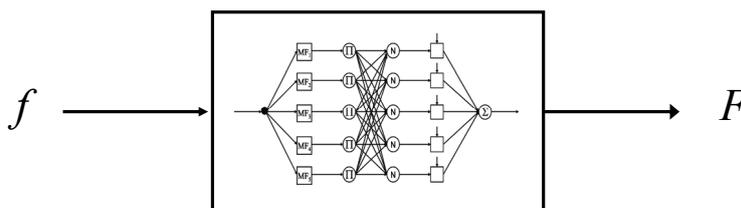


Figura 5.10. Estructura del modelo directo neuroborroso ANFIS

Los datos experimentales se obtuvieron de pruebas realizadas sobre probetas de fundición nodular GGG40. Las condiciones nominales de operación fueron velocidad de giro de 870 rpm, velocidad de avance inicial de 100 mm/min y diámetro de la herramienta de 10 mm. Los datos se tomaron de una operación con profundidad de corte de 15 mm.

Con el objetivo de realizar un mejor ajuste del modelo, se obtuvo un modelo inicial introduciendo un conjunto de datos de entrenamiento (133 datos) al sistema neuroborroso. Posteriormente, se ajustaron los parámetros del modelo creado inicialmente, introduciendo al sistema neuroborroso un conjunto de datos de prueba (128 datos) distintos de los anteriores.

En la fase de obtención de los modelos son modificables ciertos parámetros del sistema ANFIS tales como el número de funciones de pertenencia en el emborronado, la clase o tipo de dichas funciones, así como el orden de las reglas Takagi-Sugeno de desemborronado. Asimismo, se puede mejorar la precisión del modelo cambiando los parámetros del proceso de aprendizaje (método, número de iteraciones, tamaño del paso, etc.). La elección de las variables correctas y los parámetros óptimos se ha realizado a partir de un compromiso entre el criterio de error de la raíz cuadrada del error cuadrático medio (RMSE) y la respuesta dinámica del modelo.

Se analizaron sistemas Takagi-Sugeno de orden cero y de primer orden, con funciones de pertenencia *Gaussianas*, sigmoidales, triangulares y trapezoidales, desde dos hasta nueve funciones de pertenencia. El mejor resultado para los modelos directo e inverso se obtuvo con

dos funciones de pertenencia en la fase de emborronado, siendo dichas funciones del tipo campana de Gauss (3.2), y con reglas de Takagi-Sugeno (T-S) de primer orden. El aumento del número de funciones de pertenencia y del orden de los sistemas T-S no produjo mejoras significativas en la precisión.

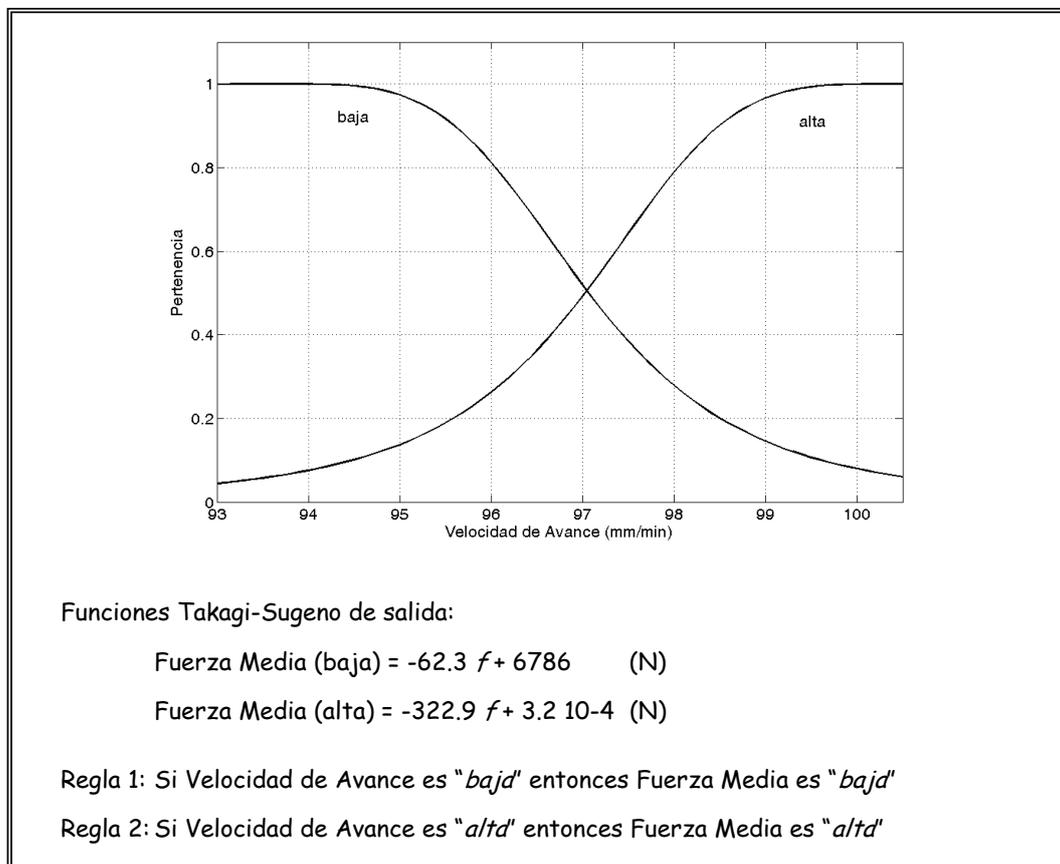


Figura 5.11. Funciones de pertenencia y reglas del modelo directo ANFIS

Nuevamente, tal y como se observa en la Figura 5.12, es necesario volver a hablar de retardos. Los datos entrada/salida con los cuáles se ha entrenado el sistema neuroborroso ANFIS tienen un retardo de unos 0.4 segundos. Este hecho es debido a que se han tomado datos del proceso a través de la plataforma experimental mostrada en el apartado 5.1. Por ello se debe modelizar el proceso con esta particularidad. Tal y como se ha explicado anteriormente, se concluye que la aparición de este retraso es debido a las comunicaciones y al propio tiempo muerto del proceso.

Los parámetros de entrenamiento fueron 100 iteraciones del algoritmo (un mayor número de iteraciones provoca un sobreentrenamiento y, como resultado de éste, picos indeseados en la salida del sistema), modo de entrenamiento híbrido (únicamente con retropropagación del error no se alcanza el valor de salida deseado) y tamaño del paso de 0.01 (el aumento de este valor no produce una mejora significativa de la salida y si un mayor cómputo de operaciones).

Por motivos de rapidez y sencillez, la obtención de los modelos se realizó en Matlab. El tiempo de entrenamiento en los modelos fue de 0.14 segundos tanto para el modelo directo como para el inverso. Estos tiempos se obtuvieron en un ordenador con procesador Intel Core2 CPU 6400 - 2.13 GHz con sistema operativo Windows XP Profesional. El entrenamiento se realizó *off-line*.

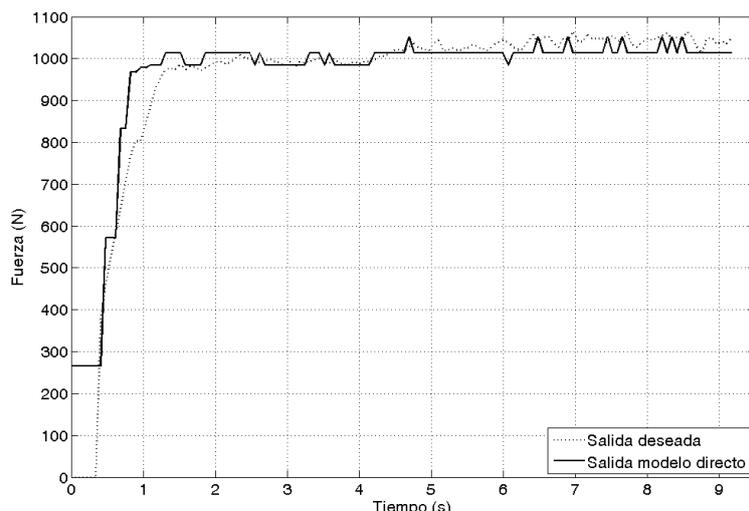


Figura 5.12. Respuesta del modelo directo neuroborroso ANFIS

Modelo Inverso

El proceso de taladrado tiene una dinámica que se ha modelado en el anterior punto y que consiste en saber qué fuerza de corte se obtendrá para una determinada velocidad de avance de la herramienta. No obstante, en ocasiones resulta también conveniente obtener una representación de la dinámica inversa del proceso obteniéndose el denominado modelo inverso. Esta técnica es especialmente útil a la hora de diseñar controladores del propio proceso, ya que son los encargados de modificar, en este caso, la velocidad de corte de la herramienta. Por ello nos interesa también conocer qué velocidad de avance se obtiene cuando existe una determinada fuerza de corte.

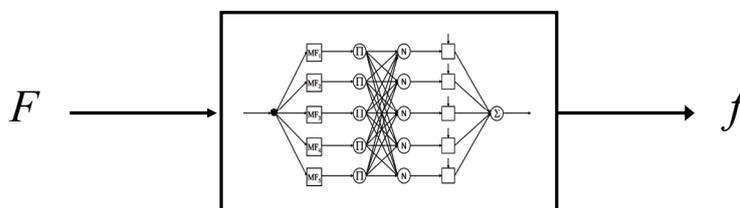


Figura 5.13. Estructura de modelo inverso neuroborroso ANFIS

Para obtener el modelo inverso, en vez de invertir el modelo directo anteriormente descrito (ya sea por técnicas clásicas o neuroborrosas), realizamos otro entrenamiento del sistema pero esta vez con la fuerza media como entrada y la velocidad de avance como salida. Nuevamente utilizaremos un sistema neuroborroso ANFIS para esta función y los mismos parámetros del modelo utilizados en el caso anterior.

En esta ocasión cobra más fuerza si cabe el empleo de un sistema neuroborroso para el modelado de la dinámica inversa del proceso ya que, en general, la inversión de modelos no lineales no es una tarea fácil, y pueden no existir soluciones analíticas, de modo que las soluciones tienen que calcularse numéricamente. Otro problema es que la inversión de modelos del proceso puede conducir a controladores inestables cuando el sistema es de fase no mínima [279].

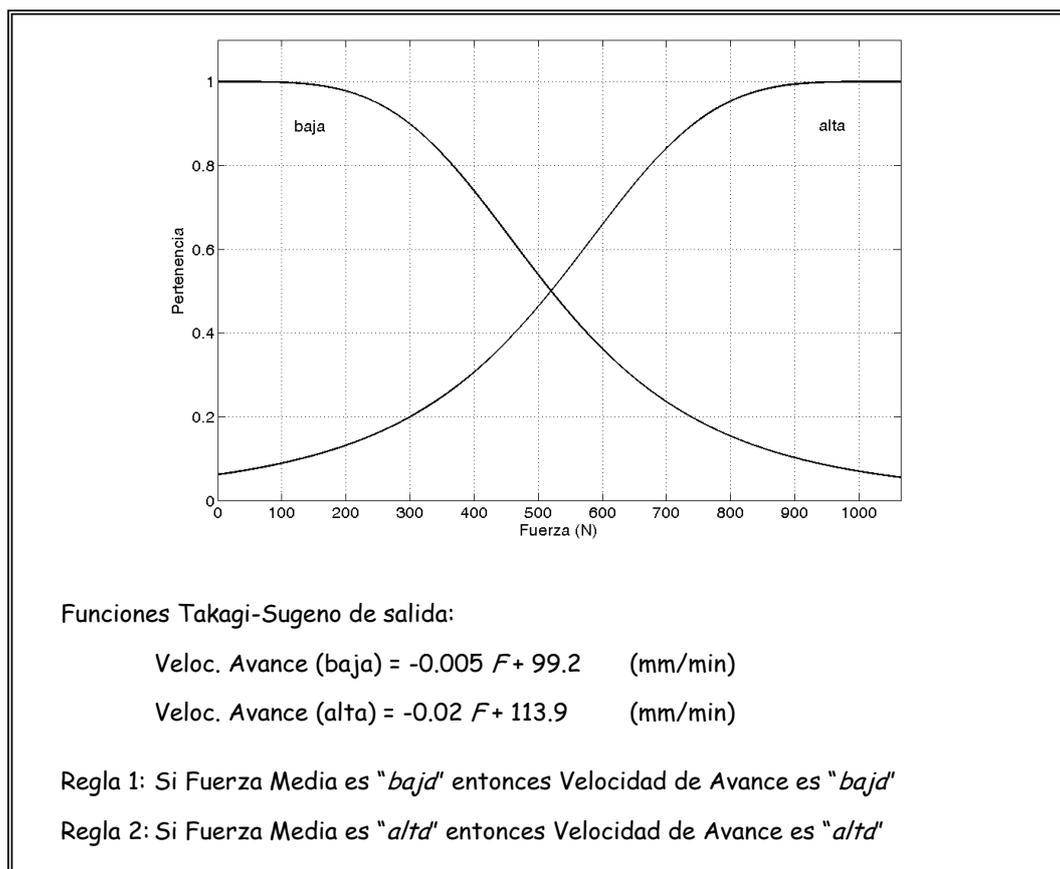


Figura 5.14. Funciones de pertenencia y reglas del modelo inverso ANFIS

Para la creación del modelo inverso se ha vuelto a trabajar con la herramienta informática Matlab. Se analizaron nuevamente sistemas Takagi-Sugeno de orden cero y de primer orden, con distintas funciones de pertenencia, con diverso número de funciones, cambiando parámetros de entrenamiento, etc. Como resultado, volvió a comprobarse que el sistema que mejor representaba la dinámica inversa del proceso tenía dos funciones de pertenencia en la fase de emborronado, siendo dichas funciones del tipo campana de Gauss (3.2), y con reglas de Takagi-Sugeno de primer orden. Es decir, se utilizaron los mismos parámetros que en el modelo directo.

Tanto en el caso del modelo directo como en el caso del modelo inverso, se eligieron modelos que, *a priori*, tienen un error medio cuadrático mayor que otros modelos (con distinto número de funciones y de distinto tipo). Esta elección se hizo teniendo en cuenta el comportamiento dinámico (respuestas sin oscilaciones) y la sencillez del modelo para un buen control en tiempo real del proceso. Un requisito fundamental del modelo directo es que la respuesta transitoria debe ser buena por la influencia negativa que tiene el sobrepaso en la vida útil de la broca. El error medio cuadrático (RMSE) para ambos modelos aparece resumido en la Tabla 5.1.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - F_i)^2} \quad (5.4)$$

donde F_i es valor obtenido por el modelo, Y_i es el valor deseado o real y N es el número total de muestras del experimento.

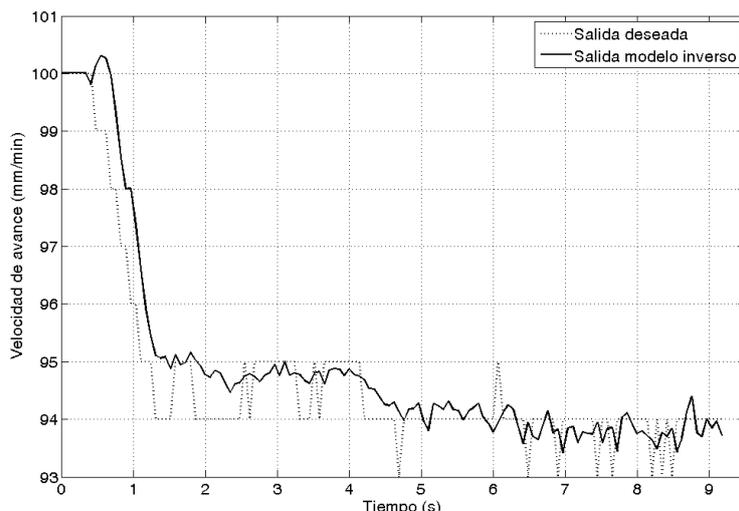


Figura 5.15. Respuesta del modelo inverso neuroborroso ANFIS

Tabla 5.1. Errores RMSE de los modelos creados

<i>Modelo</i>	<i>RMSE - datos de entrenamiento</i>	<i>RMSE - datos de verificación</i>
Directo	1.94 %	5.18 %
Inverso	0.39 %	0.68 %

5.3.2. Control

El control neuroborroso del proceso de taladrado se hace a través del paradigma de control por modelo interno. El objetivo es mantener la fuerza de corte constante en toda la operación (variable controlada) a través de la modificación de la velocidad de corte de la herramienta (acción de control). Para ello se utilizarán el modelo directo y el modelo inverso obtenidos a través de ANFIS en el apartado anterior. Previamente a mostrar la metodología utilizada y los resultados en experimentos industriales reales, se muestra el estudio realizado en simulación.

Simulación

Para poder llevar a cabo la simulación del control neuroborroso del proceso de taladrado de alto rendimiento a través de ANFIS, es necesario disponer de la información y las representaciones lineales y neuroborrosas que se han venido explicando a lo largo de este trabajo y que pasamos a resumir a continuación. Por una parte es ineludible el poseer una representación lo más fiel posible del proceso real de taladrado. Después de haber revisado en profundidad los trabajos relacionado con esta materia, se decide utilizar el modelo lineal de tercer orden propuesto por Del Toro *et al.* (4.10) [Apartado 4.2.3.]. Por otra parte necesitamos dos sistemas neuroborrosos ANFIS, uno para modelizar la dinámica directa del proceso y otro para modelizar la dinámica inversa [Apartado 5.3.1.]. Para concluir necesitamos implementar el esquema de control por modelo interno, con su correspondiente filtro. Nuevamente utilizaremos la herramienta informática Matlab, más concretamente su plataforma para simulación Simulink con el objeto de llevar a cabo el estudio.

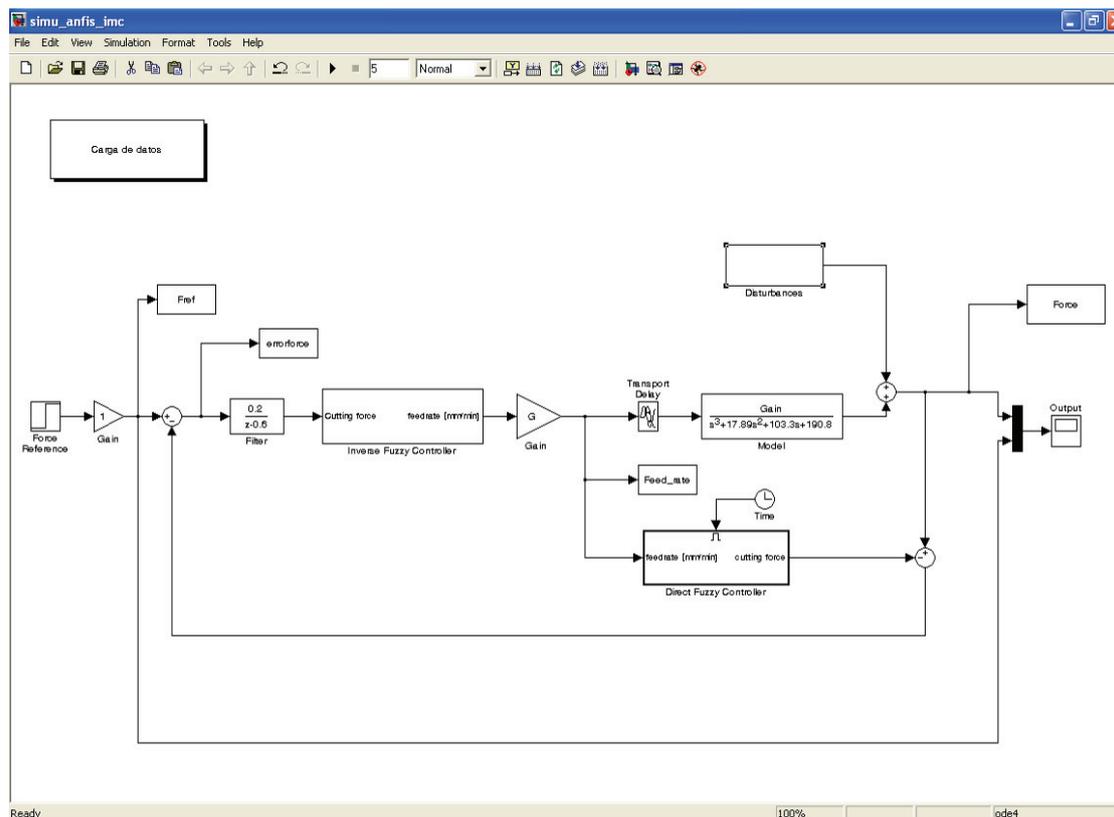


Figura 5.16. Simulación del control neuroborroso por modelo interno del proceso de taladrado

Una vez creados los modelos neuroborrosos directo e inverso, se incorporan al esquema de control por modelo interno y se decide simular una operación de taladrado del material GGG40. Este material es el mismo que se utilizó en los datos para el entrenamiento de los sistemas neuroborrosos. Las condiciones nominales de operación de la fundición nodular GGG40 (según la recomendación del fabricante de la broca) son una velocidad de giro de 870 rpm y una velocidad de avance inicial de 100 mm/min. El empleo del GGG40 nos obliga también a fijar en la ganancia del modelo lineal de tercer orden (4.10) el valor correspondiente a este tipo de material (Ganancia GGG40 = 10.26).

Para el ajuste del filtro que incorpora el esquema de control por modelo interno se eligen los valores $k_1 = 0.6$ y $k_2 = 0.8$.

Pese a que los modelos neuroborrosos directo e inverso incluyen el retardo que provoca el uso de las redes de comunicación (Profibus) y el propio tiempo muerto del proceso, en el estudio de simulación se vuelve a tener en cuenta este hecho incluyendo un bloque en la simulación que representa el retardo entre la acción de control y el proceso, tal y como sucede en el proceso de taladrado real. Este retardo estimado de 0,4 segundos es el que aparece en el modelo lineal (4.10) pero que, a efectos de simulación, se separa del bloque del modelo y se representa en un bloque distinto (modelo sin retardo por una parte y bloque con retardo por otra). La estimación del valor utilizado se ha justificado con anterioridad en el apartado 5.1.1.

Asimismo, en la fase de simulación se incluyó una perturbación o ruido aditivo a la salida del proceso con el fin de estudiar la influencia de las dinámicas no modeladas en el sistema de control. La perturbación $d(t)$ tiene la siguiente forma:

$$d(t) = A \cdot (\sin(2wt) + \sin(3wt) + \sin(4wt) + \sin(5wt)) \quad (5.5)$$

siendo $w = 7.61$. Esta frecuencia se corresponde con uno de los polos del modelo de tercer orden que representa de manera aproximada el proceso de taladrado. La amplitud de la perturbación se estima en $A = 10$ para emular un ruido en la señal del 10 % (nivel de ruido bastante común en la industria de procesos).

Tabla 5.2. Resumen de los parámetros de los modelos neuroborrosos

ANFIS	Modelo Directo	Modelo Inverso
Sistema	Simple-entrada/ Simple-salida	Simple-entrada/ Simple-salida
Tipo de función de pertenencia	Gaussiana	Gaussiana
Número de funciones de pertenencia	2	2
Tipo de Inferencia	Takagi-Sugeno	Takagi-Sugeno
Número de reglas	2	2
Iteraciones	100	100
Ratio de aprendizaje	0.01	0.01
Algoritmo de entrenamiento	Retropropagación + Mínimos cuadrados	Retropropagación + Mínimos cuadrados
Conjunto de datos de entrenamiento	133 datos	139 datos
Conjunto de datos de validación	128 datos	134 datos
Tiempo de entrenamiento	134.4 ms	134.4 ms
Tiempo medio de cómputo	0.01 ms	0.01 ms

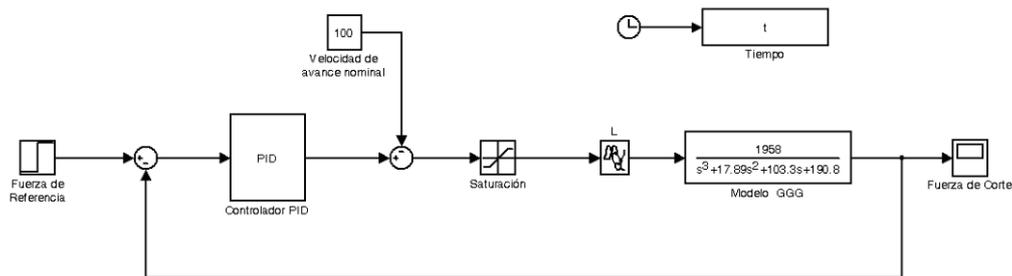
Dado que se pretende simular una operación de taladrado de 15 mm (parámetros que se utilizará en el proceso industrial real) se estima una duración aproximada de la operación de 10 segundos, fijándose este tiempo como tiempo de simulación. Por otra parte, se elige como fuerza de referencia o fuerza objetivo el valor $F_R = 1000$ N.

Cabe recordar que el principal objetivo es obtener una respuesta transitoria sin sobrepaso o máximo pico (Ovt. = 0%), con un tiempo de establecimiento inferior a 2 segundos utilizando como condiciones iniciales las proporcionadas por el manual del fabricante de la herramienta para la combinación dada de material y broca. Desde el punto de vista práctico la existencia de una condición inicial en la velocidad de avance (100 mm/min para el acero GGG40), añade a los requisitos a cumplir en la respuesta transitoria y en el tiempo de establecimiento una mayor dificultad.

Para completar el estudio comparativo y hacerlo con el mayor rigor posible, se ha incluido una simulación con un regulador PID (en un esquema de control simple a lazo cerrado) por su amplia utilización en el control de procesos a nivel industrial (Figura 5.17). Además se pretende aprovechar el acervo en el control del proceso de taladrado [239] y en los sistemas de control en red Profibus [303]:

$$\begin{aligned}
 f[k] &= f_p[k] + f_i[k] + f_d[k] \\
 f_p[k] &= K_p \cdot e[k] \\
 f_i[k] &= f_i[k-1] + \left(\frac{K_p \cdot h}{T_i} \right) \cdot e[k] \\
 f_d[k] &= \frac{T_d}{T_d + N \cdot h} f_d[k-1] + \frac{K_p \cdot T_d \cdot N}{T_d + N \cdot h} \cdot (e[k] - e[k-1]) \\
 e[k] &= F_r - F[k]
 \end{aligned} \tag{5.6}$$

donde $N = 10$ es el coeficiente del filtro para la componente derivativa y $h = 0.069s$ es tiempo de muestreo.



5.17. Simulación con un regulador PID

Los parámetros del regulador PID utilizados en el estudio comparativo fueron: $K_p = 0.1086$, $T_i = 0.1483$, $T_d = 0.0219$ (Ziegler Nichols- ZN). Igualmente, en el estudio se ha incluido un segundo regulador PID cuyos parámetros son $K_p = 0.01086$, $T_i = 0.01483$, $T_d = 0.00219$ (ganancias x 0.1). La elección de los reguladores PID diseñados y el ajuste utilizando el método de Ziegler-Nichols se ha hecho teniendo en cuenta trabajos previos relacionados con el control en red (Lee, *et al.*, 2003) [303].

La Figura 5.18 muestra el estudio en simulación del comportamiento del sistema de control por modelo interno en el que está actuando la perturbación (5.5). Si analizamos la respuesta dinámica a lazo cerrado se puede comprobar que el sobrepaso máximo (*Ovt.*) del sistema ANFIS-CMI es del 0.6 %, y los tiempos de subida y de pico son muy reducidos. En la misma figura se ven representadas también las dinámicas del control PID ajustado por Ziegler Nichols y Ziegler Nichols modificado.

La Tabla 5.3 muestra el estudio comparativo del sistema ANFIS-CMI con los controladores PID ajustados tal y como se mencionó anteriormente. Desde la perspectiva de los sistemas de control es usualmente aceptado comprobar la validez de un determinado esquema y/o estrategia de control por medio cifras de mérito o índices de comportamiento. Estas cifras aportan a través de valores numéricos información relevante sobre el comportamiento dinámico (por ejemplo, la importancia de que el sobrepaso sea pequeño para no dañar accionamientos o elementos del sistema), precisión y rapidez del sistema (los criterios cuadráticos del error y la utilización del tiempo). En este trabajo, se utilizan diferentes cifras de mérito o índices de comportamiento tales como el criterio de la integral del valor absoluto del error a través del tiempo (*ITAE*), la integral del cuadrado del error por el tiempo (*ITSE*) y la integral del valor absoluto del error (*IAE*).

$$ITAE = \int_0^T t |e(t)| dt \tag{5.7}$$

$$ITSE = \int_0^T te^2(t)dt \tag{5.8}$$

$$IAE = \int_0^T |e(t)|dt \tag{5.9}$$

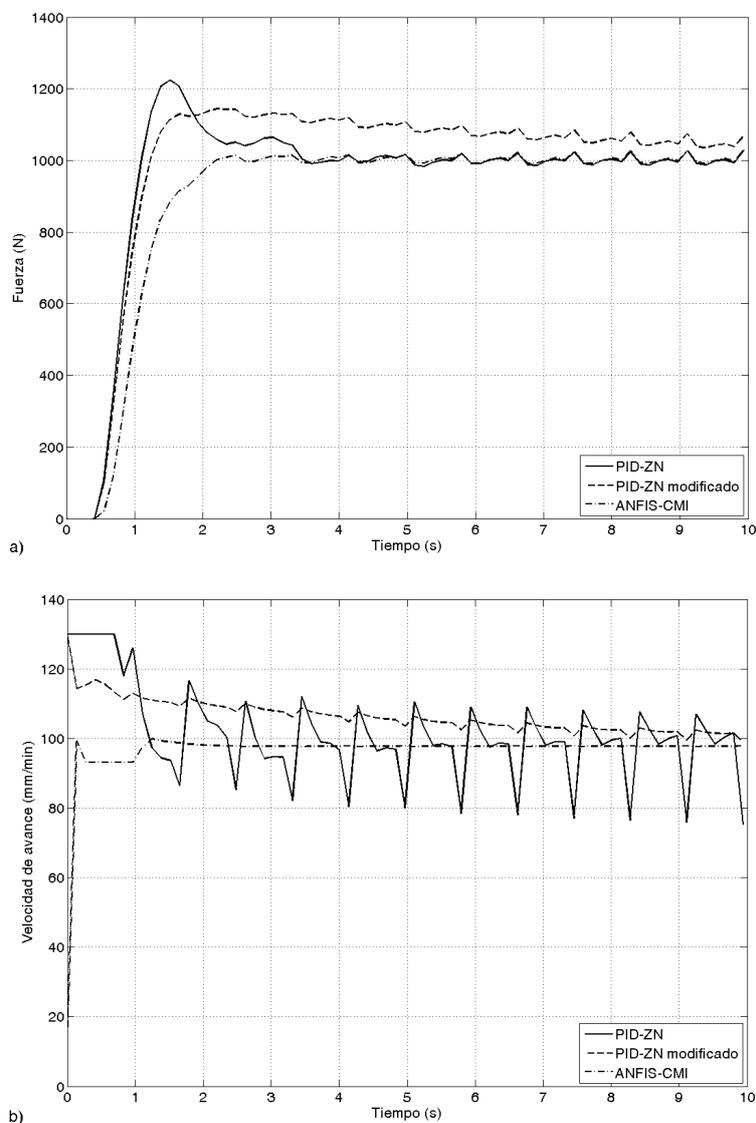


Figura 5.18. Simulación del sistema: a) respuesta del sistema ante un escalón y b) acción de control correspondiente

Tabla 5.3. Estudio de los sistemas de control

Controlador	ITAE	ITSE	IAE	Ovt. (%)
PID ZN	0.83	0.31	1.03	22.41
PID ZN modificado	4.03	0.59	1.60	14.46
ANFIS-CMI	0.54	0.32	0.96	2.36

Para analizar el sistema de control en otras condiciones, se realizaron simulaciones con diferentes retardos comprendidos entre [0.1, 0.9] segundos y diferentes ganancias en el modelo del proceso con el objeto de considerar posibles incertidumbres en el proceso (desgaste de la broca) y en el retardo de la red (*jitter*).

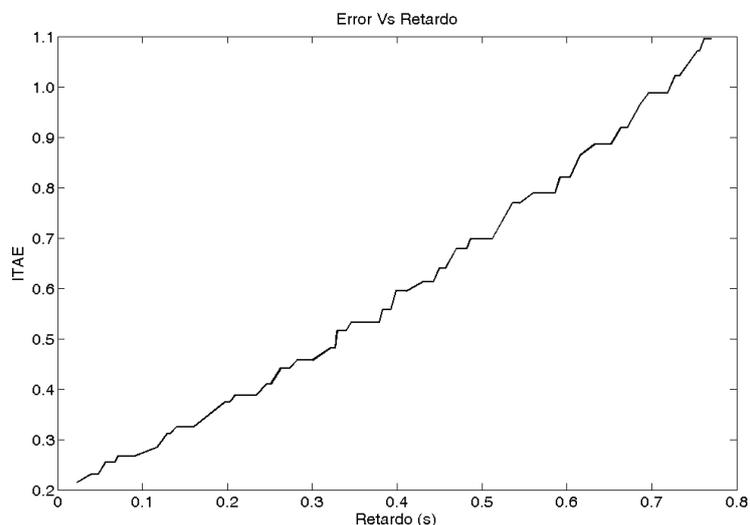


Figura 5.19. Relación entre el error *ITAE* del sistema de control ANFIS-CMI ante simulaciones con distinto retardo

En la Figura 5.20 se muestra la respuesta dinámica del sistema para el caso del mayor y del menor retardo empleados en las simulaciones realizadas. Como se puede observar, pese a que la respuesta con mayor retardo es más lenta (como cabía esperar de antemano), aun así, sigue proporcionando una respuesta exenta de inestabilidades y más que aceptable para los objetivos perseguidos.

En vista de los buenos resultados que ofrecen las simulaciones, se decide implementar el sistema de control por modelo interno basado en ANFIS y aplicarlo a un proceso de taladrado real (industrial).

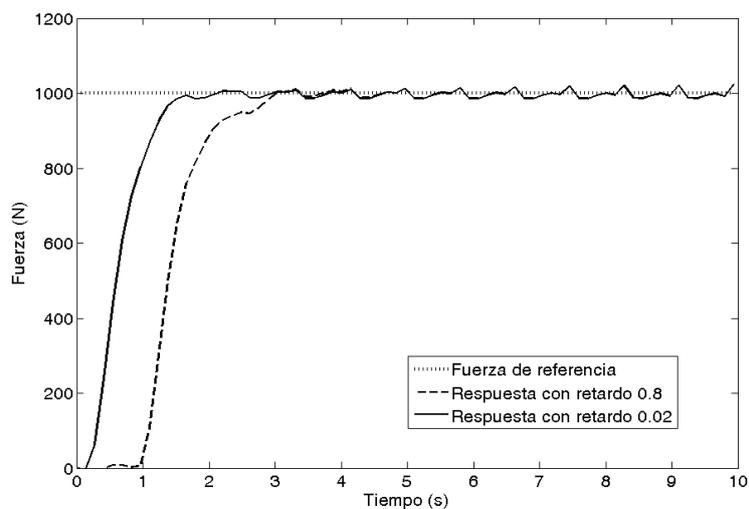


Figura 5.20. Respuesta del sistema con el menor y con el mayor de los retardos simulados

Resultados

Tal y como se ha visto en el apartado anterior, la plataforma experimental en la que se han realizado las pruebas industriales del control neuroborroso del proceso de taladrado de alto rendimiento admite dos configuraciones distintas: una realizando el control únicamente a través de la red Profibus y otra en la que el control se realiza a través de Ethernet (sobre un primer nivel de red Profibus).

Para validar el sistema de control propuesto se han realizado experimentos en ambas configuraciones y, además, se ha trabajado con diversos materiales con el objeto de probar la robustez y eficacia del sistema. Las pruebas se han realizado sobre probetas de fundición nodular GGG40 (A395) y sobre probetas de aleación de acero inoxidable 17-4PH (A564). Al ser dos materiales completamente distintos, las condiciones de operación (recomendadas por los fabricantes de brocas) varían. Estas condiciones y otros datos de interés acerca de los experimentos se encuentran resumidos en la Tabla 5.4.

El periodo de muestreo en los sistemas de control se encuentra relacionado con la velocidad nominal de giro del cabezal (el ciclo de control se ejecuta en cada revolución del cabezal). Como ya se dijo en el Apartado 5.1.1, en todos los experimentos (tanto en las dos configuraciones de red, como en los experimentos con ambos materiales) se utilizaron brocas de diámetro 10 mm Sandvik R840-1000-30-A0A.

Tabla 5.4. Condiciones de operación para los materiales estudiados

Material	A395	A564
Dureza	233 HB	43 HRc
Velocidad de giro [rpm]	870	780
Velocidad de avance ⁵ [mm/min]	100	93
Diámetro de la herramienta [mm]	10	10
Máxima profundidad de corte [mm]	14	14
Tiempo estimado de ciclo ⁶ [s]	8.4	9.0
Periodo de muestreo [ms]	69	77
Valor de referencia (<i>setpoint</i>) [N]	1000	2000

⁵ La velocidad de avance es fijada inicialmente en el programa de operación del CNC con el objeto de comenzar a ejecutar el programa, y después es manipulada por el sistema de control ANFIS-CMI.

⁶ Asumiendo velocidad de avance y velocidad de giro constantes durante toda la operación de taladrado, y sin la influencia de perturbaciones (material anisotrópico) durante el proceso de taladrado.

Control a través de Profibus

Para comprobar y validar el funcionamiento del sistema de control neuroborroso por modelo interno se realizaron varios ensayos con el material GGG40, realizando el control desde el PC1. Al igual que en la parte de simulación, se deciden realizar también ensayos experimentales con dos distintos controladores PID en un lazo de control simple (uno ajustado por Ziegler-Nichols y otro ajustado con una modificación sobre este método).

Los resultados de los ensayos experimentales en el taladrado del material GGG40 (dureza de 233HB) se muestran en la Figura 5.21. Se puede observar como a pesar de la exigente condición inicial y del retardo, el sistema de control neuroborroso basado en modelos ANFIS garantiza una respuesta dinámica rápida (tiempo de establecimiento de 2 segundos) y sin sobrepaso. Con este sistema de control se consigue aumentar la tasa de arranque de material. Además, la calidad en la respuesta transitoria y la no existencia de sobrepaso y oscilaciones en la respuesta contribuyen desde el punto de vista industrial a un mejor aprovechamiento de la vida útil de la herramienta. En este caso se observa claramente como el sistema propuesto obtiene mejores resultados que los controladores PID. En la Tabla 5.5 se muestran las distintas cifras de mérito o índices de comportamiento de todos los sistemas de control.

Tabla 5.5. Cifras de mérito de los experimentos reales con material GGG40 (A395)

<i>Controlador</i>	<i>ITAE</i>	<i>ITSE</i>	<i>IAE</i>	<i>Ovt. (%)</i>
PID ZN	4.21	2.36	1.16	18.37
PID ZN modificado	1.94	0.97	1.23	17.73
ANFIS-CMI	0.90	0.20	0.93	0.00

Con el objetivo de verificar la validez del sistema de control ANFIS-CMI, este se aplicó en el taladrado de otro material de mayor dureza, el 17-4PH (43 HRC). En este caso, las condiciones de corte difieren respecto al caso anterior. Las velocidades nominales de avance y giro fueron 93 mm/min y 780 rpm, respectivamente y fueron seleccionadas de acuerdo con el manual de usuario de la herramienta de corte. Además, el valor de referencia fue 2000 N, que también varía respecto del utilizado en el taladrado del GGG40. En la Figura 5.22 se muestra el comportamiento de la fuerza de corte y la velocidad de avance. Se puede observar la calidad de la respuesta transitoria (sin sobrepaso) y la precisión del sistema de control. Cabe destacar en esta ocasión que el sistema de control ANFIS-CMI no se ha comparado con ningún control con PID. Este hecho es debido a que, para ajustar el control PID, necesitaríamos el modelo de la planta (para realizar una simulación) o bien hacer una serie de pruebas que llevarían la planta a condiciones de inestabilidad con terribles consecuencias. El modelo utilizado para el taladrado del GGG40 no sirve para representar la dinámica del proceso de taladrado con el material 17-4PH dado que varían los parámetros del proceso.

Aparte del buen control que realiza el sistema ANFIS-CMI del taladrado del material 17-4PH, se observa de este modo otra de las importantísimas ventajas del sistema propuesto, ya que no es necesario poseer un modelo de la planta para poder llegar a controlarla de un modo efectivo.

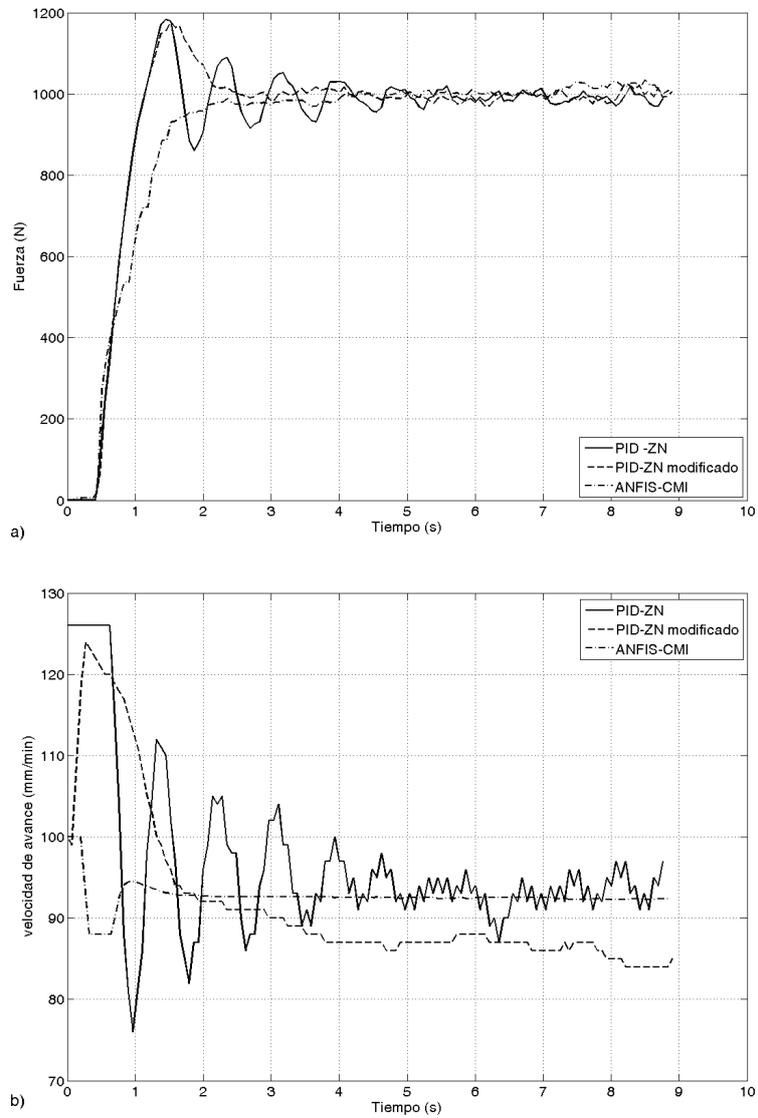


Figura 5.21. a) Comportamiento de la fuerza de corte y b) Acción de control en el taladrado del material GGG40

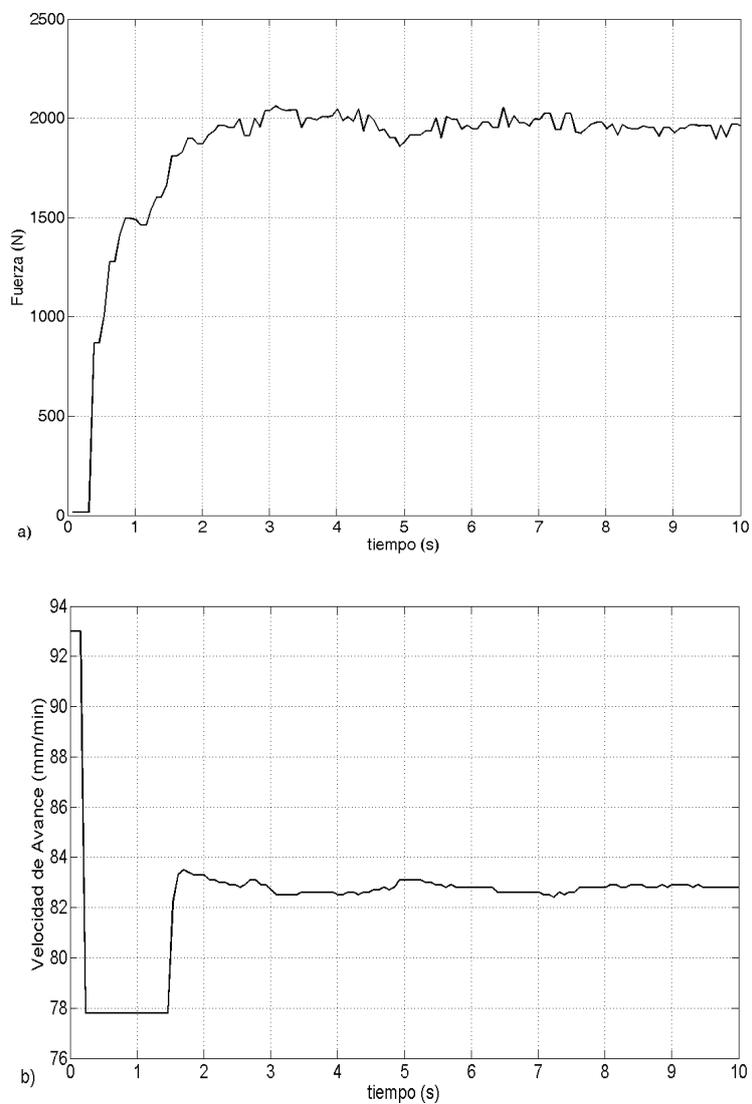


Figura 5.22. a) Comportamiento de la fuerza de corte y b) Acción de control en el taladrado del material 17-4PH

Control a través de Ethernet

Tras haber obtenido unos buenos resultados con el control neuroborroso por modelo interno (basado en modelos ANFIS) a través de Profibus, se procede ahora a realizar ensayos experimentales en los mismos materiales con el control situado en el PC2 (Ethernet). En este caso, se decide ampliar el estudio comparativo para contrastar el método propuesto con otra serie de aproximaciones. Por una parte el sistema ANFIS-CMI se comparará con el control PID ajustado con el método de Ziegler Nichols modificado, tal y como se hizo en simulación y en el apartado anterior ($K_p = 0.01086$, $T_i = 0.01483$, $T_d = 0.00219$). Por otra parte se realizará una segunda comparación con un controlador borroso: un lazo de control simple con un controlador borroso optimizado por el método de Nelder-Mead, igual que el reflejado en [138]. El sistema de control consiste en un controlador borroso con dos entradas (error de fuerza y cambio en el error), una salida (incremento en la velocidad de avance), nueve reglas de control, el operador sub-producto como operador composicional para la inferencia de reglas y el centro del área como método de desemborronado (Figura 5.23).

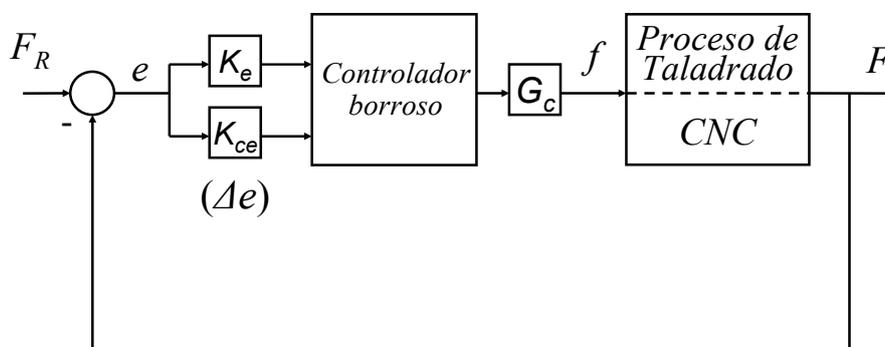


Figura 5.23. Control del proceso de taladrado a través del controlador borroso optimizado por Nelder-Mead

El universo de discurso de las variables de entrada consiste en tres funciones de pertenencia de forma triangular en el rango de $[-150,150]$. El universo de discurso de la variable de salida consiste en cinco funciones de pertenencia de forma trapezoidal, equi-espaciadas y ajustadas de acuerdo a una modificación máxima de la velocidad de avance bajo condiciones nominales de corte. El ajuste óptimo de los factores de escala en las entradas del controlador borroso $[K_e, K_{ce}]_{OPT} = [0.0559, 0.1156]$ se ha calculado usando el criterio *ITAE* y se ha determinado usando el algoritmo de búsqueda de Nelder-Mead.

Por último, para completar el estudio comparativo, se muestra también el comportamiento del proceso de taladrado de alto rendimiento sin ningún sistema de control, es decir, solamente utilizando el CNC (sin variar los parámetros a lo largo del tiempo).

El controlador PID, el regulador borroso óptimo y el controlador ANFIS-CMI utilizan todos la misma variable de control (fuerza de corte). Sin embargo, el controlador lineal y el controlador borroso están contenidos en un lazo de control simple, mientras que el control neuroborroso está basado en un lazo de control por modelo interno que contiene los modelos inverso y directo. Los sistemas borroso y neuroborroso difieren en varios aspectos. El controlador borroso es un sistema doble-entrada/simple-salida del tipo Mamdani, con funciones de pertenencia triangulares y trapezoidales y nueve reglas de control. Por contra, el sistema neuroborroso es un sistema simple-entrada/simple-salida del tipo Takagi-Sugeno con funciones de pertenencia gaussianas y solo dos reglas de control.

Los resultados de los ensayos experimentales con el material GGG40 se muestran en la Figura 5.24. El comportamiento de la fuerza de corte con el sistema ANFIS-CMI se representa en línea continua. A pesar de las exigentes condiciones iniciales y del retardo, el control neuroborroso por modelo interno cumple con los requisitos del diseño: una rápida respuesta a lazo cerrado y sin sobrepaso. Además, desde el punto de vista técnico la calidad de la respuesta transitoria y la respuesta libre de oscilaciones conducen a una mejor utilización y uso de la herramienta de corte. Se puede concluir que el sistema de control ANFIS-CMI proporciona una respuesta dinámica mejor a la de los otros sistemas. La Tabla 5.6 muestra las correspondientes cifras de mérito. A primera vista, el comportamiento del controlador borroso y el sistema ANFIS-CMI parecen similares. Sin embargo, la implementación ANFIS-CMI tiene un mejor desempeño bajo los criterios *ITSE* e *IAE* que el controlador borroso. Además, la implementación ANFIS-CMI resulta más sencilla y tiene un comportamiento computacional más eficiente. Bajo el criterio *ITAE*, el controlador borroso óptimo se muestra mejor en todos los experimentos. Este comportamiento es debido a que el ajuste de optimización del controlador borroso, se ha hecho buscando únicamente la minimización del criterio *ITAE*.

Tabla 5.6. Cifras de mérito de los experimentos reales con material GGG40 (A395) - Ethernet

<i>Controlador</i>	<i>ITAE</i>	<i>ITSE</i>	<i>IAE</i>	<i>Ovt. (%)</i>
ANFIS-CMI	0.95	0.15	0.76	No
Borroso [138]	0.75	0.20	0.88	No
PID	0.79	0.19	0.87	17.84
Solo CNC	4.76	0.72	1.39	16.36

La Figura 5.25 muestra la comparación de los resultados obtenidos en el taladrado del material 17-4PH con el control a través de Ethernet (PC2). Nuevamente no se incluye en esta comparación el control con PID por las mismas razones que en el caso anterior (Control a través de Profibus). Es importante resaltar que la respuesta transitoria con el control borroso y con el sistema ANFIS-CMI muestra un comportamiento similar. En la Tabla 5.7 se reflejan los índices de comportamiento para el proceso de taladrado de este acero inoxidable. El sobrepaso del sistema ANFIS-CMI es ligeramente superior al aportado por el controlador borroso. Sin embargo, una vez más los criterios *ITSE* e *IAE* indican que el sistema propuesto en este trabajo proporciona una mejor respuesta.

Tabla 5.7. Cifras de mérito de los experimentos reales con material 17-4PH (A564) - Ethernet

<i>Controlador</i>	<i>ITAE</i>	<i>ITSE</i>	<i>IAE</i>	<i>Ovt. (%)</i>
ANFIS-CMI	2.25	0.24	0.78	7.22
Borroso [138]	1.91	0.26	0.93	6.03
Solo CNC	3.50	0.44	1.19	20.97

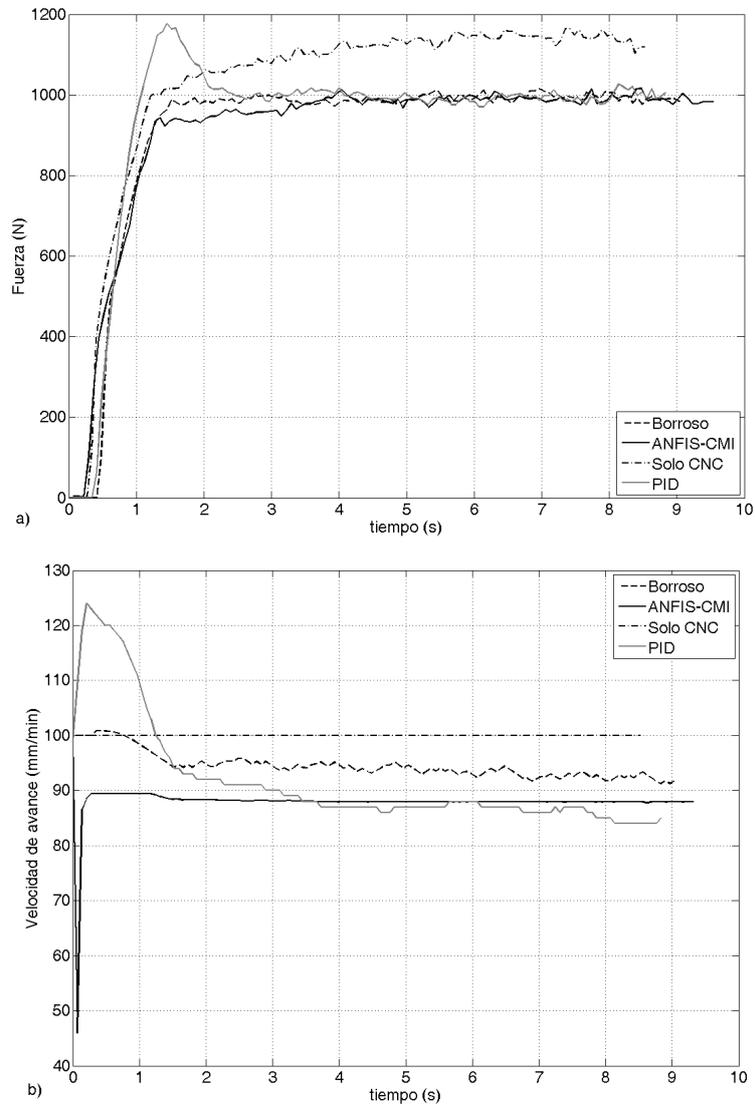


Figura 5.24. a) Comportamiento de la fuerza de corte y b) Acción de control en el taladrado del material GGG40 (Ethernet)

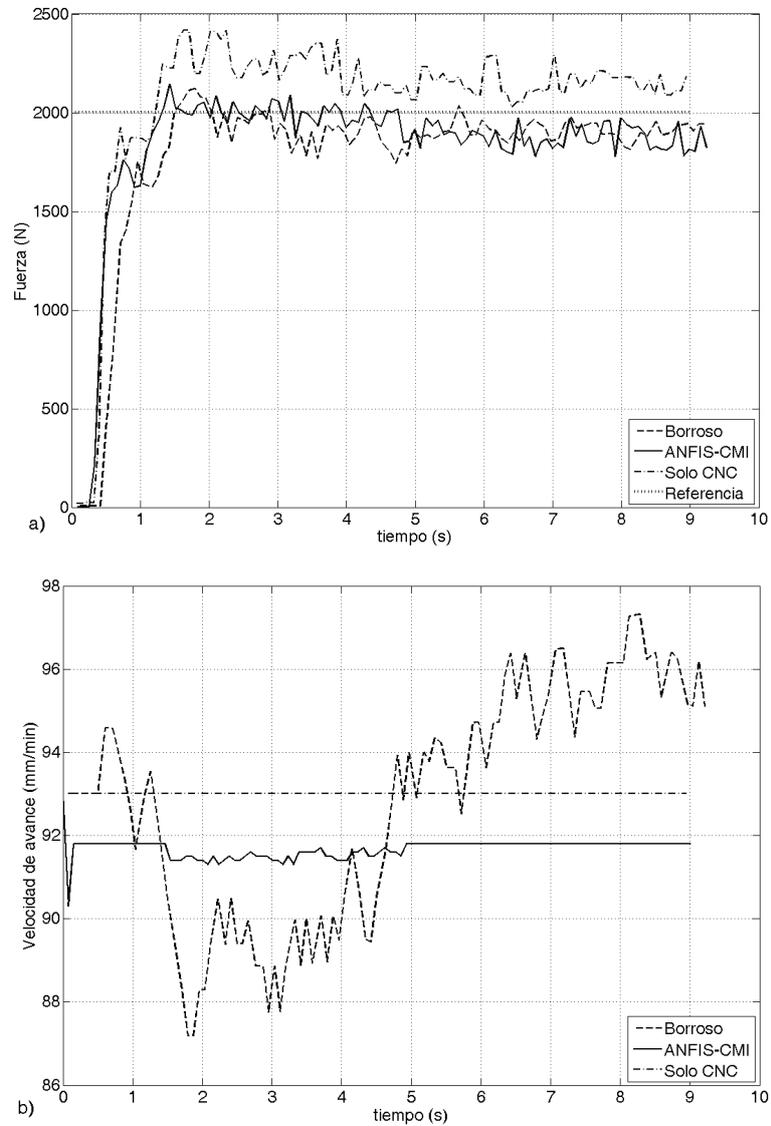


Figura 5.25. a) Comportamiento de la fuerza de corte y b) Acción de control en el taladrado del material 17-4PH (Ethernet)

Pese a que a lo largo del trabajo, en ciertas figuras los sistemas de control muestran comportamientos aparentemente similares, en todos los casos el sistema ANFIS-CMI ofrece una importante diferencia con respecto al resto, tanto al principio como al final de la operación: respuesta suave al principio y en torno al valor de referencia a lo largo de todo el proceso. Esto se traduce en que la entrada de la broca en la pieza es mucho más suave y a que el desalajo de la viruta en la parte final se hace de un modo más correcto (factores importantes para el desgaste de herramienta y calidad superficial).

Comportamientos similares al obtenido por el controlador ANFIS-CMI pueden ser alcanzados con el empleo de otras técnicas de control, sin embargo, cualquier mejora implicaría necesariamente leyes de control más complejas. Existen también diversos métodos para ajustar controladores PID (a parte de los utilizados en este trabajo), pero los modelos lineales usados para la optimización no son válidos para la región de operación completa (incertidumbres en las ganancias del proceso) y por tanto, no se pueden garantizar los resultados esperados. Por esta razón, el control PID o las estrategias de planificación de ganancias (*gain scheduling*) no han producido las mejoras esperadas en los procesos de taladrado. Del mismo modo, las estrategias de control adaptativo son generalmente más complejas, consumen más tiempo de computación y pueden provocar sobrecargas ya que los parámetros y las ganancias de los controladores son estimados en línea en tiempo real. El controlador ANFIS-CMI propuesto es sencillo y fácil de implementar si existen previamente datos entrada/salida. Para este caso de estudio, solo cuatro reglas (dos para el modelo directo y dos para el inverso) son suficientes para implementar la ley de control y asegurar el comportamiento deseado.

5.4. Modelado y Control a través de TNFIS

El presente apartado trata el diseño de un sistema neuroborroso transductivo (TNFIS) para la obtención de modelos locales del proceso de taladrado. Al igual que en el caso de ANFIS, el objetivo es incorporar posteriormente los modelos obtenidos en un sistema de control por modelo interno para el control de la fuerza de corte en un proceso de taladrado a través de la modificación de la velocidad de avance de la herramienta. La principal diferencia en este caso radica en que, debido al uso de la inferencia transductiva, la creación del modelo se hace *on-line* y en cada instante de tiempo (cada periodo de muestreo). Por tanto, aunque en este apartado se encuentren separados los puntos de modelado y control, las dos acciones se ejecutan conjuntamente.

A lo largo de la explicación del procedimiento de modelado y control del proceso de taladrado, se estudiará, analizará y verificará el comportamiento del sistema neuroborroso transductivo TNFIS en el control de un proceso complejo. Ya que la creación de cada modelo local se hace en cada dato de entrada al sistema de control, es conveniente estudiar en profundidad como TNFIS realiza el modelado dinámico. Del mismo modo es necesario evaluar la eficiencia computacional del método y la viabilidad de la aplicación en tiempo real de este algoritmo.

A continuación se describe primeramente el procedimiento de modelado, tanto de la dinámica directa como de la dinámica inversa del proceso de taladrado. Después se detallará cómo los sistemas neuroborrosos transductivos crean los modelos locales en el contexto del paradigma de control por modelo interno. Finalmente, se analizarán los resultados obtenidos tanto en simulación como en la aplicación a un proceso de taladrado real.

5.4.1. Modelado

Al igual que en el caso de modelado a través de ANFIS, y en concordancia con los modelos encontrados en la literatura, aquí se considera nuevamente el proceso de taladrado con un modelo simple-entrada / simple-salida, siendo la velocidad de avance de la herramienta de corte (f) la variable de entrada y la fuerza media de corte (F) la variable de salida. Sin embargo, en el caso de TNFIS se decide incorporar como entradas al modelo estados anteriores de las variables de entrada y salida para conseguir una mejor aproximación en las relaciones fuerza-avance del conjunto de entrenamiento de los algoritmos (*Output Error Model*).

Así, para modelizar la dinámica directa del proceso de taladrado se entrena a un sistema TNFIS por medio de datos entrada-salida en cada periodo de muestreo (5.10). Nuevamente, para obtener el modelo inverso que represente la dinámica inversa de la operación de taladrado, en lugar de invertir analíticamente el modelo directo obtenido, se diseña e implementa otro sistema TNFIS a través de otro conjunto de entrenamiento (5.11), el cual contiene datos con valores de fuerza de corte como entrada (más estados anteriores del modelo) y valores de velocidad de avance como la salida. De esta manera, el sistema aprende con éxito la dinámica inversa del proceso taladrado en cada periodo de muestreo.

$$\hat{F}(k) = G_M(f(k), f(k-1), \hat{F}(k-1)) \quad (5.10)$$

$$f(k) = G_M'(F(k), F(k-1), f(k-1)) \quad (5.11)$$

donde $\hat{F}(k)$ es la fuerza de corte estimada por el modelo directo y $f(k)$ la velocidad de avance calculada por el modelo inverso.

Similarmente a como sucedía con los modelos basados en ANFIS, como parámetros del modelo se han fijado la velocidad de giro de la herramienta, el diámetro de la herramienta de corte y la velocidad de avance inicial. Como perturbaciones no medibles ni estimables quedan el desgaste de la herramienta de corte y las posibles variaciones en la profundidad de corte. Pese a que el entrenamiento se hace para cada nuevo dato de entrada, los datos de entrenamiento se mantienen invariantes durante toda la operación. La única diferencia es que en cada instante de tiempo se seleccionarán, de entre los datos del conjunto de entrenamiento, los vecinos más cercanos al dato de entrada. Se han utilizado los mismos datos de entrenamiento que se utilizaron para entrenar a los modelos basados en ANFIS. Estos datos son datos reales de fuerza de corte y velocidad de avance obtenidos experimentalmente sobre operaciones en GGG40 y bajo las condiciones de corte recomendadas por el fabricante de herramienta. Una de las ventajas que aporta la utilización de una inferencia transductiva es que el conjunto de datos utilizados para el entrenamiento no tiene que ser muy amplio. Basta con que el conjunto de entrenamiento contenga valores representativos de cada región de operación.

La Figura 5.26 muestra los modelos (directos e inversos) obtenidos por TNFIS en cada instante de tiempo a lo largo de una operación completa de taladrado. Pese a que los modelos ofrecen una salida discreta en cada instante de tiempo, se han unido los puntos con una línea para representar la dinámica de la operación.

En esta ocasión, el grado de exactitud de los modelos vendrá determinado por la elección de ciertos parámetros del algoritmo TNFIS tales como el número de vecinos más cercanos (N_q), el número de iteraciones y la tasa de aprendizaje del algoritmo de propagación de errores, el valor umbral de agrupamiento (D_{thr} - parámetro del algoritmo ECM), etc. A la hora de elegir un valor óptimo de estos parámetros, se trata de buscar un equilibrio entre la precisión de los modelos y la respuesta dinámica de los mismos. Al igual que en el caso de ANFIS, en los modelos obtenidos por TNFIS se utilizan los mismos parámetros del algoritmo para obtener tanto el modelo directo como el modelo inverso.

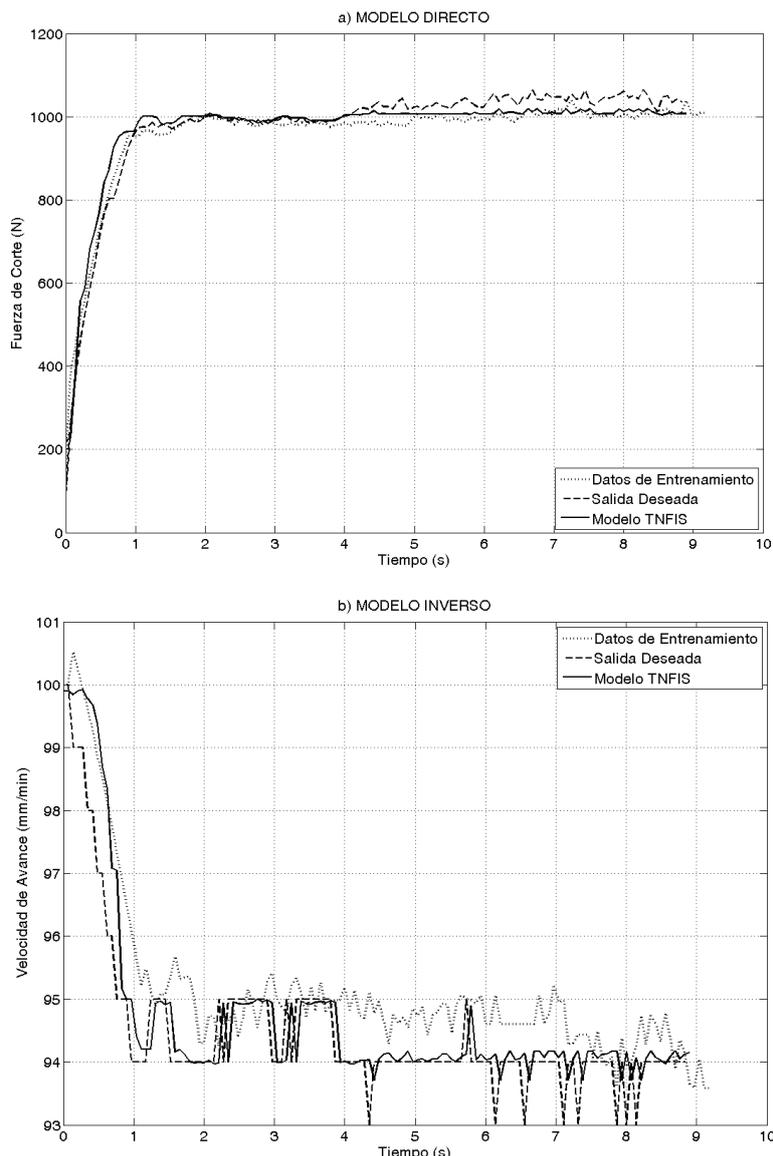


Figura 5.26. Modelos a) directo e b) inverso del proceso de taladrado obtenidos por TNFIS

En resumen, los parámetros seleccionados son: un número de vecinos más cercano (N_q) igual a 5 y un número de iteraciones del algoritmo de propagación hacia atrás de errores de 20, con una tasa de aprendizaje de 0.001. Con respecto al algoritmo ECM se ha escogido como valor umbral para la generación de conjuntos $D_{thr} = 1$.

5.4.2. Control

De nuevo, el control neuroborroso (en este caso transductivo) del proceso de taladrado se hace a través del paradigma de control por modelo interno. La combinación de este paradigma de control con el sistema neuroborroso TNFIS no supone un sustituto perfecto de otras estrategias de control. Sin embargo, su utilización reporta una serie de ventajas como son: facilidad de uso en determinadas situaciones en las que la identificación clásica de sistemas es imposible o cuando la obtención de un modelo general (a través de otras estrategias borrosas, neuronales o neuroborrosas) es difícil, innecesaria o no ha aportado los resultados esperados.

Por estas razones, los sistemas TNFIS utilizados para modelizar la dinámica directa (5.10) e inversa (5.11) del proceso de taladrado (Figura 5.26) se introducen en el esquema de control por modelo interno tal y como se muestra en la Figura 5.27. El objetivo sigue siendo mantener la fuerza de corte constante en toda la operación (variable controlada) a través de la modificación de la velocidad de corte de la herramienta (acción de control). Para ello se utilizan también los mismos valores del filtro que se seleccionaron en el caso del control a través de ANFIS ($k_1 = 0.6$ y $k_2 = 0.8$).

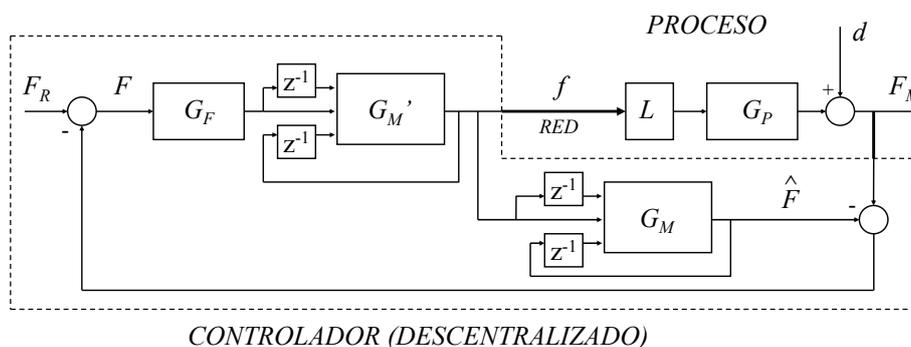


Figura 5.27. Esquema de control por modelo interno basado en modelos TNFIS

Pese a que se realizó un profundo estudio en simulación para comprobar la validez del procedimiento propuesto, se muestran a continuación directamente los resultados obtenidos en ensayos industriales reales. Por otra parte, se decide prescindir en esta ocasión (en la medida de lo posible) del software propietario y se decide realizar el control solamente a través del segundo nivel de red de la plataforma experimental, es decir, a través de Ethernet.

Control a través de Ethernet

En el control a través de Ethernet, el esquema de control de la Figura 5.27 se aplica teniendo en cuenta las limitaciones y características de este caso de estudio. En este caso la acción de control se calcula en el PC2. Tal y como se ha explicado anteriormente, este PC opera como servidor y en él se encuentra propiamente el sistema TNFIS-CMI desarrollado en C++. El sistema TNFIS-CMI calcula la acción de control (f) en base a la medida de la fuerza recibida y la envía al PC1 que posteriormente escribirá la variable en el CNC de arquitectura abierta.

Se han llevado a cabo operaciones de taladrado con el sistema de control TNFIS-CMI en el material GGG40 y en el 17-4PH. Las condiciones de operación (recomendadas por los fabricantes de herramientas) fueron las mismas que las mostradas en la Tabla 5.4. Sin embargo, cabe recordar que los sistemas TNFIS que generan los modelos directo e inverso utilizan conjuntos de entrenamiento que solo poseen datos de operaciones de taladrado sobre el material GGG40. El objetivo entonces es demostrar que la estrategia de control basada en TNFIS-CMI es adecuada para controlar una serie de condiciones de operación para las que no ha sido entrenado. También es necesario recalcar que, aunque el conjunto de datos de entrenamiento contenga unos 140 datos aproximadamente, en cada iteración únicamente se emplearán 5 de ellos (los más cercanos) para crear y ajustar el modelo local.

En esta ocasión, se vuelven a utilizar los criterios de error (cifras de mérito) de la integral del valor absoluto del error a través del tiempo ($ITAE$), de la integral del cuadrado del error por el tiempo ($ITSE$) y de la integral del valor absoluto del error (IAE) para poder comparar el sistema TNFIS-CMI con el resto de sistemas de control vistos anteriormente. El sobrepaso

(Ovt.) también se incluye en el estudio comparativo debido a la influencia que tiene la respuesta dinámica del sistema en la vida útil de la herramienta.

Los resultados del control neuroborroso transductivo por modelo interno en el taladrado de piezas GGG40 se muestran en la Figura 5.28. El comportamiento de la fuerza de corte se muestra en la parte superior. A pesar de la exigente condición inicial (*i.e.*, velocidad de avance nominal de 100 mm/min) y del retardo (*i.e.*, 0.4 s), el sistema TNFIS-CMI alcanza los requisitos de diseño con una rápida respuesta a lazo-cerrado y con la inexistencia de sobrepaso. Además, la buena calidad de la respuesta transitoria y la respuesta libre de oscilaciones responden a una mejor utilización en la vida útil de la herramienta. Del mismo modo se ha comprobado la viabilidad computacional del método, ya que el sistema es capaz de modelizar las dinámicas (directa e inversa) en cada instante de tiempo y, por tanto, es capaz de calcular una acción de control en tiempo de ciclo.

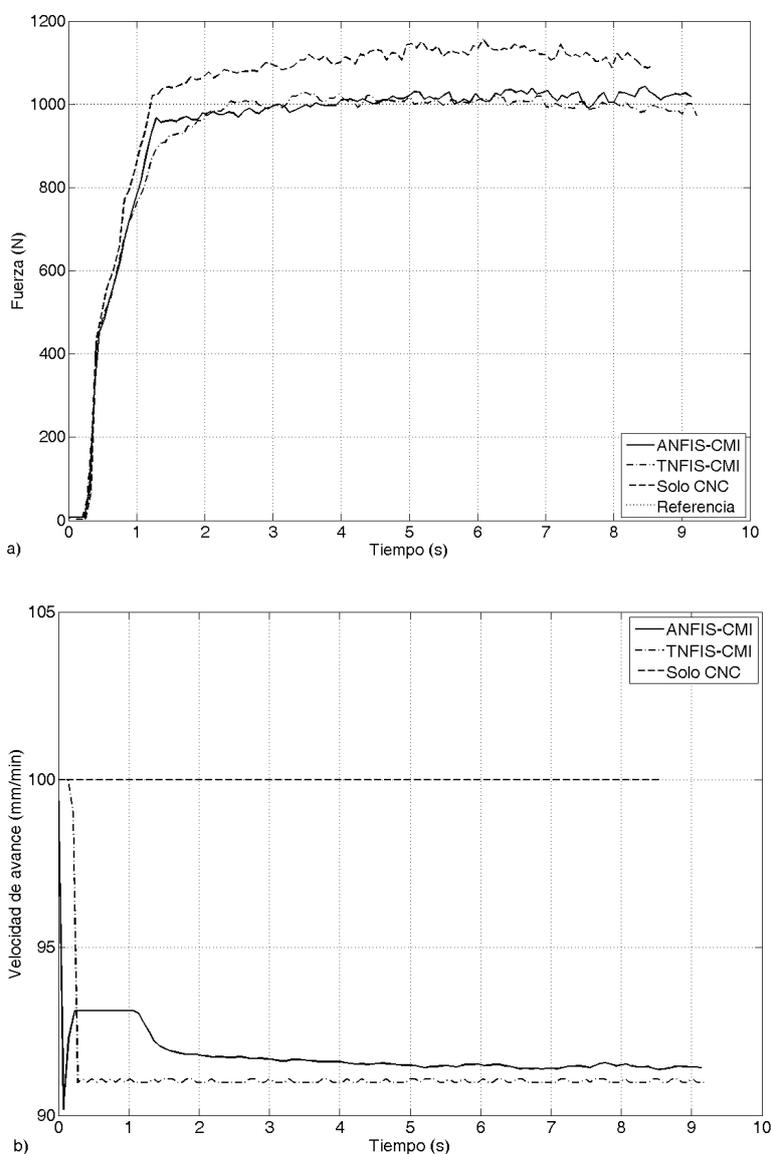


Figura 5.28. a) Respuesta del sistema real y b) acción de control en operaciones con GGG40

La Tabla 5.8 recoge los índices de comportamiento de la prueba experimental real llevada a cabo en un entorno industrial. Estos índices se han calculado usando los datos reales de la operación (*e.g.*, fuerza de corte, tiempo) recogidos en tiempo real. En esta ocasión se ha incorporado al estudio comparativo un sistema de control ANFIS-CMI como el explicado en apartados anteriores y una operación sin ningún tipo de sistema de control (Solo CNC). En vez de utilizar los datos de experimentos anteriores, se ha realizado un nuevo experimento con el sistema ANFIS-CMI y sin sistema de control el mismo día en que se realizó el ensayo con el sistema de control TNFIS-CMI. La razón es que todas las operaciones tengan aproximadamente las mismas condiciones ambientales y sobre todo, el mismo estado de desgaste de herramienta para que el estudio comparativo sea lo más estricto posible. No obstante, los índices del sistema de control ANFIS-CMI son prácticamente iguales a los mostrados en el proceso de taladrado del mismo material con el sistema de control a través de Ethernet (Tabla 5.6).

Tabla 5.8. Cifras de mérito de los experimentos reales con material GGG40 (A395) - Ethernet

<i>Controlador</i>	<i>ITAE</i>	<i>ITSE</i>	<i>IAE</i>	<i>Ovt. (%)</i>
ANFIS-CMI	0.95	0.14	0.70	0.00
TNFIS-CMI	0.75	0.15	0.83	0.00
Solo CNC	3.94	0.54	1.18	15.51

A la vista de los resultados se puede observar como el sistema TNFIS-CMI presenta un comportamiento similar al sistema ANFIS-CMI. Ninguno de los dos sistemas presenta sobrepaso, siendo el sistema TNFIS-CMI el que menor índice *ITAE* tiene. En cuanto al índice *IAE*, el sistema ANFIS presenta un mejor comportamiento. El índice *ITSE* es prácticamente igual en ambos sistemas. La respuesta dinámica de ambos sistemas también es muy similar, buena en ambas operaciones, siendo el sistema TNFIS-CMI el que mejor comportamiento presenta también en la parte final de la operación de taladrado.

Una vez realizadas las operaciones de taladrado en el material GGG40, se decide también llevar a cabo una experimentación industrial real sobre operaciones en material 17-4PH. Los resultados de estas pruebas se presentan en la Figura 5.29 y en la Tabla 5.9. Ambos sistemas de control poseen datos en su base de entrenamiento de operaciones con GGG40. Se trata por tanto de evaluar a través de este experimento la influencia que tienen los cambios en las condiciones de operación sobre el deterioro en el comportamiento del controlador.

Tabla 5.9. Cifras de mérito de los experimentos reales con material 17-4PH (A564) - Ethernet

<i>Controlador</i>	<i>ITAE</i>	<i>ITSE</i>	<i>IAE</i>	<i>Ovt. (%)</i>
ANFIS-CMI	2.04	0.20	0.77	7.23
TNFIS-CMI	1.50	0.18	0.83	6.22
Solo CNC	3.29	0.45	1.27	17.34

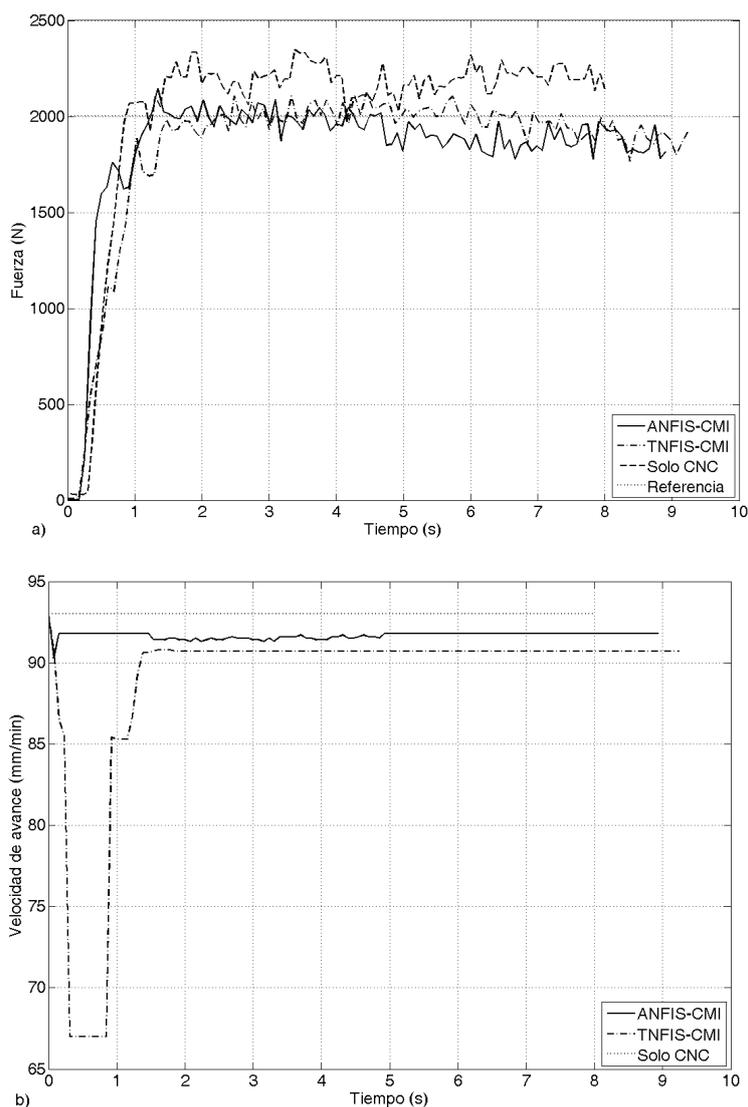


Figura 5.29. a) Respuesta del sistema real y b) acción de control en operaciones con 17-4PH

Nuevamente se incluyen en el estudio comparativo operaciones con un sistema de control ANFIS-CMI y sin sistema de control, realizadas el mismo día en que se realizó el control de la operación de taladrado a través de Ethernet con el sistema de inferencia neuroborroso transductivo en un esquema de control por modelo interno.

En esta ocasión, pese a que de nuevo ambos sistemas de control presentan una respuesta dinámica muy buena, el sistema TNFIS-CMI presenta un menor sobrepaso así como menores valores en los índices *ITAE* e *ITSE*. Únicamente en el índice *IAE* el sistema ANFIS-CMI presenta una mejor cifra de mérito. A través de una observación en la respuesta real del sistema también se puede observar como TNFIS-CMI presenta una mejor respuesta al principio y al final de la operación. Este hecho puede responder a que la evacuación de la viruta se realice de un modo más suave en la entrada de la herramienta en la pieza y al finalizar el agujero (factor importante tanto para el desgaste de la herramienta como para la calidad en la superficie de acabado).

Cabe recordar que los parámetros utilizados en cada algoritmo han sido los mostrados en los apartados de modelado de ambos sistemas neuroborrosos. No obstante se resumen a continuación en la Tabla 5.10. Tanto el modelo directo como el modelo inverso de cada estrategia han utilizado los mismos parámetros.

Tabla 5.10. Algoritmos neuroborrosos en el paradigma de control por modelo interno

Algoritmo	ANFIS	TNFIS
Sistema	Simple-entrada/ Simple-salida	Simple-entrada/ Simple-salida
Tipo de función de pertenencia	Gaussiana	Gaussiana
Número de funciones de pertenencia	2	Variable para cada entrada (máximo 5)
Tipo de Inferencia	Takagi-Sugeno	Mamdani
Número de reglas	2	Variable para cada entrada (máximo 5)
Iteraciones	100	20
Ratio de aprendizaje	0.01	0.001
Algoritmo de entrenamiento	Retropropagación + Mínimos cuadrados	Retropropagación
Conjunto de datos de entrenamiento	133 datos	139 datos
Conjunto de datos de validación	128 datos	5 datos
Tiempo de entrenamiento	134.4 ms	2.06 ms
Tiempo medio de cómputo	0.01 ms	2.3 ms

Ciertamente, en operaciones de control de taladrado la diferencia entre los sistemas ANFIS y TNFIS (de inferencia inductiva y transductiva respectivamente) no es tan significativa ya que ambos responden con comportamientos similares y ambos ofrecen mejores prestaciones en condiciones de diseño similares a otras estrategias de control analizadas (PID, Borroso).

Sistema Neuroborroso de Monitorización. Aplicación al Proceso de Torneado

El presente capítulo trata la importante problemática del desgaste de la herramienta de corte en procesos de torneado. Para hacer frente a esta problemática se propone la utilización de sistemas neuroborrosos con el fin de crear modelos que sirvan de base para monitorizar el proceso de desgaste de herramienta en operaciones de torneado. Nuevamente los modelos se crearán a partir de una serie de datos entrada-salida. Se consideran como entradas al modelo el tiempo, la fuerza de corte, las vibraciones sufridas por la herramienta (aceleraciones) y las señales de emisión acústica del proceso. Como salida del modelo se tendrá del desgaste de la herramienta (desgaste en el flanco). Tanto el conjunto de datos utilizado para crear los modelos, así como el resto de datos utilizados para validar los mismos se han obtenido de una plataforma experimental descrita en la primera parte de este capítulo. Posteriormente se detalla y fundamenta el procedimiento seguido para la monitorización del desgaste de la herramienta basada en modelos. Después se analiza y se describe cómo se modela el proceso de desgaste a través de un sistema neuroborroso ANFIS, mostrándose a continuación los resultados obtenidos. Del mismo modo, se propone diseñar otro modelo neuroborroso basado en inferencia transductiva para la monitorización del desgaste de la herramienta. En la última parte del capítulo se muestra la implementación y los resultados ofrecidos por la técnica transductiva elegida: TWNFI-i.

6.1. Plataforma Experimental

En primer lugar, es necesario aclarar que la monitorización del desgaste de la herramienta en procesos de torneado, a través de modelos neuroborrosos, está basada en la plataforma experimental y en los datos experimentales presentados por Sharma, *et al.* en [253, 254]. La razón fundamental por la que se deciden utilizar estos datos es porque se pretende contrastar la validez de los métodos propuestos en esta Tesis Doctoral con respecto a los métodos ya existentes en la literatura. Este estudio permite además comprobar los resultados obtenidos por los métodos propuestos en este trabajo antes de realizar una costosa inversión en sensores y equipamientos. A continuación se describen brevemente los distintos elementos que conforman la plataforma experimental en la que se obtuvieron los datos utilizados en este trabajo.

El esquema general de la plataforma experimental, con sus distintos elementos y sus respectivas posiciones, se muestra en la Figura 6.1. El propósito es que, para cada operación que se vaya a desarrollar en la máquina (torno), se almacenen las señales o datos de emisión acústica (número de pulsos), vibraciones sufridas por la herramienta (aceleración), fuerzas de corte, tiempo del proceso, así como la información del estado de la herramienta de corte (datos del desgaste de la herramienta). Para ello, la plataforma dispone de un dinamómetro, un acelerómetro y un sensor de emisión acústica. Además, se cuenta con un microscopio para la medición del desgaste y un PC para el procesamiento y almacenamiento de todas las señales. Lógicamente, todos los elementos de la plataforma experimental utilizan como base un torno.

Así, todas las operaciones de torneado se han llevado a cabo en un torno de alta precisión marca Kirloskar. En él, se ha eliminado el porta-herramientas convencional de serie y se ha situado en su lugar una plataforma dinamométrica. Posteriormente la herramienta de corte se ha fijado en un porta-herramientas SCLCR1010E06 (Widia) y éste se ha instalado sobre la

plataforma dinamométrica a través de unas ranuras habilitadas en la plataforma para tal efecto. En un primer momento, la señal de la plataforma dinamométrica se muestra a través del visualizador del propio torno. Sin embargo, para los objetivos posteriores de monitorización, la señal de la plataforma dinamométrica se llevará a un PC a través de una tarjeta de adquisición.

Para la medición de la aceleración (vibraciones), se decide colocar un acelerómetro IRD 90 en la superficie superior de la herramienta. El acelerómetro se conecta a su vez con un analizador de vibraciones IRD Mechanalysis 800.

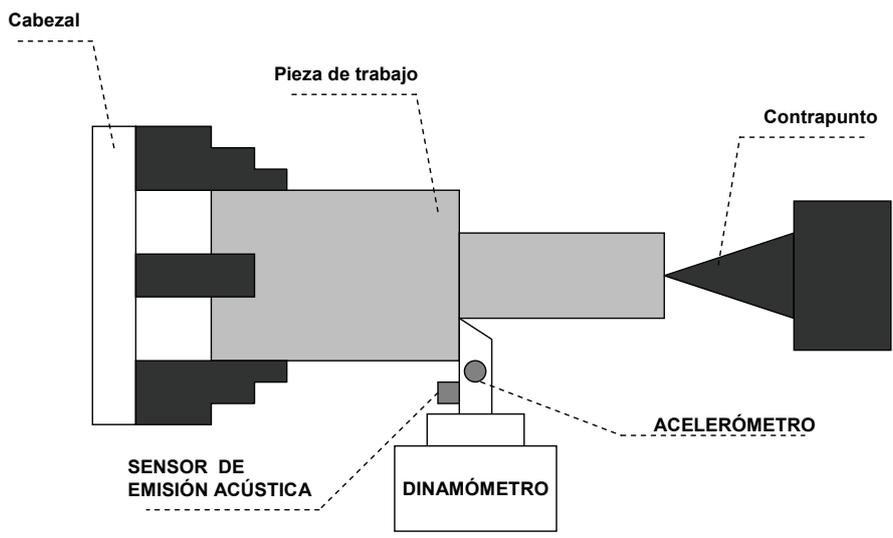


Figura 6.1. Plataforma experimental empleada en la monitorización neuroborrosa

El sensor de emisión acústica (transductor piezoeléctrico) se fija en el porta-herramientas a través de un gel de acoplamiento especial para ultrasonidos. Para la calibración del sensor de emisión acústica se utilizó la prueba de la rotura de la mina de lápiz, estimando de este modo el factor de atenuación de la señal de emisión acústica cuando la señal se transmite de la pieza de trabajo a la herramienta de corte. Las señales eléctricas producidas por este transductor son primeramente amplificadas con un amplificador de ganancia 60 dB. Posteriormente, las señales también se filtran a través de un filtro pasa-baja. El umbral de tensión se sitúa en un voltio a través del software del procesador de señales de emisión acústica AET5500. Una vez acondicionadas las señales, éstas se guardan en un ordenador para su posterior análisis.

Gracias a esta plataforma experimental, y a través de todos estos sensores, es posible recabar datos experimentales para la obtención de modelos del desgaste de la herramienta en proceso de torneado. En este caso, y tal y como se ha explicado anteriormente, se han utilizado los datos experimentales obtenidos en [253] y [254]. Estos datos se han obtenido de operaciones de torneado sobre piezas de dos materiales distintos: hierro fundido (fundición gris FG15) y una aleación de acero (En 24). De esta manera, se podrá poner a prueba la validez del modelo de desgaste (y su posterior monitorización) para diferentes materiales. En las operaciones de torneado de ambos materiales, se ha utilizado una herramienta de plaquitas de metal duro sin recubrir CCMT 060204 TTS de Widia.

Para cada material se han llevado a cabo cuatro experimentos. Las condiciones de corte o parámetros del proceso son las mismas para ambos materiales. Se han utilizado dos velocidades de corte distintas: 94 m/min y 188 m/min. Para cada velocidad de corte, se seleccionaron dos avances: 0,06 mm/rev y 0,08 mm/rev. La profundidad de corte se mantuvo constante para todas las operaciones y en ambos materiales (0,7 mm). En total, se han llevado a cabo ocho

experimentos que se resumen en la Tabla 6.1. Los datos recogidos en cada experimento (tiempo, fuerza, aceleración, emisión acústica y desgaste) se muestran en la Figura 6.2 para el caso de las operaciones sobre FG 15 y en la Figura 6.3 para el caso de las operaciones sobre el material En24.

Tabla 6.1. Condiciones de corte de las operaciones de torneado llevadas a cabo

<i>Experimento</i>	<i>Material</i>	<i>Velocidad de corte (m/min)</i>	<i>Avance (mm/rev)</i>	<i>Profundidad de corte (mm)</i>	<i>Herramienta</i>
1	FG 15	94	0.06	0.7	CCMT060204 TTS
2	FG 15	94	0.08	0.7	CCMT060204 TTS
3	FG 15	188	0.06	0.7	CCMT060204 TTS
4	FG 15	188	0.08	0.7	CCMT060204 TTS
5	En24	94	0.06	0.7	CCMT060204 TTS
6	En24	94	0.08	0.7	CCMT060204 TTS
7	En24	188	0.06	0.7	CCMT060204 TTS
8	En24	188	0.08	0.7	CCMT060204 TTS

Se recuerda nuevamente que el desgaste de la herramienta, particularmente el desgaste del flanco, fue medido *off-line* a través de un microscopio. Cabe destacar también que en todas las operaciones llevadas a cabo en la plataforma experimental no se utilizaron fluidos de corte. Para una mayor información acerca de la plataforma experimental utilizada y de los datos obtenidos a través de ella se recomienda consultar [253, 254].

6.2. Monitorización del Proceso de Torneado

Tal y como se explicó en el Capítulo 4, el desgaste de la herramienta representa uno de los factores más cruciales y determinantes en la maximización de la producción y en la automatización de procesos de mecanizado. El desgaste de la herramienta es un proceso intrínseco al mecanizado por arranque de viruta y, a su vez, es difícil de predecir debido a su naturaleza (no lineal y estocástica) [118]. Dado que su aparición no se puede evitar, en este trabajo se propone la monitorización del desgaste para poder controlar su evolución y evitar fundamentalmente fallos catastróficos en el proceso debidos a la rotura de la herramienta de corte.

La monitorización del desgaste de la herramienta en procesos de torneado es menos compleja que en otros procesos de mecanizado con filos de corte definidos (como el proceso de taladrado o el fresado), ya que en este caso solamente un único filo de corte se encuentra inmerso en el arranque de viruta. Por lo tanto, cabe esperar que será más fácil desarrollar un sistema de monitorización preciso para el proceso de torneado.

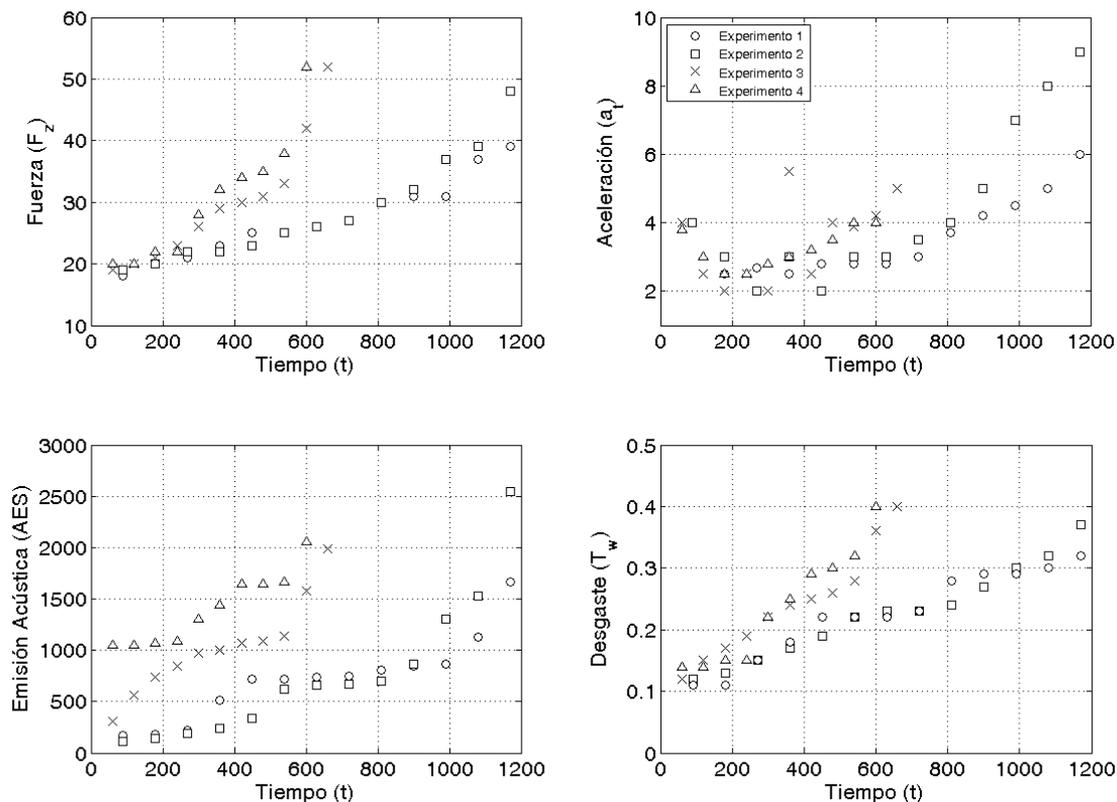


Figura 6.2. Datos obtenidos en operaciones de torneado del FG 15

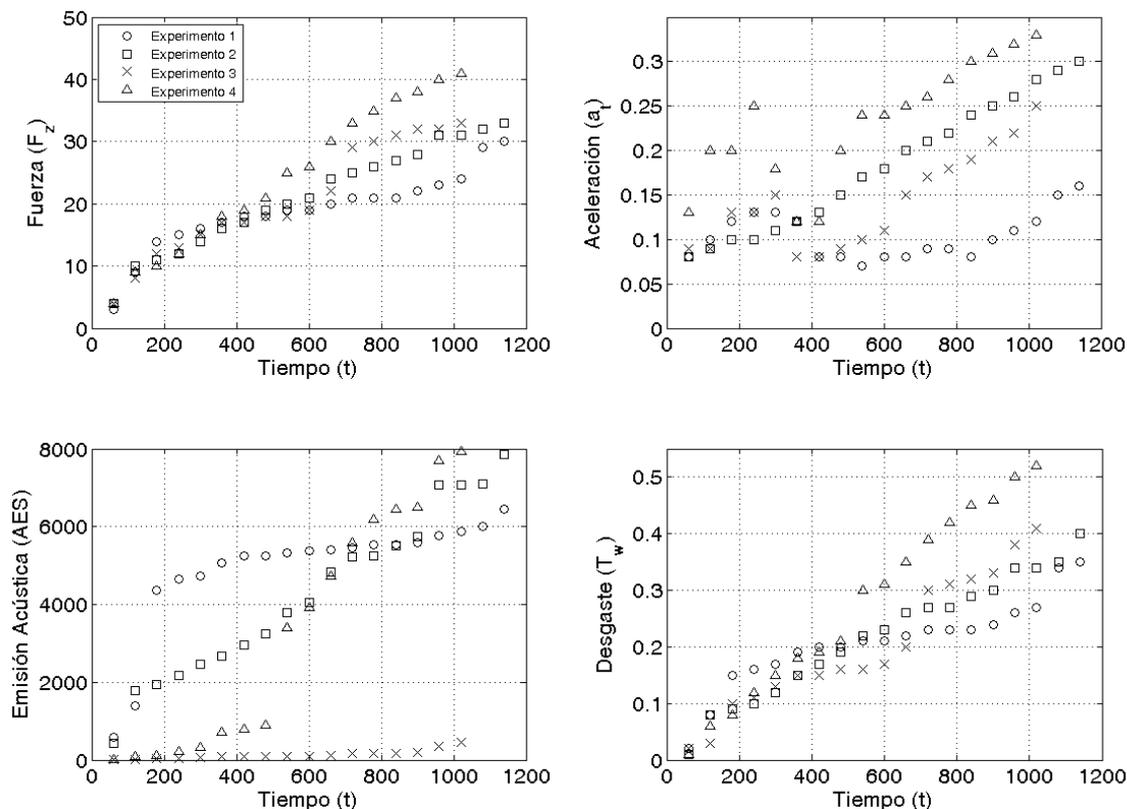


Figura 6.3. Datos obtenidos en operaciones de torneado del En24

La monitorización del desgaste de la herramienta se puede llevar a cabo por medio de dos enfoques: a través de métodos directos o a través de métodos indirectos [248]. Los métodos directos pueden medir los valores reales de ciertos parámetros de desgaste (e.g., el tamaño de una zona de desgaste). Por el contrario, los métodos indirectos miden parámetros del proceso que se correlacionan con el desgaste de la herramienta (e.g., fuerzas de corte o vibraciones). A través de los valores de estos parámetros indirectos es posible extraer conclusiones acerca del estado de la herramienta si se dispone de un modelo analítico o empírico apropiado. La tecnología de medición de los métodos directos resulta muy cara y, además, estos métodos son susceptibles al fallo debido a las condiciones ambientales existentes en una máquina herramienta (virutas, líquido de refrigeración, etc.). Por otra parte, los métodos indirectos emplean parámetros que son más fáciles de medir aunque, en ocasiones, la carga computacional de este tipo de monitorización es más alta.

No obstante, por todas las características detalladas en el Capítulo 3, los sistemas neuroborrosos se pueden considerar buenos candidatos para la creación de modelos sobre los cuales construir un sistema de monitorización. A esta aproximación indirecta se la conoce con el término de monitorización neuroborrosa o monitorización basada en modelos neuroborrosos. La monitorización del desgaste de la herramienta en procesos de torneado se puede construir también en base a modelos matemáticos exactos del proceso de desgaste. Sin embargo, la compleja naturaleza de las operaciones de arranque de material, hacen más factible la utilización de un método que sea capaz de tratar con las incertidumbres y no linealidades del proceso. Una vez fijada la metodología para la creación de los modelos, queda ahora por determinar la elección de las variables del proceso más adecuadas para modelizar el desgaste de la herramienta en operaciones de torneado, es decir, las que aporten una mayor información a la par que sean fácilmente medibles.

Para ser consecuente con el estado del arte (y según los sensores vistos anteriormente en la plataforma experimental) las señales generalmente utilizadas para el modelizar el desgaste de la herramienta son tres: emisiones acústicas (número de pulsos), fuerzas de corte y vibraciones (aceleraciones). La elección de estas señales es porque, muy a menudo, el fenómeno de desgaste de la herramienta se refleja en el dominio temporal y frecuencial de estas variables. Se pasa a continuación a estudiar más a fondo cada una de estas señales.

El fenómeno de emisión acústica puede definirse como el conjunto de ondas acústicas generadas por un material cuando es sometido a un estímulo externo. Los términos "emisión acústica" y "señal de emisión acústica" se usan indistintamente. De un modo más estricto, una emisión acústica es una onda acústica generada por un material y una señal de emisión acústica es la señal eléctrica producida por un sensor en respuesta a dicha onda. En otras palabras, la emisión acústica se refiere a las ondas producidas por tensiones mecánicas generadas por procesos dinámicos en materiales. La emisión se produce como una liberación de una serie de impulsos cortos de energía. La energía así liberada viaja como un frente de onda esférico y puede ser percibida a través de la superficie de un material utilizando transductores de alta sensibilidad, por lo general de tipo electro-mecánico, colocados en la superficie del material. La onda mecánica percibida es convertida a señal eléctrica a través de un tratamiento adecuado. El análisis de esta señal puede revelar información valiosa acerca de la fuente que causa la liberación de energía [304]. Por ello, la emisión acústica se puede utilizar para detectar el desgaste de la herramienta, tanto el que se produce de forma gradual como el desgaste abrupto [305, 306]. El parámetro de emisión acústica utilizado en este estudio es el número de pulsos (RDC – *Ring Down Count*) y se define como el número de veces que la amplitud de la señal excede los valores umbral pre-establecidos como referencia. En el análisis de estos datos se utiliza el valor promedio de RDCs.

Otra de las señales utilizadas para monitorizar el desgaste de la herramienta es la señal de vibraciones. En este contexto, cuando se habla de vibraciones nos estamos refiriendo a las vibraciones sufridas por la herramienta de corte durante el proceso de mecanizado. Éstas se

producen debido al rozamiento existente entre el flanco de la herramienta y la pieza de trabajo, debido a la formación del “filo recreado” y debido a las imperfecciones en la superficie de trabajo [307]. También se encuentran asociadas con las excentricidades en los ejes y en los contactos. La frecuencia fundamental de las vibraciones en la herramienta es la frecuencia de resonancia del sistema excitada por la fricción en el filo de corte. La aceleración es la mejor medida de las vibraciones cuando éstas se desarrollan en alta frecuencia (por encima de 1 kHz). Ya que la vibración de la herramienta corte es una vibración de alta frecuencia, se decide tomar la aceleración vertical de la herramienta como parámetro para monitorizar el desgaste de la herramienta [308] Las aceleraciones utilizada en este trabajo se miden en “g’s”.

La última de las señales utilizadas generalmente para monitorizar el desgaste de la herramienta en el proceso de torneado es la señal de fuerzas de corte. Las señal de fuerzas de corte es la que comparativamente es más fácil de medir en tiempo real [309]. La fuerza de corte resultante (F) que actúa en dirección oblicua en una operación de torneado puede descomponerse a lo largo de tres ejes perpendiculares X, Y, y Z (Figura 6.4). La componente tangencial de la fuerza (F_z) es la componente más sensible al desgaste de la herramienta en comparación con la componente axial (F_x) y con la componente radial (F_y). La razón es que la componente principal o tangencial (F_z) es la que determina el par sobre el mecanismo conductor, la deflexión de la herramienta y la potencia requerida. La literatura en el ámbito de procesos de mecanizado, y particularmente en el proceso de torneado, refleja este hecho [310]. Tal y como se puede observar en la figura, esta componente actúa en la dirección de la velocidad de corte.

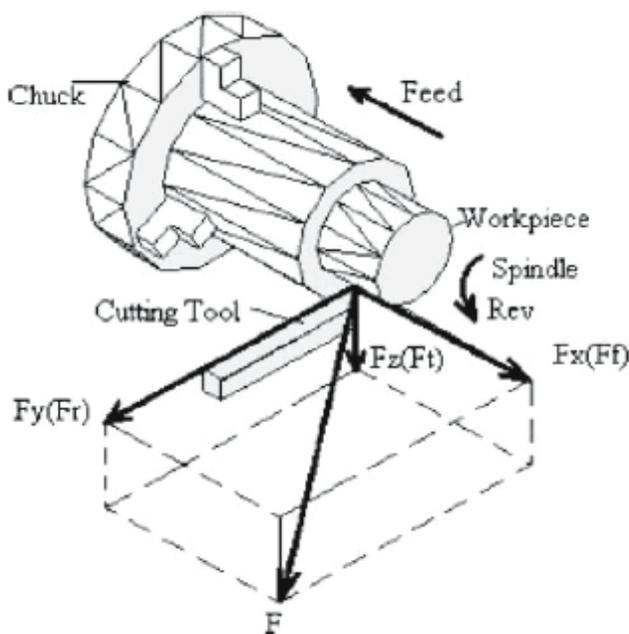


Figura 6.4. Fuerzas de corte en una operación de torneado (imagen tomada de [254])

A la vista de todas estas señales del proceso, las cuales reflejan todo lo que está ocurriendo durante el proceso de torneado, se pretende diseñar un sistema de monitorización *on-line* en base a modelos neuroborrosos que relacionen las señales de emisión acústica, vibraciones, fuerzas y tiempo con el desgaste de la herramienta en procesos de torneado. Como primera aproximación, en este trabajo se crearán los modelos neuroborrosos sobre los que posteriormente se desarrollará el sistema de monitorización (trabajo futuro). En los próximos apartados se pasan a detallar los pormenores de los modelos neuroborrosos diseñados e implementados.

6.3. Modelado y Monitorización a través de ANFIS

La combinación funcional del análisis del proceso a través de las señales de sus múltiples sensores, junto al empleo de técnicas de Inteligencia Artificial para el tratamiento de dicha información, conducen nuevamente a un enfoque prometedor a la hora de satisfacer los requisitos del proceso de torneado de alto rendimiento.

Gracias a los datos experimentales disponibles es posible crear un modelo del desgaste de la herramienta a través de un sistema de inferencia neuroborroso inductivo como ANFIS. Más adelante se implementará un sistema de monitorización basado en este modelo.

Teniendo en cuenta las características de proceso se decide crear un modelo múltiple-entrada / simple-salida en el que el desgaste de herramienta (T_w') se modelará a través del tiempo (t), de la fuerza de corte en la dirección de la velocidad de corte (F_z), de las vibraciones (aceleraciones) de la herramienta (a_t), y de la señal de emisión acústicas (AES).

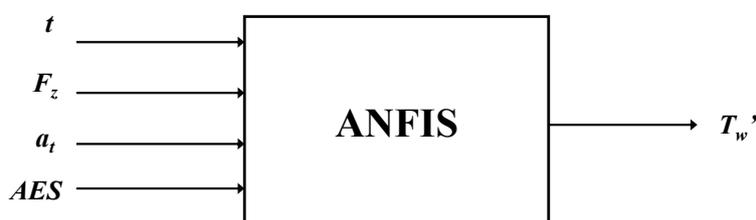


Figura 6.5. Modelo del desgaste de la herramienta a través de ANFIS

El uso de estas cuatro señales se debe a que todas ellas proporcionan información relevante sobre el desgaste de la herramienta. La eliminación de alguna de ellas deterioraría en gran medida el proceso de monitorización. De este modo, el desgaste de la herramienta en el proceso de torneado se modela de la siguiente manera:

$$T_w' = H(t, F_z, a_t, AES) \quad (6.1)$$

donde H representa en este caso el sistema de inferencia neuroborroso ANFIS.

Antes de pasar a detallar los parámetros del sistema neuroborroso, es necesario establecer una cifra de mérito o índice de comportamiento para demostrar la exactitud y la validez del modelo escogido. En esta ocasión se utilizará el error medio total (TAE – Total Average Error) (6.2). El error medio total nos da idea del comportamiento del modelo a nivel general. Sin embargo, en ciertas ocasiones, interesa conocer el comportamiento local del modelo. Para ello se ha fijado como segunda cifra de mérito (medida de precisión) el número de datos que en cada experimento superan un error medio (individual) del 10 %. Se ha elegido este índice de comportamiento porque a nivel industrial (especialmente en el ámbito de la monitorización de procesos), son aceptables ciertos márgenes de error debido a los ruidos existentes en las señales y a cierta inexactitud de los sensores. En este sentido, todo error inferior al 10 % suele ser un valor más o menos aceptable (según casos), mientras que cuando se trata de errores superior al 10 %, es necesario tener más cuidado con dicha información.

$$TAE = \frac{1}{n} \sum_{i=1}^n \frac{|T_w - T_w'|}{T_w} \cdot 100 \quad (6.2)$$

donde T_w es el desgaste real de la herramienta (medido en microscopio), T_w' es el desgaste obtenido a través del modelo y n es el número de datos de cada experimento.

El procedimiento seguido para la obtención del modelo ANFIS ha sido el siguiente. Primeramente se han dividido los datos experimentales en dos grupos según el material de la pieza a tornearse (FG 15 y En24). De entre el conjunto de datos de cada material, se han elegido aproximadamente el 50 % de los mismos para entrenar al modelo ANFIS. De esta manera, para la obtención del modelo ANFIS de desgaste en el FG 15 solo se han utilizado datos pertenecientes a ese material. Posteriormente se volverá a entrenar el modelo para el caso del En24. Una vez entrenado el modelado para cada material, se ha testeado con una serie de 4 experimentos, obteniéndose una cifra de mérito para cada experimento.

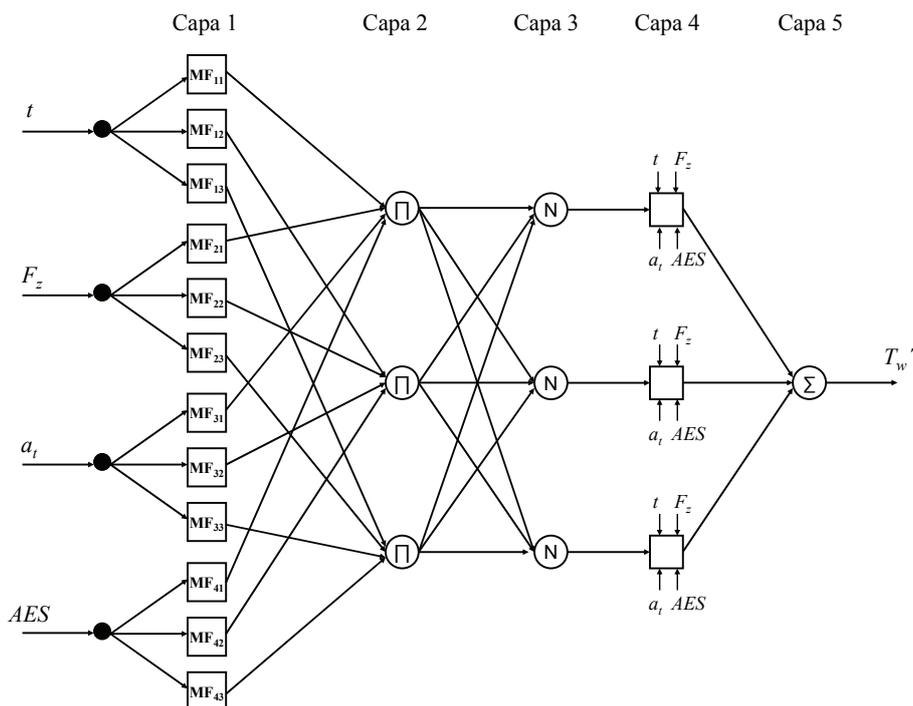


Figura 6.6. Arquitectura de ANFIS para el modelado del desgaste (suponiendo 3 funciones de pertenencia)

Recordamos nuevamente que el conjunto de datos experimentales utilizados en este trabajo se ha extraído de los trabajos [253] y [254]. En dichos trabajos se propone un modelo neuroborroso ANFIS para la monitorización del proceso de desgaste de la herramienta con las mismas variables de entrada y de salida mostradas anteriormente. De este modo, Sharma *et al.* presentan también un modelo para el desgaste del FG15 [254] y otro para el desgaste del En24 [253]. En estos trabajos utilizan los siguientes parámetros del sistema neuroborroso ANFIS: un modo de entrenamiento híbrido (retropropagación de errores y mínimos cuadrados), un número de iteraciones en el entrenamiento igual a 3, y un error de tolerancia de cero. Previamente al entrenamiento de ANFIS, en ambos trabajos han utilizado un algoritmo de *clustering* substractivo que les ha proporcionado un conjunto de 7 funciones de pertenencia y, por tanto, un total de 7 reglas neuroborrosas para el caso del desgaste de la herramienta en el material FG 15. Para el caso del material En24 se han utilizado los mismos parámetros del algoritmo ANFIS, con la excepción de que, con los datos utilizados en este caso, el algoritmo de agrupamiento substractivo aplicado ha reportado 10 funciones de pertenencia y 10 reglas neuroborrosas. Los

índices de comportamiento de dichos modelos se resumen en la Tabla 6.3 para el modelo del desgaste en el FG 15 y en la Tabla 6.4 para el modelo del desgaste en el En24.

Ante la imposibilidad de repetir el mismo procedimiento utilizado por Sharma *et al.* para modelizar el desgaste de la herramienta a través de ANFIS (debido fundamentalmente a la omisión de ciertos parámetros del algoritmo ANFIS y del algoritmo de *clustering* substractivo) en este trabajo se decide crear otro modelo neuroborroso ANFIS, tanto para la monitorización de operaciones en FG15 como en En24, con los parámetros que se muestran a continuación.

Con el objeto de impedir un crecimiento excesivo en el número de reglas obtenidas a partir de los datos de entrenamiento, en esta ocasión se decide también aplicar el algoritmo de *clustering* substractivo [133] utilizado por Sharma *et al.* A su vez, la elección de este algoritmo de agrupamiento nos acercará a los buenos resultados obtenidos en [253] y [254]. Para la aplicación de este algoritmo de agrupamiento así como para la creación y el entrenamiento del modelo neuroborroso ANFIS se ha utilizado la herramienta “*fuzzy logic toolbox*” disponible en el programa Matlab.

La idea del algoritmo de agrupamiento substractivo es asumir que cada punto del conjunto de datos es un centro potencial de un grupo, calculando posteriormente la probabilidad de que cada uno de ellos sea realmente el centro en base a la densidad de datos que posea en el entorno. El algoritmo selecciona los puntos con mayor probabilidad de ser el centro del primer grupo, eliminando a continuación todos los puntos del conjunto de datos que estén en las proximidades del centro de primer grupo (la determina el radio escogido como parámetro), a fin de determinar el próximo *cluster* con su respectivo centro. El algoritmo itera este proceso hasta que todos los datos se encuentran dentro del radio de alguno de los grupos creados. Por tanto, como parámetro del algoritmo solamente se utilizan los radios (a parte de los propios datos sobre los que se quiere operar) de los conjuntos de cada una de las variables de entrada y salida. Después de un profundo estudio acerca de cuál es el mejor valor para estos radios, se seleccionaron los siguientes: 0.8 para la variable tiempo, 0.4 para la variable fuerza en Z, 0.5 para la variable aceleración, 0.5 para la variable emisión acústica y 0.3 para la variable desgaste de herramienta.

Una vez aplicado el algoritmo de agrupamiento con estos parámetros se crea un sistema borroso inicial con 7 reglas para el caso del material FG15 y 11 reglas para el material En24. En cada una de las situaciones existen tantas funciones de pertenencia como reglas se han creado. Posteriormente, a estos sistemas borrosos iniciales se les aplica un algoritmo de entrenamiento híbrido (retropropagación de errores y mínimos cuadrados) de 3 iteraciones con un error de tolerancia de 0, creándose de este modo el sistema neuroborroso ANFIS final.

Mediante la elección de estos parámetros se puede hacer una comparación más o menos estricta con la propuesta realizada por Sharma *et al.* (ver próximo apartado). Los resultados del desgaste de la herramienta en proceso de torneado obtenidos con este modelo neuroborroso inductivo ANFIS se reflejan más adelante en las Figuras 6.10 y 6.11. Las cifras de mérito alcanzadas por este modelo se reflejan también en las Tablas 6.3 y 6.4. En ambas figuras y en ambas tablas, la leyenda *ANFIS (Sharma)* se refiere a la aproximación de dichos autores (mostrada también en [253] y [254]), mientras que la leyenda *ANFIS (Gajate)* se refiere a la aproximación propuesta en el presente documento. A continuación se muestran en la Figura 6.6 las funciones de pertenencia creadas para el caso del modelo ANFIS del desgaste de la herramienta en operaciones de torneado sobre material FG 15.

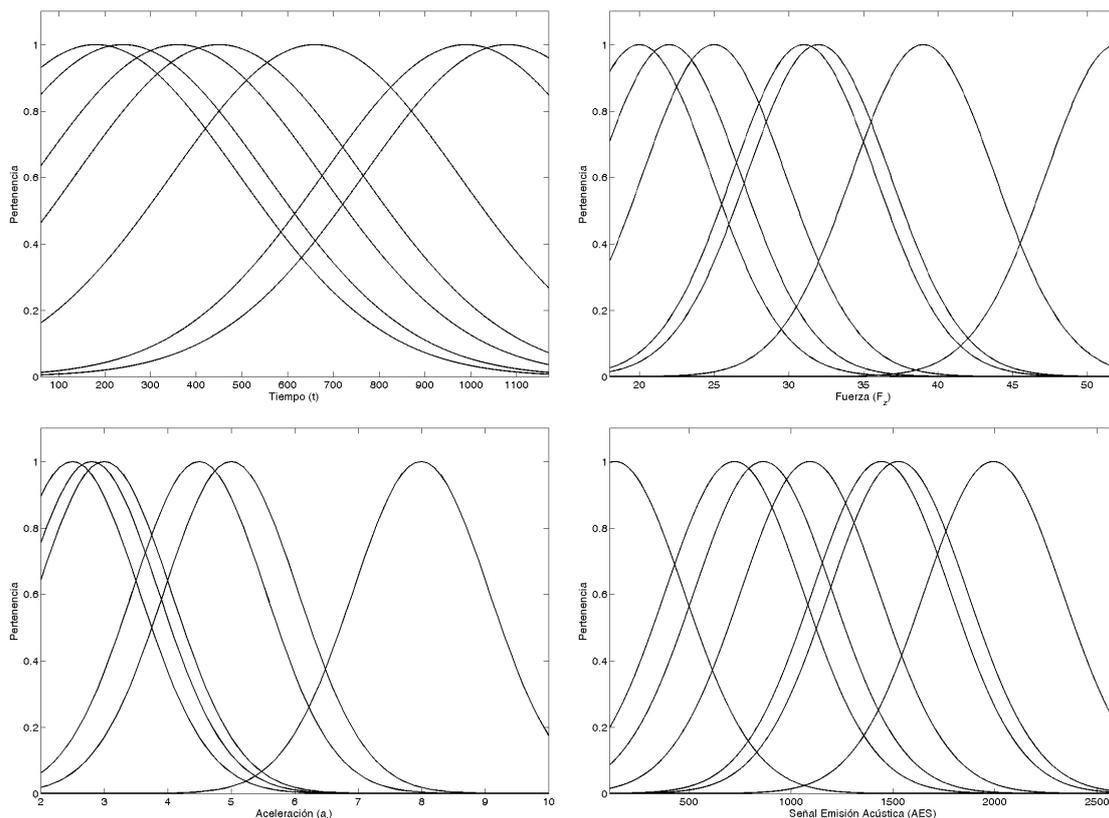


Figura 6.7. Funciones de pertenencia del modelo neuroborroso ANFIS propuesto (para el caso del FG15)

6.4. Modelado y Monitorización a través de TWNFI-i

Los sistemas de inferencia neuroborrosos transductivos son capaces de modelizar procesos dinámicos complejos, dándole más importancia a la información específica relacionada con el dato a procesar que a la información general aportada por todo el conjunto de entrenamiento con el que el sistema cuenta. Por esta razón, este tipo de inferencia neuroborrosa puede resultar muy adecuada en el modelado del desgaste de la herramienta de torneado, ya que en este proceso es ciertamente difícil la obtención de funciones generales que describan el proceso de desgaste en su totalidad.

En base a esta idea, se decide en esta ocasión diseñar un sistema de monitorización que muestre el estado del desgaste de la herramienta por medio de la utilización de modelos locales. Ya que, tal y como se ha visto en apartados anteriores, las señales de fuerza, aceleración y emisión acústica proporcionan información muy relevante acerca del desgaste de la herramienta, nuevamente se trata de modelizar el desgaste a través de un modelo de cuatro entradas (6.3). La técnica neuroborrosa transductiva elegida para la creación de los modelos locales es TWNFI-i

$$T_w' = H(t, F_z, a_t, AES) \tag{6.3}$$

donde t es el tiempo de operación, F_z es la fuerza de corte en la dirección de la velocidad de corte, a_t representa las vibraciones (aceleraciones) de la herramienta, AES es la señal de emisión acústica, T_w' es el desgaste de la herramienta estimado por el modelo y H , en este caso, representa el sistema de inferencia neuroborroso transductivo TWNFI-i.

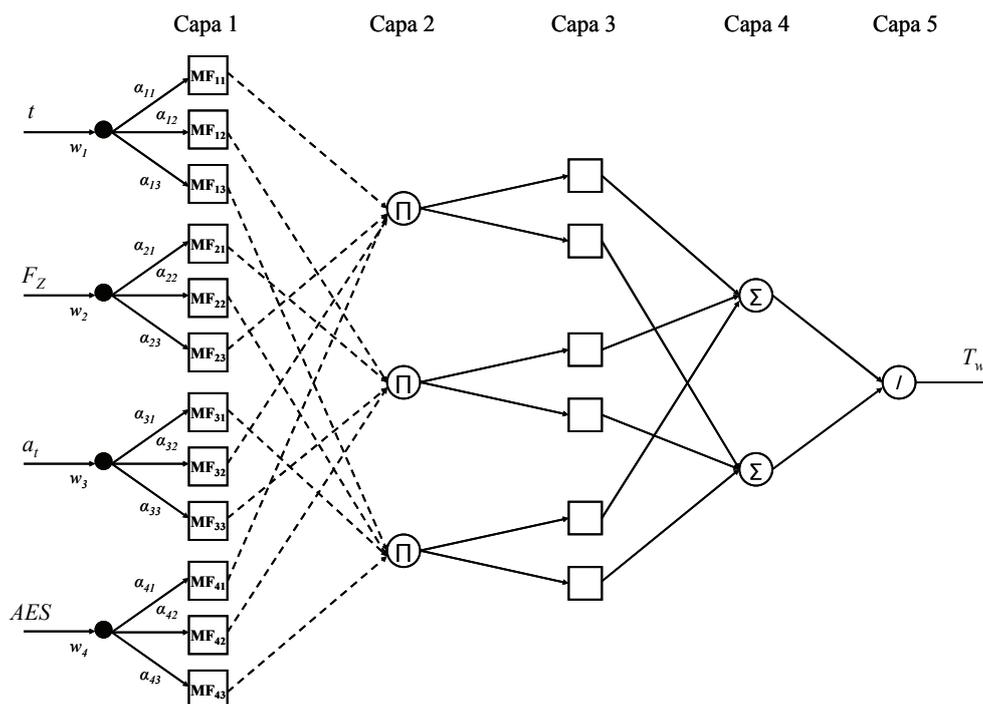


Figura 6.8. Arquitectura de TWNFI-i para el modelado del desgaste (suponiendo 3 funciones de pertenencia)

Gracias a la utilización de las mismas variables de salida y de entrada que el modelo basado en ANFIS, se puede hacer un estudio comparativo entre el modelo mediante inferencias inductivas y transductivas. La principal diferencia en este estudio es que el modelo ANFIS creará un modelo general (para cada material) a partir del conjunto de datos de su base de entrenamiento, mientras que el modelo obtenido mediante TWNFI-i se construye para cada dato de entrada al modelo a partir de los datos más próximos del conjunto de entrenamiento (distinto para cada material) a dicho dato de entrada. Posteriormente se realizará una monitorización del proceso en base a estos modelos.

El procedimiento seguido para el modelado del desgaste de la herramienta en operaciones de torneado es el mismo que el descrito en el apartado anterior. Se han dividido los datos experimentales en dos grupos según el material de la pieza a tornearse (FG 15 y En24) y se han elegido aproximadamente el 50 % de cada material para conformar las “bases de entrenamiento” para el sistema TWNFI-i. Después se han testado directamente los modelos (al mismo tiempo que éstos se creaban) con una serie de 4 experimentos para cada material, obteniéndose una cifra de mérito para cada experimento. Los índices de comportamiento son los mismos que en el modelado inductivo con el objeto de comparar ambos sistemas: error medio total (TAE) (6.2) y número de datos que en cada experimento superan un error medio (individual) del 10 %.

Los parámetros elegidos para el modelado del desgaste de la herramienta a través de TWNFI-i han sido los siguientes: modelado a partir de cuatro vecinos más cercanos (N_q), un umbral de calidad en el algoritmo de agrupamiento QT_{Clust} de 0,32 (radio máximo) con un número mínimo de elementos igual a uno, y los mismos parámetros en la retropropagación (3 iteraciones con ratio de aprendizaje de 0.001 y un error de tolerancia de 0). La elección de estos parámetros ha venido precedida de un profundo estudio en el que se han probado diversos valores de estos parámetros. Finalmente se eligieron aquellos que mostraban un compromiso entre un error medio total pequeño y un número reducido de datos que sobrepasaran el umbral

de error del 10%. Los parámetros seleccionados en TWNFI-i para modelizar el desgaste en operaciones sobre FG15 han sido los mismos que para el modelado sobre operaciones en En24.

La Figura 6.9 muestra las funciones de pertenencia que se han creado en una situación particular a través de la elección de estos parámetros en el sistema neuroborroso transductivo TWNFI-i. Las funciones corresponden al modelo local del desgaste creado para la primera cuádrupla (t, F_z, a_t, AES) , es decir, el primer elemento del experimento 2 (FG15). En esta situación puede observarse cómo a pesar de la utilización de cuatro vecinos en el algoritmo de agrupamiento, se han obtenido sólo 3 grupos y, por tanto, 3 funciones de pertenencia. Simplemente se ha mostrado este caso como ejemplo ya que para el cálculo de cada cuádrupla se construye un nuevo modelo con nuevas funciones de pertenencia.

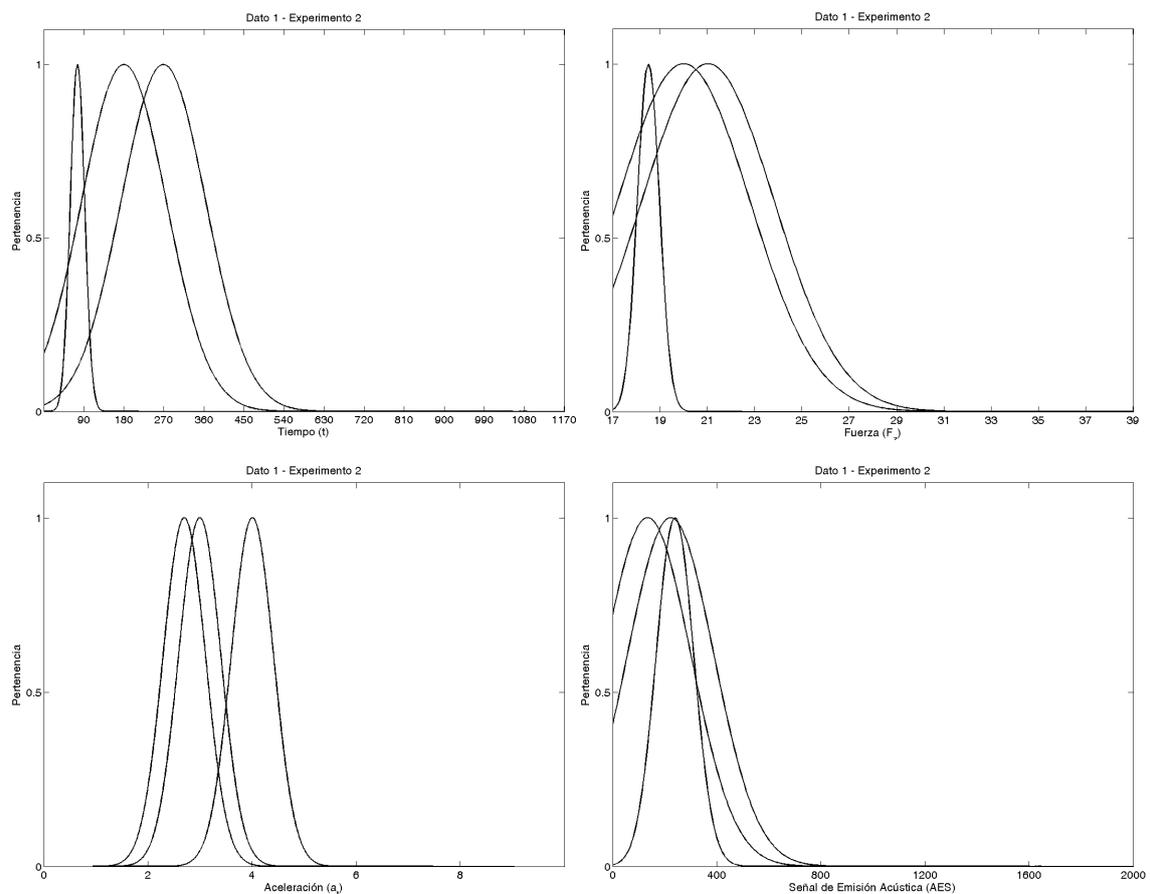


Figura 6.9. Funciones de pertenencia del modelo neuroborroso TWNFI-i propuesto (para el caso del FG15 – Experimento 2)

La Tabla 6.2 resume los parámetros del sistema neuroborroso transductivo TWNFI-i, así como los parámetros de los sistemas neuroborrosos inductivos ANFIS descritos en el apartado anterior.

Una vez se han fijado los parámetros del sistema TWNFI-i para modelizar el desgaste de la herramienta en procesos de torneado, se prueba la validez del mismo a través de la primera serie de experimentos, realizados con el material FG15. Los resultados del desgaste obtenido a través del sistema TWNFI-i se muestran en la Figura 6.10. Las cifras de mérito se recogen en la Tabla 6.3.

Tabla 6.2. Algoritmos neuroborrosos para el modelado del desgaste de la herramienta

Algoritmo	ANFIS (Sharma)	ANFIS (Gajate)	TWNFI-i
Sistema	Múltiple-entrada/ Simple-salida	Múltiple-entrada/ Simple-salida	Múltiple-entrada/ Simple-salida
<i>Clustering</i>	Substractivo	Substractivo	QT _{Clust}
Estructura	Fija	Fija	Variable
Inferencia	Inductiva	Inductiva	Transductiva
Tipo de función de pertenencia	Gaussiana	Gaussiana	Gaussiana
Sistema de inferencia	Takagi-Sugeno	Takagi-Sugeno	Mamdani
Nº de funciones de pertenencia (FG 15 / En24)	7 / 10	7 / 11	Variable con cada entrada (máx. 4)
Nº de reglas (FG 15 / En24)	7 / 10	7 / 11	Variable con cada entrada (máx. 4)
Algoritmo de entrenamiento	Retropropagación + Mínimos cuadrados	Retropropagación + Mínimos cuadrados	Retropropagación
Iteraciones	3	3	3
Ratio de aprendizaje	0.001	0.001	0.001
Criterio de parada (error)	0	0	0
Conjunto de datos de entrenamiento (FG 15 / En24)	24 / 36 datos	24 / 36 datos	24 / 36 datos

A la vista de los resultados obtenidos y de las cifras de mérito alcanzadas, el modelo de desgaste de herramienta a través de TWNFI-i en el proceso de torneado del material FG15 es el que mejores resultados ofrece en su conjunto. El error promedio de TWNFI-i en el total de experimentos con este material es de un 4.39 %, mientras que los errores obtenidos en los modelos basados en ANFIS muestran un error promedio del 12.79 % (ANFIS-Gajate) y del 13.24 % (ANFIS-Sharma). Sin embargo, el número total de puntos que han sobrepasado el error umbral del 10 % ha sido menor en el modelo del desgaste basado en ANFIS propuesto también en este trabajo. En este modelo únicamente 6 puntos superan el umbral, mientras que en el modelado a través de TWNFI-i son 7 puntos los que tiene mayores errores. No obstante, ambos modelos no superan los 8 puntos por encima del umbral de error que estima el modelo basado en ANFIS, presentado en [254].

Tabla 6.3. Errores medios de los modelos creados (FG 15)

Experimento	Modelo ANFIS (Sharma)	Nº puntos con AE ≥ 10%	Modelo ANFIS (Gajate)	Nº puntos con AE ≥ 10%	Modelo TWNFI-i	Nº puntos con AE ≥ 10%
1	7.12 %	3	5.85 %	3	4.27 %	1
2	40.40 %	4	41.79 %	2	5.04 %	3
3	3.46 %	1	1.89 %	1	2.55 %	3
4	1.97 %	0	1.65 %	0	5.71 %	0

Para comprobar la validez de los modelos en otras situaciones, se entrenan posteriormente todos los sistemas neuroborrosos para el caso de operaciones en material En24 y se chequean con la serie de experimentos realizada en este mismo material. Los resultados del desgaste obtenido por los modelos neuroborrosos se muestran en la Figura 6.11. Los índices de comportamiento se muestran en la Tabla 6.4.

Nuevamente, el modelo obtenido en base a TWNFI-i es el que menor error promedio posee (4.71 %). Los errores promedio obtenidos en los modelos inductivos (un 5.46 % en ANFIS-Gajate y un 6.94 % en ANFIS-Sharma) son ligeramente mayores, aunque en esta ocasión se encuentran más cercanos que en el caso del FG15. En cuanto al número de datos (o puntos) que han sobrepasado el error umbral del 10 %, el modelo a través de TWNFI-i es también el que menor número de datos posee (6 datos), en comparación con los 7 datos aportados por el modelo basado en ANFIS-Gajate y los 8 aportados por el modelo ANFIS-Sharma.

Tabla 6.4. Errores medios de los modelos creados (En24)

Experimento	Modelo ANFIS (Sharma)	Nº puntos con AE ≥ 10%	Modelo ANFIS (Gajate)	Nº puntos con AE ≥ 10%	Modelo TWNFI-i	Nº puntos con AE ≥ 10%
5	3.20 %	1	6.19 %	1	4.62 %	2
6	3.99 %	2	3.42 %	2	5.70 %	1
7	10.06 %	2	8.30 %	3	2.00 %	0
8	10.50 %	3	3.93 %	1	6.50 %	3

Pese a que a primera vista parece que el modelo basado en TWNFI-i es el que mejor modela el desgaste de la herramienta en el proceso de torneado de los dos materiales objeto de estudio, se decide aplicar un criterio estadístico para valorar más profundamente los resultados alcanzados. El criterio elegido es una modificación del criterio bayesiano de Schwarz (6.8). La modificación se basa en que, además de evaluar el error de los modelos, se utiliza también como criterio ponderativo el número de reglas utilizadas para alcanzar dichos resultados (en vez de utilizar el número de parámetros ajustables que viene a ser muy similar). Ya que en el caso de TWNFI-i el número de reglas neuroborrosas utilizadas o creadas depende de cada entrada en particular, se ha supuesto el peor de los casos en el cuál se utiliza el mayor número de reglas posibles (de entre el número máximo de reglas que permiten los parámetros del algoritmo seleccionados). En esta ocasión se ha supuesto la creación de 4 reglas, tanto en el modelo basado en TWNFI-i para el material FG 15 como para el material En24.

$$SSE = \sum_{i=1}^N (T_w - \hat{T}_w)^2(i) \quad (6.4)$$

$$NSSE = \sqrt{\frac{SSE}{2N}} \quad (6.5)$$

$$FPE = \frac{NSSE(N+p)}{N-p} \quad (6.6)$$

$$ENV = \frac{2 \cdot N \cdot NSSE}{N-p} \quad (6.7)$$

$$SBC = N \cdot \log\left(\frac{SSE}{N}\right) + p \cdot \log(N) \quad (6.8)$$

donde SSE es la suma de errores cuadrados, $NSSE$ es el error de predicción, FPE es el error de predicción final, ENV es la estimación de la varianza del ruido, SBC es el criterio Bayesiano de Scharwz modificado, p es el número de reglas neuroborrosas utilizadas y N es el número total de muestras modeladas.

Tabla 6.5. Análisis estadístico de los modelos neuroborrosos (FG 15)

Criterio	ANFIS (Sharma) ⁷	ANFIS (Gajate)	TWNFI-i
N	--	47	47
p	--	7	4
SSE	--	0.1922	0.0135
$NSSE$	--	0.0452	0.0085
FPE	--	0.0610	0.0101
ENV	--	0.1063	0.0185
SBC	--	-231.51	-367.89

Para el caso del modelado del desgaste de la herramienta en el proceso de torneado del material FG 15, no se han podido incluir en el análisis estadístico los resultados obtenidos por el modelo basado en ANFIS propuesto por Sharma *et al.* ya que no se dispone del valor de desgaste estimado para cada punto (el artículo sólo ofrece valores de error alcanzados en cada experimento). A pesar de este inconveniente, el criterio bayesiano de Scharwz vuelve a demostrar que el modelo basado en TWNFI es el que mejores resultados aporta (menor valor en el criterio bayesiano).

Se pasa a continuación a analizar con el mismo criterio los modelos neuroborrosos utilizados para modelizar el desgaste de la herramienta en el material En24. En esta ocasión sí que se cuentan con los datos suficientes para analizar los tres sistemas neuroborrosos.

⁷ No es posible evaluar los mencionados criterios sobre esta aproximación al no encontrarse disponibles los datos para ello

Tabla 6.6. Análisis estadístico de los modelos neuroborrosos (En24)

<i>Criterio</i>	<i>ANFIS (Sharma)</i>	<i>ANFIS (Gajate)</i>	<i>TWNFI-i</i>
<i>N</i>	72	72	72
<i>p</i>	10	11	4
<i>SSE</i>	0.0216	0.0052	0.0071
<i>NSSE</i>	0.0122	0.0027	0.0070
<i>FPE</i>	0.0162	0.0035	0.0078
<i>ENV</i>	0.0284	0.0062	0.0149
<i>SBC</i>	- 541.41	-644.20	-647.04

Nuevamente el modelo neuroborroso basado en TWNFI-i es el modelo que muestra un mejor desempeño general. La razón fundamental es que proporciona errores más pequeños que los modelos basados en ANFIS, y además proporciona estos resultados con un menor número de reglas neuroborrosas.

A la vista de los resultados podría afirmarse que, en este caso de estudio, para el modelado del desgaste de la herramienta en procesos de torneado resulta más conveniente la utilización de una inferencia transductiva (mayor peso de la información local) en vez de la utilización de inferencias inductivas. Por tanto, a la hora de monitorizar el desgaste de la herramienta en un proceso de torneado, el diseño de un sistema de monitorización basado en modelos locales representa mejor el comportamiento del desgaste y proporcionará mayores beneficios. La razón es que la inferencia neuroborrosa transductiva es más robusta frente a cambios en las condiciones y es más adecuada en el manejo de las incertidumbres en este caso particular.

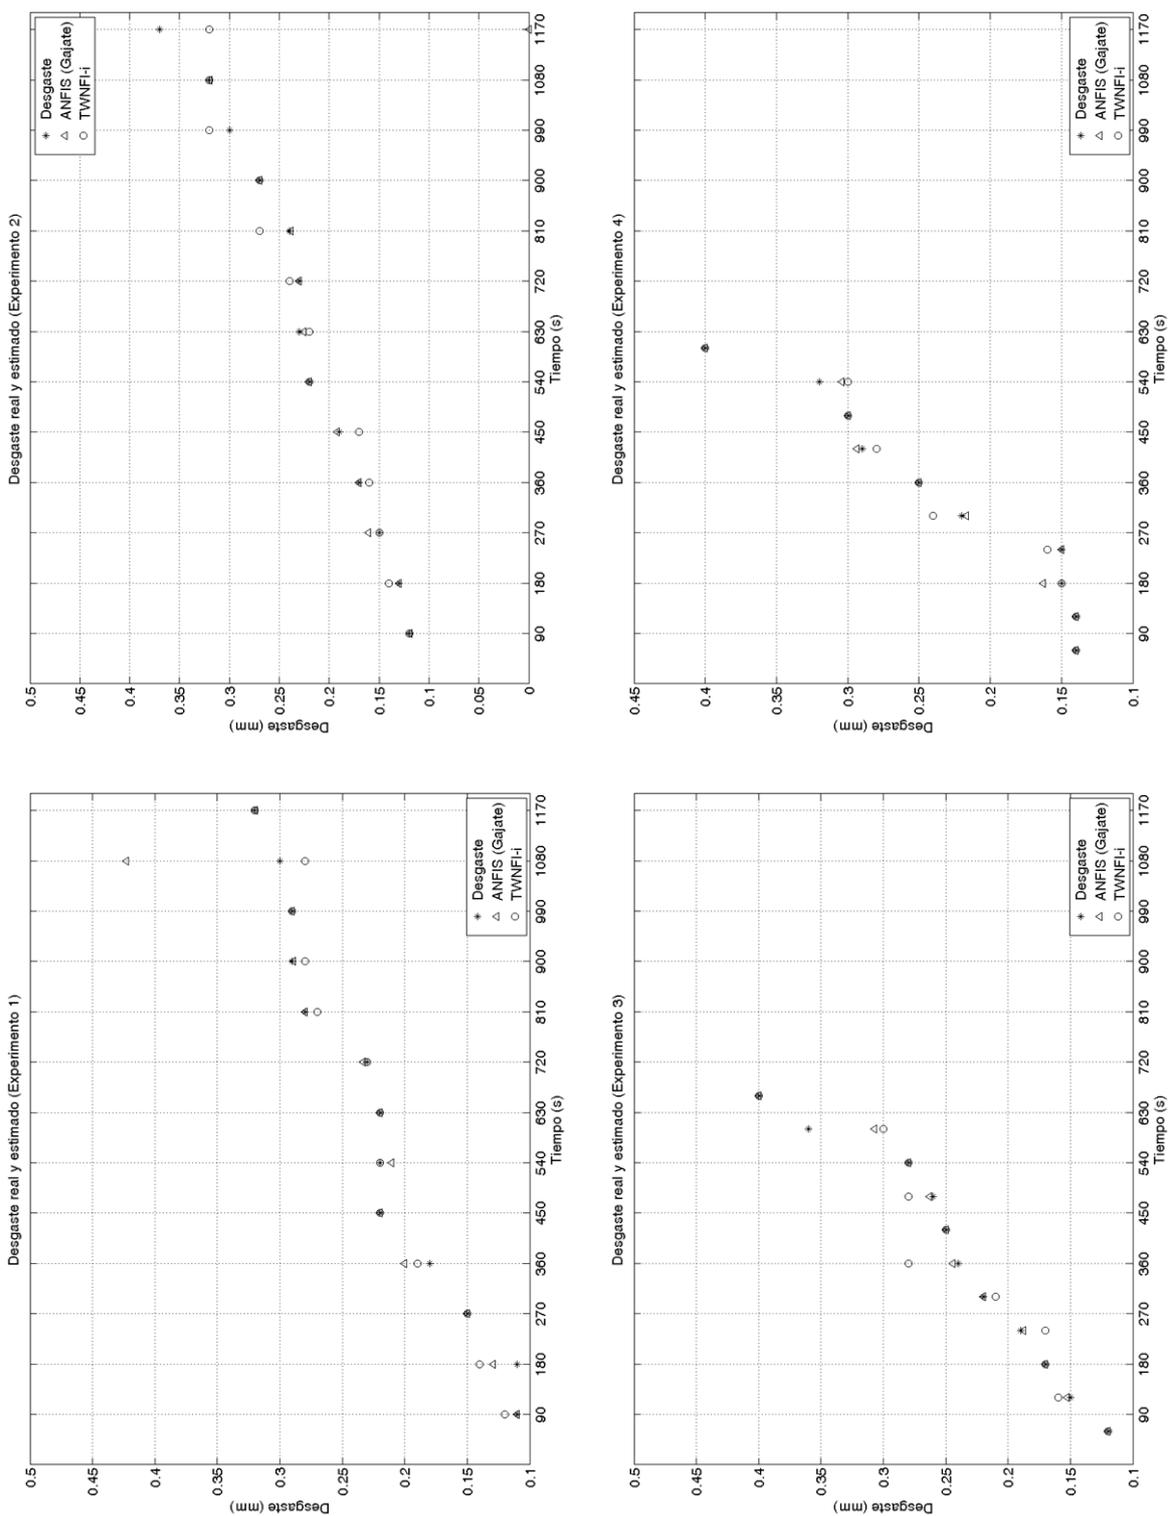


Figura 6.10. Resultados obtenidos por los modelos neuroborrosos para el desgaste de herramienta (caso del FG15)

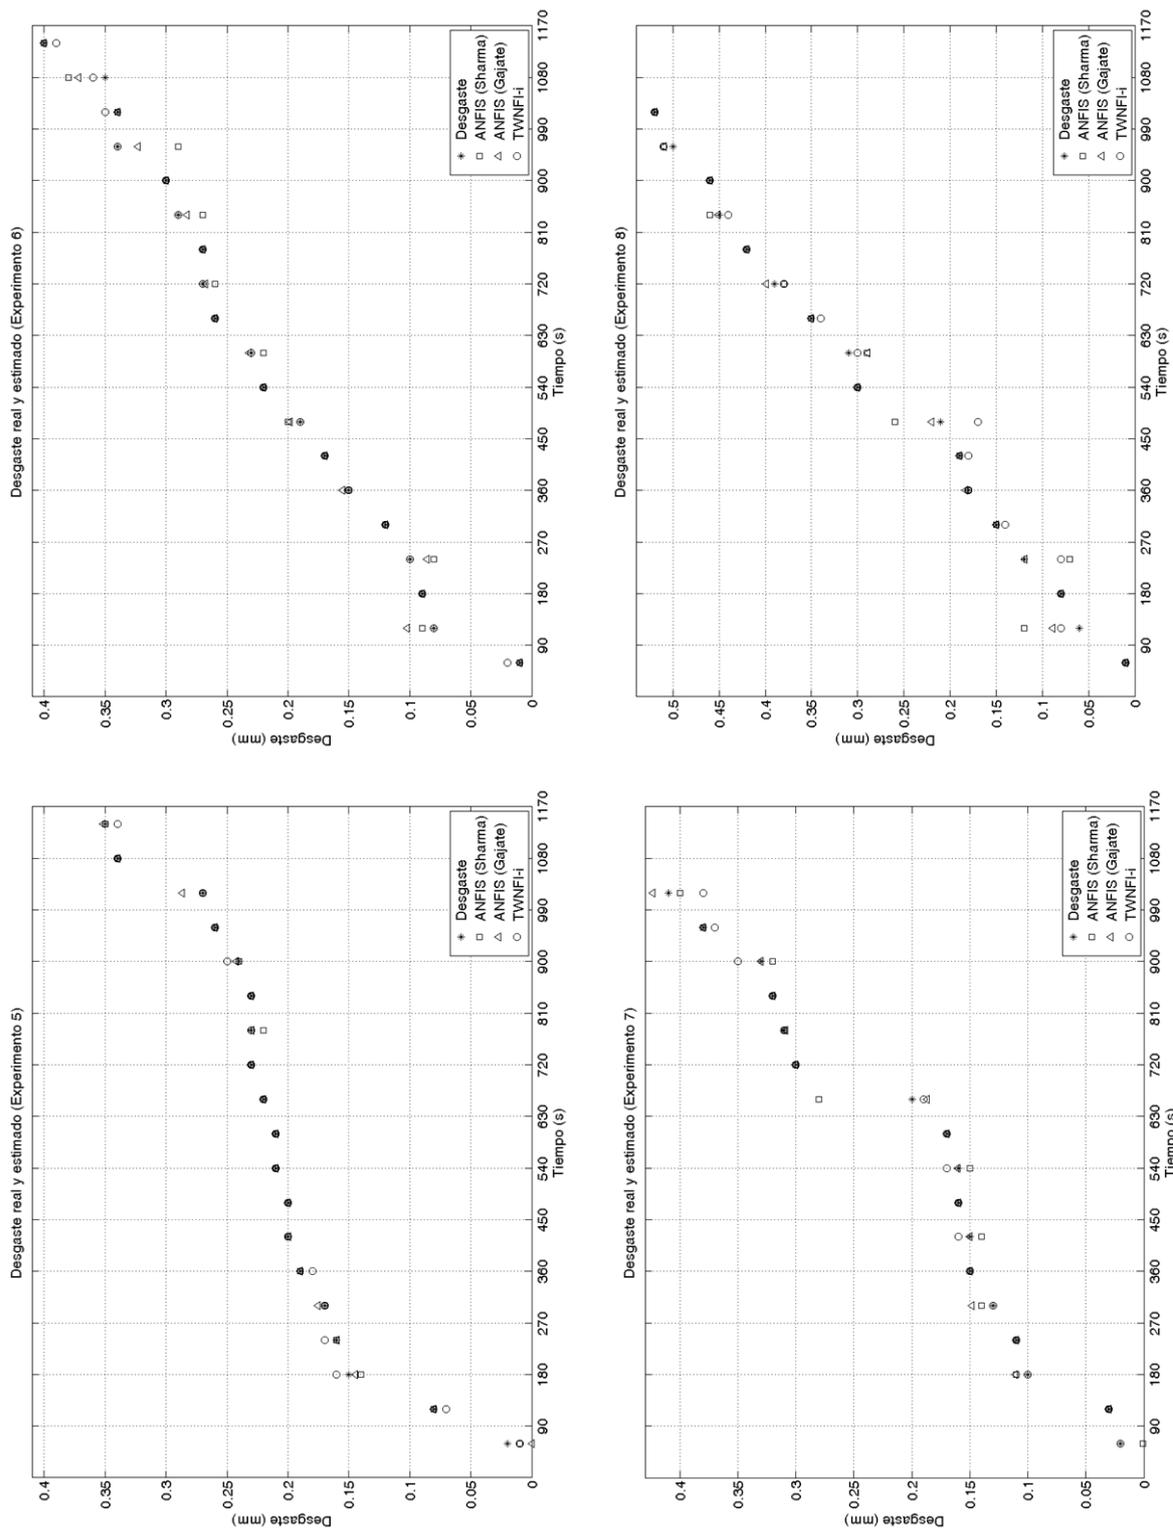


Figura 6.11. Resultados obtenidos por los modelos neuroborrosos para el desgaste de herramienta (caso del En24)

Capítulo 7

Conclusiones

Este capítulo resume las conclusiones obtenidas y las principales contribuciones recogidas en esta Tesis Doctoral. Asimismo, se recopilan además algunos de los resultados parciales de este trabajo que han sido divulgados, bien en revistas científicas o bien en congresos nacionales e internacionales. Por último, se recogen también en esta parte algunas de las posibles líneas de investigación que han quedado abiertas y que se abordarán en trabajos futuros.

7.1. Conclusiones

En esta Tesis Doctoral se propone una metodología para el diseño y la implementación de sistemas de monitorización y control inteligentes en procesos de fabricación de gran complejidad. Para ello se plantea un procedimiento basado en la obtención de modelos neuroborrosos del proceso considerado. Estos modelos se obtienen a través de un procedimiento de identificación en el cual se utilizan datos entrada-salida representativos del sistema a estudiar. Una vez se han obtenido los modelos, éstos se utilizan en los propios sistemas de monitorización y control.

Para el caso del diseño e implementación de sistemas de control neuroborrosos se propone un procedimiento para obtener un modelo neuroborroso de la dinámica del proceso (dinámica directa) y un modelo neuroborroso de su dinámica inversa. Estos modelos son introducidos en un esquema de control basado en el paradigma del control por modelo interno para efectuar en último término el control del proceso complejo.

Por otro lado, para el caso de la monitorización neuroborrosa de sistemas complejos se plantea un procedimiento para obtener un modelo neuroborroso mediante el cual se relacionen parámetros del proceso medidos directamente a través de sensores con otra serie de fenómenos de difícil medición *on-line*. De este modo, el sistema de monitorización se implementará sobre la base del modelo neuroborroso obtenido.

El procedimiento propuesto para la realización de un sistema de control neuroborroso ha sido diseñado e implementado en un proceso de taladrado (proceso electromecánico complejo). Así, a través del paradigma de control por modelo interno y los modelos neuroborrosos directo e inverso se ha realizado el control del de la fuerza de corte en un proceso de taladrado a través de la modificación de la velocidad de avance de la herramienta.

Desde el punto de vista científico, se ha corroborado la viabilidad del principio de control por modelo interno y la capacidad de un sistema neuroborroso para capturar la dinámica directa e inversa de un proceso complejo, no lineal, plagado de incertidumbres y variable en el tiempo. Además, la sinergia del paradigma CMI y las estrategias neuroborrosas propuestas proporciona un comportamiento robusto del sistema de control en presencia de dinámicas no modeladas (*e.g.*, desgaste de herramienta) y perturbaciones.

Desde el punto de vista técnico, el sistema implementado ha permitido incrementar la tasa de arranque de material y disminuir el tiempo de operación. Igualmente, la calidad de la respuesta transitoria obtenida (sin sobrepaso) ha permitido un aprovechamiento efectivo de la vida útil de la herramienta de corte, evitando el desgaste prematuro o acelerado de la broca, así como el fallo catastrófico de la misma. Del mismo modo, esta buena respuesta dinámica ha

contribuido a un buen acabado de la pieza y a la protección de los mecanismos de la propia máquina herramienta.

El procedimiento propuesto para el desarrollo de un sistema de monitorización neuroborrosa se ha aplicado a la monitorización del desgaste de la herramienta de corte en un proceso de torneado. Mediante la información obtenida a través de los sensores de fuerzas de corte, de aceleración (vibraciones), de emisión acústica y utilizando el propio tiempo de operación se ha desarrollado un modelo neuroborroso para la estimación del desgaste del flanco de la herramienta.

Desde el punto de vista científico se ha vuelto a demostrar la capacidad de los sistemas neuroborrosos para tratar con las no-linealidades y las incertidumbres de un proceso complejo como es el proceso de desgaste de una herramienta de corte. Asimismo se ha demostrado la versatilidad y la robustez que proporciona la utilización de modelos neuroborrosos, ya que son capaces de modelizar operaciones de torneado en diferentes materiales.

Desde el punto de vista técnico, el diseño propuesto del sistema de monitorización conlleva una reducción de riesgos en la operación de torneado (tanto para el operario como para el proceso), así como una maximización en el tiempo de trabajo, ya que las paradas pueden preverse, incluyendo las paradas por fallo catastrófico que, con el sistema propuesto, pueden evitarse. Además, el sistema de monitorización proporciona una herramienta potencial para el control visual del desgaste de la herramienta de corte.

Tanto en el diseño del sistema de monitorización como en el diseño e implementación del sistema de control se han utilizado dos estrategias de modelado neuroborroso distintas: una estrategia inductiva y otra transductiva. A través de la estrategia inductiva se han obtenido modelos generales que representaban el proceso al completo (de principio a fin). Por contra, a través de las estrategias transductivas se han obtenido modelos locales de la situación concreta a estudiar.

Ambas estrategias proporcionan resultados similares. Ya que sería aventurado extrapolar conclusiones generales a partir de los resultados obtenidos en la monitorización y el control de procesos de torneado y taladrado (respectivamente), únicamente se puede afirmar que, en los casos objeto de estudio de este trabajo las técnicas transductivas se han mostrado más eficaces. Además, en los casos en los cuáles era necesario calcular una salida a partir de diversas entradas, las estrategias transductivas se han mostrado también más eficientes ya que han proporcionado unos resultados ligeramente mejores a los aportados por las estrategias inductivas con un menor número de reglas neuroborrosas. Hay que destacar en este sentido que otra de las contribuciones de esta Tesis Doctoral es que se han mejorado los sistemas de inferencia transductivos que se han tomado como inspiración.

Ciertamente, desde el punto de vista científico se ha desarrollado un método integrador para el control de procesos complejos que combina las propiedades más avanzadas de los sistemas neuroborrosos (inductivas-transductivas, borrosas y neuronales) con paradigmas del control como el control por modelo interno.

Del mismo modo se ha desarrollado un método para la monitorización de sistemas complejos que incorpora capacidades y potencialidades más allá de las que en la actualidad aportan algunas de las redes neuronales artificiales más avanzadas. Mediante el procedimiento propuesto se intenta aprovechar a través de la hibridación de sistemas las excelentes propiedades y características que aportan los sistemas borrosos, inductivos y transductivos a estas avanzadas topologías.

Así, se ha desarrollado un método integrador de paradigmas de control, fusión sensorial, lógica borrosa, redes neuronales, técnicas de razonamiento y técnicas de agrupamiento que propicia sinergias no reportadas anteriormente en la literatura científica y técnica. Igualmente, se ha demostrado la eficiencia computacional del método para el control y la monitorización en

tiempo real de sistemas complejos con dinámicas rápidas. Por todas estas razones se puede afirmar también que los objetivos propuestos han sido cumplidos satisfactoriamente.

La principal ventaja del método aplicado es que no se requiere un modelo matemático exacto del proceso para el diseño del sistema de monitorización y/o control. Los datos experimentales de entrada-salida son usados para obtener los modelos neuroborrosos necesarios. Además, se trata de un procedimiento simple y computacionalmente eficiente que puede ser implementado en aplicaciones de tiempo real. Al mismo tiempo, a través de pruebas reales de taladrado y torneado en materiales diferentes (GGG40 y 17-4PH para el caso del taladrado, y FG 15 y En24 para el caso del torneado), los sistemas proporcionan un buen comportamiento, versatilidad y robustez ante las no linealidades e incertidumbre de los distintos procesos.

Anteriormente, para poder mantener la fuerza de corte constante en el proceso de taladrado o para determinar el momento de sustitución de una herramienta en el proceso de torneado, era necesario contar con la experiencia de un operador humano en este tipo de operaciones. La implantación de técnicas de Inteligencia Artificial en este tipo de procesos trata de aprovechar la experiencia de estos operadores e incorporarla a los sistemas de monitorización y control a la vez que reduce la complejidad de los sistemas.

En este sentido, también es necesario destacar que, en general, las técnicas neuroborrosas transductivas se han utilizado en el pasado para aplicaciones de reconocimiento de texto, predicción de series temporales y, fundamentalmente, en aplicaciones de diagnóstico médico. Sin embargo, a partir de la literatura a la que ha tenido acceso el autor, no se han reportado aplicaciones en el campo de los sistemas realimentados y de control, o en la monitorización de procesos de fabricación complejos.

En resumen y haciendo una generalización del procedimiento propuesto, también se puede concluir que desde un punto de vista práctico, este trabajo proporciona un método alternativo de diseño para tratar la solución a problemas de monitorización y control cuando no existan modelos explícitos del proceso durante la etapa de diseño (ecuaciones diferenciales, funciones de transferencia, ecuaciones en espacio de estados, etc.). El uso combinado de paradigmas de control por modelo interno, fusión sensorial y un sistema de inferencia basado en reglas borrosas eficiente computacionalmente, asegura un diseño eficiente del sistema de monitorización y/o control sin necesidad de hacer uso de una representación matemática exacta del proceso.

Sin embargo, la combinación de este paradigma de control con los sistemas neuroborrosos propuestos no supone un sustituto perfecto de otras estrategias de control, del mismo modo que la combinación de la fusión sensorial con el modelado neuroborroso no reemplaza el empleo de otras estrategias de monitorización. La utilización de estos sistemas de monitorización y control únicamente reporta una serie de ventajas tales como: facilidad de uso en determinadas situaciones en las que la identificación clásica de sistemas es imposible o cuando la obtención de un modelo es difícil. Del mismo modo, la utilización de estrategias transductivas resulta muy apropiada cuando la obtención de un modelo general (a través de otras estrategias borrosas, neuronales o neuroborrosas) es difícil, innecesaria o no ha aportado los resultados esperados.

7.2. Publicaciones Asociadas

Algunos de los resultados parciales obtenidos en las investigaciones llevadas a cabo para el diseño y la implementación de los sistemas de control y monitorización neuroborrosos propuestos en este trabajo, han proporcionado las siguientes publicaciones en congresos y revistas:

Revistas Indexadas:

- A. Gajate, R. Haber, P. Vega, J.R. Alique, “A Transductive Neuro-Fuzzy Control. An Application to a Drilling Process”, *IEEE Transactions on Neural Networks* (Aceptado para su publicación).
- A. Gajate, R. Haber, R. del Toro, “Neurofuzzy Drilling-Force-Based Control in an Ethernet-Based Application”, *International Journal of Innovative Computing, Information and Control (IJICIC)*, vol. 6, núm. 1, pp. 373-386, 2010.
- A. Gajate, R. Haber, “Internal Model Control based on a Neuro-Fuzzy System for Network Applications. A Case Study on the High-Performance Drilling Process”, *IEEE Transactions on Automation Science and Engineering*, vol. 6, núm. 2, pp. 367-372, 2009.
- A. Gajate, R. Haber, “Control Neuroborroso en Red. Aplicación al Proceso de Taladrado de Alto Rendimiento”, *Revista Iberoamericana de Automática e Informática (RIAI)*, vol. 6, núm. 1, pp. 31-38, 2009.
- A. Gajate, R. Haber, R. del Toro, P. Vega, “Tool Wear Monitoring Using Neuro-Fuzzy Techniques. A Comparative Study in a Turning Process”, *Journal of Intelligent Manufacturing* (en fase de revisión).

Congresos Internacionales:

- A. Gajate, R. Haber, J.R. Alique, P. Vega, “Evolving Neuro-Fuzzy Systems for Controlling Complex Electromechanical Systems. A Case Study on the Drilling Force Control”, *2010 IEEE World Congress on Computational Intelligence (WCCI 2010)*, Art. núm. 197, España, 2010.
- A. Gajate, R. Haber, P. Vega, “A Transductive Neuro-Fuzzy Force Control: An Ethernet-Based Application to a Drilling Process”, *16th International Conference on Neural Information Processing (ICONIP 2009)*, LNCS 5864, Part II, pp. 573-582, Tailandia, 2009.
- A. Gajate, R. Haber, J.R. Alique, P. Vega, “Transductive-Weighted Neuro-fuzzy Inference System for Tool Wear Prediction in a Turning Process”, *4th International Conference on Hybrid Artificial Intelligence Systems (HAIS 2009)*, LNAI 5572, pp. 113-120, España, 2009.
- R. Haber, A. Gajate, R. del Toro, “Neurofuzzy Force-Based Control in an Ethernet-Based Application. A Case Study on a Drilling Process”, *3rd International Conference on Innovative Computing, Information and Control (ICICIC 2008)*, Art. núm. 4603253, pp. 64-68, China, 2008.

Congresos Nacionales:

- A. Gajate, P. Vega, R. Haber, “Modelado y Control Neuro-Difuso de Procesos de Taladrado de Alto Rendimiento”, *XV Congreso Español sobre Tecnologías y Lógica Fuzzy (ESTYLF 2010)*, Huelva, 2010.
- A. Gajate, R. Haber, B. Caballero, D. Martín, “Control del Proceso de Taladrado de Alto Rendimiento Basado en Sistemas Dotados con Aprendizaje Transductivo”, *Simposio de Control Inteligente*, Santander, 2008.
- A. Gajate, R. Haber, “Control Neuroborroso en Red. Aplicación al Proceso de Taladrado de Alto Rendimiento”, *XXVIII Jornadas de Automática*, Huelva, 2007.

7.3. Trabajo Futuro

Los trabajos de investigación que han conducido a la presentación de esta Tesis Doctoral han tratado de aportar un procedimiento para el desarrollo de sistemas de supervisión y control inteligentes cuando no se dispone de un modelo explícito del sistema a estudiar. Sin embargo, esta disertación ha dejado otra serie de líneas de investigación abiertas, algunas de las cuales se tratarán de abordar en trabajos futuros.

En relación con la extracción de conocimiento a partir de datos para la creación de los modelos, se puede llegar a mejorar la obtención de conocimiento mediante la utilización de algoritmos de agrupamiento más avanzados o bien mediante el empleo de algoritmos de agrupamiento borroso más eficientes que ofrezcan directamente las funciones de pertenencia a los modelos neuroborrosos.

Relacionada también con el manejo del conocimiento, la línea de investigación encargada del auto-aprendizaje de los modelos a partir de los propios datos facilitados por el mismo modelo, o por el sistema de control en el que se encuentra, dotaría de una mayor flexibilidad a los modelos e incrementaría sus potencialidades.

Del mismo modo, el desarrollo de un nuevo sistema neuroborroso que adecúe su estructura, conocimiento, aprendizaje, rendimiento, etc. en función de las diferentes necesidades que se producen a lo largo del tiempo en un sistema complejo, proporcionaría una herramienta potencial muy poderosa para el desarrollo de sistemas de monitorización, control y supervisión de procesos con múltiples incertidumbres e intrínsecamente no-lineales.

También queda abierta y contemplada la cuestión acerca del empleo de los procedimientos propuestos para la monitorización y control de otra serie de procesos complejos.

Bibliografía

- [1] L. Ljung, "System Identification: Theory for the User.," New Jersey: Prentice-Hall, 1999.
- [2] R. Babuska and H. B. Verbruggen, "An overview of fuzzy modeling for control," *Control Engineering Practice*, vol. 4, pp. 1593-1606, 1996.
- [3] S. Y. Liang, R. L. Hecker, and R. G. Landers, "Machining process monitoring and control: The state-of-the-art," *Journal of Manufacturing Science and Engineering, Transactions of the ASME*, vol. 126, pp. 297-310, 2004.
- [4] Y. Sheng and M. Tomizuka, "Intelligent modeling of thrust force in drilling process," *Journal of Dynamic Systems, Measurement and Control, Transactions of the ASME*, vol. 128, pp. 846-855, 2006.
- [5] A. Molina, C. A. Rodriguez, H. Ahuett, J. A. Cortés, M. Ramírez, G. Jiménez, and S. Martínez, "Next-generation manufacturing systems: Key research issues in developing and integrating reconfigurable and intelligent machines," *International Journal of Computer Integrated Manufacturing*, vol. 18, pp. 525-536, 2005.
- [6] Y. Koren, U. Heisel, F. Jovane, T. Moriwaki, G. Pritschow, G. Ulsoy, and H. Van Brussel, "Reconfigurable manufacturing systems," *CIRP Annals - Manufacturing Technology*, vol. 48, pp. 527-540, 1999.
- [7] C. Prada, "El futuro del control de procesos," *Revista Iberoamericana de Automática e Informática Industrial*, vol. 1, pp. 5-14, 2004.
- [8] R. E. Haber, J. R. Alique, A. Alique, and R. H. Haber, "Controlling a complex electromechanical process on the basis of a neurofuzzy approach," *Future Generation Computer Systems*, vol. 21, pp. 1083-1095, 2005.
- [9] J. M. Andújar and A. J. Barragán, "A methodology to design stable nonlinear fuzzy control systems," *Fuzzy Sets and Systems*, vol. 154, pp. 157-181, 2005.
- [10] J. M. Andújar, "Sistemas borrosos multivariables, modelización neuro-borrosa, control y análisis de estabilidad," Tesis, Universidad de Huelva, España, 2000.
- [11] G. I. Sainz, M. J. Fuente, and P. Vega, "Recurrent neuro-fuzzy modeling of a wastewater treatment plant," *European Journal of Control*, vol. 10, pp. 84-96, 2004.
- [12] J. M. Zamarreño and P. Vega, "Neural predictive control. Application to a highly nonlinear system," *Engineering Applications of Artificial Intelligence*, vol. 12, pp. 149-158, 1999.
- [13] M. Santos and A. L. Dexter, "Temperature control in liquid helium cryostat using self-learning neurofuzzy controller," *IEE Proceedings: Control Theory and Applications*, vol. 148, pp. 233-238, 2001.
- [14] A. G. Rehorn, J. Jiang, and P. E. Orban, "State-of-the-art methods and results in tool condition monitoring: A review," *International Journal of Advanced Manufacturing Technology*, vol. 26, pp. 693-710, 2005.
- [15] H. K. Tönshoff, J. P. Wulfsberg, H. J. J. Kals, W. König, and C. A. van Luttervelt, "Developments and Trends in Monitoring and Control of Machining Processes," *CIRP Annals - Manufacturing Technology*, vol. 37, pp. 611-622, 1988.
- [16] M. J. Willis and M. T. Tham, "Advanced Process Control," in <http://lorien.ncl.ac.uk/ming/advcontrl/apc.htm>. Newcastle University, 1994.
- [17] R. Johansson, "System Modeling and Identification," in *Information and System Sciences*. New Jersey: Prentice Hall, 1993.
- [18] F. E. Cellier, *Continuous System Modeling*. New York, 1991.

- [19] J. Rissanen, "Modeling by shortest data description," *Automatica*, vol. 14, pp. 465-471, 1978.
- [20] R. Babuska, *Fuzzy Modeling for Control*: Kluwer Academic Publishers, 1998.
- [21] K. J. Aström and P. Eykhoff, "System identification-A survey," *Automatica*, vol. 7, pp. 123-162, 1971.
- [22] N. K. Sinha and B. Kuszta, *Modeling and identification of dynamic systems*: Springer, 1983.
- [23] C. Filippi, J. L. Greffe, J. Bordet, J. Villermaux, J. L. Barnay, P. Bonte, and C. Georgakis, "Tendency modeling of semibatch reactors for optimization and control," *Chemical Engineering Science*, vol. 41, pp. 913-920, 1986.
- [24] J. Benz, J. Polster, R. Bär, and G. Gauglitz, "Program system SIDYS: Simulation and parameter identification of dynamic systems," *Computers and Chemistry*, vol. 11, pp. 41-48, 1987.
- [25] P. Eykhoff, "System Identification," John Wiley, 1974.
- [26] R. Haber and H. Unbehauen, "Structure identification of nonlinear dynamic systems - A survey on input/output approaches," *Automatica*, vol. 26, pp. 651-677, 1990.
- [27] T. Söderström and P. Stoica, "System Identification," New York: Prentice Hall, 1989.
- [28] L. Ljung and Z.-D. Yuan, "Asymptotic Properties of Black-Box Identification of Transfer Functions," *IEEE Transactions on Automatic Control*, vol. AC-30, pp. 514-530, 1985.
- [29] Y.-C. Zhu, "Black-box identification of MIMO transfer functions. Asymptotic properties of prediction error models," *International Journal of Adaptive Control and Signal Processing*, vol. 3, pp. 357-373, 1989.
- [30] A. G. Arrieta, L. A. Romero, A. L. Sánchez, and J. M. Del Amo, "Neural network approach to gun and munition recognition from shot sound," *Latin American Applied Research*, vol. 31, pp. 61-64, 2001.
- [31] L. Jin, P. N. Nikiforuk, and M. M. Gupta, "Dynamic recurrent neural networks for control of unknown nonlinear systems," *Journal of Dynamic Systems, Measurement and Control, Transactions of the ASME*, vol. 116, pp. 567-576, 1994.
- [32] J. Sjöberg, Q. Zhang, L. Ljung, A. Benveniste, B. Delyon, P. Y. Glorennec, H. Hjalmarsson, and A. Juditsky, "Nonlinear black-box modeling in system identification: A unified overview," *Automatica*, vol. 31, pp. 1691-1724, 1995.
- [33] A. Juditsky, H. Hjalmarsson, A. Benveniste, B. Delyon, L. Ljung, J. Sjöberg, and Q. Zhang, "Nonlinear black-box models in system identification: Mathematical foundations," *Automatica*, vol. 31, pp. 1725-1750, 1995.
- [34] C. Alippi and V. Piuri, "Experimental neural networks for prediction and identification," *IEEE Transactions on Instrumentation and Measurement*, vol. 45, pp. 670-676, 1996.
- [35] G. Cybenko, "Approximation by superpositions of a sigmoidal function," *Mathematics of Control, Signals, and Systems*, vol. 2, pp. 303-314, 1989.
- [36] R. P. Lippmann, "An introduction to computing with neural nets," *Artificial Neural Networks: Theoretical Concepts*, pp. 36-54, 1988.
- [37] D. W. Patterson, "Artificial Neural Networks," New Jersey: Prentice-Hall, 1996.
- [38] M. Setnes, R. Babuska, and H. B. Verbruggen, "Transparent fuzzy modelling," *International Journal of Human Computer Studies*, vol. 49, pp. 159-179, 1998.
- [39] D. G. Bobrow, "Qualitative reasoning about physical systems: An introduction," *Artificial Intelligence*, vol. 24, pp. 1-5, 1984.
- [40] D. S. Weld and J. De Kleer, "Reading in qualitative reasoning about physical systems," Morgan Kaufman, 1990.
- [41] S. Feray-Beaumont, R. Corea, M. T. Tham, and A. J. Morris, "Process modelling for intelligent control," *Engineering Applications of Artificial Intelligence*, vol. 5, pp. 483-492, 1992.
- [42] L. A. Zadeh, "Fuzzy sets," *Information and Control*, vol. 8, pp. 338-353, 1965.
- [43] L. A. Zadeh, "Quantitative fuzzy semantics," *Information Sciences*, vol. 3, pp. 159-176, 1971.

- [44] P. M. Frank, "Analytical and qualitative model-based fault diagnosis - A survey and some new results," *European Journal of Control*, vol. 2, pp. 6-28, 1996.
- [45] V. Venkatasubramanian, R. Rengaswamy, and S. N. Kavuri, "A review of process fault detection and diagnosis part II: Qualitative models and search strategies," *Computers and Chemical Engineering*, vol. 27, pp. 313-326, 2003.
- [46] P. C. Young, "An instrumental variable method for real-time identification of a noisy process," *Automatica*, vol. 6, pp. 271-287, 1970.
- [47] R. K. Mehra and J. Peschon, "An innovations approach to fault detection and diagnosis in dynamic systems," *Automatica*, vol. 7, pp. 637-640, 1971.
- [48] M. E. Tipping, "Sparse Bayesian Learning and the Relevance Vector Machine," *Journal of Machine Learning Research*, vol. 1, pp. 211-244, 2001.
- [49] Z. Ghahramani and M. I. Jordan, "Factorial Hidden Markov Models," *Machine Learning*, vol. 29, pp. 245-273, 1997.
- [50] J. M. Tague, "A Bayesian approach to interactive retrieval," *Information Storage and Retrieval*, vol. 9, pp. 129-142, 1973.
- [51] M. Correa, C. Bielza, M. D. J. Ramirez, and J. R. Alique, "A Bayesian network model for surface roughness prediction in the machining process," *International Journal of Systems Science*, vol. 39, pp. 1181-1192, 2008.
- [52] P. Smyth, D. Heckerman, and M. I. Jordan, "Probabilistic independence networks for hidden Markov probability models," *Neural Computation*, vol. 9, pp. 227-269, 1997.
- [53] V. De Fonzo, F. Aluffi-Pentini, and V. Parisi, "Hidden Markov Models in bioinformatics," *Current Bioinformatics*, vol. 2, pp. 49-61, 2007.
- [54] R. C. Rose and B. H. Juang, "Hidden Markov models for speech and signal recognition," *Electroencephalography and clinical neurophysiology. Supplement*, vol. 45, pp. 137-152, 1996.
- [55] S. Sinharay, "Model diagnostics for Bayesian networks," *Journal of Educational and Behavioral Statistics*, vol. 31, pp. 1-33, 2006.
- [56] D. M. Titterington, "Bayesian methods for neural networks and related models," *Statistical Science*, vol. 19, pp. 128-139, 2004.
- [57] R. Isermann, K. H. Lachmann, and D. Matko, "Adaptive control systems," New York: Prentice Hall, 1992.
- [58] O. Nelles, "Nonlinear system identification with local linear neuro-fuzzy models," Darmstadt, Germany: Darmstadt University of Technology, 1999.
- [59] T. A. Johansen and R. Murray-Smith, "The operating regime approach to nonlinear modelling and control," in *Multiple Model Approaches to Modelling and Control* London: Taylor & Francis., 1997, pp. 3-72.
- [60] L. X. Wang, "A course in fuzzy systems and control," New Jersey: Prentice Hall, 1997.
- [61] M. Santos, R. López, and J. M. De La Cruz, "A neuro-fuzzy approach to fast ferry vertical motion modelling," *Engineering Applications of Artificial Intelligence*, vol. 19, pp. 313-321, 2006.
- [62] H. J. A. F. Tulleken, "Grey-box modelling and identification using physical knowledge and bayesian techniques," *Automatica*, vol. 29, pp. 285-308, 1993.
- [63] N. L. Kristensen, H. Madsen, and S. B. Jorgensen, "Parameter estimation in stochastic grey-box models," *Automatica*, vol. 40, pp. 225-237, 2004.
- [64] T. Bohlin, "A case study of grey box identification," *Automatica*, vol. 30, pp. 307-318, 1994.
- [65] T. Bohlin and S. F. Graebe, "Issues in nonlinear stochastic grey box identification," *International Journal of Adaptive Control and Signal Processing*, vol. 9, pp. 465-490, 1995.
- [66] Q. Xiong and A. Jutan, "Grey-box modelling and control of chemical processes," *Chemical Engineering Science*, vol. 57, pp. 1027-1039, 2002.
- [67] K. C. Tan and Y. Li, "Grey-box model identification via evolutionary computing," *Control Engineering Practice*, vol. 10, pp. 673-684, 2002.

- [68] F. Previdi, "Identification and control using local linear models," Milano, Italy: Politecnico di Milano, 1998.
- [69] J. S. Shamma and M. Athans, "Analysis of gain scheduled control for nonlinear plants," *IEEE Transactions on Automatic Control*, vol. 35, pp. 898-907, 1990.
- [70] W. J. Rugh, "Analytical framework for gain scheduling," *IEEE Control Systems Magazine*, vol. 11, pp. 79-84, 1991.
- [71] K. J. Aström and B. Wittenmark, "Adaptive Control," Massachusetts: Addison-Wesley, 1995.
- [72] W. S. Cleveland, S. J. Devlin, and E. Grosse, "Regression by local fitting. Methods, properties, and computational algorithms," *Journal of Econometrics*, vol. 37, pp. 87-114, 1988.
- [73] C. G. Atkeson, "Memory-based approaches to approximating continuous functions," in *Workshop on Nonlinear Modeling & Forecasting*, Santa Fe Institute, 1990.
- [74] K. J. Hunt and T. A. Johansen, "Design and analysis of gain-scheduled control using local controller networks," *International Journal of Control*, vol. 66, pp. 619-651, 1997.
- [75] B. A. Foss, T. A. Johansen, and A. V. Sorensen, "Nonlinear predictive control using local models - applied to a batch fermentation process," *Control Engineering Practice*, vol. 3, pp. 389-396, 1995.
- [76] K. J. Hunt, J. C. Kalkkuhl, H. Fritz, and T. A. Johansen, "Constructive empirical modelling of longitudinal vehicle dynamics using local model networks," *Control Engineering Practice*, vol. 4, pp. 167-178, 1996.
- [77] B. A. Foss and T. A. Johansen, "On local and fuzzy modelling," in *3rd Int. Conference on Industrial Fuzzy Control and Intelligent Systems*, Houston, Texas, 1993, pp. 80-87.
- [78] A. Skeppstedt, L. Ljung, and M. Millnert, "Construction of composite models from observed data," *International Journal of Control*, vol. 55, pp. 141-152, 1992.
- [79] T. Takagi and M. Sugeno, "Fuzzy identification of systems and its applications to modeling and control," *IEEE Transactions on Systems, Man and Cybernetics*, vol. 15, pp. 116-132, 1985.
- [80] M. Sugeno and G. T. Kang, "Structure identification of fuzzy model," *Fuzzy Sets and Systems*, vol. 28, pp. 15-33, 1988.
- [81] K. S. Narendra and J. Balakrishnan, "Adaptive control using multiple models," *IEEE Transactions on Automatic Control*, vol. 42, pp. 171-187, 1997.
- [82] K. S. Narendra and J. Balakrishnan, "Improving transient response of adaptive control systems using multiple models and switching," *IEEE Transactions on Automatic Control*, vol. 39, pp. 1861-1866, 1994.
- [83] K. S. Narendra, J. Balakrishnan, and M. K. Ciliz, "Adaptation and learning using multiple models, switching, and tuning," *IEEE Control Systems Magazine*, vol. 15, pp. 37-51, 1995.
- [84] C. Barnes, S. Brown, G. Flake, R. Jones, M. O. Rourke, and Y. C. Lee, "Applications of neural networks to process control and modelling," *Artificial Neural Networks, Proceedings of 1991 Internal. Conf. Artif. Neur. Nets*, vol. 1, pp. 321-326, 1991.
- [85] R. A. Jacobs, M. I. Jordan, S. J. Nowlan, and G. E. Hinton, "Adaptive mixtures of local experts," *Neural Comput.*, 2006.
- [86] R. D. Jones, Y. C. Lee, C. W. Barnes, G. W. Flake, K. Lee, P. S. Lewis, and S. Qian, "Function approximation and time series prediction with neural networks," 1990, pp. 649-665.
- [87] K. Stokbro, D. K. Umberger, and J. A. Hertz, "Exploiting neurons with localized receptive fields to learn chaos," *Complex Syst.*, vol. 4, pp. 603-622, 1990.
- [88] L. Bottou and V. Vapnik, "Local learning algorithms," *Neural Computation*, vol. 4, pp. 888-900, 1992.
- [89] K. J. Aström and T. Hägglund, "Automatic tuning of simple regulators with specifications on phase and amplitude margins," *Automatica*, vol. 20, pp. 645-651, 1984.

- [90] K. J. Aström and T. Hägglund, "The future of PID control," *Control Engineering Practice*, vol. 9, pp. 1163-1175, 2001.
- [91] K. J. Aström, T. Hägglund, C. C. Hang, and W. K. Ho, "Automatic tuning and adaptation for PID controllers - a survey," *Control Engineering Practice*, vol. 1, pp. 699-714, 1993.
- [92] M. V. Kothare, P. J. Campo, M. Morari, and C. N. Nett, "A unified framework for the study of anti-windup designs," *Automatica*, vol. 30, pp. 1869-1883, 1994.
- [93] H. Subawalla, V. P. Paruchuri, A. Gupta, H. G. Pandit, and R. Russell Rhinehart, "Comparison of model-based and conventional control: A summary of experimental results," *Industrial and Engineering Chemistry Research*, vol. 35, pp. 3547-3559, 1996.
- [94] M. S. Branicky, V. S. Borkar, and S. K. Mitter, "A unified framework for hybrid control: Model and optimal control theory," *IEEE Transactions on Automatic Control*, vol. 43, pp. 31-45, 1998.
- [95] C. E. García, D. M. Prett, and M. Morari, "Model predictive control: Theory and practice-A survey," *Automatica*, vol. 25, pp. 335-348, 1989.
- [96] S. J. Qin and T. A. Badgwell, "A survey of industrial model predictive control technology," *Control Engineering Practice*, vol. 11, pp. 733-764, 2003.
- [97] J. Richalet, A. Rault, J. L. Testud, and J. Papon, "Model predictive heuristic control. Applications to industrial processes," *Automatica*, vol. 14, pp. 413-428, 1978.
- [98] P. Gahinet and P. Apkarian, "Linear matrix inequality approach to H_∞ control," *International Journal of Robust and Nonlinear Control*, vol. 4, pp. 421-448, 1994.
- [99] M. Morari and E. Zafiriou, *Robust Process Control*. Englewood Cliffs, NJ: Prentice-Hall, 1989.
- [100] C. E. Garcia and M. Morari, "Internal model control. A unifying review and some new results," *Industrial and Engineering Chemistry Process Design and Development*, vol. 21, pp. 308-323, 1982.
- [101] R. A. Brooks, "Robust layered control system for a mobile robot," *IEEE journal of robotics and automation*, vol. RA-2, pp. 14-23, 1986.
- [102] P. P. Khargonekar, I. R. Petersen, and K. Zhou, "Robust stabilization of uncertain linear systems: Quadratic stabilizability and H_∞ control theory," *IEEE Transactions on Automatic Control*, vol. 35, pp. 356-361, 1990.
- [103] G. C. Goodwin and D. Q. Mayne, "A parameter estimation perspective of continuous time model reference adaptive control," *Automatica*, vol. 23, pp. 57-70, 1987.
- [104] M. Francisco and P. Vega, "Diseño integrado de procesos de depuración de aguas utilizando control predictivo basado en modelos," *Revista Iberoamericana de Automática e Informática Industrial*, vol. 3, pp. 88-98, 2006.
- [105] C. G. Källström, K. J. Aström, N. E. Thorell, J. Eriksson, and L. Sten, "Adaptive autopilots for tankers," *Automatica*, vol. 15, pp. 241-254, 1979.
- [106] G. Stein, G. L. Hartmann, and R. C. Hendrick, "Adaptive control laws for F-8 flight test," *IEEE Transactions on Automatic Control*, vol. AC-22, pp. 758-767, 1977.
- [107] D. J. Leith and W. E. Leithead, "Survey of gain-scheduling analysis and design," *International Journal of Control*, vol. 73, pp. 1001-1025, 2000.
- [108] W. J. Rugh and J. S. Shamma, "Research on gain scheduling," *Automatica*, vol. 36, pp. 1401-1425, 2000.
- [109] F. Liao, J. L. Wang, and G. H. Yang, "Reliable robust flight tracking control: An LMI approach," *IEEE Transactions on Control Systems Technology*, vol. 10, pp. 76-89, 2002.
- [110] C. H. Fang, Y. S. Liu, S. W. Kau, L. Hong, and C. H. Lee, "A new LMI-based approach to relaxed quadratic stabilization of T-S fuzzy control systems," *IEEE Transactions on Fuzzy Systems*, vol. 14, pp. 386-397, 2006.
- [111] M. Chilali, P. Gahinet, and P. Apkarian, "Robust pole placement in LMI regions," *IEEE Transactions on Automatic Control*, vol. 44, pp. 2257-2270, 1999.
- [112] C. G. Atkeson, A. W. Moore, and S. Schaal, "Locally Weighted Learning for Control," *Artificial Intelligence Review*, vol. 11, pp. 75-113, 1997.

- [113] P. Vega, M. J. Fuente, and C. M. Dominguez, "Two algorithms for robust fault detection and diagnosis of an industrial plant," *Control and Computers*, vol. 24, pp. 93-101, 1996.
- [114] J. Aguilar Martín, "Técnicas de Inteligencia Artificial en la Supervisión de Procesos Industriales," in *Cursos de especialización en Automática* Cartagena, Murcia, 2001.
- [115] D. L. Hall and J. Llinas, "An introduction to multisensor data fusion," *Proceedings of the IEEE*, vol. 85, pp. 6-23, 1997.
- [116] M. A. Erdmann and M. T. Mason, "Exploration of sensorless manipulation," *IEEE journal of robotics and automation*, vol. 4, pp. 369-379, 1988.
- [117] J. Holtz, "Sensorless position control of induction motors - An emerging technology," *IEEE Transactions on Industrial Electronics*, vol. 45, pp. 840-852, 1998.
- [118] B. Sick, "On-line and indirect tool wear monitoring in turning with artificial neural networks: A review of more than a decade of research," *Mechanical Systems and Signal Processing*, vol. 16, pp. 487-546, 2002.
- [119] R. Isermann, "Process fault detection based on modelling and estimation methods: a survey," *Automatica*, vol. 20, pp. 307-404, 1984.
- [120] R. Isermann, "Fault diagnosis of machines via parameter estimation and knowledge processing - Tutorial paper," *Automatica*, vol. 29, pp. 815-835, 1993.
- [121] R. Isermann, "Model-based fault-detection and diagnosis - Status and applications," *Annual Reviews in Control*, vol. 29, pp. 71-85, 2005.
- [122] F. Hayes-Roth, "Rule-based systems," *Communications of the ACM*, vol. 28, pp. 921-932, 1985.
- [123] P. M. Frank, "Fault diagnosis in dynamic systems using analytical and knowledge-based redundancy. A survey and some new results," *Automatica*, vol. 26, pp. 459-474, 1990.
- [124] M. A. Jafari and T. O. Boucher, "A rule-based system for generating a ladder logic control program from a high-level systems model," *Journal of Intelligent Manufacturing*, vol. 5, pp. 103-120, 1994.
- [125] D. W. Coit, B. T. Jackson, and A. E. Smith, "Static neural network process models: Considerations and case studies," *International Journal of Production Research*, vol. 36, pp. 2953-2967, 1998.
- [126] C. Feng, X. Wang, and Z. Yu, "Neural networks modelling of honing surface roughness parameter defined by ISO 13565," *SIAM Journal of Manufacturing Systems*, vol. 21, pp. 1-35, 2002.
- [127] R. K. Jain, V. K. Jain, and P. K. Kalra, "Modelling of abrasive flow machining process: A neural network approach," *Wear*, vol. 231, pp. 242-248, 1999.
- [128] D. Barschdorff, L. Monostori, T. Kottenstede, G. Warnecke, and M. Müller, "Cutting tool monitoring in turning under varying cutting conditions; An artificial neural network approach," *Proceedings of the 6th International Conference on Industrial and Engineering Applications of Artificial Intelligence and Expert Systems (IEA'93 AIE)*, pp. 353-359, 1993.
- [129] M. Rahman, Q. Zhou, and G. S. Hong, "Application of Kohonen neural network for tool condition monitoring," *International Conference on Intelligent Manufacturing*, pp. 422-429, 1995.
- [130] K. J. Hunt, D. Sbarbaro, R. Zbikowski, and P. J. Gawthrop, "Neural networks for control systems - A survey," *Automatica*, vol. 28, pp. 1083-1112, 1992.
- [131] K. S. Narendra and K. Parthasarathy, "Identification and control of dynamical systems using neural networks," *IEEE Transactions on Neural Networks*, vol. 1, pp. 4-27, 1990.
- [132] H. Al-Wedyan, K. Demirli, and R. Bhat, "A technique for fuzzy logic modeling of machining process," in *Annual Conference of the North American Fuzzy Information Processing Society - NAFIPS*, Vancouver, BC, 2001, pp. 3021-3026.
- [133] S. L. Chiu, "Fuzzy model identification based on cluster estimation," *Journal of Intelligent and Fuzzy Systems*, vol. 2, pp. 267-278, 1994.
- [134] M. Sugeno and T. Yasukawa, "Fuzzy-logic-based approach to qualitative modeling," *IEEE Transactions on Fuzzy Systems*, vol. 1, pp. 7-31, 1993.

- [135] P. Bikramjit, D. K. Pratihar, M. S. Mondal, and R. Joarder, "Prediction of power requirement in turning using a GA-fuzzy approach," *Soft Comput Ind Recent Appl*, pp. 167-169, 2002.
- [136] M. K. Kamatala, E. T. Baumgartner, and K. S. Moon, "Turned surface finish prediction based on fuzzy logic theory," *Proceedings of the 20th International Conference on Computer and Industrial Engineering*, vol. 1, pp. 101-104, 1996.
- [137] R. E. Haber, A. Alique, J. R. Alique, R. Haber-Haber, and S. Ros, "Current trends and future developments of new control systems based on fuzzy logic and their application to high speed machining," *Revista de Metalurgia (Madrid)*, vol. 38, pp. 124-133, 2002.
- [138] R. E. Haber, D. Martin, R. Haber-Haber, and A. Alique, "Networked fuzzy control system for a high-performance drilling process," *Journal of Manufacturing Science and Engineering-Transactions of the ASME*, vol. 130, Jun 2008.
- [139] C. C. Lee, "Fuzzy logic in control systems: Fuzzy logic controller - Part I," *IEEE Transactions on Systems, Man and Cybernetics*, vol. 20, pp. 404-418, 1990.
- [140] C. C. Lee, "Fuzzy logic in control systems: Fuzzy logic controller - Part II," *IEEE Transactions on Systems, Man and Cybernetics*, vol. 20, pp. 419-435, 1990.
- [141] E. H. Mamdani, "Application of fuzzy algorithms for control of simple dynamic plant," *Proceedings of the Institution of Electrical Engineers*, vol. 121, pp. 1585-1588, 1974.
- [142] W. A. Farag, V. H. Quintana, and G. Lambert-Torres, "A genetic-based neuro-fuzzy approach for modeling and control of dynamical systems," *IEEE Transactions on Neural Networks*, vol. 9, pp. 756-767, 1998.
- [143] A. P. De Weijer, C. B. Lucasius, L. Buydens, G. Kateman, H. M. Heuvel, and H. Mannee, "Curve fitting using natural computation," *Analytical Chemistry*, vol. 66, pp. 23-31, 1994.
- [144] T. P. Chemaly and C. Aldrich, "Visualization of process data by use of evolutionary computation," *Computers and Chemical Engineering*, vol. 25, pp. 1341-1349, 2001.
- [145] B. Carse, T. C. Fogarty, and A. Munro, "Evolving fuzzy rule based controllers using genetic algorithms," *Fuzzy Sets and Systems*, vol. 80, pp. 273-293, 1996.
- [146] A. C. Nearchou, "Adaptive navigation of autonomous vehicles using evolutionary algorithms," *Artificial Intelligence in Engineering*, vol. 13, pp. 159-173, 1999.
- [147] B. Denby and S. Le Hégarat-Masclé, "Swarm intelligence in optimisation problems," *Nuclear Instruments and Methods in Physics Research, Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, vol. 502, pp. 364-368, 2003.
- [148] M. Dorigo, V. Maniezzo, and A. Colomi, "Ant system: Optimization by a colony of cooperating agents," *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, vol. 26, pp. 29-41, 1996.
- [149] B. Samanta and C. Nataraj, "Application of particle swarm optimization and proximal support vector machines for fault detection," *Swarm Intelligence*, vol. 3, pp. 303-325, 2009.
- [150] A. R. M. Rao and G. Anandakumar, "Optimal placement of sensors for structural system identification and health monitoring using a hybrid swarm intelligence technique," *Smart Materials and Structures*, vol. 16, pp. 2658-2672, 2007.
- [151] C. F. Juang and P. H. Chang, "Designing fuzzy-rule-based systems using continuous ant-colony optimization," *IEEE Transactions on Fuzzy Systems*, vol. 18, pp. 138-149, 2010.
- [152] D. S. Lee and A. C. Lee, "Pheromone propagation controller: The linkage of swarm intelligence and advanced process control," *IEEE Transactions on Semiconductor Manufacturing*, vol. 22, pp. 357-372, 2009.
- [153] J. E. Hunt and D. E. Cooke, "Learning using an artificial immune system," *Journal of Network and Computer Applications*, vol. 19, pp. 189-212, 1996.
- [154] J. Y. Yan and J. G. Yang, "Immune system based RBF neural network modeling for machine tool thermal error," *Shanghai Jiaotong Daxue Xuebao/Journal of Shanghai Jiaotong University*, vol. 43, pp. 148-152, 2009.

- [155] G. Ruan and Y. Tan, "A three-layer back-propagation neural network for spam detection using artificial immune concentration," *Soft Computing*, vol. 14, pp. 139-150, 2010.
- [156] S. L. Hou, W. Wang, J. H. Hu, and G. N. Zhou, "Immune-neural networks model of aeroengine performance monitoring," *Hangkong Dongli Xuebao/Journal of Aerospace Power*, vol. 23, pp. 1748-1752, 2008.
- [157] K. A. Williams, F. Garbanzo, and C. L. Karr, "Experimental implementation of an artificial immune system on a robotic manipulator," *Applied Artificial Intelligence*, vol. 24, pp. 175-193, 2010.
- [158] Z. Zhang and S. Qian, "Immune algorithm with dynamic environments and its application to greenhouse control," *Optimization and Engineering*, vol. 11, pp. 125-144, 2010.
- [159] R. R. Sumar, A. A. Rodrigues Coelho, and L. d. Santos Coelho, "Use of an artificial immune network optimization approach to tune the parameters of a discrete variable structure controller," *Expert Systems with Applications*, vol. 36, pp. 5009-5015, 2009.
- [160] A. Aamodt and E. Plaza, "Case-based reasoning: foundational issues, methodological variations, and system approaches," *AI Communications*, vol. 7, pp. 39-59, 1994.
- [161] I. Watson and F. Marir, "Case-based reasoning: A review," *The Knowledge Engineering Review*, vol. 9, pp. 327-354, 1994.
- [162] M. A. Simón, L. Alonso, and A. Antón, "A hybrid visual field classifier to support early glaucoma diagnosis," *Inteligencia Artificial*, vol. 9, pp. 9-17, 2005.
- [163] R. S. Engelmores and D. Majumdar, "A quick overview of artificial intelligence and expert systems," *Nuclear Engineering and Design*, vol. 113, pp. 173-180, 1989.
- [164] J. J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities," *Proceedings of the National Academy of Sciences of the United States of America*, vol. 79, pp. 2554-2558, 1982.
- [165] T. Kohonen, "The self-organizing map," *Proceedings of the IEEE*, vol. 78, pp. 1464-1480, 1990.
- [166] J. J. Hopfield and D. W. Tank, "'Neural' computation of decisions in optimization problems," *Biological Cybernetics*, vol. 52, pp. 141-152, 1985.
- [167] T. Calonge, L. Alonso, and R. Ralha, "Transputer implementations of a multilayer perceptron used for speech-recognition task," *Microcomputer Applications*, vol. 16, pp. 64-69, 1997.
- [168] L. A. Zadeh, "Soft computing and fuzzy logic," *IEEE Software*, vol. 11, pp. 48-56, 1994.
- [169] L. A. Zadeh, "The concept of a linguistic variable and its application to approximate reasoning-I," *Information Sciences*, vol. 8, pp. 199-249, 1975.
- [170] L. A. Zadeh, "Fuzzy logic = computing with words," *IEEE Transactions on Fuzzy Systems*, vol. 4, pp. 103-111, 1996.
- [171] J. M. Mendel, "Fuzzy logic systems for engineering: a tutorial," *Proceedings of the IEEE*, vol. 83, pp. 345-377, 1995.
- [172] L. A. Zadeh, "Fuzzy logic," *Computer*, vol. 21, pp. 83-93, 1988.
- [173] E. H. Mamdani and S. Assilian, "Experiment in linguistic synthesis with a fuzzy logic controller," *International Journal of Man-Machine Studies*, vol. 7, pp. 1-13, 1975.
- [174] E. H. Mamdani, "Application of fuzzy logic to approximate reasoning using linguistic synthesis," *IEEE Transactions on Computers*, vol. C-26, pp. 1182-1191, 1977.
- [175] F. Matía, A. Jiménez, R. Galán, and R. Sanz, "Fuzzy controllers: Lifting the linear-nonlinear frontier," *Fuzzy Sets and Systems*, vol. 52, pp. 113-128, 1992.
- [176] J. S. R. Jang, C. T. Sun, and E. Mizutani, *Neuro-Fuzzy and Soft Computing*. New Jersey, USA: Prentice-Hall, Inc., 1997.
- [177] T. Back, U. Hammel, and H. P. Schwefel, "Evolutionary computation: Comments on the history and current state," *IEEE Transactions on Evolutionary Computation*, vol. 1, pp. 3-17, 1997.
- [178] A. E. Eiben, R. Hinterding, and Z. Michalewicz, "Parameter control in evolutionary algorithms," *IEEE Transactions on Evolutionary Computation*, vol. 3, pp. 124-141, 1999.

- [179] Z. Michalewicz, "Evolutionary algorithms for constrained parameter optimization problems," *Evolutionary Computation*, vol. 4, pp. 1-32, 1996.
- [180] S. Forrest, "Genetic algorithms: Principles of natural selection applied to computation," *Science*, vol. 261, pp. 872-878, 1993.
- [181] Y. Jin and J. Branke, "Evolutionary optimization in uncertain environments - A survey," *IEEE Transactions on Evolutionary Computation*, vol. 9, pp. 303-317, 2005.
- [182] J. Kennedy and R. Eberhart, "Particle swarm optimisation," *Proceedings of the IEEE international conference of neural network (ICNN'95)*, vol. IV, 1995.
- [183] L. N. de Castro, "Fundamentals of natural computing: an overview," *Physics of Life Reviews*, vol. 4, pp. 1-36, 2007.
- [184] K. J. Kim and S. B. Cho, "A comprehensive overview of the applications of artificial life," *Artificial Life*, vol. 12, pp. 153-182, 2006.
- [185] C. P. Lim and L. C. Jain, "Advances in swarm intelligence," in *Studies in Computational Intelligence*. vol. 248, 2009, pp. 1-7.
- [186] G. L. Ada and G. Nossal, "The clonal-selection theory," *Scientific American*, vol. 257, pp. 62-69, 1987.
- [187] S. A. Hofmeyr and S. Forrest, "Architecture for an artificial immune system," *Evolutionary computation*, vol. 8, pp. 443-473, 2000.
- [188] D. Dasgupta, "Advances in artificial immune systems," *IEEE Computational Intelligence Magazine*, vol. 1, pp. 40-43, 2006.
- [189] L. Monostori and C. Egresits, "On hybrid learning and its application in intelligent manufacturing," *Computers in Industry*, vol. 33, pp. 111-117, 1997.
- [190] W. Pedrycz, "Hybridization schemes in architectures of computational intelligence," in *Studies in Fuzziness and Soft Computing*. vol. 208, 2007, pp. 3-20.
- [191] S. Mitra and S. K. Pal, "Fuzzy multi-layer perceptron, inferencing and rule generation," *IEEE Transactions on Neural Networks*, vol. 6, pp. 51-63, 1995.
- [192] S. C. Lee and E. T. Lee, "Fuzzy neural networks," *Mathematical Biosciences*, vol. 23, pp. 151-177, 1975.
- [193] S. K. Pal and S. Mitra, "Multilayer perceptron, fuzzy sets, and classification," *IEEE Transactions on Neural Networks*, vol. 3, pp. 683-697, 1992.
- [194] J. M. Keller and D. J. Hunt, "Incorporating fuzzy membership functions into the perceptron algorithm," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. PAMI-7, pp. 693-699, 1985.
- [195] D. Nauck, F. Klawonn, and R. Kruse, "Foundations of neuro-fuzzy systems," Chichester, U.K.: Wiley, 1997.
- [196] J. M. Keller and H. Tahani, "Implementation of conjunctive and disjunctive fuzzy logic rules with neural networks," *International Journal of Approximate Reasoning*, vol. 6, pp. 221-240, 1992.
- [197] H. Takagi, N. Suzuki, T. Koda, and Y. Kojima, "Neural networks designed on approximate reasoning architecture and their applications," *IEEE Transactions on Neural Networks*, vol. 3, pp. 752-760, 1992.
- [198] L.-X. Wang and J. M. Mendel, "Fuzzy basis functions, universal approximation, and orthogonal least-squares learning," *IEEE Transactions on Neural Networks*, vol. 3, pp. 807-814, 1992.
- [199] J.-S. R. Jang, "ANFIS: adaptive-network-based fuzzy inference system," *IEEE Transactions on Systems, Man and Cybernetics*, vol. 23, pp. 665-685, 1993.
- [200] H. R. Berenji and P. Khedkar, "Learning and tuning fuzzy logic controllers through reinforcements," *IEEE Transactions on Neural Networks*, vol. 3, pp. 724-740, 1992.
- [201] S. Mitra and Y. Hayashi, "Neuro-fuzzy rule generation: survey in soft computing framework," *IEEE Transactions on Neural Networks*, vol. 11, pp. 748-768, 2000.
- [202] S. Mitra and S. K. Pal, "Fuzzy self-organization, inferencing, and rule generation," *IEEE Transactions on Systems, Man, and Cybernetics Part A: Systems and Humans*, vol. 26, pp. 608-620, 1996.

- [203] S. Mitra, "Fuzzy MLP based expert system for medical diagnosis," *Fuzzy Sets and Systems*, vol. 65, pp. 285-296, 1994.
- [204] J. M. Keller, R. Krishnapuram, and F. C.-H. Rhee, "Evidence aggregation networks for fuzzy logic inference," *IEEE Transactions on Neural Networks*, vol. 3, pp. 761-769, 1992.
- [205] Y. Hayashi, J. J. Buckley, and E. Czogala, "Fuzzy neural network with fuzzy signals and weights," *International Journal of Intelligent Systems*, vol. 8, pp. 527-537, 1993.
- [206] G. A. Carpenter, S. Grossberg, N. Markuzon, J. H. Reynolds, and D. B. Rosen, "Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps," *IEEE Transactions on Neural Networks*, vol. 3, pp. 698-713, 1992.
- [207] A. Ghosh, N. R. Pal, and S. K. Pal, "Self-organization for object extraction using a multilayer neural network and fuzziness measures," *IEEE Transactions on Fuzzy Systems*, vol. 1, pp. 54-58, 1993.
- [208] J. J. Buckley and Y. Hayashi, "Fuzzy neural networks: A survey," *Fuzzy Sets and Systems*, vol. 66, pp. 1-13, 1994.
- [209] H. Ishibuchi, K. Kwon, and H. Tanaka, "A learning algorithm of fuzzy neural networks with triangular fuzzy weights," *Fuzzy Sets and Systems*, vol. 71, pp. 277-293, 1995.
- [210] N. K. Kasabov and Q. Song, "DENFIS: Dynamic evolving neural-fuzzy inference system and its application for time-series prediction," *IEEE Transactions on Fuzzy Systems*, vol. 10, pp. 144-154, 2002.
- [211] Q. Song and N. Kasabov, "TWNFI - a transductive neuro-fuzzy inference system with weighted data normalization for personalized modeling," *Neural Networks*, vol. 19, pp. 1591-1596, 2006.
- [212] Q. Song and N. K. Kasabov, "NFI: A neuro-fuzzy inference method for transductive reasoning," *IEEE Transactions on Fuzzy Systems*, vol. 13, pp. 799-808, 2005.
- [213] C. J. Lin, C. H. Chen, and C. T. Lin, "Efficient self-evolving evolutionary learning for neurofuzzy inference systems," *IEEE Transactions on Fuzzy Systems*, vol. 16, pp. 1476-1490, 2008.
- [214] R. J. Oentaryo, M. Pasquier, and C. Quek, "GenSoFNN-Yager: A novel brain-inspired generic self-organizing neuro-fuzzy system realizing Yager inference," *Expert Systems with Applications*, vol. 35, pp. 1825-1840, 2008.
- [215] W. L. Tung and C. Quek, "eFSM - A novel online neural-fuzzy semantic memory model," *IEEE Transactions on Neural Networks*, vol. 21, pp. 136-157, 2010.
- [216] H. Ishibuchi, M. Nii, and T. Murata, "Linguistic rule extraction from neural networks and genetic-algorithm-based rule selection," in *IEEE International Conference on Neural Networks - Conference Proceedings*, Houston, TX, USA, 1997, pp. 2390-2395.
- [217] R. Xu and D. Wunsch II, "Survey of clustering algorithms," *IEEE Transactions on Neural Networks*, vol. 16, pp. 645-678, 2005.
- [218] M. Halkidi, Y. Batistakis, and M. Vazirgiannis, "On clustering validation techniques," *Journal of Intelligent Information Systems*, vol. 17, pp. 107-145, 2001.
- [219] M. S. Yang, "A survey of fuzzy clustering," *Mathematical and Computer Modelling*, vol. 18, pp. 1-16, 1993.
- [220] K. L. Petri, R. E. Billo, and B. Bidanda, "A Neural Network Process Model for Abrasive Flow Machining Operations," *Journal of Manufacturing Systems*, vol. 17, pp. 52-64, 1998.
- [221] H. C. Zhang and S. H. Huang, "Applications of neural networks in manufacturing: A state-of-the-art survey," *International Journal of Production Research*, vol. 33, pp. 705-728, 1995.
- [222] Z. J. Viharos, L. Monostori, and S. Markos, "Selection of input and output variables of ANN based modeling of cutting processes," *Proceedings of the X. Workshop on Supervising and Diagnostics of Machining Systems of CIRP*, vol. 26, p. 121, 1999.

- [223] G. Sathyanarayanan, I. J. Lin, and M.-K. Chen, "Neural network modelling and multiobjective optimization of creep feed grinding of superalloys," *International Journal of Production Research*, vol. 30, pp. 2421-2438, 1992.
- [224] W. Grzesik and S. Brol, "Hybrid approach to surface roughness evaluation in multistage machining processes," *Journal of Materials Processing Technology*, vol. 134, pp. 265-272, 2003.
- [225] Y. C. Shin and P. Vishnupad, "Neuro-fuzzy control of complex manufacturing processes," *International Journal of Production Research*, vol. 34, pp. 3291-3309, 1996.
- [226] R. J. Kuo and P. H. Cohen, "Manufacturing process control through integration of neural networks and fuzzy model," *Fuzzy Sets and Systems*, vol. 98, pp. 15-31, 1998.
- [227] Y. T. Chen and S. R. T. Kumara, "Fuzzy logic and neural networks for design of process parameters: A grinding process application," *International Journal of Production Research*, vol. 36, pp. 395-415, 1998.
- [228] K. Hashmi, M. A. El Baradie, and M. Ryan, "Fuzzy logic based intelligent selection of machining parameters," *Computers and Industrial Engineering*, vol. 35, pp. 571-574, 1998.
- [229] W. L. R. Ip, "A fuzzy basis material removal optimization strategy for sculptured surface machining using ball-nosed cutters," *International Journal of Production Research*, vol. 36, pp. 2553-2571, 1998.
- [230] Y. H. Lee, B. H. Yang, and K. S. Moon, "An economic machining process model using fuzzy non-linear programming and neural network," *International Journal of Production Research*, vol. 37, pp. 835-847, 1999.
- [231] R. G. Landers, A. G. Ulsoy, and Y. H. Ma, "A comparison of model-based machining force control approaches," *International Journal of Machine Tools and Manufacture*, vol. 44, pp. 733-748, 2004.
- [232] J. B. Kim, S. J. Lee, and Y. P. Park, "Stable and efficient drilling process by active control of the thrust force," *Mechanical Systems and Signal Processing*, vol. 8, pp. 585-595, 1994.
- [233] M. Elhachimi, S. Torbaty, and P. Joyot, "Mechanical modelling of high speed drilling. 1: Predicting torque and thrust," *International Journal of Machine Tools and Manufacture*, vol. 39, pp. 553-568, 1999.
- [234] M. Elhachimi, S. Torbaty, and P. Joyot, "Mechanical modelling of high speed drilling. 2: Predicted and experimental results," *International Journal of Machine Tools and Manufacture*, vol. 39, pp. 569-581, 1999.
- [235] R. J. Furness, T. C. Tsao, J. S. Rankin II, M. J. Muth, and K. W. Manes, "Torque control for a form tool drilling operation," *IEEE Transactions on Control Systems Technology*, vol. 7, pp. 22-30, 1999.
- [236] Y. T. Oh, G. D. Kim, and C. N. Chu, "Design of a Drilling Torque Controller for a Machining Center," *International Journal of Advanced Manufacturing Technology*, vol. 22, pp. 329-335, 2003.
- [237] R. Del Toro, M. Schmittziel, R. Haber-Guerra, and R. Haber-Haber, "System identification of the high performance drilling process for network-based control," in *Proc. of ASME IDETC 2007: 21st. Biennial Conference on Mechanical Vibration and Noise (VIB)* Las Vegas, NV, USA, 2007.
- [238] M. Pirtini and I. Lazoglu, "Forces and hole quality in drilling," *International Journal of Machine Tools and Manufacture*, vol. 45, pp. 1271-1281, 2005.
- [239] R. Haber-Haber, R. Haber, M. Schmittziel, and R. M. del Toro, "A classic solution for the control of a high-performance drilling process," *International Journal of Machine Tools and Manufacture*, vol. 47, pp. 2290-2297, 2007.
- [240] S. H. Yeo, L. P. Khoo, and S. S. Neo, "Tool condition monitoring using reflectance of chip surface and neural network," *Journal of Intelligent Manufacturing*, vol. 11, pp. 507-514, 2000.

- [241] Y. Zhang, Z. Zhang, and Z. Han, "Detection of tool breakage in turning operations using neural networks," *International Conference on Intelligent Manufacturing*, pp. 463-468, 1995.
- [242] M. S. Lan and D. A. Dornfeld, "In-process tool fracture detection," *Journal of Engineering Materials and Technology, Transactions of the ASME*, vol. 106, pp. 111-118, 1984.
- [243] J. Colgan, H. Chin, K. Danai, and S. R. Hayashi, "On-line tool breakage detection in turning: a multi-sensor method," *Journal of engineering for industry*, vol. 116, pp. 117-122, 1994.
- [244] T. Szecei, "DC motor based cutting tool condition monitoring system," *Journal of Materials Processing Technology*, vol. 92-93, pp. 350-354, 1999.
- [245] C. J. Li and S. Y. Li, "New sensor for real-time milling tool condition monitoring," *Journal of Dynamic Systems, Measurement and Control, Transactions of the ASME*, vol. 115, pp. 285-290, 1993.
- [246] E. N. Diei and D. A. Dornfeld, "Acoustic emission sensing of tool wear in face milling," *Journal of engineering for industry*, vol. 109, pp. 234-240, 1987.
- [247] S. Ramalingam and D. A. Frohrib, "Real-time condition sensing with a new class of sensor-transducer system," vol. 2, pp. 677-684, 1987.
- [248] G. Byrne, D. Dornfeld, I. Inasaki, G. Ketteler, W. Konig, and R. Teti, "Tool Condition Monitoring (TCM) - The Status of Research and Industrial Application," *CIRP Annals - Manufacturing Technology*, vol. 44, pp. 541-567, 1995.
- [249] E. Kannatey-Asibu Jr and D. A. Dornfeld, "Quantitative relationships for acoustic emission from orthogonal metal cutting," *Journal of engineering for industry*, vol. 103, pp. 330-340, 1981.
- [250] W. M. Sim, R. C. Dewes, and A. C. Aspinwal, "A knowledge-based system for the selection of cutting tools and data for high speed machining of moulds/dies," *Proceedings of the 33rd International Matador Conference*, pp. 119-125, 2000.
- [251] M. S. Crouse, R. D. Nowak, and R. G. Baraniuk, "Wavelet-based statistical signal processing using hidden Markov models," *IEEE Transactions on Signal Processing*, vol. 46, pp. 886-902, 1998.
- [252] T. Wang, C. Meng, and G. Zhao, "Research on intelligent monitoring technology of machining process," *International Conference on Intelligent Manufacturing*, pp. 333-337, 1995.
- [253] V. S. Sharma, S. K. Sharma, and A. K. Sharma, "An approach for condition monitoring of a turning tool," *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, vol. 221, pp. 635-646, 2007.
- [254] V. S. Sharma, S. K. Sharma, and A. K. Sharma, "Cutting tool wear estimation for turning," *Journal of Intelligent Manufacturing*, vol. 19, pp. 99-108, 2008.
- [255] M. L. Minsky, "Heuristic aspects of the artificial intelligence problem," Massachusetts Inst. of Tech. Lexington Lincoln Lab, 1956.
- [256] P. J. Antsaklis and K. M. Passino, *An introduction to intelligent and autonomous control*: Kluwer Academic Publishers Norwell, MA, USA, 1993.
- [257] L. A. Zadeh, "Soft computing, fuzzy logic and recognition technology," in *IEEE International Conference on Fuzzy Systems*, Anchorage, AK, USA, 1998, pp. 1678-1679.
- [258] P. P. Bonissone, Y. U. T. O. Chen, K. Goebel, and P. S. Khedkar, "Hybrid soft computing systems: Industrial and commercial applications," *Proceedings of the IEEE*, vol. 87, pp. 1641-1667, 1999.
- [259] N. K. Sinha and M. M. Gupta, *Soft Computing and Intelligent Systems: Theory and Applications*: Academic Press Series in Engineering, 2000.
- [260] B. Kosko, "Neural Networks and Fuzzy Systems - A Dynamical Systems Approach to Machine Intelligence," *Prentice Hall, Englewood Cliffs, XJ*, 1992.

- [261] A. Abraham, "Adaptation of Fuzzy Inference System Using Neural Learning, Fuzzy System Engineering: Theory and Practice," in *Studies in Fuzziness and Soft Computing*. vol. 3: Springer Verlag Germany, 2005, pp. 53-83.
- [262] L. Chin-Teng and C. S. G. Lee, *Neural fuzzy systems: a neuro-fuzzy synergism to intelligent systems*: Prentice-Hall, Inc., 1996.
- [263] R. Ruíz Limón, *Historia y evolución del pensamiento científico*, 2006.
- [264] M. A. Denai, F. Palis, and A. Zeghib, "Modeling and control of non-linear systems using soft computing techniques," *Applied Soft Computing Journal*, vol. 7, pp. 728-738, 2007.
- [265] V. Vapnik, *Statistical Learning Theory*. New York, USA: John Wiley & Sons, Inc., 1998.
- [266] L. J. Heyer, S. Kruglyak, and S. Yooseph, "Exploring expression data identification and analysis of coexpressed genes," *Genome Research*, vol. 9, pp. 1106-1115, 1999.
- [267] J. Sjöberg, Q. Zhang, L. Ljung, A. Benveniste, B. Delyon, P. Y. Glorennec, H. Hjalmarsson, and A. Juditsky, "Nonlinear black-box modeling in system identification: a unified overview," in *Automatica*. vol. 31, 1995, pp. 1691-1724.
- [268] T. Bohlin, "A Case-Study of Gray Box Identification," in *Automatica*. vol. 30, 1994, pp. 307-318.
- [269] F. C. Sun, Z. Q. Sun, and H. X. Li, "Stable adaptive controller design of robotic manipulators via neuro-fuzzy dynamic inversion," *Journal of Robotic Systems*, vol. 22, pp. 809-819, 2005.
- [270] C.-C. Hang and P. C. Parks, "Comparative studies of model reference adaptive control systems," *IEEE Transactions on Automatic Control*, vol. AC-18, pp. 419-428, 1973.
- [271] H. P. Whitaker, J. Yamron, and A. Kezer, *Design of model reference adaptive control systems for aircraft*: MIT., 1958.
- [272] I. D. Landau, "Model reference adaptive controllers and stochastic self-tuning regulators - A unified approach," *Journal of Dynamic Systems, Measurement and Control, Transactions of the ASME*, vol. 103, pp. 404-416, 1981.
- [273] A. M. Shahri, B. J. Evans, and F. Naghdy, "Neuro-fuzzy adaptive torque control of a SCARA robot," in *Proceedings of the Australian and New Zealand Conference on Intelligent Information Systems*, Adelaide, Aust, 1996, pp. 241-244.
- [274] X. J. Liu, F. Lara-Rosano, and C. W. Chan, "Model-reference adaptive control based on neurofuzzy networks," *IEEE Transactions on Systems, Man and Cybernetics Part C: Applications and Reviews*, vol. 34, pp. 302-309, 2004.
- [275] M. A. Henson, "Nonlinear model predictive control: Current status and future directions," *Computers and Chemical Engineering*, vol. 23, pp. 187-202, 1998.
- [276] J. M. Escaño, C. Bordons, M. R. García, C. Vilas, and A. A. Alonso, "Control Predictivo basado en Modelo Neuroborroso de un Autoclave Industrial," in *Jornadas de Automática*, 2007.
- [277] J. A. R. Hernández, D. A. S. Cerda, and E. Shelomov, "Control predictivo basado en un modelo neurodifuso auto-regresivo aplicado al proceso de arranque del generador de vapor de una unidad termoeléctrica," in *Revista Colombiana de Tecnologías Avanzadas*. vol. 2, 2004.
- [278] C. G. Economou, M. Morari, and B. O. Palsson, "Internal model control. Extension to nonlinear systems," *Industrial & Engineering Chemistry, Process Design and Development*, vol. 25, pp. 403-411, 1986.
- [279] R. Carotenuto, "Iterative system inversion technique," *International Journal of Adaptive Control and Signal Processing*, vol. 15, pp. 85-91, 2001.
- [280] Y. Altintas and M. Weck, "Chatter stability of metal cutting and grinding," *CIRP Annals - Manufacturing Technology*, vol. 53, pp. 619-642, 2004.
- [281] A. Rivero, G. Aramendi, S. Herranz, and L. N. L. De Lacalle, "An experimental investigation of the effect of coatings and cutting parameters on the dry drilling performance of aluminium alloys," *International Journal of Advanced Manufacturing Technology*, vol. 28, pp. 1-11, 2006.

- [282] A. Guasch, M. Piera, J. Casanovas, and J. Figueras, *Modelado y simulación. Aplicación a procesos logísticos de fabricación y servicios*: Edicions UPC, 2003.
- [283] L. N. López de Lacalle Marcaide, J. A. Sánchez Galíndez, and A. Lamikiz Menchaca, *Mecanizado de alto rendimiento. Procesos de arranque*: Ediciones Técnicas Ízaro, 2004.
- [284] F. W. Taylor, "On the art of metal cutting," *Transactions ASME*, vol. 28, 1901.
- [285] V. P. Astakhov, *Metal Cutting Mechanics*: CRC Press, 1999.
- [286] Y. g. Usachev, "Phenomena occurring during the cutting of metals," *Izv. Petrogradskogo Politechnicheskogo Inst.*, vol. 23, pp. 321-338, 1915.
- [287] H. Ernst and M. E. Merchant, "Chip formation, friction and high quality machined surfaces," *Surface Treatment of Metals*, vol. 29, pp. 299-378, 1941.
- [288] I. Mukherjee and P. K. Ray, "A review of optimization techniques in metal cutting processes," *Computers and Industrial Engineering*, vol. 50, pp. 15-34, 2006.
- [289] G. Byrne, D. Dornfeld, and B. Denkena, "Advancing cutting technology," *CIRP Annals - Manufacturing Technology*, vol. 52, pp. 483-507, 2003.
- [290] J. R. Alique, "Control Numérico," Barcelona: Boixareu-Marcombo, 1981.
- [291] S. Millán Gómez, *Procedimientos de Mecanizado*. Madrid: Editorial Paraninfo, 2006.
- [292] V. S. Sharma, M. Dogra, and N. M. Suri, "Advances in the turning process for productivity improvement - A review," *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, vol. 222, pp. 1417-1442, 2008.
- [293] J. F. G. Oliveira, F. Ferraz Jr, R. T. Coelho, and E. J. Silva, "Architecture for machining process and production monitoring based in open computer numerical control," *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, vol. 222, pp. 1605-1612, 2008.
- [294] J. Chae and S. S. Park, "High frequency bandwidth measurements of micro cutting forces," *International Journal of Machine Tools and Manufacture*, vol. 47, pp. 1433-1441, 2007.
- [295] I. S. Jawahir, A. K. Balaji, K. E. Rouch, and J. R. Baker, "Towards integration of hybrid models for optimized machining performance in intelligent manufacturing systems," *Journal of Materials Processing Technology*, vol. 139, pp. 488-498, 2003.
- [296] A. Davies, "Intelligent machine," *Manufacturing Engineer*, vol. 73, pp. 182-185, 1994.
- [297] M. Felser, "Real-time ethernet - Industry prospective," *Proceedings of the IEEE*, vol. 93, pp. 1118-1129, 2005.
- [298] K. C. Lee, S. Lee, and M. H. Lee, "Worst case communication delay of real-time industrial switched Ethernet with multiple levels," *IEEE Transactions on Industrial Electronics*, vol. 53, pp. 1669-1676, 2006.
- [299] A. Yiming and T. Eisaka, "Industrial hard real-time communication protocol over switched Ethernet," *WSEAS Transactions on Computers*, vol. 5, pp. 844-851, 2006.
- [300] H. Kleines, J. Sarkadi, F. Suxdorf, and K. Zwoell, "Measurement of real-time aspects of Simatic® PLC operation in the context of physics experiments," *IEEE Transactions on Nuclear Science*, vol. 51, pp. 489-494, 2004.
- [301] S. Vitturi, "Stochastic model of the profibus DP cycle time," *Iee Proceedings-Science Measurement and Technology*, vol. 151, pp. 335-342, Sep 2004.
- [302] K. Cantillo, R. E. Haber, J. E. Jiménez, A. Alique, and R. Galán, "CORBA-Based open platform for processes monitoring. An application to a complex electromechanical process," *Lecture Notes in Computer Science*, vol. 3036, pp. 523-526, 2004.
- [303] K. C. Lee, S. Lee, and M. H. Lee, "Remote fuzzy logic control of networked control system via profibus-DP," *IEEE Transactions on Industrial Electronics*, vol. 50, pp. 784-792, 2003.
- [304] R. Miller and E. Hill, *Non-destructive testing handbook*, 2000.
- [305] T. Moriwaki and K. Okushima, "Detection for Cutting Tool Fracture by Acoustic Emission Measurement," *CIRP Annals - Manufacturing Technology*, vol. 29, pp. 35-40, 1980.

- [306] X. Li, "A brief review: Acoustic emission method for tool wear monitoring during turning," *International Journal of Machine Tools and Manufacture*, vol. 42, pp. 157-165, 2002.
- [307] M. S. Selvam, "Tool vibration and its influence on surface roughness in turning," *Wear*, vol. 35, pp. 149-157, 1975.
- [308] S. B. Rao, "Tool wear monitoring through the dynamics of stable turning," *ASME Journal of engineering for industry*, vol. 108, pp. 183-190, 1986.
- [309] H. V. Ravindra, Y. G. Srinivasa, and R. Krishnamurthy, "Modelling of tool wear based on cutting forces in turning," *Wear*, vol. 169, pp. 25-32, 1993.
- [310] D. E. Dimla Snr, "Sensor signals for tool-wear monitoring in metal cutting operations - a review of methods," *International Journal of Machine Tools and Manufacture*, vol. 40, pp. 1073-1098, 2000.