

Universidad de Matanzas “Camilo Cienfuegos”
Facultad de Ingenierías Química y Mecánica
Departamento de Ingeniería Mecánica



Optimización Multiobjetivos del Proceso de Torneado

TESIS PRESENTADA EN OPCIÓN AL GRADO CIENTÍFICO DE

DOCTOR EN CIENCIAS TÉCNICAS.

Autor: Ing. Ramón Quiza Sardiñas

Tutor: Dr. Ing. Marcelino Rivas Santana

Matanzas, 2004.

AGRADECIMIENTOS

Al concluir este trabajo, quiero dejar constancia de mi más sincero agradecimiento a todas aquellas personas que han colaborado o ayudado en la realización del mismo, en especial a mi tutor Marcelino Rivas quien no sólo ha sido guía, sino también apoyo y soporte de toda la investigación.

Mi reconocimiento a Eleno Alfonso, Eduardo Torres, Félix Juan Domínguez, Agustín Benítez y Eduardo Vigil por haberse convertido en consejeros y fuentes de consulta constantes y desinteresadas durante todo el trabajo.

Agradezco a Julio César Álvarez y al personal del laboratorio de extensometría del CICMA por su inapreciable ayuda en la realización de los experimentos. A Danely Abreu y a Aracelis Milanés, por estar disponibles siempre para esas pequeñas tareas que parecen sin importancia pero que comprometen el éxito de un trabajo, y a Ronel Álvarez por tener siempre a mi disposición su computadora y su impresora

Por último, y no por ello menos importante, quiero hacer patente mi más profunda gratitud a toda mi familia por su ayuda y cariño, sin los cuales el trabajo hubiera sido demasiado ingrato y difícil.

Ramón Quiza

DECLARACIÓN DE AUTORIDAD

Declaro que soy el único autor de este trabajo, que pertenece íntegramente a la Facultad de Ingenierías Química y Mecánica de la Universidad de Matanzas. Autorizo su consulta a otras instituciones, a los profesionales, técnicos y personas en general que lo necesiten, siempre que se respete la procedencia del mismo, quedando prohibida la reproducción total o parcial de este documento, sin la autorización expresa de la Universidad de Matanzas.

Ramón Quiza Sardiñas.

RESUMEN

En el presente trabajo se propone un método de optimización multiobjetivos de regímenes de corte para el torneado, basado en técnicas de inteligencia artificial, en el cual se consideran, simultáneamente, dos objetivos mutuamente conflictivos: el tiempo de elaboración y el gasto de herramientas.

Para la modelación de la vida útil de la herramienta, las componentes de la fuerza de corte y la temperatura en la zona de corte, se ha desarrollado un modelo combinado, basado en el uso simultáneo de tres modelos independiente: una regresión estadística, una red neuronal de tipo perceptrón multicapas (MLP) y una red neuronal de funciones de base radial (RBF).

La optimización multiobjetivos se realiza a través del enfoque a posteriori, que permite obtener la frontera de Pareto para luego, a partir de ella, tomar las decisiones correspondientes. Para llevar a cabo la optimización, se ha implementado un algoritmo genético, al cual se le han realizado las adaptaciones correspondientes para adecuarse a las características del problema específico.

Se desarrolla un estudio de caso, tomado de una situación práctica real, para ilustrar y comprobar la validez tanto del modelo combinado como del método de optimización. Se lleva a cabo una valoración técnico-económica del régimen seleccionado, previa comparación con los valores obtenidos por los métodos convencionales.

TABLA DE CONTENIDOS

Introducción	1
Capítulo 1 - Fundamentación Teórica y Análisis Crítico de la Bibliografía	6
1.1 – Modelación de las variables que intervienen en el proceso de corte	6
1.1.1 – Consideraciones iniciales	6
1.1.2 – Modelación analítica	7
1.1.3 – Modelación mediante el método de elementos finitos	10
1.1.4 – Modelación empírica mediante estadística	13
1.1.5 – Modelación empírica mediante técnicas de inteligencia artificial	16
1.2 – Optimización del proceso de torneado	20
1.2.1 – Principios básicos de optimización del torneado	20
1.2.2 – Criterios de optimización	21
1.2.3 – Restricciones	24
1.2.4 – Métodos de optimización	26
1.3 – Algoritmos evolutivos para la optimización multiobjetivos	28
1.3.1 – Formulación general del problema de optimización multiobjetivos	28
1.3.2 – Características generales de los algoritmos evolutivos	30
1.3.3 – Algoritmos genéticos (AG's)	32
1.4 – Conclusiones parciales del Capítulo	33
Capítulo 2 – Propuesta para la Optimización Multiobjetivos del Torneado	35
2.1 – Modelo combinado para las variables del proceso	35
2.1.1 – Descripción general del modelo	35
2.1.2 – Diseño experimental	36
2.1.3 – Aproximador funcional basado en la regresión estadística	37
2.1.4 – Aproximador funcional basado en la red MLP	38
2.1.5 – Aproximador funcional basado en la red RBF	42
2.1.6 – Evaluación de la precisión de cada modelo y suma ponderada	43

2.2 – Metodología para la optimización multiobjetivos	44
2.2.1 – <i>Objetivos de optimización</i>	44
2.2.2 – <i>Datos del problema</i>	46
2.2.3 – <i>Variables de optimización</i>	47
2.2.4 – <i>Restricciones</i>	48
2.2.5 – <i>Esquema general de cálculo</i>	49
2.2.6 – <i>Implementación del algoritmo genético</i>	51
2.2.7 – <i>Resultados de la optimización y toma de decisiones</i>	60
2.3 – Conclusiones parciales del capítulo	61
Capítulo 3 – Estudio Experimental del Proceso de Corte	63
3.1 – Descripción de la instalación experimental	63
3.2 – Diseño experimental	67
3.3 – Análisis preliminar de los datos experimentales	68
3.4 - Conclusiones parciales del Capítulo	75
Capítulo 4 – Estudio de un Caso de Aplicación	76
4.1 – Planteamiento del caso de estudio	76
4.2 – Modelación de las variables que intervienen en el proceso	77
4.2.1 – <i>Modelación de la vida útil de la herramienta</i>	77
4.2.2 – <i>Modelación de la componente tangencial de la fuerza de corte</i>	80
4.2.3 – <i>Modelación de la componente axial de la fuerza de corte</i>	82
4.2.4 – <i>Modelación de la temperatura en la zona de corte</i>	85
4.3 – Selección de los datos	87
4.4 – Establecimiento de las restricciones	88
4.5 – Ejecución de la optimización	88
4.6 – Análisis de los resultados	90
4.7 – Análisis económico	92
4.8 – Conclusiones parciales del Capítulo	93

Conclusiones	95
Recomendaciones	96
Bibliografía	97
Anexos	115
Anexo 1 – Nomenclatura utilizada	115
Anexo 2 – Diagrama de bloques de un algoritmo genético simple	120
Anexo 3 – Deducción de las expresiones para el cálculo de la precisión y la ponderación de los modelos en un punto arbitrario	121
Anexo 4 – Características técnicas del portaplacas PTGNR 2525M	123
Anexo 5 – Características técnicas de la plaquita de TNMG 22 04 08-PM	124
Anexo 6 – Fotografías del equipamiento empleado	125
Anexo 7 – Ejemplo de datos de las mediciones de fuerzas y desplazamientos, y gráfico correspondiente.....	127
Anexo 8 – Calibración de los puentes de Wheatstone para la medición de las fuerzas de corte	128
Anexo 9 – Calibración del termopar natural para medición de la temperatura en la zona de corte.	132
Anexo 10 – Datos experimentales del desgaste de la herramienta (experimentos principales)	134
Anexo 11 – Datos experimentales del desgaste de la herramienta (experimentos de validación)	145
Anexo 12 – Datos experimentales del desgaste de la herramienta (experimentos de comprobación)	148
Anexo 13 – Datos experimentales de termo-FEM y valores de temperatura correspondientes	150
Anexo 14 – Modelo de regresión para la vida útil	152
Anexo 15 – Modelo de red neuronal MLP para la vida útil	153
Anexo 16 – Modelo de red neuronal RBF para la vida útil	157

Anexo 17 – Código del modelo combinado para la vida útil	161
Anexo 18 – Comparación de los modelos para la vida útil	163
Anexo 19 – Modelo de regresión para la fuerza de corte tangencial.....	166
Anexo 20 – Modelo de red MLP para la fuerza de corte tangencial	167
Anexo 21 – Modelo de red neuronal RBF para la fuerza de corte tangencial.....	171
Anexo 22 – Código del modelo combinado para la fuerza de corte tangencial	175
Anexo 23 – Comparación de los modelos para la fuerza de corte tangencial	177
Anexo 24 – Modelo de regresión para la fuerza de corte axial	180
Anexo 25 – Modelo de red MLP para la fuerza de corte axial	181
Anexo 26 – Modelo de red neuronal RBF para la fuerza de corte axial	185
Anexo 27 – Código del modelo combinado para la fuerza de corte axial	189
Anexo 28 – Comparación de los modelos para la fuerza de corte axial	191
Anexo 29 – Modelo de regresión para la temperatura.....	194
Anexo 30 – Modelo de red MLP para la temperatura	195
Anexo 31 – Modelo de red neuronal RBF para la temperatura	199
Anexo 32 – Código del modelo combinado para la temperatura.....	203
Anexo 33 – Comparación de los modelos para la temperatura	205
Anexo 34 – Análisis económico de la solución propuesta	208

INTRODUCCIÓN

La utilización racional de los recursos es una condición indispensable de cualquier proceso productivo que pretenda insertarse, con un mínimo de competitividad, en la economía contemporánea. En este sentido, los procesos de corte de metales, no son la excepción, sino la regla, dentro de la manufactura moderna.

Prácticamente desde sus orígenes, el estudio científico del maquinado se ha centrado en lograr procesos de arranque de virutas cada vez más eficientes, que requieran menores tiempos de elaboración y cuyos costos sean tan bajos como se pueda.

Al analizar la literatura especializada, se evidencia que en la práctica productiva existe la siguiente **situación problemática**: la selección de regímenes de corte se basa en el uso de tablas o manuales especializados, los cuales no ofrecen realmente parámetros óptimos sino sólo valores de tanteo [Dereli, Filiz y Baykasoglu, 2001], que no se adecuan siempre a las variadas condiciones de trabajo.

Por otro lado, las técnicas tradicionales de optimización de procesos de corte toman como función objetivo bien el tiempo de maquinado [Sönmez *et al.*, 1999], asumiendo que éste es proporcional al costo de producción; o bien el propio costo [Saravanan, Asokan y Vijayakumar, 2003; Zuperl y Cus, 2003], pero considerando sólo producciones en serie o masivas, en las cuales las máquinas herramientas están ocupadas todo el tiempo laboral. Como es sabido, este no es siempre el caso de los talleres de maquinado en la industria cubana (y, en general, en los países en vías de desarrollo), en la cual la fabricación se limita, muchas veces, a piezas de repuesto en pequeñas series o en producciones individuales. Naturalmente esto provoca que el tiempo de maquinado deje de jugar el papel determinante que le asignan en la mayor parte de la literatura especializada.

Otro factor que perjudica la selección de regímenes de corte adecuados, en la industria nacional, es que las recomendaciones de los fabricantes de herramientas de corte plantean que el gasto de herramientas es sólo una pequeña fracción del costo total de fabricación [Sandvik, 1994], lo cual es razonablemente cierto sólo si el trabajo de la máquina herramienta ocupa toda la jornada laboral, y si los salarios y el precio de la electricidad son altos, comparados con el precio de las herramientas de corte. En caso contrario el costo de las herramientas crece en importancia.

A todo lo anterior hay que sumarle que los modelos utilizados para relacionar variables como la vida útil de la herramienta y la fuerza de corte con los parámetros del régimen de corte, en la metodología de determinación de regímenes de corte (y, por tanto de su optimización), son, comúnmente, expresiones matemáticas sencillas, obtenidas a partir de regresiones estadísticas, como la Ley de Taylor y otras similares [Wilkins, 1999].

Sin embargo, en la actualidad, la introducción de nuevos tipos de materiales para las herramientas, tales como el nitruro de boro cúbico policristalino (PCBN), las cerámicas revestidas y los carburos de granulometría pequeña han hecho que la interpretación clásica de los mecanismos de desgaste deje de tener una validez absoluta [Dolinšek y Kopac, 1999; Poulachon, Moisan y Jawahir, 2001]. Además, en el corte de aceros endurecidos a altas velocidades, el incremento en la temperatura de la zona de corte, comúnmente excede al límite de estabilidad térmica del material de corte, causando una drástica reducción de la vida útil de la herramienta. Estas causas hacen que ecuaciones como las de Taylor no sean lo suficientemente versátiles para proporcionar resultados satisfactorios [Dolinšek, Šuštaršić y Kopac, 2001].

La situación anterior está provocada por la existencia del siguiente **problema científico**: los métodos actuales de optimización mono-objetivo del proceso de torneado, basados en

las técnicas tradicionales y en la modelación estadística de propiedades, no son los suficientemente eficaces y versátiles para garantizar una selección óptima de los regímenes de corte.

Para dar solución a este problema, se plantea la siguiente **hipótesis**: *la optimización multiobjetivos, basada en la estadística y las técnicas de inteligencia artificial permite seleccionar con precisión y flexibilidad los parámetros óptimos del régimen de corte en el proceso de torneado.*

Para validar la hipótesis anterior, como **objetivo general** del presente trabajo se propone: desarrollar un método de optimización multiobjetivos del proceso de torneado, utilizando estadística y técnicas de inteligencia artificial, y validarla mediante algunos estudios de casos.

En vista a cumplimentar el objetivo anterior, se han trazado las siguientes **tareas**:

1. Llevar a cabo un análisis bibliográfico que permita conocer el estado actual de los conocimientos científicos sobre las siguientes temáticas:
 - Modelos utilizados para relacionar las variables del proceso de torneado (vida útil de la herramienta, componentes de la fuerza y temperatura en la zona de corte), con los parámetros del régimen de corte (profundidad, avance y velocidad de corte).
 - Técnicas y metodologías empleadas en la optimización de regímenes de corte en el torneado.
 - Técnicas empleadas en la optimización multiobjetivos, destacando los algoritmos evolutivos.

2. Desarrollo de un modelo combinado, basado en el uso de la regresión estadística y las redes neuronales artificiales, que permita relacionar las variables del proceso de torneado con los parámetros del régimen de corte.
3. Desarrollo de un método de optimización multiobjetivos, basado en algoritmos genéticos, para la optimización del proceso de torneado, que incluya el uso de los modelos combinados citados.
4. Estudio experimental de un proceso de corte concreto para establecer los modelos combinados de las variables necesarias, para desarrollar un caso de estudio de optimización. Dicho estudio incluye:
 - Diseño de la experimentación para obtener los datos necesarios.
 - Obtención de dichos datos mediante la realización de los experimentos correspondientes.
 - Calibración de los instrumentos de medición empleados.
 - Comprobación de la no existencia de valores extraño entre los datos.
5. Estudio de caso para validar el método anterior, utilizando los modelos combinados obtenidos previamente, y que incluya:
 - Definición y planteamiento del caso estudiado.
 - Ajuste del modelo combinado para las variables consideradas, comparando su precisión con la de los modelos independientes.
 - Establecimiento de las funciones objetivos y restricciones correspondientes al caso concreto.
 - Ejecución del proceso de optimización.
 - Análisis de los resultados correspondientes.

La tesis presenta los siguientes aspectos novedosos:

- Propuesta de un modelo, basado en regresión estadística y redes neuronales, para la correlación del desgaste, la fuerza de corte y otras variables, con los parámetros del régimen de corte, en los procesos de torneado.
- Desarrollo de una metodología de optimización multiobjetivos *a posteriori*, basada en algoritmos genéticos, para la obtención de regímenes de corte óptimos en el torneado.
- La utilización de representaciones gráficas de la frontera de Pareto para la selección de los regímenes de corte más adecuados, en dependencia de situaciones concretas de la práctica industrial.

CAPÍTULO 1

Fundamentación Teórica y Análisis Crítico de la Bibliografía

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

1.1 – Modelación de las variables que intervienen en el proceso de corte.

1.1.1 – Consideraciones iniciales.

En el torneado, al igual que en cualquier proceso de elaboración por arranque de virutas, intervienen un grupo considerable de variables. Uno de los objetivos básicos de todo estudio del maquinado, consiste en establecer las relaciones adecuadas entre estas variables, o sea, determinar el modelo que las describa.

Dentro de la diversidad de modelos existentes [Martínez, 1986], los empleados para la optimización son los modelos numéricos o matemáticos, que relaciona entre sí los valores cuantitativos de las variables. Dentro de estos modelos matemáticos, son especialmente importantes en el proceso de corte los modelos analíticos o teóricos (dentro de los cuales cabe destacar a los basados en análisis por elementos finitos) y los modelos empíricos, ya sean basados en regresiones estadísticas y o en técnicas de inteligencia artificial.

Dentro de todas las variables, hay varias cuya correcta modelación es imprescindible para la optimización de regímenes de corte, entre ellas se destacan la vida útil de la herramienta, la fuerza de corte (especialmente sus componentes tangencial y axial) y la

temperatura en la zona de corte. Estas variables deben ser modeladas en función de los parámetros del régimen de corte, o sea, de la profundidad, el avance y la velocidad de corte.

La importancia de la modelación de estas variables está dada por el papel que juegan en el proceso de torneado. El desgaste es uno de los parámetros más importante dentro del maquinado, que no sólo afecta la calidad superficial y dimensional de las piezas elaboradas [Liew, Ngoi y Lu, 2003], sino que también aumenta la fuerza de corte [Poulachon, Moisan y Jawahir, 2001]. Este incremento de la fuerza, a su vez, provoca inestabilidad en el movimiento de la herramienta y, por consiguiente, mayores inexactitudes en la fabricación [Zhou *et al.*, 2003].

La fuerza de corte también tiene una importancia extraordinaria en el torneado, ya que además de actuar como una limitante del proceso, tiene una influencia directa sobre la potencia de corte y las vibraciones del sistema, influyendo notablemente sobre la calidad de la pieza elaborada [Stein y Huh, 2002].

1.1.2 – Modelación analítica.

La modelación analítica (también llamada teórica o fenomenológica) es la que refleja con más exactitud la realidad, porque no sólo establece la relación cuantitativa entre las diversas variables, sino que también determina las relaciones causales entre ellas. Desafortunadamente, los fenómenos que intervienen en el proceso de corte son demasiado complejos, por lo que, para desarrollar modelos teóricos, hay que establecer ciertas simplificaciones que limitan seriamente su validez práctica [Kumar y Kumar, 2000].

Los modelos teóricos generales del corte ortogonal, entre los que cabe señalar el modelo de tarjetas de Piispanen y el de Merchant, entre otros, aunque han aportado mucho al entendimiento de los fenómenos del proceso de corte, no ofrecen resultados cuantitativos aceptables [Shaw, 1984].

Por su importancia, un gran número de modelos teóricos han sido propuestos para relacionar el desgaste con otros factores del proceso de corte, pero ninguno ha logrado un uso significativo [Dan y Mathew, 1990]. Entre los más recientes están el de d'Errico [1997] que modela la temperatura en la zona de corte, con respecto a la velocidad de corte, incorporando la influencia del desgaste de la herramienta en el aumento de la temperatura como parte de la sensibilidad global de los parámetros del modelo; el de Molinari y Nouari [2002] que modela el desgaste por difusión a altas temperaturas; y el de Zhao, Barber y Zou, [2002] que incluye el efecto de la tensión normal y la influencia de la temperatura sobre el desgaste de flanco en el corte ortogonal.

Un modelo muy interesante es el propuesto por Galante, Lombardo y Passannanti [1998], que considera el comportamiento de desgaste de la herramienta de corte como un proceso estocástico con incrementos gaussianos independientes con tendencia. El modelo considera que la vida útil de la herramienta tiene una distribución de probabilidad gaussiana inversa; permite relacionar la vida útil con los parámetros del régimen de corte, mostrando buen ajuste a los datos experimentales en diferentes condiciones de trabajo. Debe destacarse que la ecuación de Taylor puede ser considerada como una aproximación de primer orden de este modelo.

Li, Ng y Lim [1999] utilizan un modelo teórico para predecir los niveles de desgaste para diferentes condiciones de corte. A pesar de que la tendencia de los resultados del modelo

muestran la misma tendencia que los datos experimentales, los propios autores señalan que aún se requiere un refinamiento del mismo para lograr predicciones aceptables.

Para la modelación del desgaste en herramientas con rompevirutas complejos (como los utilizados en la industria moderna), Jawahir y colaboradores [2000] proponen un método basado en la superficie equivalente. A pesar de su indudable valor teórico, este modelo, tal como se señala en las conclusiones del propio trabajo, aún requiere de desarrollos futuros para ofrecer resultados adecuados.

Un modelo de contacto entre la herramienta y la viruta que considera la distribución de tensiones cortantes en la zona secundaria de deformación ha sido propuesto por Qi y Mills [2003]. El mismo tiene en cuenta los fenómenos de las capas tribológicas (*tribo-layers*) de diferente naturaleza, tales como las capas de inclusiones en la pieza elaborada, las capas de óxidos formadas como consecuencia de reacciones químicas, las capas de deformación plástica y las capas de transferencia de material. Aunque el artículo apunta que el modelo puede mejorar la predicción del desgaste y la vida útil, aún requiere de desarrollo en este sentido.

Otro modelo reportado recientemente en la literatura es el de Moufki y colaboradores [2004], para procesos de corte oblicuo que permite predecir las fuerzas de corte, la dirección de formación de la viruta, la longitud de contacto entre la viruta y la herramienta y la distribución de temperaturas en la superficie de contacto entre la herramienta y la viruta. Aunque el análisis se limita al estado estacionario, la comparación de sus resultados con los datos experimentales es aceptablemente buena.

Por su parte, la modelación de la fuerza de corte, desde el punto de vista teórico, se ha basado en los modelos de Merchant, y de Lee y Shafter [Shaw, 1984] y en la teoría del

campo de líneas de desplazamiento de Oxley [1981]. Dado que estos modelos no tienen en cuenta una gran cantidad de factores, los resultados obtenidos no son completamente satisfactorios desde el punto de vista cuantitativo.

Para tomar en consideración el efecto de las propiedades térmicas del material de la herramienta, Huang y Liang [2003] han propuesto un modelo basado en la teoría predictiva del maquinado. La complejidad del modelo es relativamente alta, y los resultados ofrecidos por el mismo, demasiado imprecisos para justificar su aplicación práctica.

Teniendo en cuenta lo anteriormente expuesto, el autor de esta tesis considera que, a pesar de su extraordinario aporte a la comprensión de los fenómenos de los procesos de corte, los modelos teóricos, en su estado actual, no ofrecen resultados cuantitativos lo suficientemente precisos. Algunos modelos modernos ofrecen resultados más precisos, pero requieren ciertos datos o coeficientes que sólo pueden ser determinados en la práctica, por lo cual no eliminan la necesidad de estudios experimentales.

1.1.3 – Modelación mediante el método de elementos finitos.

Dentro de los modelos analíticos, se encuentran aquellos cuyo planteamiento se resuelve numéricamente, destacándose los que emplean el método de los elementos finitos (*finite elements méthos*, FEM). Dicho método se ha convertido, en los últimos tiempos en una popular herramienta para las más diversas ramas del análisis mecánico. Su principal ventaja es su bajo costo, si se compara con el resto de las técnicas que dependen de datos experimentales [Mackerle, 2003].

Entre los estudios que abarcan todo el proceso de torneado se encuentran el de Lin y Yarnng [1997] que utiliza la teoría de elementos finitos para grandes deformaciones y la formulación lagrangiana actualizada, para desarrollar un modelo analítico elasto-plástico, tridimensional, que examina el corte de metal en la punta de la cuchilla.

Ceretti y colaboradores [2000] han modelado la fuerza de corte en el proceso de torneado, ortogonal y tridimensional, comparando sus resultados con datos experimentales. El-Gallab y Sklad [2000] presentan un modelo robusto tridimensional de análisis por elementos finitos de la herramienta de corte, el cual es aplicado al maquinado de material compuesto de matriz metálica y partículas Al/SiC. El modelo incluye el desgaste de cráter, la picadura y la astilladura del filo. Los valores de temperatura, tensiones y desgaste predichos por el modelo, coinciden con los resultados experimentales.

Para evaluar la maquinabilidad de la superaleación de base níquel Inconel 718, con herramientas de carburos metálicos con y sin revestimiento, MacGinley y Monaghan [2001] emplean un análisis por elementos finitos. El desgaste y la distribución de tensiones obtenidas como resultados del modelo concuerdan favorablemente con los datos experimentales.

Shatla, Kerk y Altan [2001] proponen un modelo basado en análisis por elementos finitos para predecir variables del proceso en el corte de metales. El modelo emplea los datos del flujo de desplazamiento determinado por los autores en un trabajo anterior. La mayoría de los resultados predichos están en razonable concordancia con los datos experimentales.

La aplicación de algunos programas específicos, diseñados especialmente para FEA en el maquinado, ha permitido lograr resultados bastante satisfactorios. Una simulación llevada a cabo con el paquete *AdvantEdge*, de *Third Wave Systems* [Marusich, Thiele, y Brand, 2001], ha modelado la fuerza de corte con un error máximo de 10 %, en el torneado de acero AISI 4130.

Un interesante trabajo desarrollado por Yen y colaboradores [2004] no sólo muestra resultados aceptables por su similitud con los datos experimentales, sino también propone modificaciones a los programas comerciales de FEA para maquinado, con el objetivo de mejorar su eficacia en la predicción del desgaste.

También la influencia de los cortes previos sobre la formación de la viruta y las tensiones residuales superficiales ha sido estudiada [Kalhori, 2001], aunque los resultados de la modelación aún tienen ciertas inexactitudes.

Ren y colaboradores [2004] emplean el método de elementos finitos para modelar la temperatura en la zona de corte, en el torneado de aceros con alto contenido de cromo, endurecidos, con herramientas de PCBN.

Recientemente, Bil, Kiliç y Tekkaya [2004] han comparado los resultados de tres modelos diferentes basados en FEA, con datos experimentales. A pesar de lograr éxitos en la predicción de determinadas variables en específico, ninguno de los tres modelos mostró ser capaz de predecir correctamente todos los parámetros implicados en el proceso. Según criterio de los propios autores del trabajo, esto puede deberse a una pobre modelación de la separación en la formación de la viruta.

Aunque los modelos basados en FEA, aún tienen limitaciones en cuanto a la exactitud de sus predicciones, es opinión del autor de esta tesis, que éste es un buen enfoque para el estudio de los procesos de corte. La principal dificultad, de su aplicación a los métodos de optimización es la lentitud de procesamiento de este modelo, provocada por la necesidad de resolver grandes sistemas de matrices.

1.1.4 – Modelación empírica mediante estadística.

Otro enfoque al problema de la modelación, es la obtención de relaciones empíricas, las cuales prescinden de una explicación causal de los fenómenos y se limitan a ofrecer un aproximador funcional que relacione ciertos datos obtenidos experimentalmente. Este ha sido el enfoque que ha predominado en la modelación de los procesos de corte de metales.

La primera correlación satisfactoria para modelar el desgaste de la herramienta de corte fue la ecuación de Taylor [1907]:

$$VT^a = C_T, \quad (1.1)$$

que relaciona la vida útil de la herramienta, T , con la velocidad de corte, V , utilizada en el proceso. C_T es una constante que depende del material elaborado y otras condiciones de corte; y a , un coeficiente que depende del material de corte.

Posteriormente, a la Ley de Taylor se le agregaron varios términos para tener en cuenta el avance y la profundidad de corte, obteniéndose la llamada Ley de Taylor Generalizada [Altan *et al.*, 1998]:

$$T \cdot V^{1/a} \cdot f^{1/b} \cdot a_p^{1/g} = C_T, \quad (1.2)$$

en la cual f es el avance; a_p , la profundidad de corte; y a , b y g coeficientes que dependen del material de corte, la geometría de la herramienta y otros factores del proceso concreto, con la particularidad que [Shaw, 1984]:

$$a < b < g. \quad (1.2a)$$

A pesar de su sencillez, la Ley de Taylor Generalizada, ofrece resultados aceptables para materiales de corte y condiciones de maquinado tradicionales, y continúa utilizándose hasta hoy en día [Liu *et al.*, 2002; Davin, 2003; Lin, Bahttacharyya y Kecman, 2003; Oraby y Hayhurst; 2004].

Para considerar la influencia de otros factores, se han sugerido modificaciones adicionales a la expresión de Taylor. Tal es el caso de la propuesta por Poulachon, Moisan y Jawahir [2001] que toma en cuenta la dureza del material elaborado.

Wong, Kim y Kwon [2004] proponen un conjunto de expresiones para describir el desgaste tanto de flanco como de cráter, en aceros perlíticos. Las expresiones son deducidas a partir de datos experimentales obtenidos para otros materiales y que son generalizadas para el material considerado. El modelo muestra buenos resultados, pero para velocidades de corte altas las transformaciones de fase que ocurren en el material elaborado limitan su aplicabilidad.

Recientemente, Chou [2003] ha hecho un estudio experimental sobre la influencia de la microestructura del acero, sobre el desgaste en el torneado pesado. Lamentablemente, los resultados los ofrece en forma de gráficos, sin presentar modelos matemáticos.

Para la modelación de la fuerza de corte se han introducido expresiones similares a la de Taylor, como la siguiente [Arshinov y Alekseev, 1979]:

$$F_i = C_{Fi} V^{a_F} f^{b_F} a_p^{g_F} K_{Fi}, \quad (1.3)$$

donde F_i es la i -ésima componente de la fuerza de corte; C_F , una constante que depende del material elaborado; a_F , b_F y g_F , exponentes que dependen del tipo de maquinado y del material de corte; y K_{Fi} , un factor de corrección que tiene en cuenta las condiciones específicas de elaboración. Una modificación de la expresión anterior [Szecsi, 1999] tiene en cuenta la influencia de la profundidad de corte y el avance sobre los exponentes de la ecuación:

$$F_i = C_{Fi} a_p^{m + \frac{n}{2} \ln\left(\frac{a}{f}\right)} f^{m + \frac{n}{2} \ln\left(\frac{f}{a}\right)} K_{Fi}, \quad (1.3)$$

en la cual m y n son coeficientes que dependen de las condiciones concretas de maquinado.

Algunos autores [Jae-Wong y Min-Yang, 2001; Chen, Chou y Li, 2002] emplean una expresión simplificada para la componente tangencial de la fuerza de corte, en la forma:

$$F_C = a_p f k_s, \quad (1.4a)$$

donde k_s es la fuerza específica de corte, constante para cada material.

Sandvik [1994], también emplea la expresión anterior, pero introduce una modificación para tener en cuenta la influencia del espesor medio de la viruta, h_M , resultando:

$$F_C = a_p f k_s \left(\frac{0,4}{h_M} \right)^{0.29}, \quad (1.4b)$$

Armarego, Verezub y Samaranayake [2002] han estudiado, experimentalmente, el efecto del revestimiento de TiN y de TiCN sobre la fuerza de corte, en herramientas de acero de

corte rápido y de carburos cementados. Aunque se obtuvieron resultados interesantes, estos tienen la forma de gráficos y conclusiones cualitativas más que de modelos cuantitativos propiamente dichos.

Modelos estadísticos del tipo de la Ley de Taylor se emplean, también, para modelar otros parámetros como la temperatura en la zona de corte [Arshinov y Alekseev, 1979; Liu *et al.*, 2002], con resultados aceptables.

En atención a todo lo anterior, el autor considera que el inconveniente fundamental de los estudios experimentales es que no ofrecen, prácticamente, ninguna información sobre los mecanismos físicos del proceso. Esto impide generalizar los resultados obtenidos fuera del rango experimental estudiado. Por otro lado, a veces resulta muy difícil anular la influencia de los factores no estudiados, lo cual puede resultar en conclusiones falseadas. A pesar de lo anterior, estos modelos han sido aplicados por años a la práctica industrial con resultados aceptables.

1.1.5 – Modelación empírica mediante técnicas de inteligencia artificial.

La aparición, en los últimos años, de un grupo de materiales de corte, entre los que se incluyen las cerámicas revestidas, los nitruros de boro cúbico policristalinos (PCBN) y los carburos de granulometría pequeña, han modificado la esencia misma de los procesos de corte. Mientras en el corte a bajas velocidades (correspondientes al rango de trabajo de las herramientas de materiales tradicionales) los mecanismos de desgaste son básicamente abrasivos [Oliveira, Silva y Vieira, 2003; Devillez, Lesko y Mozerc, 2004], a las altas velocidades de corte en que pueden operar los nuevos materiales, los mecanismos químicos (oxidación y difusión) juegan un papel preponderante [Zeng, Zhang y Tang, 2001; Vleugels, Hari y Van der Biest, 2001].

Por otro lado, en el maquinado a altas velocidades, la temperatura en la zona de corte se incrementa significativamente, llegando a sobrepasar el límite de estabilidad térmica del material de corte [Poulachon, Moisar y Jawahir, 2001]. Este hecho trae como consecuencia una drástica reducción de la vida útil de la herramienta. Un fenómeno similar tiene lugar con el aumento del avance y la profundidad de corte, que también provocan un incremento en la generación de calor y, por tanto, en la temperatura de la zona de corte.

Es importante señalar que la consideración de una velocidad de corte como alta, depende notablemente del material elaborado. Así, por ejemplo, una velocidad de 250 m/min se considera alta en el maquinado de aleaciones de níquel, mientras que para el aluminio es una velocidad convencional y para los aceros más comunes corresponde al rango de transición [Fallböhmer *et al.*, 2002].

La notoria no linealidad de los fenómenos involucrados en el proceso de corte, hace que las expresiones lineales (o potenciales) del tipo de la Ley de Taylor no sean lo suficientemente versátiles para describir el desgaste a altas velocidades y con materiales de corte novedosos [Dolinšek, Šuštaršic, y Kopac, 2001]. En este sentido, el empleo de técnicas de inteligencia artificial (IA) como aproximadores funcionales para la modelación de propiedades, constituye una variante válida de los modelos empíricos recién examinados.

Probablemente la técnica más popular y más estudiada dentro de la IA, la constituyan las redes neuronales artificiales (RNA's). Estas son estructuras adaptativas de tratamiento de información, inspiradas en la estructura cerebral, donde el procesamiento se lleva a cabo mediante la interconexión de elementos de proceso muy sencillos, denominados nodos o neuronas [Muñoz, 1996].

Algunas arquitecturas de RNA's, son capaces de aproximar una función arbitraria con cualquier grado de precisión [Ibnkahla, 2001; Bullinaria, 2003]. Entre las que más se emplean para este fin, están el perceptrón multicapas (*multi-layer perceptron*, MLP) y la red de función de base radial (*radial basis function networks*, RBF) [Muñoz, 1996].

Las RNA's tienen una amplia aplicación en el monitoreo o la predicción del desgaste [Sick, 2002; Li, 2002] y de la fuerza de corte [Szecsi, 1999], pero mayormente dirigidos a la estimación de parámetros en tiempo real.

Para la predicción del desgaste, se han propuesto varios aproximadores funcionales basados en RNA's. Algunos [Ezugwu, Arthur y Hines, 1995; Li y Nee, 1996; Chao y Hwang, 1997; Chien y Tsai, 2003] predicen la vida útil de la herramienta a partir de los parámetros del régimen de corte, a través de redes de tipo MLP. Otra variante que también se ha empleado consiste pronosticar el desgaste para un instante, a través de redes de tipo MLP [Niranjan y Ramamoorthy, 2001] o RBF [Elanayar y Shin, 1995].

La principal desventaja de los trabajos anteriores es que no realizan una comparación con técnicas estadísticas convencionales. Tampoco se cumple con los requerimientos especificados para el análisis estadístico de los resultados [Flexer, 1996; Dossier y Hence, 2004]. A esto hay que agregarle que la precisión que muestran estos modelos, no es mayor que la usual entre las regresiones estadísticas.

Lin, Bahttacharyya y Kecman [2003] comparan el comportamiento de una red neuronal con el de una regresión estadística, en el modelado del desgaste en el maquinado de materiales compuestos, llegando a la interesante conclusión de que la regresión ofrece mejores resultados. Debe notarse que en el mismo trabajo se señala el carácter predominantemente abrasivo del desgaste en el maquinado de materiales compuestos.

También para el modelado de la fuerza de corte se han empleado las RNA's, pero en una escala notablemente inferior al desgaste. También en este caso, el uso de RNA's está dirigido hacia el monitoreo de la fuerza de corte [Stein y Huh, 2002] en mucho mayor grado que a la modelación.

De los modelos presentados cabe señalar el de Shiraish y Aoshima [1997], aunque éste es más un sistema de medición que un aproximador funcional propiamente dicho. Szecsi [1999] propone el uso de una red neuronal artificial para relacionar las componentes de la fuerza de corte no sólo con la velocidad de corte, el avance, la profundidad, sino también con otros factores como la dureza del material maquinado, y la geometría de la cuchilla. La principal dificultad del modelo radica en la cantidad, excesivamente grande de datos de entrenamiento que requiere.

También Raj y sus colaboradores [2000] utilizan una red neuronal artificial para correlacionar las fuerzas de corte con los parámetros del régimen de corte. El modelo muestra un buen ajuste con los datos experimentales.

Aunque en menor escala, también otras técnicas de IA son usadas en la modelación de variables en el proceso de corte. Entre las más utilizadas, cabe señalar los sistemas borrosos de inferencia (solos o combinados con RNA's) [Li, Djordjevich y Venuvinod, 2000; Haber *et al.*, 2003], los sistemas expertos [Silva *et al.*, 2000] y los algoritmos genéticos [Suresh, Venkateswara y Deshmukh, 2002]. Sin embargo el uso de estos sistemas ha estado encaminado, casi exclusivamente al monitoreo de señales y muy poco al pronóstico sin sensores.

La principal desventaja de las técnicas de inteligencia artificial es la alta capacidad de cómputo que demandan [Benardos y Vosniakos, 2003]. Este inconveniente, sin embargo,

cada vez se hace menos significativo debido al progresivo aumento de la potencia de los ordenadores que tiene lugar desde hace unos años hasta la fecha.

1.2 – Optimización del proceso de torneado.

1.2.1 – Principios básicos de optimización del torneado.

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

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

Evidentemente, los niveles 2 y 3 requieren de un esfuerzo y una inversión normalmente grande, por lo que el trabajo del tecnólogo comúnmente se limita al nivel 1, o sea, a la determinación de los parámetros óptimos dentro de un proceso establecido.

En el torneado, como en el resto del mecanizado, los parámetros principales que controlan el proceso, son las variables del régimen de corte: profundidad, avance y revoluciones del husillo. Por tanto, la optimización del mismo se basa en la selección de un régimen de corte que maximice o minimice (según corresponda) uno o varios criterios determinados.

Dada la que la complejidad del proceso de corte, las tareas de optimización se hacen bien difíciles [Kumar y Kumar, 2000]. Además, existen otras causas que afectan el éxito de la optimización del torneado [Sönmez *et al.*, 1999], entre las que se encuentran: la necesidad de contar con modelos para las variables del proceso (la vida útil de la

herramienta, la fuerza de corte, etc.), que permitan establecer relaciones y restricciones cercanas a la realidad; la complejidad de las características de la máquina y de la herramienta de corte, que muchas veces incluyen variables cualitativas o discontinuas; la dificultad en la selección de un criterio efectivo de optimización; y las limitaciones de las técnicas de optimización matemáticas y numéricas.

Todo lo anterior ha provocado que el desarrollo de los métodos de optimización del torneado (y del maquinado, en general), a pesar de la cantidad de investigaciones que le han sido dedicadas, haya sido sorprendentemente lento [Wang *et al.*, 2002].

1.2.2 – Criterios de optimización.

La selección del criterio de optimización (o sea, de la función objetivo a optimizar), es, quizás, el punto más importante en cualquier estudio sobre el tema. Tradicionalmente, el criterio utilizado, se ha basado en el costo de la producción. En este sentido se enfocan desde el primer trabajo conocido sobre optimización [Taylor, 1907], hasta investigaciones muy recientes [Liang, Mgwatu y Zuo, 2001; Wang *et al.*, 2002; Saravanamn, Asokan y Vijayakumar, 2003; Cus y Balic, 2003].

La expresión de costo utilizada varía ligeramente de un autor a otro. Shaw [1984] considera el costo por pieza (Z) como la suma de tres costos básicos: costo directo de la máquina y el trabajo (Z_0), el costo por cambio de la herramienta (Z_{CH}) y el costo de herramienta (Z_T) para cada pieza:

$$Z = Z_0 + Z_{CH} + Z_T = z_0 t + z_0 t_{CH} \frac{t}{T} + z_T \frac{t}{T}, \quad (1.5)$$

donde z_0 es el costo de máquina y salario por unidad de tiempo; z_T el costo de cada filo de la herramienta, t el tiempo de maquinado y t_{CH} el tiempo invertido en el cambio de la

herramienta. Esta misma expresión utilizan Kayakan *et al.* [1996]; Meng, Arsecularatne y Mathew [2000]; Amiolemhen y Ibadode [2004] y Saravanan, Asokan y Vijayakumar [2003], aunque estos últimos introducen una pequeña modificación sin trascendencia.

Bhaskara Reddy, Shunmugam y Narendran [1998] minimizan el costo total de elaboración, en operaciones de pasadas múltiples, mediante la minimización del costo de cada pasada.

La principal limitante de esta expresión es que considera que el tiempo de trabajo de la máquina es igual al tiempo de maquinado, lo cual es cierto sólo para operaciones de una pasada. Para solucionar esta dificultad, Wang *et al.* [2002] diferencian entre el tiempo de maquinado (t) y tiempo de trabajo de la máquina (t'), resultado la expresión:

$$Z = z_0 \left(t_{PC} + t' + t_{CH} \frac{t}{T} \right) + z_T \frac{t}{T}, \quad (1.6)$$

donde t_{PC} es el tiempo preparativo y conclusivo.

Si bien la efectividad de este criterio, desde el punto de vista económico es indiscutible, el enfoque que se le da en la literatura consultada, no es completamente satisfactorio, según criterio del autor de esta tesis. Esto se debe a que las expresiones para el cálculo del costo de cada pieza elaborada, están deducidas considerando un flujo continuo en la producción, lo cual no siempre corresponde a la práctica industrial real.

Otro criterio de optimización que comúnmente se utiliza, es el tiempo de elaboración [Chua *et al.*, 1991; Ahmad y Anwarul, 2001; Quiza y Rivas, 2003], que se basa en el presupuesto de que el costo de herramienta es despreciable frente al monto total [Sandvik, 1994]. El tiempo de elaboración se asume igual o proporcional al tiempo de maquinado:

$$t = \frac{L + L' + L''}{f \cdot n}, \quad (1.7)$$

donde L es la longitud a elaborar; L' y L'' la distancia recorrida por la herramienta en la entrada y la salida del corte, respectivamente; f , el avance; y n , la velocidad de rotación del husillo. Como se puede apreciar, la expresión anterior desprecia el tiempo de cambio de la herramienta, y el de trabajo en vacío.

Algunas veces, se emplea como función objetivo la cantidad de metal cortado por unidad de tiempo (*material removal rate*), que no es más que otra forma de considerar el tiempo de elaboración. Entre los trabajos que utilizan este criterio están el de Chien y Tsai [2003] y el de Ko y Kim [1998].

Además, si bien la consideración de que el costo de herramienta es despreciable, está justificado en las condiciones de la industria de los países industrializados, para los países en vías de desarrollo el autor considera que deja de tener validez absoluta [Quiza y Rivas, 2004].

Algunos autores ofrecen modelos que permiten considerar varios objetivos, aunque no de forma simultánea. En este grupo se encuentran el de Cakir y Gurarda [1998] y el de Lee y Tarng [2000] que posibilitan la optimización bien del costo de producción o bien de la cantidad de metal cortado producción.

Una solución a la sobrevaloración de uno de los criterios de optimización es emplear múltiples objetivos. Esta es una tendencia que gana terreno en la actualidad [Zuperl y Cus, 2003; Cus y Balic, 2003; Quiza y Rivas, 2004]. No obstante, el enfoque de optimización que a predominado a sido *a priori*, que se basa en la integración de los diversos objetivos en una única función, generalmente mediante una adecuada ponderación ofrecida por expertos. En este sentido están orientados los trabajos de Cus y

Balic [2003] y de Zuperl y Cus [2003], que utilizan una denominada “función implícita del fabricante”, que integra tres objetivos independientes: tiempo de elaboración, costo de producción y calidad.

El autor de esta tesis considera que este enfoque tiene una limitación, dada por el requerimiento de una valoración previa, casi siempre subjetiva, de la importancia relativa de cada objetivo de optimización.

Croitoru, Severincu y Belous [2001] han desarrollado un método de optimización multiobjetivo, pero éste no se adapta a variables discontinuas y, además, el método de solución es gráfico, lo que hace muy lento y engorroso el proceso de cálculo.

Quiza y Rivas [2004], proponen la optimización multiobjetivo, considerando dos criterios que deben ser simultáneamente minimizados: el tiempo de elaboración y el gasto de herramienta, lo cual parece ser más adecuado a las condiciones de la industria cubana.

1.2.3 – Restricciones.

Un aspecto muy importante dentro de toda optimización es establecer las restricciones adecuadas, las cuales dependen de las características del proceso. En el torneado, se reporta el uso de varias restricciones que garantizan la factibilidad del régimen seleccionado, en dependencia de las condiciones específicas: máquina, herramienta, material elaborado, etc.

Entre las restricciones utilizadas por casi todos los autores [Chua *et al.*, 1991; Kayakan *et al.*, 1996; Cakir y Gurarda, 1998; Lee y Tarng, 2000; Ahmad y Anwarul, 2001; Wang *et al.*, 2002; Saravanan, Asokan y Vijayakumar, 2003; Quiza y Rivas, 2003; Quiza y Rivas,

2004] están mantener los parámetros del régimen de corte (profundidad, avance y velocidad de corte) dentro de los rangos admitidos por la herramienta:

$$a_{P-H}^{MIN} \leq a_P \leq a_{P-H}^{MAX} , \quad (1.8a)$$

$$f_H^{MIN} \leq f \leq f_H^{MAX} , \quad (1.8b)$$

$$V_H^{MIN} \leq V \leq V_H^{MAX} , \quad (1.8c)$$

Otra restricción que hay que tener en cuenta, en pasadas de desbaste, es que la fuerza (F) y la potencia de corte (P) no superen los valores máximos admisibles por la máquina-herramienta [Chua *et al.*, 1991; Cakir y Gurarda, 1998; Ko y Kim, 1998; Saravanan, Asokan y Vijayakumar, 2003; Kayakan *et al.*, 1996; Meng, Arsecularatne y Mathew, 2000; Lee y Tarng, 2000; Ahmad y Anwarul, 2001; Wang *et al.*, 2002; Quiza y Rivas, 2003; Quiza y Rivas, 2004]:

$$F \leq F_{MAX} , \quad (1.9a)$$

$$P \leq P_{MAX} , \quad (1.9b)$$

Para pasadas de acabado, es importante considerar que la rugosidad superficial (R) no supere a la establecida en los requisitos técnicos de la superficie elaborada [Cakir y Gurarda, 1998; Ko y Kim, 1998; Lee y Tarng, 2000; Saravanan, Asokan y Vijayakumar, 2003; Wang *et al.*, 2002]:

$$R \leq R_{MAX} , \quad (1.10)$$

Una restricción adicional propuesta por Saravanan, Asokan y Vijayakumar [2003], que presenta cierto interés, es que la temperatura en la zona de corte (q) no supere cierto valor admisible (q_{MAX}). Sin embargo en el trabajo citado no se señala como seleccionar esta temperatura. Alfonso [2002], para el torneado de aceros templados, plantea que esta temperatura debe ser la de recristalización del material elaborado. Alfonso propone utilizar, en lugar de la temperatura, la termo-fem (e):

$$e \leq e_{RECR} , \quad (1.11)$$

donde e_{RECR} es la termo-fem a la cual ocurre la recrystalización.

Adicionalmente, Nefiodov y Osipov [1980], plantean que la herramienta utilizada, bajo las condiciones de trabajo seleccionadas, deben cumplir las condiciones de resistencia y rigidez:

$$F_C \leq \frac{B \cdot H^2 \cdot S_F}{6 \cdot L_{VOL}} , \quad (1.12a)$$

$$F_C \leq \frac{y_{MAX} \cdot E \cdot B \cdot H^3}{4 \cdot L_{VOL}} , \quad (1.12b)$$

donde F_C es la componente tangencial de la fuerza de corte; B y H , el ancho y la altura de la sección transversal del vástago de la herramienta; S_F , la tensión límite a la flexión del material del vástago; E , el módulo de elasticidad del material del vástago; L_{VOL} , la longitud del voladizo de la herramienta; y y_{MAX} , la flecha de pandeo máxima admisible para la punta de la herramienta (0,1 mm para el torneado y 0,05 para el de acabado).

1.2.4 – Métodos de optimización.

Para la optimización de regímenes de corte en el torneado, se han empleado diversos métodos. El primero, muy difundido por su relativa sencillez y su claro significado matemático, es el analítico, que se basa en el uso de las derivadas de la función objetivo. Utilizado por primera vez por Taylor [1907] para determinar la velocidad de corte óptima en operaciones de una sola pasada, este método es ampliamente descrito en libros y manuales [Shaw, 1984; Sandvik, 1994] y aún se mantiene en uso [Kayakan *et al.*, 1996; Wang *et al.*, 2002].

La principal limitación del método analítico es su dificultad al aplicarlo al régimen de corte, donde la función objetivo no siempre es derivable y, frecuentemente, incluye variables discretas o discontinuas. Aunque se han hecho intentos para solucionar esta dificultad [Shaw, 1984], los resultados conducen a expresiones muy complejas y de validez muy discutible.

La programación dinámica y la programación geométrica también han sido aplicadas a la optimización de regímenes de corte [Chua *et al.*, 1991; Cakir y Gurarda, 1998; Dereli y Filiz, 1999; Lee y Tarng, 2000]. Estas técnicas ofrecen buenos resultados en sistemas no lineales, pero cuando el número de parámetros involucrados se hace grande, el esfuerzo computacional que requieren los hace impracticables.

También el método robusto de Tagushi [Nian, Yang y Tarng, 1999] y el algoritmo de hormiguero (ant colony algorithm) [Vijayakumar *et al.*, 2003] han sido empleado para la selección de regímenes de corte óptimos en el torneado, con cierto éxito.

En los últimos años, se ha incrementado el uso de algoritmos evolutivos en los problemas optimización [Kurpati, Azarm y Wu, 2002]. Dentro de estas técnicas, los algoritmos genéticos (AG's) son la estrella indiscutible [Herreros, 2000].

Varios autores han reportado el empleo de AG's para la selección de regímenes de corte óptimos en el torneado [Bhaskara Reddy, Shunmugam y Narendran, 1998; Ahmad y Anwarul, 2001; António y Davim, 2002; Cus y Balic, 2003; Quiza y Rivas, 2003; Amiolemhen y Ibhádode, 2004]. Saravanan, Asokan y Vijayakumar [2003] proponen un método basado en AG's para la optimización del torneado, y comparan los resultados con los ofrecidos por un método basado en la cristalización simulada (*simulated annealing*), propuesto en el mismo artículo. La eficacia reportada para ambos métodos es similar.

Chien y Tsai [2003] no sólo emplean un AG para optimizar el régimen de corte, sino que seleccionan los parámetros más convenientes para el GA, mediante el método de Tagushi.

Todos estos trabajos están dirigidos a la optimización de un sólo objetivo. Quiza y Rivas [2004], por el contrario, utilizan los AG's para la optimización multiobjetivo mediante la técnica min-max. Si bien los resultados ofrecidos, son satisfactorios, la técnica empleada es ineficiente, ya que necesita una corrida del programa para cada punto de la frontera de Pareto obtenida.

1.3 – Algoritmos evolutivos para la optimización multiobjetivos.

1.3.1 – Formulación general del problema de optimización multiobjetivos.

De forma general, un problema de optimización multiobjetivo puede considerarse aquel en el cual es necesario optimizar $\mathbf{y}(\mathbf{x})$, sujeto a $W = \{\mathbf{x} \in \mathbf{R}^N : \mathbf{g}(\mathbf{x}) \leq 0\}$, donde \mathbf{x} es el vector de las X variables de decisión (o variables de optimización); $\mathbf{y}(\mathbf{x})$ es el vector de las Y funciones objetivos ($y_1(\mathbf{x}), \dots, y_Y(\mathbf{x})$); y W es un subconjunto no nulo de \mathbf{R}^N , llamado espacio de búsqueda. El vector $\mathbf{g}(\mathbf{x}) = g_1(\mathbf{x}), \dots, g_G(\mathbf{x})$, representa las G restricciones del sistema [Abbass, 2000]. Por comodidad, se considera que todos los objetivos deben ser minimizados. Evidentemente, cualquier objetivo a maximizar puede, sin pérdida de rigor, convertirse en objetivo a minimizar multiplicando la respectiva ecuación por -1 .

Existen tres vías básicas de enfocar un problema de optimización multiobjetivo, en cuanto a la forma de la toma de decisiones [Van Veldhuizen y Lamont, 2000]:

- *A priori*: La toma de decisiones precede a la optimización. Se basa en la combinación de los diversos objetivos en una función de costo escalar,

convirtiendo el problema en uno de un solo objetivo. Dentro de este grupo se destacan la escalarización por combinación (lineal o no lineal); la ponderación de los criterios por ordenamiento y las técnicas de min-max.

- *Progresivas*: La toma de decisiones se realiza conjuntamente con la optimización, a través del suministro de información parcial sobre la precedencia de los criterios. Esta información se integra dentro del propio algoritmo de solución. Es un enfoque intermedio entre los otros dos.
- *A posteriori*: La toma de decisiones se realiza luego de que la optimización ha llegado a un conjunto de soluciones igualmente factibles, denominadas conjunto óptimo de Pareto.

Según reporta la bibliografía [Van Veldhuizen y Lamont, 2000; Sánchez, 2002], las técnicas *a posteriori* ofrecen los mejores resultados y constituyen el foco de atención de las actuales investigaciones sobre optimización multiobjetivo. El autor de esta tesis quiere hacer notar que, según lo visto en el epígrafe anterior (1.2), este enfoque es prácticamente inexistente en la optimización de regímenes de corte.

Dentro del enfoque *a posteriori* de la optimización multiobjetivos, hay varios conceptos importantes. Se denomina solución óptima de Pareto, a la solución $\mathbf{x}^* \in W$, tal que no existe otra $\mathbf{x} \in W$, tal que $y_i(\mathbf{x}) \leq y_i(\mathbf{x}^*)$, para todo $i = 1 \dots Y$, y existe, al menos, un i tal que $y_i(\mathbf{x}) < y_i(\mathbf{x}^*)$ [Kurpatic, Azarn y Wu, 2002]. Las soluciones óptimas de Pareto también se denominan soluciones no inferiores, admisibles, eficientes o no dominadas [Sánchez, 2002]. Estas soluciones se consideran óptimas en el sentido de que no hay ninguna otra, dentro del espacio de búsqueda considerado, que mejore uno de los objetivos buscados sin empeorar a la vez los otros [Abbass, Sarker y Newton, 2001]. Al conjunto de todas las soluciones óptimas de Pareto, se le denomina frontera de Pareto.

Los métodos a posteriori se basan en la determinación previa de la frontera de Pareto, para luego, a partir de ella, tomar la decisión correspondiente. Este enfoque tiene la ventaja de que no limita la toma de decisiones a un único valor, sino que permite la consideración de diferentes opciones razonablemente eficientes [Leyland, 2002].

Dentro de las diversas técnicas de optimización multiobjetivo propuestas, los algoritmos evolutivos son los que ofrecen mejores resultados en el enfoque a posteriori [Van Veldhuizen y Lamont, 2000; Coello, 2000; Leyland, 2002].

1.3.2 – Características generales de los algoritmos evolutivos.

Los algoritmos evolutivos (*evolutionary algorithms* EA's) son estrategias de búsqueda en paralelo que simulan el proceso de selección natural de los organismos vivos [Sánchez, 2002]. Los EA's se basan en el mantenimiento de una población de individuos dentro del espacio de búsqueda, operando sobre ellos de forma que nuevos individuos se vayan generando a partir de los existentes. Los nuevos individuos son evaluados a partir de una función de ajuste (*fitness function*) que corresponde con la función objetivo de la optimización y si resultan mejores que los existentes, los reemplazan. Al repetir este proceso un número de veces, cabe esperar una convergencia de la población hacia el óptimo [Abbass, 2000].

A diferencia de otros métodos de optimización, los EA's son muy poco exigentes con las funciones que emplean. Consideraciones de convexidad o concavidad, derivabilidad y continuidad no son en absoluto necesarias para las funciones en los EA's [Abbass, Sarker y Newton, 2001].

Los EA's permiten obtener, simultáneamente, un conjunto de puntos del espacio de búsqueda que definan completamente la frontera de Pareto [Herreros, 2002]. En este sentido es muy importante que los EA's dispongan de los mecanismos necesarios para garantizar la diversidad de la población, ya que no sólo es necesario obtener un conjunto de soluciones situadas lo más cerca posible de la frontera de Pareto, sino que estén uniformemente distribuidas por la misma [Sánchez, 2002].

El tratamiento de las restricciones es un aspecto clave dentro de los EA's. Coello [2000] propone un método para tratar las restricciones como otros tantos objetivos a optimizar. Un método similar utilizan Viera *et al.* [2002]. A pesar de que este enfoque reporta buenos resultados, complica innecesariamente la toma de decisiones. Kurpatic, Azarn y Wu [2002] proponen la penalización de la función de adaptación en dependencia de la cantidad de restricciones violadas. Jiménez, Gómez-Skarmeta y Sánchez [2001] proponen un algoritmo donde los elementos de la población que no cumplen las restricciones son agrupados y tratados independientemente.

Dentro de los algoritmos evolutivos cabe señalar los siguientes:

- Programación evolutiva: Utiliza una representación adaptada al problema concreto que va a resolver. No utiliza cruce entre los individuos, pero la mutación que emplea puede ofrecer resultados similares [Sánchez, 2002].
- Estrategias de evolución: Al igual que la programación evolutiva, la representación que utiliza depende del problema considerado. Incluye el cruce entre los progenitores [Leiva, 2001].

- Algoritmos genéticos: Utilizan cadenas de caracteres para representar las variables del problema dado. Esta característica los hace muy robustos, ya que pueden tratar una gran cantidad de problemas sin necesidad de variar sus estructuras [Sánchez, 2002; Leyland, 2002].

Dada su capacidad para tratar tanto variables discretas como continuas, los algoritmos genéticos son los EA's más convenientes para la optimización de regímenes de corte. Por otro lado, los algoritmos genéticos son los EA's más estudiados [Gero y Kazarov, 2001].

Existen varios EA's para optimización multiobjetivo, entre los que cabe señalar el PDE, de Abbass y colaboradores [Abbas, Sarker y Newton, 2001] y el ENORA, de Jiménez, Gómez-Skarmeta y Sánchez [2001]. Este último es especialmente interesante por la forma en que trata las restricciones.

1.3.3 – Algoritmos genéticos (AG's).

Como fue señalado anteriormente, el rasgo principal de los AG's, es la representación en forma de cadena de caracteres de las variables del espacio de búsqueda [Gero y Kazárov, 2001]. Esta característica está inspirada en la relación entre el genotipo y el fenotipo de los organismos vivos, y es muy adecuada para el tratamiento de variables cualitativas o discontinuas.

Como en todos los algoritmos evolutivos, los AG's parten de una población inicializada aleatoriamente, dentro del espacio de búsqueda. Los operadores principales que se emplean en los AG's son: selección, cruzamiento y mutación [Soodamani y Liu, 2000]. En el Anexo 2 se muestra el diagrama de bloques general de los algoritmos genéticos.

Algunos AG's propuestos para optimización multiobjetivo son:

- VEGA (*Vector Evaluated Genetic Algorithm*) propuesto por Shaffer en 1985 [Kurpatic, Azarn y Wu, 2002]. Es un algoritmo *a priori* que no permite obtener la frontera de Pareto.
- MOGA (*Multi Objective Genetic Algorithm*), desarrollado por Fonseca y Fleming en 1998 [Van Vedhuizen y Lamont, 2000]. El manejo de las restricciones que propone, tiene serias limitaciones [Kurpatic, Azarn y Wu, 2002].
- El propuesto por Kurpatic, Azarn y Wu [2002], que se basa en el MOGA, pero propone mejoras en el tratamiento de las restricciones.
- NSGA (*Non-dominated Sorting Genetic Algorithm*), propuesto de Srinivas y Deb, en 1994, y perfeccionado por Deb *et al.* [2000].
- El micro algoritmo genético propuesto por Toscano [2001] que solventa muchas de las limitaciones de los anteriores.

1.4 – Conclusiones parciales del Capítulo.

El estudio de la bibliografía especializada, ha permitido arribar a las siguientes conclusiones:

1. Los modelos existentes para relacionar la vida útil de la herramienta, la fuerza y la temperatura en la zona de corte, con los parámetros del régimen de corte, tienen limitaciones, y pueden ser mejorados para lograr una mayor precisión en sus predicciones.
2. Dentro de los modelos reportados, los basados en inteligencia artificial, especialmente en redes neuronales, son los que, potencialmente, ofrecen mejor

capacidad para adaptarse a las diversas condiciones del maquinado moderno, dada su capacidad de operar como aproximadores funcionales universales.

3. Los métodos de optimización de regímenes de corte, basados en un sólo objetivo, no son adecuados para todas las situaciones de la práctica industrial. Tampoco son convenientes los métodos multiobjetivos *a priori*, ya que limitan la toma de decisiones sobre los resultados. En la búsqueda bibliográfica realizada, no se encontró ninguna referencia a métodos de optimización multiobjetivo *a posteriori*, aplicados al proceso de torneado.
4. Los algoritmos evolutivos son capaces de resolver problemas de optimización multiobjetivo *a posteriori*, ya que permiten obtener un conjunto de soluciones próximas a la frontera de Pareto en una sola corrida.
5. Dentro de los algoritmos evolutivos, los algoritmos genéticos, por su capacidad de tratar tanto variables continuas como discontinuas, son los más convenientes para la optimización de regímenes de corte en el proceso de torneado. En la revisión bibliográfica se evidenció, en los últimos cinco años, un aumento significativo del uso de los mismos para este propósito.

CAPÍTULO 2

Propuesta para la Optimización Multiobjetivos del Torneado

En el capítulo precedente, fueron señaladas las limitaciones de los modelos existentes para relacionar las variables del proceso (vida útil y componentes de la fuerza de corte, entre otras), con los parámetros del régimen de corte: profundidad, avance y velocidad de corte. También se hizo mención de los problemas del enfoque mono-objetivo en la optimización de regímenes de corte, evidenciándose las potencialidades de los algoritmos genéticos para la optimización multiobjetivos. Dadas estas consideraciones, el siguiente capítulo persigue, como objetivo fundamental, proponer un nuevo esquema de optimización multiobjetivos del proceso de torneado, basado en el uso de algoritmos genéticos, y que incluya un modelo combinado basado en la regresión estadística y en las redes neuronales para representar las variables del proceso.

2.1 – Modelo combinado para las variables del proceso.

2.1.1 – Descripción general del modelo.

Para relacionar los valores cuantitativos de las variables que intervienen en el proceso de corte (vida útil y componentes de la fuerza de corte, entre otros), se propone un modelo basado en las técnicas de inteligencia artificial. Dicho modelo está formado por una combinación de tres aproximadores funcionales empíricos independientes: una regresión estadística, una red neuronal de tipo perceptron multicapas (MLP), y una red neuronal de funciones de base radial (RBF) (Ver Fig. 2.1). Cada uno de ellos, es ajustado o entrenado, según corresponda, con el mismo conjunto de datos experimentales.

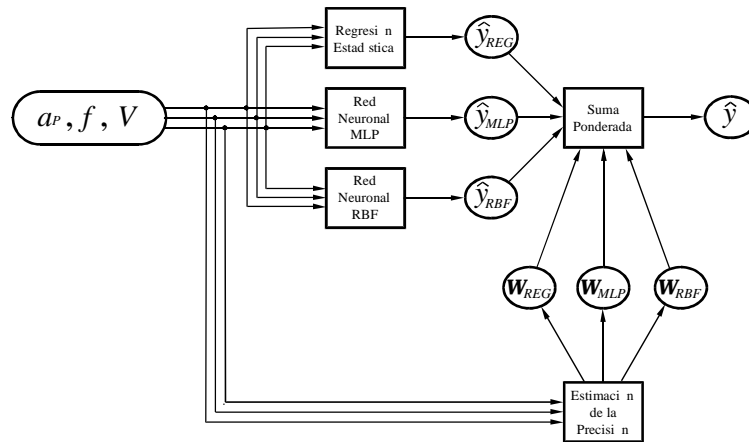


Figura 2.1 – Esquema general del modelo.

Para los valores dados de las variables independientes, se estima la precisión de cada uno de los modelos. Por último, se determina el valor final del modelo combinado, mediante la suma ponderada de los valores de los tres modelos, de modo tal que el peso respectivo sea función de la precisión estimada el mismo.

2.1.2 – Diseño experimental.

Para el ajuste del modelo de regresión estadística, y para el entrenamiento de las dos redes neuronales, es necesario disponer de datos experimentales. Estos datos, se agrupan en tres conjuntos [Flexer, 1996]:

- **Conjunto principal:** Está formado los datos necesarios para ajustar el modelo estadístico y para entrenar las dos redes neuronales empleadas. La distribución de dichos datos, se establece mediante un diseño experimental factorial completo de tres niveles (convencionalmente denominados -1 , 0 y 1). Aunque, para obtener la superficie de respuesta con la regresión, es suficiente un diseño menos costoso (como el compuesto central o el de Box-Behnken), para el entrenamiento

adecuado de las redes, es muy conveniente contar con puntos experimentales distribuidos por toda el rango de las variables estudiadas, por lo que el factorial completo de tres niveles es el adecuado.

- **Datos de validación:** Incluye los puntos necesarios para comprobar la capacidad de generalización de los modelos basados en redes neuronales. Está integrado por los ocho puntos situados en los niveles $-0,5$ y $+0,5$ del conjunto principal. Esta selección permite evaluar el comportamiento de los modelos en los puntos más alejados de los utilizados como entrenamiento y que, a la vez, están uniformemente distribuidos por el espacio de búsqueda.
- **Datos de comprobación:** Contiene los puntos necesarios para comprobar el ajuste del modelo combinado. Está integrado por cuatro puntos seleccionados de forma aleatoria dentro de los rango admisibles de las variables de optimización.

Para evitar, en lo posible, la influencia de factores casuales, se deben tomar, al menos, tres muestras de cada punto experimental, en los tres conjuntos. Para asegurarse de que no hay valores extraños, se llevará a cabo la prueba de anormalidad de las observaciones, tal como se establece en la NC 92-21: 79 [CEN, 1979].

2.1.3 – Aproximador funcional basado en la regresión estadística.

El aproximador funcional basado en la regresión estadística tiene la forma de una relación lineal de la forma:

$$\ln(y) = C + \mathbf{a} \ln(V) + \mathbf{b} \ln(f) + \mathbf{g} \ln(a), \quad (2.1a)$$

donde C , \mathbf{a} , \mathbf{b} y \mathbf{g} son los coeficientes de la regresión. Por comodidad, la ecuación anterior puede ser escrita como:

$$y = C'V^a f^b a^g, \quad (2.1b)$$

donde $C' = e^C$ que coincide con la conocida Ley de Taylor para la vida útil y con modelos similares utilizados para otras variables.

Es muy importante el análisis estadístico de la regresión, donde deben incluirse, al menos, el coeficiente de la regresión, el error medio de las estimaciones y el estadístico de Durbin-Watson para analizar la posible autocorrelación de los residuales. También es importante el análisis de varianza (ANOVA) de la regresión y el de sensibilidad de los coeficientes. Si el modelo anterior no muestra un buen ajuste, pudiera considerarse algún otro, lineal o potencial.

2.1.4 – Aproximador funcional basado en la red MLP.

El segundo aproximador funcional que integra el modelo, se basa en el uso de una red neuronal de tipo perceptron multicapas (MLP) para relacionar la variable en cuestión con los parámetros del régimen de corte. El MLP seleccionado tiene una sola capa de neuronas ocultas (ver Fig. 2.2) dadas las características no muy complejas de la dependencia entre las variables.




Figura 2.2 – Estructura del MLP utilizado en el modelo.

La primera capa contiene las tres neuronas de entradas ($E_1 \dots E_3$), a las cuales se les asignan los valores de los parámetros del régimen de corte.

Para el buen funcionamiento de la red, estos valores de entrada deben ser normalizados entre 0 y 1, mediante interpolación lineal de los logaritmos de los valores, según la expresión:

$$\tilde{x}_i = \frac{\ln(x_i) - \ln(x_i^{MIN})}{\ln(x_i^{MAX}) - \ln(x_i^{MIN})}, \quad (2.2)$$

donde \tilde{x}_i representa el valor normalizado del parámetro del régimen respectivo (profundidad de corte, avance o velocidad); x_i , el valor real; x_i^{MIN} , el valor mínimo de dicho parámetro y x_i^{MAX} , el valor máximo. La logaritmicación de los valores de las variables de entrada se basa en la dependencia aproximadamente potencial de su relación con la variable modelada. No obstante, pudiera utilizarse otra expresión de no dar ésta los resultados esperados.

En la capa oculta (neuronas $O_1 \dots O_N$), se ubicará el mínimo número de neuronas necesario para realizar una buena aproximación funcional. Si existen muy pocas neuronas en esta capa, los errores en la predicción serán demasiado altos. Si, por el contrario, la cantidad de neuronas en la capa oculta es excesiva, se produce el fenómeno conocido como sobreajuste (*overfitting*) que trae consigo una pobre capacidad de generalización.

El valor de cada una de las neuronas de la capa oculta (\hat{y}_{o-i}) se determina a través de la función sigmoidea, determinada por la expresión:

$$\hat{y}_{o-i} = \frac{1}{1 + \exp[-(b_{o-i} + \sum_j w_{o-ij} \tilde{x}_j)]}, \quad (2.3)$$

donde \tilde{x}_j es el valor de la j-ésima entrada normalizada; b_{o-i} , la predisposición (*bias*) de la neurona oculta en cuestión, y w_{o-ij} el peso que enlaza la neurona oculta con la j-ésima entrada.

La salida está integrada por una sola neurona (S) correspondiente a la variable modelada. El valor de esta salida (\hat{y}_s) se determina por la combinación lineal de las salidas de las neuronas ocultas, mediante la expresión:

$$\hat{y}_s = b_s + \sum_i w_{s-i} y_{o-i}, \quad (2.4)$$

donde b_s es la predisposición (*bias*) de la neurona de salida; w_{s-i} es el peso que conecta a la i-ésima neurona oculta con la salida.

Para el ajuste de los pesos y biases de la red se utiliza el método de retropropagación del error (*backpropagation*), basado en gradiente descendiente, con momento. Para determinar los valores más convenientes de la cantidad de neuronas, y de los parámetros del entrenamiento (velocidad de aprendizaje, factor de momento y número máximo de iteraciones), se emplea el método de Tagushi [Phadke, 2004]. Como objetivos del diseño se utilizan la precisión de la red y su capacidad de generalización.

La precisión de la red neuronal se evalúa mediante el error medio cuadrático de los residuales (*RMSE*) de los conjuntos principal y de validación:

$$RMSE = \sqrt{\frac{\sum_{i=1}^{N_{PRI}} (y_{PRI}^i - \hat{y}_{PRI}^i)^2 + \sum_{i=1}^{N_{VAL}} (y_{VAL}^i - \hat{y}_{VAL}^i)^2}{N_{PRI} + N_{VAL}}}, \quad (2.5)$$

donde \hat{y}_{PRI}^i y y_{PRI}^i son el valor predicho y el valor real del i-ésimo punto del conjunto principal; \hat{y}_{VAL}^i y y_{VAL}^i , los valores predicho y real del i-ésimo punto del conjunto de validación; N_{PRI} , la cantidad de puntos del ejemplo principal y N_{VAL} , la cantidad de puntos del conjunto de validación.

La capacidad de generalización se evalúa mediante el valor de probabilidad asociado al estadígrafo *t-Student*, en una prueba de igualdad de medias para los residuales de los conjuntos principal y de validación. Cuanto más cercano se encuentre este valor a 1, con menos confiabilidad se podrá rechazar la hipótesis de igualdad de medias y, por tanto, la red tendrá mejor capacidad de generalización.

Para la determinación de los valores de los factores de diseño en los puntos experimentales, se utiliza un arreglo ortogonal L9 (3^4), de cuatro factores con tres niveles, cuyos valores (mínimo, medio y máximo, convencionalmente denotados como -1, 0 y +1), se muestran en la Tabla 2.1.

Tabla 2.1 – Arreglo ortogonal L9 (3^4).

Punto	Factor 1	Factor 2	Factor 3	Factor 4
1	-1	-1	-1	-1
2	-1	0	0	0
3	-1	+1	+1	+1
4	0	-1	0	+1
5	0	0	+1	-1
6	0	+1	-1	0
7	+1	-1	+1	0
8	+1	0	-1	+1
9	+1	+1	0	-1

El valor más convenientes para cada factor de diseño, se determina a partir de un gráfico donde los dos objetivos de diseño se representan en función del factor considerado. Debe elegirse un valor de compromiso tal que garantice un bajo error en las predicciones de la red y una buena capacidad de buena generalización.

Las predicciones de la red finalmente seleccionada, deben ser verificados con los valores de los conjuntos de entrenamiento y de validación, analizando especialmente la distribución de sus residuales.

2.1.5 – Aproximador funcional basado en la red RBF.

El tercer aproximador funcional también se basa en el uso de una red neuronal artificial, pero de tipo de función de base radial (RBF). Esta red tiene una estructura similar a la del modelo anterior (ver Fig. 2.2), pero se diferencia en algunos puntos muy importantes.

En primer lugar, las salidas de las neuronas ocultas no se determinan por una función sigmoidea, sino por una función de base radial, determinada por la expresión:

$$\hat{y}_{o-i} = \exp \left[-b_{o-i}^2 \cdot \sum_j (w_{o-ij} - \tilde{x}_{oj})^2 \right], \quad (2.5)$$

donde la nomenclatura es la misma que para la red MLP.

Otra diferencia entre ambas redes, es la forma de determinar los pesos y las predisposiciones. La red RBF no utiliza un algoritmo basado en gradiente descendiente. La capa oculta, originalmente está vacía, y el proceso de entrenamiento consiste en irle agregando neuronas hasta lograr que el error máximo ofrecido esté por debajo del establecido. Los pesos de cada neurona agregada se determinan por los valores de las entradas del ejemplo para el cual se obtuvo el mayor error. La predisposición de las neuronas ocultas se calcula a partir de un valor de dispersión (\mathbf{s}) que se establece previamente, según:

$$b_{o-i} = \frac{0,8326}{\mathbf{s}}, \forall i = 1 \dots W_o. \quad (2.6)$$

El valor de esta dispersión debe ser lo suficientemente grande para garantizar un correcto solapamiento entre las diversas neuronas, pero no tanto que cada una no tenga su propia área de acción dentro del espacio de entradas. Los pesos y la predisposición de la neurona de salida se ajustan mediante el método de los mínimos cuadrados.

Para la selección de la red más adecuada, también se emplea el método de Tagushi. En este caso, los factores de diseño son el valor de la dispersión y la cantidad máxima de neuronas de la capa oculta de la red. Los objetivos de diseño son los mismos que en la red de tipo MLP.

Como sólo hay dos factores de diseño, el arreglo ortogonal degenera en un diseño experimental factorial completo de dos factores con tres niveles. Los valores más convenientes de cada factor de diseño se determina de modo idéntico a como se hace en la red MLP, tal como se explicó en el subtópico anterior. También es este caso, una vez elegida la red que finalmente se va a utilizar, deben comprobarse sus predicciones para los conjuntos de entrenamiento y validación.

2.1.6 – Evaluación de la precisión de cada modelo y suma ponderada.

Para evaluar la precisión de cada modelo en un punto determinado del rango experimental, se determina la distancia normalizada desde el mismo a los puntos más cercanos de los conjuntos principal y de validación, S^{PRI} y S^{VAL} , según las expresiones:

$$S^{PRI} = \min(|\mu_1^{PRI} - \mathbf{m}|, |\mu_2^{PRI} - \mathbf{m}|, \dots, |\mu_{W^{PRI}}^{PRI} - \mathbf{m}|); \quad (2.7a)$$

$$S^{VAL} = \min(|\mu_1^{VAL} - \mathbf{m}|, |\mu_2^{VAL} - \mathbf{m}|, \dots, |\mu_{W^{VAL}}^{VAL} - \mathbf{m}|); \quad (2.7b)$$

donde \mathbf{m} , representa el vector posicional normalizado del punto considerado, y donde μ_i^{PRI} y μ_i^{VAL} son los vectores posicionales de los i -ésimos puntos de los conjuntos principal y de validación.

A partir de dichas distancias S^{PRI} y S^{VAL} , se determinan la precisión, \mathbf{z} , según la expresión:

$$\mathbf{z} = \mathbf{z}^{PRI} + \frac{S^{VAL}(\mathbf{z}^{VAL} - \mathbf{z}^{PRI})}{S^{VAL} + S^{PRI}}, \quad (2.8)$$

donde \mathbf{z}^{PRI} y \mathbf{z}^{VAL} son las precisiones del modelo para los conjuntos principal y de validación. Aquí por precisión se entiende la raíz del valor cuadrático medio del error relativo.

La ponderación de cada modelo \mathbf{w}_i , se determina mediante la expresión:

$$\mathbf{w}_i = \frac{\exp(-\mathbf{z}_i)}{\exp(-\mathbf{z}_{REG}) + \exp(-\mathbf{z}_{MLP}) + \exp(-\mathbf{z}_{RBF})}, \quad (2.9)$$

donde \mathbf{z}_i es la precisión del modelo considerado, y \mathbf{z}_{REG} , \mathbf{z}_{MLP} y \mathbf{z}_{RBF} , las precisiones de los modelos basados en la regresión estadística y en las redes MLP y RBF, respectivamente.

Por último, el valor predicho por el modelo combinado, se determina por una suma ponderada de los valores predichos por cada modelo, afectados por las ponderaciones respectivas:

$$\hat{y} = \mathbf{w}_{REG} \hat{y}_{REG} + \mathbf{w}_{MLP} \hat{y}_{MLP} + \mathbf{w}_{RBF} \hat{y}_{RBF}. \quad (2.10)$$

En el Anexo 3 se muestran la deducción de las expresiones utilizadas en este epígrafe.

2.2 – Metodología para la optimización multiobjetivos.

2.2.1 – Objetivos de optimización.

Como se vio en el análisis bibliográfico, en la selección de regímenes de corte eficientes, en el proceso de torneado, se persiguen varias metas simultáneas. Entre ellas, por su importancia, han sido seleccionadas dos como objetivos del proceso de optimización: el *tiempo de elaboración* y la *vida útil consumida de la herramienta*.

El tiempo de elaboración, t_T , se puede considerar como la combinación de cuatro tiempos básicos: el tiempo de maquinado, t ; el tiempo auxiliar, t_A ; y el tiempo de cambio de la herramienta, t_{CH} . O sea:

$$t_T = t + t_A + t_{CH} . \quad (2.11)$$

El tiempo de maquinado se determina como:

$$t = N_P t_0 = N_P \cdot \frac{L + L' + L''}{f \cdot n} , \quad (2.12)$$

donde N_P es la cantidad de pasadas; t_0 , el tiempo de elaboración de cada pasada; L , la longitud a maquinar; L' y L'' , las longitudes de entrada y de salida de la herramienta; f , el avance y n , la frecuencia de rotación del husillo del torno. A su vez, L' se toma como:

$$L' = a_p \cdot \cot(\mathbf{j}) , \quad (2.13)$$

donde a es la profundidad de corte y \mathbf{j} , el ángulo de posición principal de la herramienta. La longitud de salida, L'' , se toma, usualmente, entre 1 ... 2 mm [Kosilova, 1985].

El tiempo auxiliar se toma de la experiencia práctica, o de tablas especializadas, teniendo en cuenta las dimensiones de la pieza y la cantidad de pasadas.

El tiempo invertido en el cambio de la herramienta, por su parte, puede ser considerado como:

$$t_{CH} = t_{CH0} \frac{t}{T} = t_{CH0} N_P \frac{t_0}{T} , \quad (2.15)$$

donde t_{CH0} es el tiempo invertido en cambiar una herramienta (o un filo, si se trabaja con herramienta de filos intercambiables); y T , la vida útil del filo de la herramienta.

Sustituyendo las expresiones (2.12) – (2.15) en (2.11) obtenemos:

$$t_T = N_P t_0 + t_A + t_{CH0} N_P \frac{t_0}{T} . \quad (2.16)$$

Por su parte, la *vida útil consumida*, \mathbf{x} , se define como la razón entre el tiempo de trabajo de la herramienta y su vida útil, o sea:

$$\mathbf{x} = \frac{N_P \mathbf{t}_0}{T}; \quad (2.17)$$

y, por comodidad, se ofrece en por ciento.

Como se puede notar, ambos objetivos son conflictivos, ya que no pueden ser minimizados simultáneamente.

2.2.2 – Datos del problema.

Para llevar a cabo el proceso de optimización es necesario contar con una cantidad de datos del problema. Estos datos incluyen:

- Datos del proceso: Diámetros inicial (d_0) y final (d) y longitud de la superficie a elaborar (L); tiempo de cambio de una cuchilla o un filo (\mathbf{t}_{CH0}).
- Datos de la máquina: Gama de avances (f_M) y revoluciones (n_M). En ambos casos, estos conjuntos pueden ser un rango continuo:

$$f_M = \{x \in \mathbf{R} : f_M^{MIN} \leq x \leq f_M^{MAX}\} \quad (2.18a)$$

$$n_M = \{x \in \mathbf{R} : n_M^{MAX} \leq x \leq n_M^{MAX}\} \quad (2.18b)$$

o un conjunto de valores discretos:

$$f_M = \{f_M^1, f_M^2, \dots, f_M^{N_f}\} \quad (2.18c)$$

$$n_M = \{n_M^1, n_M^2, \dots, n_M^{N_n}\} \quad (2.18d)$$

También es necesario conocer la potencia del motor P_{MOT} , y la máxima fuerza que admite el mecanismo de avance, F_{F-MAX} , y la eficiencia de la transmisión, \mathbf{h} .

- Datos de la herramienta: Incluye la geometría de la herramienta (ángulo de ataque, g_r ; de inclinación, I ; y de posición principal, j), las dimensiones del vástago (ancho, b_{VAS} y altura h_{VAS} ; para vástagos de sección rectangular; y diámetro, d_{VAS} , para vástagos de sección circular) y los rangos admisibles de profundidad de corte, de avance y de velocidad de corte:

$$a_{P-H} = \{x \in \mathbf{R} : a_{P-H}^{MIN} \leq x \leq a_{P-H}^{MAX}\} \quad (2.19a)$$

$$f_H = \{x \in \mathbf{R} : f_H^{MIN} \leq x \leq f_H^{MAX}\} \quad (2.19b)$$

$$V_H = \{x \in \mathbf{R} : V_H^{MIN} \leq x \leq V_H^{MAX}\} \quad (2.19c)$$

2.2.3 – Variables de optimización.

Las variables de optimización que se emplean en el problema dependen del tipo de torneado a realizar: desbaste o acabado. Para el torneado de desbaste, se consideran como variables de optimización, el número de pasadas, N_P ; el avance, f ; y la frecuencia de rotación del husillo, n . Estas variables son de diversos tipos. Mientras la cantidad de pasadas siempre es una variable discreta, el avance y las frecuencia de rotación del husillo pueden ser tanto continuas como discretas, en dependencia de las características de la máquina – herramienta empleada.

La cantidad de pasadas se selecciona de forma tal que la profundidad de corte se mantenga dentro del rango admisible por la herramienta; el avance se toma dentro del rango admisible común para la máquina y la herramienta; y la frecuencia de rotación del husillo se elige teniendo en cuenta sólo la gama de la máquina. De aquí tenemos las expresiones:

$$N_P = \text{rnd}(x \in \mathbf{N} : \frac{d_0 - d}{2 \cdot a_{P-H}^{MAX}} \leq x \leq \frac{d_0 - d}{2 \cdot a_{P-H}^{MIN}}); \quad (2.20a)$$

$$f = \text{rnd}(x \in (f_M \cap f_H)); \text{ y} \quad (2.20b)$$

$$n = \text{rnd}\left(x \in n_M : \frac{1000 \cdot V_H^{MIN}}{p \cdot d} \leq x \leq \frac{1000 \cdot V_H^{MAX}}{p \cdot d_0}\right). \quad (2.20c)$$

En el torneado de acabado, siendo un proceso que se realiza en una única pasada, la profundidad de corte se establece según recomendaciones tecnológicas, no constituyendo una variable de optimización. En cambio, el avance y la frecuencia de rotación, sí lo son. También, en este caso, el avance y la frecuencia de rotación pueden ser discretas o continuas y se seleccionan de acuerdo con las expresiones (2.20b y 2.20c).

2.2.4 – Restricciones.

No es necesario comprobar que los parámetros de corte estén dentro de los rangos admitidos por la herramienta, ya que esto se tuvo en cuenta al asignar sus valores iniciales (Ec. 2.20a – 2.20c).

Es necesario comprobar que la fuerza y la potencia de corte no superen determinados valores. En primer lugar, la componente tangencial de la fuerza de corte F_C , no puede ser mayor que la admisible por la herramienta, tanto por su resistencia como por su rigidez; o sea que:

$$F_C \leq \frac{s_{ADM} W_F}{l_{VOL}}, \quad (2.21)$$

$$F_C \leq \frac{3f_{ADM} EJ}{l_{VOL}^3} \quad (2.22)$$

donde s_{ADM} y E , son la tensión admisible y el módulo de elasticidad del material del vástago de la cuchilla; W_F y J , el módulo en flexión, y el momento de inercia de la sección del vástago de la cuchilla, l_{VOL} la longitud en voladizo desde la punta de la cuchilla hasta el apoyo y f_{ADM} , la mayor flecha admisible para la punta de la cuchilla ($f_{ADM} = 0,1$ mm para operaciones de desbaste y $f_{ADM} = 0,05$ mm, para acabado).

La segunda restricción es que la componente axial de la fuerza de corte, F_F , no supere la admisible por el mecanismo de avance de la máquina herramienta, F_{F-MAX} , según:

$$F_F \leq F_{F-MAX} ; \quad (2.23)$$

y que la potencia de corte, P_C , no supere la que puede ofrecer la máquina, o sea:

$$P_C = \frac{F_C \cdot V}{6 \cdot 10^4} \leq h \cdot P_{MOT} , \quad (2.24)$$

donde P_{MOT} es la potencia que ofrece el motor.

También debe garantizarse que la temperatura en la zona de corte, q , sea menor o igual a la máxima admitida por el material de la herramienta, q_{H-MAX} :

$$q \leq q_{H-MAX} . \quad (2.25)$$

En las pasadas de acabado, además, se debe garantizar que la rugosidad superficial, R , esté por debajo de los límites establecidos por las especificaciones técnicas de la superficie elaborada, R_{MAX} , o sea:

$$R \leq R_{MAX} . \quad (2.26)$$

Tanto en el acabado como en el desgaste, las restricciones señaladas son las mínimas requeridas, pero pueden ser agregadas otras para satisfacer las necesidades de una situación específica.

2.2.5 – Esquema general de cálculo.

El esquema general de cálculo que se muestra a continuación explica la secuencia de operaciones necesarias para determinar los valores de las variables que intervienen en el proceso de optimización. Por sus características diferentes, los esquemas de cálculo del desbaste y del acabado se dan por separado.

Esquema de cálculo para desbaste.

El primer paso del cálculo consiste en la selección de los valores de las variables de optimización: cantidad de pasadas, N_p ; el avance, f ; y la frecuencia de rotación del husillo, n ; las cuales se seleccionan como se explicó en el epígrafe 2.2.3 .

Para cada pasada, la profundidad de corte de cada pasada, a_p , como:

$$a_p = \frac{d_0 - d}{2 \cdot N_p} . \quad (2.27)$$

La velocidad de corte, aunque, en puridad, es diferente para cada pasada, se determina para aquella en la que es mayor, o sea, para la primera pasada, donde:

$$V = \frac{P \cdot (d_0 - 2a_p) \cdot n}{1000} . \quad (2.28)$$

La vida útil de la herramienta se determina haciendo uso del sistema descrito en el subtópico anterior, según:

$$T = \Psi_T(a_p, f, V), \quad (2.29)$$

donde Ψ_T representa al modelo combinado como aproximador funcional para la vida útil. Naturalmente, en lugar del sistema propuesto, pudiera emplearse otro modelo matemático cualquiera, sin que se vea afectada la esencia del método de optimización, aunque sí la calidad de sus resultados.

El tiempo de maquinado de cada pasada se determina tal como se estableció la ecuación (2.12), y el tiempo auxiliar se determina según tablas especializadas o mediante experimentación práctica; con él se calculan el tiempo total de elaboración y la vida útil consumida, según las expresiones (2.16) y (2.17).

Las componentes tangencial y axial de la fuerza de corte, F_C y F_F , también se determinan mediante el sistema “inteligente” propuesto:

$$F_C = \Psi_{F_C}(a_p, f, V), \quad (2.30a)$$

$$F_F = \Psi_{F_F}(a_P, f, V). \quad (2.30b)$$

Por último, se calcula la potencia de corte, como establece la expresión (2.24).

Esquema de cálculo para acabado.

Para el torneado de acabado, la selección de los valores de las variables de optimización: avance, f , y la frecuencia de rotación del husillo, n ; realiza de la misma manera que en el desbaste, tal como se explicó en los epígrafes 2.2.3 y 2.2.5. Naturalmente, sólo existe una sola pasada ($N_P = 1$) cuya profundidad de corte se determina por recomendaciones tecnológicas. Usualmente, $a_P = 0,1 \dots 0,4$ mm, para el acabado y $a_P = 0,5 \dots 2,0$ mm para el semiacabado [Kosilova, 1985].

La velocidad de corte se determina según la expresión (2.28) y la vida útil según (2.29), tal como se hace para el desbaste. También el tiempo de maquinado de cada pasada se determina por la expresión (2.12).

El tiempo total de elaboración, se determina por la expresión:

$$t_T = N_P t_0 + t_{CH0} N_P \frac{t_0}{T} + t_{PC}. \quad (2.31)$$

que se deduce de (2.16) al considerar que la cantidad de pasadas es igual a uno. La vida útil consumida, se calcula según (2.17).

2.2.6 – Implementación del algoritmo genético.

Consideraciones iniciales.

El algoritmo genético que se propone, para llevar a cabo la optimización multiobjetivo del proceso de torneado, se basa en el micro algoritmo genético (micro-AG) para optimización multiobjetivo, desarrollado por Toscano [2001]. Éste es un algoritmo elitista que cuenta con una técnica para mantener la diversidad de la población. Su

principal desventaja es que carece de un mecanismo claro para el tratamiento de restricciones.

Para incluir el tratamiento de restricciones en el algoritmo implementado, se utilizan las mejoras propuestas por Kurpati, Azarn y Wu [2002], que se basan en los siguientes principios:

- En la población dada, las soluciones factibles tienen mejor rango que las no factibles, por lo tanto, tienen más probabilidades de ser seleccionadas para la reproducción.
- La magnitud de la infactibilidad (o sea, cuanto se distancia un individuo de los valores límites establecidos en las restricciones), es un factor importante a tener en cuenta.
- La cantidad de restricciones violadas debe tenerse también en cuenta al manipular las restricciones.

Basándose en los principios anteriores, se establece un coeficiente de infactibilidad para cada individuo, G_i , que se define como:

$$G_i = \frac{\sum_{j=1}^G \max[g_j(\mathbf{x}_i), 0]}{\frac{1}{M} \sum_{k=1}^M \sum_{j=1}^G \max[g_j(\mathbf{x}_k), 0]}, \quad (2.33)$$

y que permite comparar dos individuos no factibles entre sí.

La utilización de pocos individuos en la población (principio básico de los micro AG's), si bien reduce el costo computacional, no es un enfoque eficaz cuando el problema tiene numerosas restricciones fuertes, que provocan que una parte importante (muchas veces mayoritaria) de la población inicial, esté integrada por individuos no factibles. En este

caso tenemos al problema estudiado es este trabajo, la optimización de regímenes de corte en el torneado.

Un aspecto destacado del micro-AG de Toscano es la utilización de una población estática que no varía durante todo el proceso. Esta población estática permite, para cada nueva iteración, agregar a la población un conjunto de individuos “frescos”, a un costo computacional reducido. Naturalmente, esto ayuda a mantener una adecuada diversidad dentro de las soluciones potenciales del problema.

Descripción general del algoritmo propuesto.

El diagrama de bloques del algoritmo genético propuesto para utilizar en la optimización multiobjetivo se muestra en la Fig. 2.3. El mismo se basa, al igual que el propuesto por Toscano, en el uso simultáneo de dos poblaciones de individuos: una dinámica que va variando según transcurren las iteraciones, Q_i , y otra estática, Q_{EST} , cuyos componentes se mantienen inalterables durante todo el proceso. Ambas poblaciones se crean, aleatoriamente, a inicio del proceso.

El tamaño de ambas poblaciones depende de la complejidad del problema, pero en todo caso, la población estática debe ser varias veces mayor que la dinámica, para garantizar una adecuada diversidad en cada generación.

Una vez creada la población dinámica inicial, Q_0 , se evalúan las funciones objetivo y las restricciones para cada una de las soluciones que la integran. Para las soluciones no factibles se determina, además, el coeficiente de infactibilidad según (2.33).




Fig. 2.3 – AG propuesto para la optimización multiobjetivo del proceso de torneo

Luego, durante un número de K_C de iteraciones, se hace evolucionar la población dinámica hacia, Q_i , la frontera de Pareto, a partir de su población inicial. Esta evolución se produce a través de selección por torneo, cruzamiento y mutación.

Una vez concluido este ciclo, se seleccionan los individuos no dominados de la población dinámica, y se agregan a una población élite o paretiana, Q_{PAR} , la cual es filtrada para mantener la dominancia de los individuos que la integran, y su diversidad.

Si aún no se ha alcanzado la condición de término, se crea una nueva población dinámica inicial, a partir de la actual, y de la población estática. Luego, se repite el proceso.

A continuación se detallan las características de cada uno de los pasos anteriores en la implementación realizada.

Generación de las poblaciones iniciales.

Cada una de las poblaciones que intervienen en el algoritmo propuesto (dinámica, estática y élite), está compuesta por un grupo de soluciones posibles dentro del dominio de cada una de las variables de optimización. En el problema considerado, se tienen tres variables de optimización:

$$x_1 = N_p; \ x_2 = f \text{ y } x_3 = n. \quad (2.34)$$

Para cada uno de los individuos de la población dinámica inicial y la población estática, estas variables son seleccionadas, aleatoriamente, tal como se establece en las expresiones (2.20a – 2.20c).

La codificación de cada individuo o solución, es un aspecto muy importante del problema. La tira utilizada estará integrada por elementos binarios (0 ó 1), y se compondrá de 96 caracteres, en tres grupos de 32, uno para cada una de las variables, ordenadas según se muestra en (2.34).

Para codificar el conjunto de las variables de optimización del i -ésimo individuo de la población, se determina un número entero $\hat{x}_{i,j}$, a partir del valor de cada variable independiente en dicho individuo. Luego, el valor $\hat{x}_{i,j}$ se convierte a un número binario de 32 cifras. Los códigos binarios así obtenidos para cada una de las variables, se concatenan para obtener la cadena, U_i , correspondiente. Lo anteriormente explicado corresponde a la expresión:

$$U_i = \text{concatenar}[(\hat{x}_{i,1})_2 + (\hat{x}_{i,2})_2 + (\hat{x}_{i,3})_2] \quad (2.35)$$

donde $(\hat{x}_{i,j})_2$ representa el número $\hat{x}_{i,j}$ escrito en notación binaria.

La determinación del valor de $\hat{x}_{i,j}$, depende del tipo de variable: continua o discreta. Para las variables continuas, se determina como:

$$\hat{x}_{i,j} = \text{redondear} \left((2^{32} - 1) \cdot \frac{x_{i,j} - x_{i,j}^{MIN}}{x_{i,j}^{MAX} - x_{i,j}^{MIN}} \right), \quad (2.36)$$

donde $x_{i,j}$ es el valor de la j-ésima variable para el individuo i-ésimo; y x_j^{MIN} y x_j^{MAX} , los valores mínimo y máximo de la j-ésima variable en toda la población.

Para las variables discretas, el valor $\hat{x}_{i,j}$ se determina como:

$$\hat{x}_{i,j} = \text{redondear} \left((2^{32} - 1) \cdot \frac{x_{i,j}^{INDEX}}{N_{xj} - 1} \right), \quad (2.37)$$

donde $x_{i,j}^{INDEX}$, es el índice de la variable $x_{i,j}$, dentro del conjunto de los valores discretos de x_j ; y N_{xj} , la cantidad total de valores en dicho conjunto.

Las consideraciones anteriores están hecha para las operaciones de desbaste, pero se procede de igual modo para el acabado. En este caso, sólo se tienen dos variables independientes $x_1 = f$ y $x_2 = n$, lo que, naturalmente, limita la longitud de la cadena de codificación a 64 caracteres.

Evaluación de la población.

Las funciones objetivos de cada individuo de la población:

$$y_1 = \mathbf{t}_T \text{ y } y_2 = \mathbf{x}; \quad (2.38)$$

son evaluadas según el esquema general de cálculo, explicado en el epígrafe 2.2.5. También según dicho esquema, son evaluadas las restricciones. Éstas, son transformadas

de forma tal que sus valores estén próximos a 1, lo que permite escalar cada una las restricciones a un orden similar. Estas restricciones, luego de ser modificadas resultan:

$$g_1 = \frac{F_C l_{VOL}}{\mathbf{s}_{ADM} W_F} - 1 \leq 0, \quad (2.39a)$$

$$g_2 = \frac{F_C l_{VOL}^3}{3 f_{ADM} EJ} - 1 \leq 0, y \quad (2.39b)$$

$$g_3 = \frac{F_F}{F_{F-MAX}} - 1 \leq 0. \quad (2.39c)$$

$$g_4 = \frac{F_C \cdot V}{6 \cdot 10^4 \cdot \mathbf{h} \cdot P_{MOT}} - 1 \leq 0 \quad (2.39d)$$

$$g_5 = \frac{\mathbf{q}}{\mathbf{q}_{H-MAX}} - 1 \leq 0 \quad (2.39e)$$

Para los individuos no factibles, se determina el índice de infactibilidad, \mathbf{G} , según la expresión (2.33).

Selección, cruzamiento y mutación.

Los operadores de selección, cruzamiento y mutación, permiten obtener una nueva población de individuos (soluciones), a partir de la población actual. Estos operadores deben ser tales que la nueva población, en sentido general, y siempre desde una óptica probabilística, tenga mejor aptitud (*fitness*) que la población anterior.

En el AG propuesto, la selección se realiza por torneo binario. Para cada individuo a crear en la nueva población, se eligen aleatoriamente, de la población actual, dos parejas de candidatos a progenitores. Los miembros de cada pareja se comparan entre sí, eligiendo un progenitor de cada pareja de acuerdo a las siguientes reglas:

- Un individuo factible siempre es mejor que uno no factible.
- Entre dos individuos factibles, es mejor el que domina al otro. Dos individuos factibles, de los cuales ninguno domina al otro, son igualmente buenos.

- Entre dos individuos no factibles, el mejor es el de menor índice de infactibilidad.

En el cruzamiento, las cadenas de codificación de los dos progenitores seleccionados, se combinan, para dar lugar a la cadena del individuo descendiente. En el AG propuesto, se utiliza el cruzamiento de dos puntos, tal como se muestra en la Fig. 2.4. Esta forma de cruzamiento es menos disruptiva que la de múltiples puntos, y evita algunos de los problemas que presenta el cruzamiento de un sólo punto.




Figura 2.4 – Cruzamiento de 2 puntos.

Por último, la mutación permite variar un carácter dentro de la cadena genética del descendiente, constituyendo una técnica que ayuda a mantener la diversidad y evita la convergencia prematura a mínimos locales. La mutación es un operador completamente estocástico y sólo debe aplicarse con una frecuencia muy baja, de lo contrario el AG se convierte en un simple algoritmo de búsqueda aleatoria. En el AG propuesto se utiliza un valor de probabilidad de mutación de 10^{-4} , constante para todo el proceso.

Actualización de la población élite.

El mantenimiento de una población élite o paretiana, Q_{PAR} , es una técnica elitista que permite preservar las mejores soluciones generadas durante el proceso. Al final de cada

iteración, se seleccionan los individuos no dominados de la población resultante, Q_{Kc} , y se agregan a élite.

Para el mantenimiento de una adecuada composición de la población élite, después de cada iteración, se procede a un filtraje. Éste consiste en eliminar todos los individuos dominados de dicha población. También se eliminarán aquellos individuos entre los cuales exista una distancia de euclidiana menor que un determinado valor, d_{LIM} :

$$\sqrt{(y_{i,1} - y_{j,1})^2 + (y_{i,2} - y_{j,2})^2} \geq d_{LIM}, \quad (2.40)$$

donde $y_{i,1}$, $y_{i,2}$ son los valores de las funciones objetivos para el individuo i -ésimo; y $y_{j,1}$, $y_{j,2}$, las funciones objetivo para el individuo j -ésimo.

Creación de la población inicial de la nueva iteración.

Una vez actualizada la población élite, se crea una nueva población inicial para repetir el proceso evolutivo. Esta población se genera mediante la selección aleatoria de individuos de la población estática, Q_{EST} , y de la población resultante de la iteración anterior Q_{Kc} .

Esta forma de selección permite comenzar el nuevo proceso evolutivo con una población que contenga individuos cercanos a la frontera de Pareto, con otros individuos de posición aleatoria, garantizando una diversidad suficiente para evitar la convergencia de la población élite hacia un solo sector de la frontera de Pareto.

Este proceso se repite hasta alcanzar la condición de parada, que tendrá lugar cuando los individuos de la población élite formen una frontera de Pareto uniforme; decisión reservada al operador humano. También se detiene el ciclo, al rebasar un número determinado de iteraciones establecido como máximo.

2.2.7 – Resultados de la optimización y toma de decisiones.

Como resultado de la optimización multiobjetivos, se obtiene el gráfico de Pareto, que contiene todos los individuos no dominados (ver. Fig. 2.5). Todos estos puntos son igualmente óptimos, tal como se explicó en el capítulo 1, pero la conveniencia de utilizar uno u otro, depende de la situación concreta.

Por ejemplo, si el taller considerado está trabajando en condiciones normales, el régimen de corte más conveniente corresponderá a los puntos 3, 4 o 5, donde hay un consumo bajo de la vida útil de la herramienta de corte y, a la vez, el tiempo de elaboración es aceptablemente pequeño. Puede notarse que dichos puntos son los más cercanos al origen de coordenadas.




Fig. 2.5 – Gráfico de Pareto con los resultados de la optimización.

Por el contrario, si el taller tiene una producción pequeña o discontinua, que no ocupa todo el tiempo, no hay necesidad de usar bajos tiempos de operación. En estos casos, obtener una vida útil larga es mucho más importante; por tanto, se debe seleccionar el régimen de corte correspondiente a los puntos 10 u 11.

Por último, en condiciones especiales, tales como en tiempo de guerra u otra emergencia, el volumen de producción es el elemento más importante a la hora de seleccionar el régimen de corte. Por tanto, en estas circunstancias, se debe seleccionar el régimen de corte correspondiente a los puntos 1 o 2, el cual garantiza el menor tiempo de maquinado, a pesar de su elevado consumo de herramientas con la consiguiente elevación de los costos.

Finalmente, debe añadirse, que el análisis del gráfico de Pareto no excluye el estudio de los costos, sino que éste puede servir de complemento, ayudando a la toma de decisiones, y dando una mayor fiabilidad a la opción adoptada.

2.3 – Conclusiones parciales del capítulo.

El desarrollo del Capítulo 2, ha permitido llegar a las siguientes conclusiones:

1. El sistema propuesto combina las redes neuronales con la regresión estadística para modelar, empíricamente, la vida útil de la herramienta, las componentes de la fuerza y la temperaturas en la zona de corte, en dependencia de los parámetros del régimen de corte.
2. Dada la utilización de redes neuronales, el sistema es potencialmente capaz de modelar las relaciones complejas no lineales de las variables citadas con los parámetros del régimen de corte, tal como tienen lugar en las condiciones de maquinado modernas.

3. El empleo de varios modelos en paralelo aumenta la capacidad de generalización del sistema, ya que de tener el lugar el sobreajuste de uno de los modelos, los otros contrarrestarían es efecto indeseado.
4. Se han establecido las principales características del proceso de optimización multiobjetivo del proceso de torneado, definiendo las funciones objetivos, las variables de optimización y las restricciones, tanto para el acabado como para el desbaste.
5. Se implementó un algoritmo genético, basado en el micro AG de Toscano, que se ajusta a las características específicas de la optimización multiobjetivos del proceso de torneado.
6. Se estableció el gráfico de Pareto, obtenido como resultado de la optimización, como fuente para la toma de decisiones, definiendo los principales criterios para llevarla a cabo.

CAPÍTULO 3

Estudio Experimental del Proceso de Corte

En el capítulo precedente, se estableció el método de optimización multiobjetivos para el proceso de torneado, incluyendo un sistema de modelación para sus principales variables. Para validar dicha propuesta, se llevó a cabo un conjunto de experimentos cuya realización se describe en el presente capítulo.

3.1 – Descripción de la instalación experimental.

El estudio realizado se encaminó a obtener los modelos de vida útil de la herramienta, de las componentes tangencial y axial de la fuerza de corte y de la temperatura en la zona de corte, para un proceso de torneado de semiacabado. La máquina seleccionada fue un torno C11MT, cuyas características se muestran en la Tabla 3.1. Se comprobó, previamente, que el torno cumpliera con los requisitos de precisión y rigidez indicados en la NC 11-81: 85 [CEN, 1985].

Tabla 3.1 – Características técnicas principales del torno C11MT.

Modelo: C11MT

Potencia del motor: 7,5 kW

Eficiencia de la transmisión: 75 %

Máxima fuerza admisible por el mecanismo de avance: 2000 N

Rango de velocidades de rotación del husillo: 16 ... 2000 r.p.m.

Rango de avances longitudinales: 0,09 ... 1,39 mm/rev

El torno ha sido modificado con la instalación de un convertidor de frecuencias para motores de AC, DVET-7.5, que permite trabajar con toda la gama de revoluciones del husillo del torno, en forma continua.

Como herramienta de corte se emplea un vástago Sanvik Coromant PTG NR 2525M 22, y las correspondientes placas, modelo TNMG 22 04 08-PM. Las características técnicas del vástago y la placa empleados, se especifican en los Anexos 4 y 5, respectivamente. El material elaborado fue acero AISI 1045, con una dureza de 197 HB.

Para medir el desgaste, se utilizó un microscopio óptico de mediciones con aumento de 15X y precisión de 1 μm . El tipo de desgaste predominante, para las condiciones experimentales dadas, fue el de flanco, por lo cual se tomó como criterio de vida útil que éste alcanzara un valor de 300 μm . La evaluación del nivel de desgaste, tal como indica la ISO 3685, se hizo tomando tres mediciones en la zona B (ver Figura 3.1) y promediándolas.




Fig. 3.1 – Medición del desgaste de flanco según ISO 3685.

La medición de la frecuencia de rotación del husillo se realizó con un tacómetro digital ONO Sokki HT-413, cuya precisión es de $\pm 0,5$ r.p.m. El desplazamiento longitudinal del carro del avance del torno, se midió con un transductor de desplazamiento Kyowa DT-100, cuyo error máximo es de $\pm 0,01\text{mm}$ (ver Fig. A6.2, del Anexo A6).

Para la medición de las componentes tangencial y axial de la fuerza de corte, se utilizaron dos puentes de Wheatstone (uno para cada componente), formados por cuatro extensómetros, tal como se muestra en la Figura 3.2.




Fig. 3.2 – Esquema de los puentes de Wheatstone extensométricos para la medición de las componentes tangencial y axial de la fuerza de corte.

Para medir la temperatura de la zona de corte, se empleó el termopar natural formado por la herramienta y la pieza. Ambas fueron aisladas de la máquina-herramienta con láminas de baquelita. El contacto eléctrico entre la pieza y los dispositivos de medición se llevó a cabo a través de un colector de mercurio instalado en el interior del husillo.

Las señales eléctricas, producidas por el sensor de desplazamiento; por los extensómetros y por el termopar natural, fueron aumentadas por un amplificador digital DPM-602B (ver Fig. A6.3, del Anexo 6), e introducidas en una computadora personal (ver Fig. A6.4, del Anexo 6), mediante una tarjeta de captura de datos, tomando 820 mediciones por segundo en cada canal, durante 8 segundos.

La calibración de los puentes de Wheatstone, se realizó mediante la colocación de masas conocidas y la medición de valores de las señales correspondientes. En la Tabla A8.1, del

Anexo 8, se muestran dichos valores para ambos puentes de Wheatstone, tanto para la carga como para la descarga. Los modelos de calibración, obtenidos por regresión estadística lineal son:

$$F_F = 427,3 \cdot U - 73,15; \quad (3.1a)$$

para la componente axial de la fuerza de corte, y:

$$F_C = 416,8 \cdot U - 66,15; \quad (3.1b)$$

para la componente tangencial. En ambos casos, el error del modelo está por debajo de 10 N, por lo cual este valor se puede tomar como error máximo para las mediciones de fuerza.

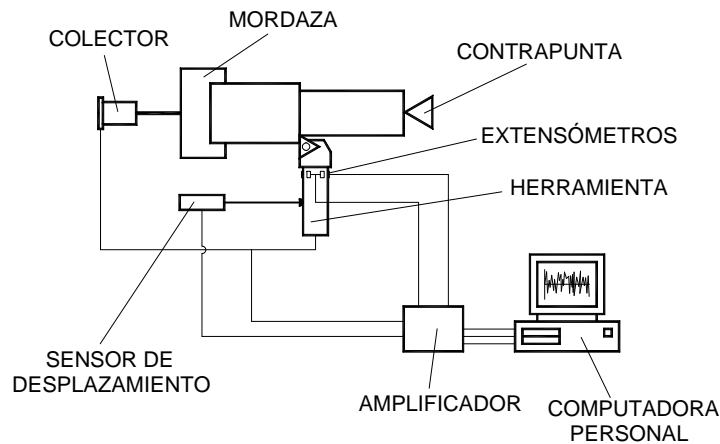


Fig. 3.3 – Esquema de la instalación utilizada en las mediciones.

La calibración del termopar natural se realizó calentando la unión de la pieza y la cuchilla con una resistencia de kanthal (ver Fig. A9.1 del Anexo 9). Se ejecutaron tres repeticiones tomándose tres conjuntos de mediciones. Se obtuvo como modelo de calibración para la temperatura:

$$q = 1,021 + 84,84 \cdot e_N; \quad (3.2)$$

con un error máximo del modelo del 1,9 %. En el Anexo 9 se ofrece el resumen de la obtención del modelo de calibración de la temperatura de la zona de corte. En la Figura 3.3, se muestra el esquema general de la instalación.

3.2 – Diseño experimental.

Como se estableció en el Capítulo 2, el diseño experimental seleccionado para el conjunto principal fue el fraccional completo de tres niveles. Los valores correspondientes a los niveles, fueron establecidos de acuerdo a las recomendaciones de los fabricantes de la herramienta y la literatura especializada [Sandvik, 1994]. En la Tabla 3.2 se muestran los valores para los tres niveles de cada uno de los factores experimentales.

Tabla 3.2 – Valores de los factores experimentales.

Factor experimental	Niveles		
	Mínimo	Medio	Máximo
Profundidad de corte, a_p [mm]	0,50	1,25	2,00
Avance, f [mm/rev]	0,15	0,25	0,35
Velocidad de corte, V [m/min]	200	250	300

Para el conjunto de validación se tomaron los niveles intermedios, tal como se estableció en el Capítulo 2. Dichos valores se muestran en la Tabla 3.3. En el caso del avance, los valores no corresponden exactamente a los niveles medios, debido a limitaciones de la gama de avances del torno.

Tabla 3.3 – Valores de los factores experimentales para el conjunto de validación.

Factor experimental	Niveles	
	Mínimo	Máximo
Profundidad de corte, a_p [mm]	0,88	1,62
Avance, f [mm/rev]	0,19	0,31
Velocidad de corte, V [m/min]	225	275

Finalmente, los puntos del conjunto de comprobación se seleccionan de forma aleatoria dentro de los rangos admisibles para las variables y teniendo en cuenta las posibilidades de la máquina-herramienta. En la Tabla 3.4 se muestran sus valores.

Tabla 3.4 – Valores de los factores experimentales para el conjunto de comprobación.

Factor experimental	Puntos del conjunto			
	Pto. 1	Pto. 2	Pto. 3	Pto. 4
Profundidad de corte, a_p [mm]	1,90	1,15	1,40	0,70
Avance, f [mm/rev]	0,31	0,23	0,28	0,17
Velocidad de corte, V [m/min]	270	285	230	245

3.3 – Análisis preliminar de los datos experimentales.

Tal como se estableció en el epígrafe 2.1.2, antes de proceder a la obtención de los modelos de vida útil de la herramienta, de fuerza axial y tangencial y de temperatura en la zona de corte, se realizó un análisis de normalidad a los datos experimentales, para detectar y eliminar posibles valores atípicos.

Los valores del desgaste de la herramienta se midieron a intervalos variables, que dependieron de la frecuencia de rotación del husillo y el avance. No obstante, siempre se trató de tener cierta regularidad en los mismos y de hacerlos más pequeños cuando el desgaste se acercaba al valor límite. En los Anexos 10 y 11 se muestran los valores de desgaste y los correspondientes gráficos para los puntos experimentales de los puntos de entrenamiento y los de validación..

El valor de la vida útil para punto experimental se tomó como el valor medio del rango de tiempo en el cual, la gráfica de desgaste medio cruza al valor límite (300 μm). El semirecorrido de este intervalo, se tomó como error máximo para punto experimental. En la Tabla 3.5, se muestran estos valores. Como puede verse, el error máximo no supera el 10%, lo cual es un valor perfectamente aceptable para este tipo de mediciones.

Tabla 3.5 – Valores medios y errores experimentales de la vida útil.

a_p [mm]	f [mm/rev]	V [m/min]	T_{MIN} [min]	T_{MAX} [min]	T_{MEDIA} [min]	DT [min]	Error [%]
<i>Conjunto principal</i>							
0,50	0,15	200	302,9	331,5	317,2	14,3	4,5%
0,50	0,15	250	145,4	153,8	149,6	4,2	2,8%
0,50	0,15	300	74,7	84,1	79,4	4,7	5,9%
0,50	0,25	200	213,9	226,4	220,2	6,3	2,8%
0,50	0,25	250	98,3	111,7	105,0	6,7	6,4%
0,50	0,25	300	49,1	55,6	52,4	3,3	6,2%
0,50	0,35	200	171,3	190,3	180,8	9,5	5,3%
0,50	0,35	250	73,9	83,4	78,7	4,8	6,0%
0,50	0,35	300	42,6	48,4	45,5	2,9	6,4%
1,25	0,15	200	185,5	208,4	197,0	11,5	5,8%
1,25	0,15	250	87,0	103,5	95,3	8,3	8,7%
1,25	0,15	300	48,7	54,8	51,8	3,1	5,9%
1,25	0,25	200	132,7	144,2	138,5	5,8	4,2%
1,25	0,25	250	62,6	70,0	66,3	3,7	5,6%
1,25	0,25	300	31,6	35,1	33,4	1,8	5,2%
1,25	0,35	200	104,6	115,2	109,9	5,3	4,8%
1,25	0,35	250	47,7	55,1	51,4	3,7	7,2%
1,25	0,35	300	25,1	28,2	26,7	1,6	5,8%
2,00	0,15	200	165,0	180,0	172,5	7,5	4,3%
2,00	0,15	250	66,4	78,9	72,7	6,3	8,6%
2,00	0,15	300	38,2	43,5	40,9	2,7	6,5%
2,00	0,25	200	119,5	129,8	124,7	5,2	4,1%
2,00	0,25	250	53,6	58,6	56,1	2,5	4,5%
2,00	0,25	300	28,6	33,2	30,9	2,3	7,4%
2,00	0,35	200	89,1	98,4	93,8	4,7	5,0%
2,00	0,35	250	39,3	47,9	43,6	4,3	9,9%
2,00	0,35	300	22,3	23,9	23,1	0,8	3,5%
<i>Conjunto de validación</i>							
0,88	0,19	225	128,7	138,5	133,6	4,9	3,7%
0,88	0,19	275	64,2	72,2	68,2	4,0	5,9%
0,88	0,31	225	87,6	98,4	93,0	5,4	5,8%
0,88	0,31	275	46,2	52,0	49,1	2,9	5,9%
1,62	0,19	225	101,7	112,9	107,3	5,6	5,2%
1,62	0,19	275	49,3	55,1	52,2	2,9	5,6%
1,62	0,31	225	65,0	73,8	69,4	4,4	6,3%
1,62	0,31	275	33,1	36,7	34,9	1,8	5,2%

Tabla 3.5 – Valores medios y errores experimentales de la vida útil (continuación).

a_p [mm]	f [mm/rev]	V [m/min]	T_{MIN} [min]	T_{MAX} [min]	T_{MEDIA} [min]	DT [min]	Error [%]
<i>Conjunto de comprobación</i>							
1,90	0,31	270	34,9	39,1	37,0	2,1	5,7%
1,15	0,23	285	42,1	48,3	45,2	3,1	6,9%
1,40	0,28	230	75,6	80,5	78,1	2,5	3,1%
0,70	0,17	245	118,6	129,7	124,2	5,6	4,5%

Los valores de las componentes principal (tangencial) y de avance (axial) de la fuerza corte, se determinaron filtrando y promediando las señales tomadas durante los experimentos. De cada registro se tomaron los valores correspondientes a un segundo.

En las Tablas 3.6 y 3.7 se muestran los valores medios de las mediciones de fuerza de corte principal y la de avance, respectivamente, para las tres réplicas de cada punto experimental

Tabla 3.6 – Valores experimentales de la componente tangencial de la fuerza de corte.

a_p [mm]	f [mm/r.]	V [m/min]	F_C [N]			F_{C-MED}	$S(F_C)$	t_{MIN}	t_{MAX}
			Rép.1	Rép. 2	Rép. 3				
Conjunto principal									
0,50	0,15	200	130	150	140	140	10,0	1,00	1,00
0,50	0,15	250	120	110	90	107	15,3	1,09	0,87
0,50	0,15	300	100	90	110	100	10,0	1,00	1,00
0,50	0,25	200	180	190	170	180	10,0	1,00	1,00
0,50	0,25	250	150	160	190	167	20,8	0,80	1,12
0,50	0,25	300	190	170	180	180	10,0	1,00	1,00
0,50	0,35	200	270	280	290	280	10,0	1,00	1,00
0,50	0,35	250	240	290	250	260	26,5	0,76	1,13
0,50	0,35	300	240	260	270	257	15,3	1,09	0,87
1,25	0,15	200	290	300	320	303	15,3	0,87	1,09
1,25	0,15	250	310	270	280	287	20,8	0,80	1,12
1,25	0,15	300	350	310	280	313	35,1	0,95	1,04

Tabla 3.6 – Valores experimentales de la componente tangencial de la fuerza (cont.).

a_p [mm]	f [mm/r.]	V [m/min]	F_C [N]			F_{C-MED}	$S(F_C)$	t_{MIN}	t_{MAX}
			Rép.1	Rép. 2	Rép. 3				
Conjunto principal (continuación)									
1,25	0,25	200	450	430	420	433	15,3	0,87	1,09
1,25	0,25	250	440	400	410	417	20,8	0,80	1,12
1,25	0,25	300	430	480	410	440	36,1	0,83	1,11
1,25	0,35	200	630	590	580	600	26,5	0,76	1,13
1,25	0,35	250	590	600	570	587	15,3	1,09	0,87
1,25	0,35	300	620	610	590	607	15,3	1,09	0,87
2,00	0,15	200	600	520	570	563	40,4	1,07	0,91
2,00	0,15	250	520	470	510	500	26,5	1,13	0,76
2,00	0,15	300	440	510	490	480	36,1	1,11	0,83
2,00	0,25	200	1130	1040	940	1037	95,0	1,02	0,98
2,00	0,25	250	820	900	940	887	61,1	1,09	0,87
2,00	0,25	300	850	860	900	870	26,5	0,76	1,13
2,00	0,35	200	1370	1440	1240	1350	99,5	1,08	0,89
2,00	0,35	250	1090	1110	1140	1113	25,2	0,93	1,06
2,00	0,35	300	920	990	1070	993	75,1	0,98	1,02
Conjunto de validación									
0,88	0,19	225	230	200	210	213	15,3	0,87	1,09
0,88	0,19	225	230	220	210	220	10,0	1,00	1,00
0,88	0,31	225	360	410	380	383	25,2	0,93	1,06
0,88	0,31	275	340	360	380	360	20,0	1,00	1,00
1,62	0,19	225	490	480	510	493	15,3	0,87	1,09
1,62	0,19	275	460	440	430	443	15,3	0,87	1,09
1,62	0,31	225	840	800	780	807	30,6	0,87	1,09
1,62	0,31	275	710	740	750	733	20,8	1,12	0,80
Conjunto de comprobación									
1,90	0,31	270	930	920	950	933	15,3	0,87	1,09
1,15	0,23	285	360	350	380	363	15,3	0,87	1,09
1,40	0,28	230	570	540	580	563	20,8	1,12	0,80
0,70	0,17	245	150	140	170	153	15,3	0,87	1,09

Tabla 3.7 – Valores experimentales de la componente axial de la fuerza de corte.

a_p [mm]	f [mm/r.]	V [m/min]	F_F [N]			F_{F-MED}	$S(F_F)$	t_{MIN}	t_{MAX}
			Rép.1	Rép. 2	Rép. 3				
<i>Conjunto principal</i>									
0,50	0,15	200	110	100	100	103	5,8	0,58	1,15
0,50	0,15	250	70	70	70	70	0,0	-	-
0,50	0,15	300	50	50	60	53	5,8	0,58	1,15
0,50	0,25	200	140	140	140	140	0,0	-	-
0,50	0,25	250	110	110	110	110	0,0	-	-
0,50	0,25	300	100	110	110	107	5,8	1,15	0,58
0,50	0,35	200	220	230	230	227	5,8	1,15	0,58
0,50	0,35	250	180	170	170	173	5,8	0,58	1,15
0,50	0,35	300	150	150	150	150	0,0	-	-
1,25	0,15	200	230	240	230	233	5,8	0,58	1,15
1,25	0,15	250	200	190	190	193	5,8	0,58	1,15
1,25	0,15	300	190	190	180	187	5,8	1,15	0,58
1,25	0,25	200	330	330	340	333	5,8	0,58	1,15
1,25	0,25	250	290	270	290	283	11,5	1,15	0,58
1,25	0,25	300	250	270	250	257	11,5	0,58	1,15
1,25	0,35	200	460	480	480	473	11,5	1,15	0,58
1,25	0,35	250	410	420	390	407	15,3	1,09	0,87
1,25	0,35	300	370	360	350	360	10,0	1,00	1,00
2,00	0,15	200	430	460	450	447	15,3	1,09	0,87
2,00	0,15	250	340	360	340	347	11,5	0,58	1,15
2,00	0,15	300	290	300	280	290	10,0	1,00	1,00
2,00	0,25	200	840	840	850	843	5,8	0,58	1,15
2,00	0,25	250	600	590	610	600	10,0	1,00	1,00
2,00	0,25	300	510	510	500	507	5,8	1,15	0,58
2,00	0,35	200	1090	1030	1080	1067	32,1	1,14	0,73
2,00	0,35	250	770	810	740	773	35,1	0,95	1,04
2,00	0,35	300	610	580	570	587	20,8	0,80	1,12
<i>Conjunto de validación</i>									
0,88	0,19	225	140	170	170	160	17,3	1,15	0,58
0,88	0,19	275	160	130	140	143	15,3	0,87	1,09
0,88	0,31	225	270	280	310	287	20,8	0,80	1,12
0,88	0,31	275	210	240	250	233	20,8	1,12	0,80
1,62	0,19	225	390	370	350	370	20,0	1,00	1,00
1,62	0,19	275	280	280	290	283	5,8	0,58	1,15

Tabla 3.7 – Valores experimentales de la componente axial de la fuerza (cont.).

a_P [mm]	f [mm/r.]	V [m/min]	F_F [N]			F_{F-MED}	$S(F_F)$	t_{MIN}	t_{MAX}
			Rép.1	Rép. 2	Rép. 3				
Conjunto de validación (cont.)									
1,62	0,31	225	610	600	610	607	5,8	1,15	0,58
1,62	0,31	275	460	480	480	473	11,5	1,15	0,58
Conjunto de comprobación									
1,90	0,31	270	600	590	620	603	15,3	0,87	1,09
1,15	0,23	285	220	230	230	227	5,8	1,15	0,58
1,40	0,28	230	440	400	410	417	20,8	0,80	1,12
0,70	0,17	245	100	90	110	100	10,0	1,00	1,00

Como se puede ver, tanto en las observaciones de la componente tangencial de la fuerza de corte, como en los de la componente axial, los valores máximo y mínimo del estadígrafo t , calculados para cada punto experimental, no supera el valor de 1,15, establecido como máximo por la norma para grupos de tres valores. Por lo tanto, se puede concluir que no hay valores anormales entre estos datos.

También los valores de temperatura en la zona de corte se determinaron tomando una muestra de un segundo, de la señales registradas para cada una de las tres réplicas. Al igual que para la fuerza, las señales fueron filtradas.

En el Anexo 13 se ofrecen los valores de las termo-FEM para las tres réplicas de cada punto experimental y sus correspondientes valores de temperatura, determinados según la calibración previamente realizada. En la Tabla 3.8, se muestran los valores de dichas temperaturas, con el respectivo análisis de anormalidad.

Como se puede ver en dicha tabla, los valores máximo y mínimo del estadístico t están por debajo de 1,15, por lo que se puede afirmar que no existen valores anormales en el conjunto de datos experimentales de la temperatura en la zona de corte para ninguno de los conjuntos tomados.

Tabla 3.8 – Valores experimentales de la temperatura de la zona de corte.

a_p [mm]	f [mm/r.]	V [m/min]	q [N]			q_{MED}	$S(q)$	t_{MIN}	t_{MAX}
			Rép.1	Rép. 2	Rép. 3				
<i>Conjunto principal</i>									
0,50	0,15	200	647	665	628	647	18,5	0,99	1,01
0,50	0,15	250	714	747	752	738	20,6	0,69	1,15
0,50	0,15	300	842	825	782	816	30,9	0,83	1,11
0,50	0,25	200	764	756	739	753	12,8	0,86	1,10
0,50	0,25	250	887	927	917	910	20,8	0,80	1,12
0,50	0,25	300	951	922	894	922	28,5	1,01	0,99
0,50	0,35	200	895	883	887	888	6,1	1,09	0,87
0,50	0,35	250	1041	991	1063	1032	36,9	0,85	1,10
0,50	0,35	300	1151	1099	1128	1126	26,1	0,96	1,04
1,25	0,15	200	728	712	702	714	13,1	1,07	0,91
1,25	0,15	250	789	843	808	813	27,4	1,08	0,89
1,25	0,15	300	870	901	851	874	25,2	1,07	0,91
1,25	0,25	200	840	844	843	842	2,1	0,80	1,12
1,25	0,25	250	972	1011	1041	1008	34,6	0,95	1,04
1,25	0,25	300	1011	1067	1057	1045	29,9	0,74	1,14
1,25	0,35	200	976	924	942	947	26,4	1,09	0,88
1,25	0,35	250	1110	1171	1098	1126	39,1	1,14	0,72
1,25	0,35	300	1137	1130	1195	1154	35,7	1,15	0,67
2,00	0,15	200	865	824	846	845	20,5	0,97	1,02
2,00	0,15	250	933	911	918	921	11,2	1,10	0,86
2,00	0,15	300	955	941	1005	967	33,6	1,13	0,77
2,00	0,25	200	938	885	879	901	32,5	1,15	0,67
2,00	0,25	250	1097	1047	1107	1084	32,1	0,73	1,14
2,00	0,25	300	1158	1113	1066	1112	46,0	0,99	1,01
2,00	0,35	200	1083	1051	994	1043	45,1	0,89	1,08
2,00	0,35	250	1186	1181	1179	1182	3,6	1,11	0,83
2,00	0,35	300	1237	1307	1245	1263	38,3	1,15	0,68
<i>Conjunto de validación</i>									
0,88	0,19	225	773	799	815	796	21,2	0,91	1,07
0,88	0,19	275	909	926	960	932	26,0	1,09	0,87
0,88	0,31	225	951	1011	994	985	30,9	0,83	1,11
0,88	0,31	275	1121	1087	1095	1101	17,8	1,13	0,79
1,62	0,19	225	832	841	875	849	22,7	1,13	0,76
1,62	0,19	275	994	917	951	954	38,6	1,04	0,96

Tabla 3.8 – Valores experimentales de la temperatura de la zona de corte (cont.).

a_p [mm]	f [mm/r.]	V [m/min]	q [N]			q_{MED}	$S(q)$	t_{MIN}	t_{MAX}
			Rép.1	Rép. 2	Rép. 3				
Conjunto de validación									
1,62	0,31	225	977	994	1002	991	12,8	0,86	1,10
1,62	0,31	275	1129	1206	1163	1166	38,6	1,04	0,96
Conjunto de comprobación									
1,90	0,31	270	1189	1104	1112	1135	46,9	1,15	0,66
1,15	0,23	285	994	968	985	982	13,2	0,88	1,09
1,40	0,28	230	1019	1011	1053	1028	22,3	1,14	0,75
0,70	0,17	245	765	782	790	779	12,8	0,86	1,10

3.4 - Conclusiones parciales del Capítulo.

A lo largo del desarrollo del Capítulo, se ha podido arribar a las conclusiones siguientes:

1. La instalación experimental utilizada tiene características adecuadas a las necesidades de la investigación, y todos los instrumentos empleados tienen niveles de errores máximos aceptables.
2. La calibración establecida para la medición de la fuerza y la temperatura permite obtener los valores de estas magnitudes a partir de las correspondientes señales eléctricas, con un error aceptablemente pequeño.
3. Los datos de vida útil, las componentes principal y de avance de la fuerza de corte, y de temperatura en la zona de corte, obtenidos a través del estudio experimental, poseen valores lógicos y están, con un nivel de confiabilidad aceptable, libres de observaciones anormales.

CAPÍTULO 4

Estudio de un Caso de Aplicación

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

4.1 – Planteamiento del caso de estudio.

Como primer caso a estudiar, se desea seleccionar los regímenes de corte óptimos, para un proceso de cilindrado de semiacabado del escalón extremo del eje del centro rotacional de la centrífuga continua Silver-Asea (ver Fig. 4.1), la cual se elabora en la Empresa de Reparaciones TANACEN, del Ministerio del Azúcar.




Fig. 4.1 – Croquis del escalón considerado en el caso de estudio.

La operación se llevará a cabo en el torno universal 16K20 y utilizando cuchilla TNMG 22 04 08-PM montada sobre un vástago PTG NR 2525M (ver Anexos 4 y 5), ambos producidos por *Sandvik Coromant*.

4.2 – Modelación de las variables que intervienen en el proceso.

Como se estableció, en el Capítulo 2, como paso previo a la optimización del proceso de torneado, es necesario contar con modelos matemáticos fiables de ciertas variables que intervienen en el proceso de corte. En nuestro caso concreto, las variables a modelar son: vida útil de la herramienta, las componentes principal (tangencial) y de avance (axial) de la fuerza de corte, y la temperatura de la zona de corte. Las cuatro variables fueron modeladas con el modelo combinado propuesto en el Capítulo 2, comparando su precisión, con la ofrecida, independientemente, por los tres modelos que lo integran. Los datos experimentales para la modelación, fueron determinados como se explicó en el Capítulo 3.

4.2.1 – Modelación de la vida útil de la herramienta.

Para el ajuste del modelo de regresión estadística de la vida útil de la herramienta con respecto a la profundidad de corte, al desgaste y a la velocidad de corte, se utilizó el programa *Statgraphics Plus 5.0*. Se realizó una regresión múltiple con las cuatro variables (tres independientes y una dependiente) logaritmizadas, obteniéndose el siguiente modelo:

$$T = \frac{5,485 \cdot 10^9}{a_p^{0,4598} \cdot f^{0,6963} \cdot V^{3,4556}} \quad (4.1)$$

En el Anexo 14, se ofrece el resumen estadístico del modelo. Como el valor de probabilidad asociado a la tabla ANOVA, es menor que 0,01, se puede afirmar que hay una relación estadísticamente significativa entre las variables, con un nivel de confiabilidad del 99 %. El valor de R^2 garantiza que el modelo ajustado explica más del 99 % de la variabilidad en $\ln(T)$. Por su parte, el análisis de la sensibilidad de los coeficientes muestra que todos los términos de la expresión tienen influencia estadísticamente significativa, con un nivel de confiabilidad del 99 %.

Según se observa en los gráficos de residuales contra predicciones y de observaciones contra predicciones (ver Figuras A14.1 y A14.2 del Anexo 14), los residuales siguen una distribución regular alrededor de la línea cero, sin mostrar ninguna tendencia significativa.

Por su parte, la implementación y el entrenamiento de las redes neuronales de los modelos, se llevó a cabo en el programa Matlab 6.0 (R12). Tal como se estableció en el Capítulo 2, para la selección de los parámetros estructurales y de entrenamiento de la red, se empleó el método de Tagushi. En la sección A15.1 del Anexo 15, se muestran los elementos de la selección de los parámetros de la red. A través del arreglo ortogonal indicado, se estudia la influencia de los factores considerados, en los objetivos de diseño (el error cuadrático medio de las predicciones de la red y su capacidad de generalización).

A través de esta selección, se determinaron como mas convenientes los siguientes valores: velocidad de aprendizaje: 0,1; constante de momento: 0,1; cantidad de iteraciones: 45000; y cantidad de neuronas en la capa oculta: 4. Con estos parámetros de construyó la red MLP utilizada en la modelación de la vida útil. En la sección A15.2 del citado Anexo 15, se muestra la evolución del error cuadrático medio durante el entrenamiento (ver Fig. A15.1). También se observan los gráficos de residuales y observaciones contra predicciones (ver Fig. A15.2 y A15.3), de donde se deduce que el modelo tiene un buen ajuste y sus residuales están uniforme y aleatoriamente distribuidos alrededor de cero, tanto para los datos de entrenamiento como para los de validación.

Por último, en la sección A15.3 del Anexo 15, se muestra el código de la red entrenada, programado en *Visual Basic for Applications*.

Para la determinación de los parámetros más convenientes en la red RBF, también se utilizó el método de Tagushi. En la sección A16.1 de Anexo 16 se muestran los elementos de dicha selección. De análisis gráfico de la influencia de los factores en los

objetivos de diseño, se seleccionan los valores más convenientes para ellos; estos son: dispersión de la red: 1,5; y error máximo a obtener: 0,005 .

La red implementada con los parámetros anteriores, alcanzó el error deseado al cabo de 10 iteraciones. En la figura A16.1 se muestra el registro del proceso de entrenamiento. Como se puede ver en las Fig. A16.2 y A16.3, del propio Anexo 16, la distribución de los residuales del modelo no tiene ninguna tendencia reconocible, si bien se nota una mayor dispersión para el conjunto de validación comparado con el de entrenamiento. Esto evidencia cierta pérdida en la capacidad de generalización de este modelo. En la sección A16.3, se ofrece el código de la red entrenada.

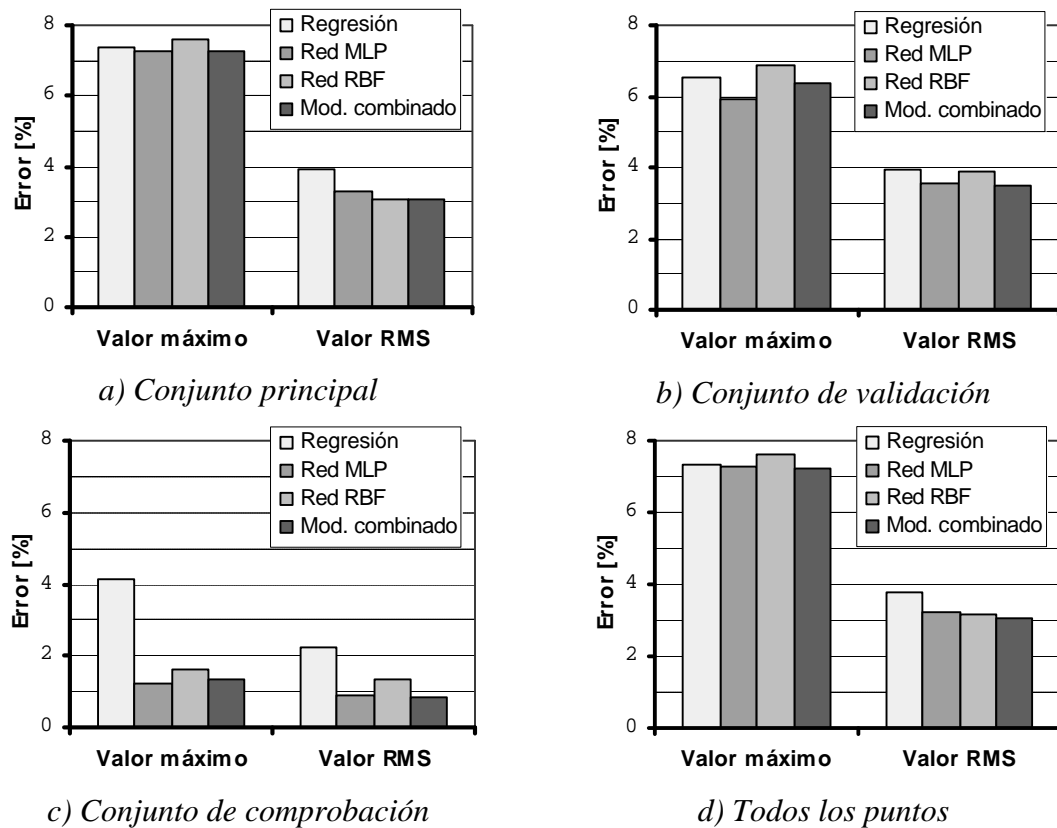


Fig. 4.2 – Representación gráfica de los errores máximo y cuadrático medio para los modelos de la vida útil de la herramienta.

Con los tres modelos anteriormente ajustados, se estableció el modelo combinado para la vida útil, cuyo código se ofrece en el Anexo 17. En las Tablas A18.1 – A18.3, del Anexo 18, se muestran los errores absolutos y relativos para los puntos experimentales de los conjuntos principal, de validación y de comprobación. En la Figura 4.2 se muestra una representación gráfica de los valores máximo y cuadrático medio de dichos errores.

Como se puede ver, el modelo combinado mejora los resultados de los otros modelos, globalmente considerados, presentando un error máximo del 7,2 % y un error cuadrático medio del 3,0 %, para todos los puntos analizados.

4.2.2 – Modelación de la componente tangencial de la fuerza de corte.

El modelo de regresión, obtenido para la componente tangencial de la fuerza de corte, quedó de la forma:

$$F_C = \frac{6555 \cdot a_p^{1,095} \cdot f^{0,9167}}{V^{0,2857}}. \quad (4.2)$$

En el Anexo 19, se muestran el resumen del análisis estadístico del modelo obtenido. El valor de probabilidad asociado al estadígrafo F de Fisher, es menor que 0,01, por lo cual existe una relación estadísticamente significativa entre las variables, con un coeficiente de confiabilidad del 99 %. El valor de R^2 indica que el modelo ajustado explica más del 97 % de la variabilidad de la variable estudiada. Los valores de probabilidad asociado a los estadígrafos t , de cada término de la regresión, indican que todos son significativos con un 99 % de confiabilidad.

En las Figura 18.1 y 18.2 del propio Anexo, se muestran los gráficos de residuales y observaciones vs. predicciones del modelo. Como se puede observar en ellos, el modelo tiene un buen ajuste y los residuales están aleatoriamente distribuidos alrededor de cero.

La selección de los parámetros para la red MLP se realizó tal como se muestra en la sección A20.1, del Anexo 20, siendo de forma análoga al modelo de la vida útil. Los valores seleccionados para cada factor de diseño fueron: velocidad de aprendizaje: 0,5; constante de momento: 0,1; número de iteraciones: 45000 y cantidad de neuronas en la capa oculta: 3.

En la Figura A20.1 del propio Anexo 20, se muestra el gráfico del proceso de entrenamiento de la red seleccionada, observándose que, a pesar de ciertas inestabilidades momentáneas, hay convergencia del proceso.

En las Figuras A20.2 y A20.3, del mismo Anexo, se muestran los gráficos de residuales y de observaciones contra predicciones para la red MLP. Como se puede ver, el modelo tiene buen ajuste y una correcta distribución de los residuales, tanto para el conjunto principal como para el de validación. Finalmente, en la sección A20.3, se ofrece el código de la red entrenada.

Para la selección de los parámetros de la red RBF también se empleó el método de Tagushi, tal como se muestra en la sección A21.1 del Anexo 21, seleccionándose los siguientes parámetros: coeficiente de dispersión: 1,25; y error máximo deseado: 0,005.

La red constituida con dichos parámetros, alcanzó el error fijado al cabo de 14 iteraciones (ver Fig. A21.1 del Anexo 21). La Fig. A21.2 del propio anexo muestra una adecuada distribución de los residuales, aunque con mayor dispersión para el conjunto de validación que para el de entrenamiento. Esto, al igual que en la vida útil, puede reflejar cierta merma en la capacidad de generalización de la red.

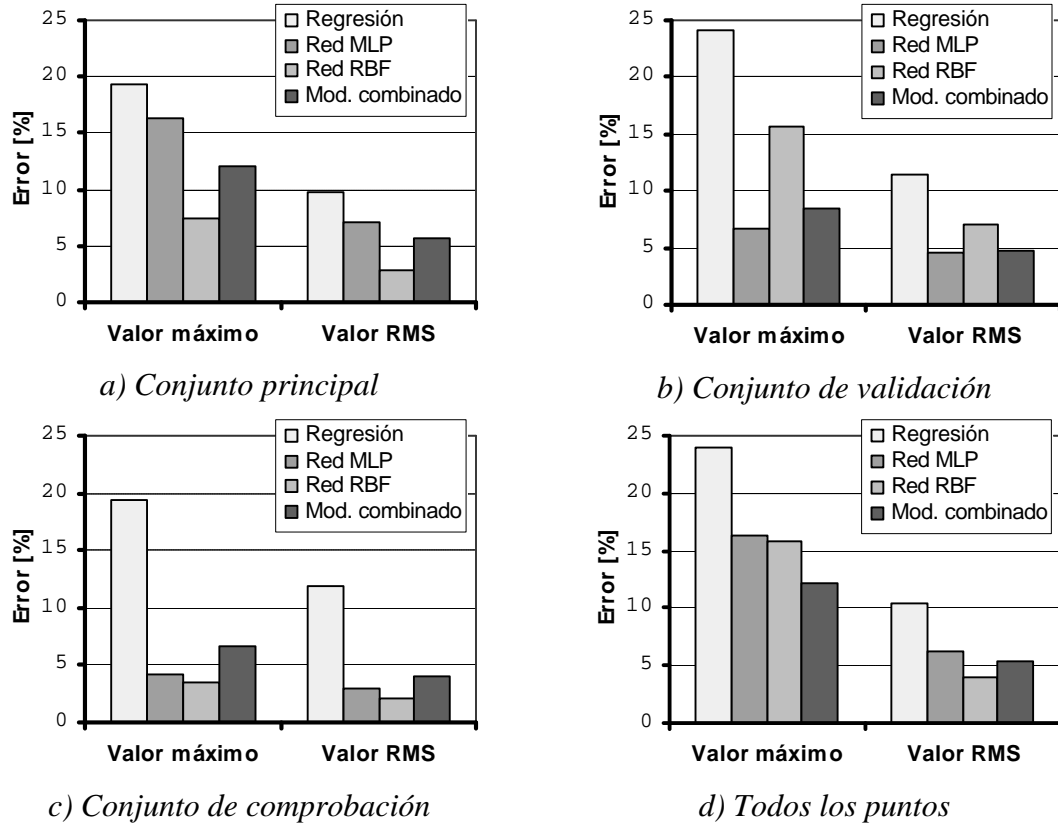


Fig. 4.3 – Representación gráfica de los errores máximo y cuadrático medio para los modelos de la componente principal (tangencial) de la fuerza de corte.

En el Anexo 22 se muestra el código del modelo combinado para la fuerza tangencial, construido a partir de los tres modelos anteriores. En el Anexo 23, se ofrecen los valores predichos por los modelos para los diversos conjuntos considerados. La comparación de los gráficos de error (ver Fig. 4.3) muestra que el modelo combinado mejora sensiblemente la calidad de la predicciones, siendo el único de los modelos considerados cuyo error está por debajo del 10% para todos los puntos analizados. Es también el que menor error medio cuadrático muestra para todos los conjuntos.

4.2.3 – Modelación de la componente axial de la fuerza de corte.

Para la componente de avance de la fuerza de corte, se obtuvo el siguiente modelo de regresión estadística, cuyos detalles se muestran en el Anexo 24:

$$F_F = \frac{243044 \cdot a_p^{1,120} \cdot f^{0,9444}}{V^{1,005}}. \quad (4.3)$$

Dado valor de probabilidad mostrado en la tabla de ANOVA, es menor que 0,01, se puede decir que existe una relación estadísticamente significativa entre las variables, con un coeficiente de confiabilidad del 99 %. El valor de R^2 indica que el modelo ajustado explica más del 97 % de la variabilidad de la variable estudiada, mientras que los valores de probabilidad asociado a los estadígrafos t , de cada término de la regresión, garantizan que todos son significativos con un 99 % de confiabilidad.

Para la red MLP se determinó el valor más conveniente de sus parámetros tal como se vio para la vida útil y la fuerza tangencial. En el Anexo 25 se muestra el resumen del método de Tagushi aplicado a este caso. Los valores de los factores de diseño considerados resultaron: velocidad de aprendizaje: 0,5; constante de momento: 0,1; número de iteraciones: 45000; y cantidad de neuronas en la capa oculta: 5.

Con los parámetros anteriores, se implementó y entrenó la red utilizada para modelar la componente de avance de la fuerza. En la Fig. A25.1, del Anexo 25, se muestra la gráfica del error durante el proceso de entrenamiento. En las Fig. A25.2 y A25.3 se observa que el modelo tiene un buen ajuste y una adecuada distribución de los residuales. En la sección A25.3 se ofrece el código de la red entrenada.

Del proceso de selección de los parámetros para la red RBF (ver sección A26.1 del Anexo 26), resultaron los siguientes valores: coeficiente de dispersión: 1,1; y error máximo a obtener: 0,005. La red así implementada alcanzó el error señalado luego de 13 iteraciones (ver Fig. A26.1).

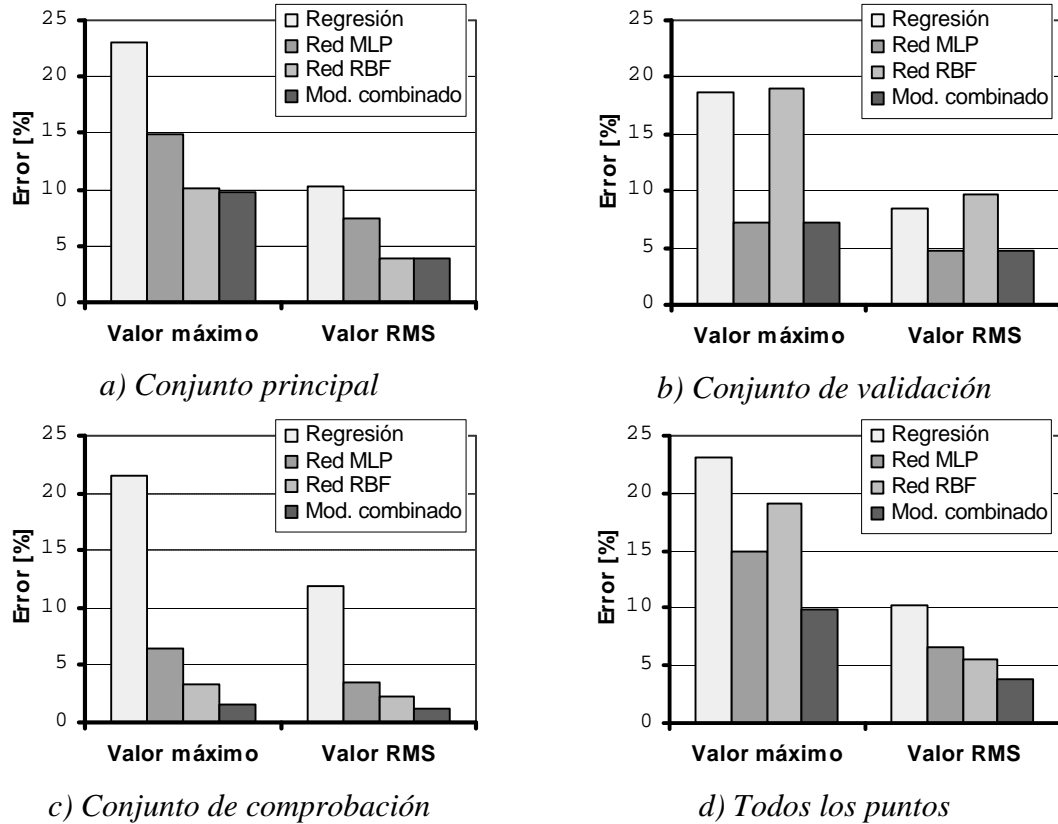


Fig. 4.4 – Representación gráfica de los errores máximo y cuadrático medio para los modelos de la componente de avance (axial) de la fuerza de corte.

Según se observa en las Fig. A26.2 y A26.3, el modelo se ajusta bien a los datos, pero con cierta dispersión en los residuales del conjunto de validación, lo cual, a igual que en los modelos RBF de la vida útil y de la fuerza tangencial, es indicio de una capacidad de generalización no totalmente satisfactoria.

Por último, se implementó el modelo combinado a partir de los hasta aquí obtenidos, y cuyo código se muestra en el Anexo 27. En el Anexo 28 se ofrecen los valores predichos por los modelos de fuerza axial para cada punto de los tres conjuntos considerados. Como se puede observar en la Fig. 4.4, el modelo combinado es superior a los otros, estando el error de sus predicciones por debajo del 10% en todos los casos estudiados.

4.2.4 – Modelación de la temperatura en la zona de corte.

Luego de análisis de regresión estadística de los datos de temperatura en la zona de corte, se obtuvo el siguiente modelo:

$$q = 92,94 \cdot a_p^{0,1243} \cdot f^{0,3367} \cdot V^{0,5063}; \quad (4.4)$$

el cual posee un coeficiente de ajuste R^2 de 0,9396. El valor de probabilidad asociado al estadístico F-Fisher, en la tabla de ANOVA del modelo, garantiza una relación estadísticamente significativa entre las variables, con un nivel de confiabilidad del 99%. También con el mismo nivel de confiabilidad se observa, del análisis de sensibilidad de los coeficientes, que todos los factores del modelos son estadísticamente significativos.

En el Anexo 29 se muestra el resumen estadístico del modelo. Los residuales (ver. Fig. A29.1) están distribuidos uniforme y aleatoriamente, alrededor de cero, sin evidenciar ninguna tendencia.

Los elementos más importantes del proceso de selección de los valores de los parámetros de la red MLP, utilizada para modelar la temperatura, se ofrecen en la sección A30.1 del Anexo 30. Luego de la aplicación del método de Tagushi, se obtuvieron los siguientes valores: velocidad de aprendizaje: 0,3; constante de momento: 0,9; número de iteraciones: 5000; y cantidad de neuronas en la capa oculta: 3. El gráfico del proceso de entrenamiento de la red finalmente seleccionada se muestra en la Fig. A30.1.

Como se puede observar en las Fig. A30.1 y A30.2, del propio Anexo 30, el modelo basado en la red MLP tiene un buen ajuste y una adecuada distribución de los residuales tanto para el conjunto de entrenamiento como para el de validación. En la sección A30.3, del citado Anexo 30, se ofrece el código de programación de la red entrenada.

Por su parte, para la red RBF, luego del proceso de selección (ver sección A31.1, del Anexo 31), se obtuvieron los siguientes parámetros: coeficiente de dispersión: 1,15; y error máximo a alcanzar: 0,006. La red entrenada con estos valores, alcanzó el error establecido en 20 iteraciones (ver Fig. A31.1 Anexo 31). El modelo tiene buen ajuste y

una distribución adecuada de los residuales (Fig. A31.2 y A31.3, Anexo 31), aunque se evidencia mayor dispersión en los residuales del conjunto de validación que en los del conjunto de entrenamiento. Esto coincide con el comportamiento de las restantes redes RBF ajustadas, y evidencia una capacidad de generalización no tan buena como sería de desear. En la sección A31.3 del Anexo 31 se muestra el código de la red entrenada.

Con los tres modelos se implementó el modelo combinado cuyo código se ofrece en el Anexo 32. En el Anexo 33 se muestran los valores calculados por los modelos para los tres conjuntos analizados (principal o de entrenamiento, de validación y de comprobación). En la Fig. 4.5 se ofrece una representación gráfica de los errores máximo y cuadrático medio de todos los modelos para los tres conjuntos y para todos los puntos considerados simultáneamente.

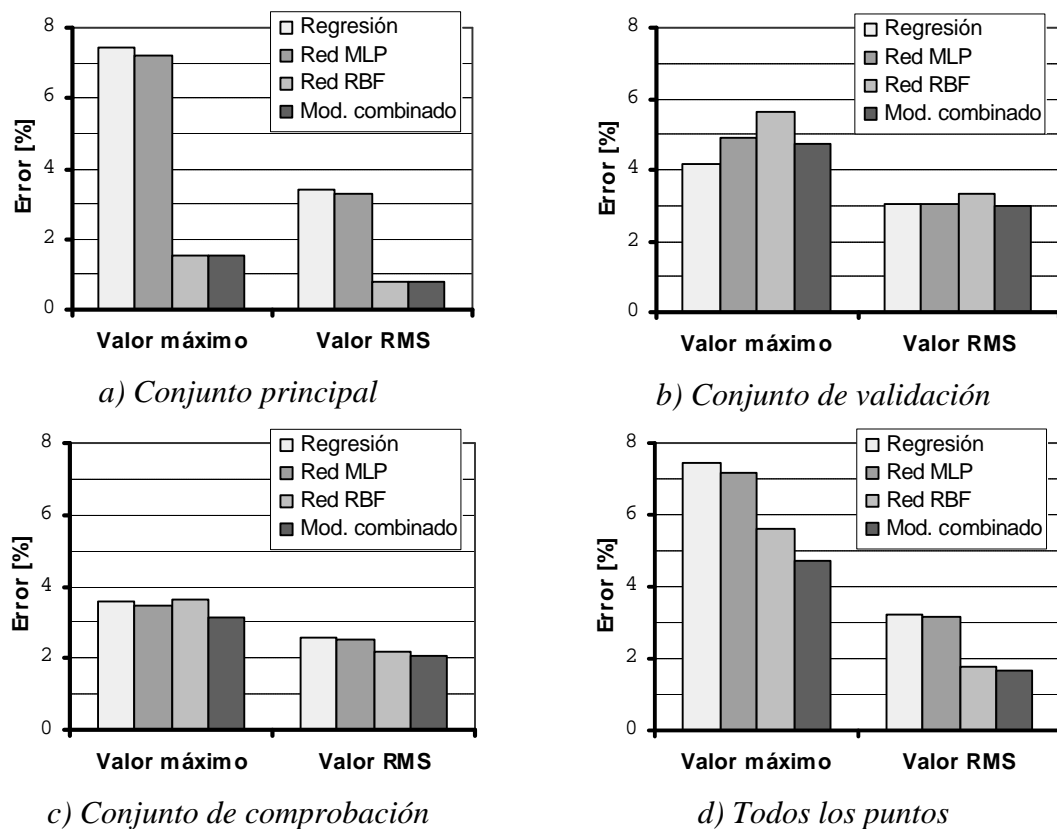


Fig. 4.5 – Representación gráfica de los errores máximo y cuadrático medio para los modelos de la temperatura en la zona de corte.

Como se puede observar, el comportamiento del modelo combinado es mejor que el de los otros, siendo él único cuyo error no supera el 5% para ninguno de los puntos estudiados.

4.3 – Selección de los datos.

Los datos necesarios para desarrollar el proceso de optimización se obtuvieron de diferentes fuentes. Del plano de la pieza a elaborar, se determinaron las dimensiones y requisitos técnicos que intervienen en la elaboración del escalón considerado: diámetro final: $d = 70$ mm; longitud a maquinar: $L = 155$ mm; y rugosidad superficial mínima deseada: $Ra = 3,2$ μm ($Rz = 15$ μm).

Del catálogo del torno 16K20, se obtuvieron la potencia del motor $P_{MOT} = 10$ kW; la eficiencia de la transmisión $\eta = 75$ %; la fuerza máxima admisible por el mecanismo de avance $F_{F-MAX} = 6000$ N; la gama de revoluciones del husillo $n_M = 12,5 \dots 2000$ r.p.m.; y la gama de avances longitudinales $f_M = 0,05 \dots 0,70$ mm/rev.

El rango de los parámetros de corte admisibles para la herramienta, se determinó teniendo en cuenta la validez de los modelos obtenidos en el subtópico anterior. Estos rangos fueron: $a_{P-H} = 0,5 \dots 2$ mm; $f_H = 0,15 \dots 0,35$ mm/rev; y $V_H = 200 \dots 300$ m/min. El resto de los datos necesarios de la herramienta son: ángulo de posición principal $\beta = 90^\circ$; dimensiones del vástago $b_{VAS} = 25$ mm y $h_{VAS} = 25$ mm; longitud del voladizo de la cuchilla $l_{VOL} = 45$ mm.

Los datos económicos necesarios fueron suministrados por la empresa TANACEN: salario del operario (mecánico de taller A), $z_{SAL} = 254,02$ CUP/mes; precio de la placa TNMG 22 04 08-PM, $z_{HER} = 2,35625$ USD; tarifa eléctrica, $z_{EL} = 0,068$ CUP/(kW-h);

valor de la máquina-herramienta, $z_{MAQ} = 3305,22$ CUP; tiempo de vida útil para la máquina herramienta, $T_{MAQ} = 10$ años.

4.4 – Establecimiento de las restricciones.

Como el caso de estudio considera una operación de semiacabado, sólo hay que tener en cuenta las restricciones asociadas con la flecha de la punta de la cuchilla y con la rugosidad superficial. La temperatura en la zona de corte no se incluyó entre las restricciones porque, según se puede ver en el modelo obtenido, su valor siempre es menor que el admisible por la herramienta utilizada.

4.5 – Ejecución de la optimización.

Para llevar a cabo el proceso de optimización, propiamente dicho, se implementó el algoritmo genético propuesto, en una hoja de cálculo de Microsoft Excel, definiendo las subrutinas correspondientes.

La profundidad de corte, por tratarse de una pasada de semiacabado, se tomó según recomiendan Kosilova *et al.* [1985] como 0,5 mm. El tiempo auxiliar se tomó como 1,3 min, según se indica para operaciones de una sola pasada en superficies de 30 a 100 mm de diámetro y de 100 hasta 500 mm de longitud.

Para desarrollar el proceso de evolución se definieron las poblaciones estáticas y dinámicas, de 150 y 25 individuos respectivamente. Dichos individuos fueron inicializados estableciendo aleatoriamente su valores de avance y frecuencia de rotación del husillo, tal como se indica en las expresiones (2.20b) y (2.20c). El proceso de cálculo, evaluación, cruzamiento, mutación y selección, se llevó a cabo durante 15 iteraciones, al

final de las cuales se obtuvieron 10 puntos no dominados cuyos parámetros de corte se ofrecen en la Tabla 4.1 .

Tabla 4.1 – Régimen de corte para los puntos no dominados con gama continua.

Punto	a_p [mm/rev]	f [mm/rev]	n [r.p.m.]	V [m/min]	F_C [N]	F_F [N]	P_C [kW]
1	0,5	0,3	915	201	228	180	0,76
2	0,5	0,3	958	211	222	171	0,78
3	0,5	0,3	1002	220	217	163	0,80
4	0,5	0,3	1060	233	214	153	0,83
5	0,5	0,3	1105	243	212	147	0,86
6	0,5	0,3	1151	253	211	141	0,89
7	0,5	0,3	1201	264	210	136	0,93
8	0,5	0,3	1248	274	210	132	0,96
9	0,5	0,3	1312	289	213	128	1,02
10	0,5	0,3	1354	298	215	125	1,07

En la Tabla 4.2 se muestran los valores de las principales variables del proceso para los puntos óptimos determinados, incluyendo las funciones objetivos: vida útil consumida, x , y tiempo total de elaboración, t_T .

Tabla 4.2 – Variables del proceso para los puntos no dominados.

Punto	R_z [μm]	T [min]	x [%]	t [min]	t_A [min]	t_{CH} [min]	t_T [min]
1	14,1	195,6	0,29	0,56	1,30	0,00	1,87
2	14,1	162,3	0,33	0,54	1,30	0,00	1,84
3	14,1	141,3	0,37	0,52	1,30	0,00	1,82
4	14,1	115,6	0,42	0,49	1,30	0,00	1,79
5	14,1	99,5	0,47	0,47	1,30	0,00	1,77
6	14,1	85,9	0,52	0,45	1,30	0,00	1,75
7	14,1	71,0	0,58	0,43	1,30	0,00	1,73
8	14,1	59,6	0,64	0,41	1,30	0,01	1,72
9	14,1	54,6	0,72	0,39	1,30	0,01	1,70
10	14,1	49,2	0,77	0,38	1,30	0,01	1,69

4.6 – Análisis de los resultados.

Para facilitar el análisis de los resultados estos se muestran en forma gráfica. En primer lugar, los puntos no dominados, obtenidos en la optimización, se grafican en coordenadas de vida útil consumida contra tiempo. Este gráfico es, en realidad, la representación de la frontera de Pareto obtenida.

Como se puede observar en la primera de ellas, en los diversos puntos no dominados obtenidos, se presentan diferentes relaciones entre los objetivos de optimización. Aquí, el punto 10 corresponde al régimen más productivo (menor tiempo de elaboración por unidad), pero también es donde el consumo de herramientas es mayor. Este punto (u otro cercano a él), es el adecuado para situaciones que requieran una producción acelerada, tales como emergencias nacionales o compromisos comerciales que deben cumplirse a un determinado plazo.




Fig. 4.6 – Gráfico de la frontera de Pareto para la variante con gama continua.

Por otra parte, el punto 1 corresponde al régimen de mayor ahorro de herramientas de corte y, por consiguiente, de mayores tiempos de elaboración. Este régimen es el más conveniente si los talleres no tienen contenido de trabajo para toda la jornada o si las herramientas de corte fueran excesivamente caras o deficitarias.

El resto de los puntos son casos intermedios, entre los cuales podría buscarse un compromiso razonable entre los dos objetivos a optimizar. Por supuesto, este compromiso dependerá no sólo de consideraciones de costo propiamente dichas, sino también de otras como la disponibilidad de tiempo y personal, la fiabilidad del suministro de herramientas, el tipo de moneda (nacional o divisa) en que se paga cada uno de los componentes del costo, etc.

Las condiciones de trabajo de la empresa TANACEN se caracterizan por el pago en divisas de las herramientas de corte, mientras que el resto de los costos se paga en moneda nacional. Además, el contenido de trabajo no obliga a una productividad excesivamente elevada. Por tanto, se debe seleccionar un punto razonablemente cercano la derecha de la frontera de Pareto, donde el consumo de herramientas sea bajo, aunque esto se logre a expensas de un aumento del tiempo de elaboración.

Como la gama de velocidades del husillo de la máquina utilizada es escalonada, la posibilidad de selección se reduce sólo dos puntos de la curva: tres y ocho (los cuales se muestran destacados en la Fig. 4.6), que corresponden a las frecuencias de rotación de 1000 y 1250 r.p.m. De ellos, el más conveniente es el punto tres porque, de acuerdo a lo visto en el párrafo anterior, está más cerca del extremo derecho de la frontera de Pareto.

Además, si se comparan el gasto de herramientas y el tiempo de elaboración en los puntos 3 y 8, se ve que en el primero se produce un ahorro del 43 % del consumo de herramientas de corte, y esto se logra a costa de un aumento del tiempo de elaboración de sólo un 6 %.

En la Tabla 4.3 se muestran los valores de los parámetros de corte y las principales variables del proceso de corte para el punto seleccionado (punto 3) una vez que se recalcula para la frecuencia de rotación real que permite la máquina (1000 r.p.m.).

Tabla 4.3 – Régimen de corte y variables del proceso para el óptimo seleccionado.

a_p [mm/rev]	f [mm/rev]	n [r.p.m.]	V [m/min]	F_C [N]	F_F [N]	P_C [kW]
0,5	0,2	1000	220	218	163	0,80
R_z [μm]	T [min]	x [%]	t [min]	t_A [min]	t_{CH} [min]	t_T [min]
14,1	142,3	0,36	0,52	1,30	0,00	1,82

4.7 – Análisis económico.

Para evaluar la factibilidad económica de la solución brindada por el algoritmo de optimización propuesto, se comparó el costo total de la operación considerada en el caso de estudio con el régimen seleccionado en el epígrafe anterior y con el costo de la misma empleando el régimen actualmente en uso en la empresa y que fue determinado por técnicas convencionales.

Tabla 4.3 – Comparación de la variante de régimen de corte propuesta y la actual.

Parámetro	Variante Propuesta	Variante Actual
Profundidad de corte [mm]	0,5	0,5
Avance [mm/rev]	0,3	0,2
Revoluciones del husillo [r.p.m.]	1000	315
Velocidad de corte [m/min]	219,9	69,3
Vida útil de la herramienta [min]	142,3	90
Tiempo de maquinado [min]	0,52	2,46
Tiempo auxiliar [min]	1,30	1,30
Tiempo de cambio de herramienta [min]	0,00	0,09
Tiempo total [min]	1,82	3,85
Vida útil consumida [%]	0,36	2,73
Costo de salario [\$]	0,0401	0,0849
Costo de electricidad [\$]	0,0005	0,0008
Costo de amortización [\$]	0,0047	0,0100
Costo subtotal en moneda nacional [\$]	0,0453	0,0957
Costo de herramientas [\$]	0,0094	0,0212
Costo subtotal en divisa [\$]	0,0094	0,0212
Costo total [\$]	0,0547	0,1169

En el Anexo 34, se muestra el cálculo de los componentes del costo de la operación, tanto para la variante actual como para la propuesta como resultado de este trabajo. En la Tabla 4.4 se muestra el resumen de dicho análisis, destacando los principales indicadores.

Como se puede ver, la variante propuesta implica un ahorro del 53 % en los costos de la operación. En la figura 4.7 se muestra una gráfica de los costos destacando las componentes en moneda nacional y en divisa.




Fig. 4.7 – Representación gráfica del análisis de costos.

Como se puede observar, la variante propuesta trae consigo una significativa reducción de los costos, tanto si se consideran globalmente, como si se analizan sus componentes en moneda nacional y en divisa. En base a lo anterior, queda garantizada la factibilidad económica de la variante propuesta.

4.8 – Conclusiones parciales del Capítulo.

Mediante el desarrollo del estudio de caso, llevado a cabo en este Capítulo, se ha podido arribar a las siguientes conclusiones:

1. El modelo combinado ha demostrado su eficacia en la modelación de la vida útil de la herramienta, las componentes tangencial y axial de la fuerza de corte y la temperatura en la zona de corte. La precisión mostrada por el mismo supera a las de la regresión estadística y las redes MLP y RBF por separado.
2. El algoritmo de optimización propuesto permite obtener un conjunto de puntos no dominados para aproximar la frontera de Pareto, en la optimización multi-objetivos del proceso de torneado.
3. Entre las bondades del algoritmo genético empleado se encuentran la eficacia en el tratamiento de las restricciones, el mantenimiento de la capacidad de generalización y la habilidad para tratar con variables discretas.
4. A partir de la representación gráfica del conjunto de puntos no dominados, obtenidos como resultado de la optimización, y teniendo en cuenta los costos de la operación, se puede realizar una adecuada toma de decisiones, que refleje las condiciones propias y los intereses de las diferentes instalaciones industriales.
5. El análisis económico prueba la factibilidad de la variante seleccionada como resultado de la optimización, frente a la utilizada actualmente y que fue determinada mediante técnicas convencionales.

CONCLUSIONES

Al culminar el presente trabajo, se pudo arribar a las siguientes conclusiones:

1. El modelo combinado propuesto, mejora sensiblemente la precisión de las predicciones de desgaste, la fuerza de corte y la temperatura en la zona de corte y, por tanto, tiene una influencia positiva sobre los resultados de la optimización.
2. El esquema de optimización propuesto, permite considerar dos objetivos diferentes y mutuamente conflictivos: el consumo de herramientas y el tiempo de elaboración, realizando la toma de decisiones desde el enfoque *a posteriori*.
3. El algoritmo genético implementado permite obtener un conjunto de puntos no dominados, que representen la frontera de Pareto como conjunto de los óptimos del espacio de búsqueda. En esta obtención mostró ser capaz de sortear, exitosamente, las dificultades que presenta trabajar en un sistema con variables discretas y múltiples restricciones.
4. Los resultados de la optimización, presentados en forma de gráfico de Pareto, permiten realizar la toma de decisiones con facilidad y teniendo en cuenta las diversas condiciones practicas que se pueden presentar en la industria.

RECOMENDACIONES

Derivadas del trabajo, se tienen las siguientes recomendaciones:

1. Desarrollar mayor cantidad de estudios de casos para crear una base de datos de modelos entrenados que permitan la aplicación del modelo combinado sin necesidad de recurrir a la fase experimental.
2. Crear una aplicación informática que permita realizar el ajuste del modelo combinado, sin tener que recurrir a software externo como *Matlab* o *Statgraphics*.
3. Analizar la aplicación del esquema de optimización propuesto a otros procesos de corte como el fresado o el taladrado.

BIBLIOGRAFÍA

- 1 Abbass, H.A., 2000, “The self-adaptive Pareto differential evolution algorithm” [online], *Congress on Evolutionary Computation*, Piscataway, NJ (USA), Vol. **1**, pp. 831 – 836, [citado: 2-ago-2003], disponible en Internet en <http://www.cs.adfa.edu.au/~abbass/publications/hardcopies/CEC-SPDE-02.pdf>.
- 2 Abbass, H.A., Sarker, R. y Newton, C., 2001, “PDE: A Pareto-frontier differential evolution approach for multi-objective optimization problems” [online], *Congress on Evolutionary Computation*, Piscataway, NJ (USA), Vol. **2**, pp. 971 – 978, , [citado: 2-ago-2003], disponible en Internet en <http://www.jeo.org/emo/abbass01.pdf.gz>.
- 3 Ahmad, N. y Anwarul Haque, A.F.M., 2001, “Optimization of process planning parameters for rotational components by genetic algorithms” [online], *4th Int. Conference on Mechanical Engineering*, Dhaka (Bangladesh), Vol. **VII**, pp. 227 – 233, [citado: 6-nov-2003], disponible en Internet en: <http://www.buet.ac.bd/ipe/nafris/cv.pdf>.
- 4 Alfonso, E., 2002, “Apuntes sobre la interrelación composición – microestructura – propiedades del acero”. *Monografías 2002* [cd-rom]. Matanzas: Universidad de Matanzas. ISBN 959-16-0188-3.
- 5 Altan, T.; Fallböhmer, P.; Rodríguez, C.A. y Özel, T., 1998, “High-speed cutting of cast iron and alloy steels - state of research” [online], *CIRP-VDI Conference on High-Performance Tools*, Düsseldorf (Germany), pp. 309-330, [citado: 12-ene-

- 2001], disponible en Internet en: <<http://www.rci.rutgers.edu/~ozel/pdf/cirp-vdi-98.pdf>>.
- 6 Amiolemhen, E. y Ibadode, A.O.A., 2004, “Application of genetic algorithms – determination of the optimal machining parameters in the conversion of a cylindrical bar stock into a continuous finished profile”, *International Journal of Machine Tools and Manufacture* **44** (12 - 13), pp. 1403 - 1412.
 - 7 António, C.A.C. y Davim, P.J., 2002, “Optimal cutting conditions in turning of particulate metal matrix composites based on experiment and a genetic search model”, *Composites Part A: Applied Science and Manufacturing* **33** (2), pp. 213 - 219.
 - 8 Armarego, E.J.A.; Verezub, S. y Samaranayake, P., 2002, “The effect of coatings on the cutting process, friction, forces and predictive cutting models in machining operations”, *Proceedings of the Institution of Mechanical Engineering* **216** (B), pp. 347 - 356.
 - 9 Arshinov, V.A. y Alekseev, G.A., 1979, *Metal cutting theory and cutting tool design*, 4th Ed., Moscú (Rusia): Mir Publishers.
 - 10 Benardos, P.G. y Vosniakos, G.C., 2003, “Predicting surface roughness in machining: a review”, *International Journal of Machine Tools & Manufacture* **43**, pp. 833 - 844.
 - 11 Bhaskara Reddy, S.V.; Shunmugam, M.S. y Narendran, T.T., 1998, “Optimal sub-division of the depth of cut to achieve minimum production cost in multi-pass

- turning using a genetic algorithm”, *Journal of Materials Processing Technology* **79** (1 - 3), pp. 101 - 108.
- 12 Bil, H.H.; Kiliç, N.E. y Tekkaya, A.E., 2004, “A comparison of orthogonal cutting data from experiments with three different finite element models”, *International Journal of Machine Tools and Manufacture* **44** (9), pp. 933 - 944.
- 13 Bullinaria, J., 2003, *Introduction to neural computation* [online], Birmingham (UK): University of Birmingham [citado 15-sep-2003], disponible en la Internet: <http://www.cs.bham.ac.uk/~jxb/inc.html>.
- 14 Cakir, M.C. y Gurarda, A., 1998, "Optimization and graphical representation of machining conditions in multi-pass turning operations", *Computer Integrated Manufacturing Systems*, **11** (3), pp. 157 - 170.
- 15 CEN (Comité Estatal de Normalización), 1985, NC 11-81: Máquinas Herramientas. Tornos paralelos de cilindrar y roscar. Verificación de la precisión y la rigidez.
- 16 CEN (Comité Estatal de Normalización), 1979, NC 92-21: Control de la calidad. Procedimiento para evaluar la anormalidad de los resultados de las observaciones
- 17 Ceretti, E.; Lazzaroni, C.; Menegardo, L. y Altan, T., 2000, “Turning simulations using a three-dimensional FEM code”, *Journal of Material Processing Technology* **98**, pp. 99 - 103.

-
- 18 Chao, P.Y. y Hwang, Y.D., 1997, "An improved neural network model for the prediction of cutting tool life", *Journal of Intelligent Manufacturing* **8**, pp. 107 - 115.
- 19 Chen, S.H.; Chou, J.H. y Li, J.J., 2002, "Optimal grey-fuzzy controller design for a constant turning force system", *International Journal of Machine Tools & Manufacture* **42**, pp. 343 - 455.
- 20 Chien, W.T. y Tsai, C.S., 2003, "The investigation on the prediction of tool wear and the determination of optimum cutting conditions in machining 17-4PH stainless steel", *Journal of Material Processing Technology* **140** (1 - 3), pp. 340 - 345.
- 21 Chou, Y.K., 2003, "Hard turning of M50 steel with different microstructures in continuous and intermittent cutting", *Wear* **255**, pp. 1388 - 1394.
- 22 Chua, M.S.; Loh, H.T.; Wong, Y.S. y Rahman, M., 1991, "Optimization of cutting conditions for multi-pass turning operations using sequential quadratic programming", *Journal of Materials Processing Technology* **28** (1 - 2), pp. 253 - 262.
- 23 Coello, C.A., 2000, "Treating constraints as objectives for single-objective evolutionary optimization", *Engineering Optimization* **32** (3), pp. 275 - 308.
- 24 Croitoru, C.; Severincu, M. y Belous, V., 2001, "A solution for the multi-criteria optimisation of the cutting process" [online], *Buletinul Institutului Politehnic din Iasi XLVII* (LI), pp. 83 - 90, [citado: 5-mar-2002], disponible en Internet en <<http://athena.mt.tuiasi.ro/icms/papers/2k1014.pdf>>.

-
- 25 Cus, F.; Balic, J., 2003, "Optimization of cutting process by GA approach", *Robotics and Computer Integrated Manufacturing* **19**, pp. 113 - 121.
- 26 Dan, L. y Mathew, J., 1990, "Tool wear and failure monitoring techniques for turning: a review", *International Journal of Machine Tools & Manufacture* **30**, pp. 579 - 598.
- 27 Davim, J.P., 2003, "Design of optimization of cutting parameters for turning metal matrix composites based on the orthogonal arrays", *Journal of Material Processing Technology* **132**, pp. 340 - 344.
- 28 Deb, K.; Agrawal, S.; Pratab, A. y Meyarivan, T., 2000, *A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization: NSGA-II* [online], KanGAL Report 200001, Kanpur (India): Indian Institute of Technology, [citado: 23-may-2001], disponible en Internet en <<http://www.lania.mx/~ccoello/EMOO/deb00.ps.gz>>.
- 29 Dereli, T. y Filiz, I.H., 1999, "Optimisation of process planning functions by genetic algorithms", *Computers & Industrial Engineering* **36**, pp. 281 - 308.
- 30 Dereli, T.; Filiz, I.H. y Baykasoglu, A., 2001, "Optimizing cutting parameters in process planning of prismatic parts by using genetic algorithms", *International Journal of Production Research* **39** (15), pp. 3303 - 3328.
- 31 D'Errico, G.E., 1997, "A systems theory approach to modelling of cutting temperature with experimental identification", *Composites Part A: Applied Science and Manufacturing* **33** (2), pp. 213-219.

-
- 32 Devillez, A.; Lesko, S. y Mozerc, W., 2004, "Cutting tool crater wear measurement with white light interferometry", *Wear* **256**, pp. 56 - 65.
- 33 Dodier, R.H. y Henze, G. P., 2004, "Statistical analysis of neural networks as applied to building energy prediction", *Journal of Solar Energy Engineering* **126**, pp. 1 - 9.
- 34 Dolinšek, S. y Kopac, J., 1999, "Acoustic emission signals for tool wear identification", *Wear* **225 - 229**, pp. 295 - 303.
- 35 Dolinšek, S.; Šuštaršič, B. y Kopac, J., 2001, "Wear mechanisms of cutting tools in high-speed cutting processes", *Wear* **250**, pp. 349 - 356.
- 36 Elanayar, S. y Shin, Y.C., 1995, "Robust tool wear estimation with radial basis function neural networks", *Journal of Dynamic Systems, Measurement and Control* **117**, pp. 459 - 467.
- 37 El-Gallab, M. y Sklad, M., 2000, "Machining of Al/SiC particulate metal matrix composites part III: comprehensive tool wear models", *Journal of Materials Processing Technology* **101** (1 - 3), pp. 10-20.
- 38 Ezugwu, E.O.; Arthur, S.J. y Hines, E.L., 1995, "Tool-wear prediction using artificial neural networks", *Journal of Material Processing Technology* **49**, pp. 255 - 264.

-
- 39 Fallböhmer, P.; Rodríguez, C.A.; Özel, T. y Altan, T., 2002, “High-speed machining of cast iron and alloy steels for die and mold manufacturing”, *Journal of Material Processing Technology* **98**, pp. 104 - 115.
- 40 Flexer, A., 1996, “Statistical evaluation of neural network experiments: minimum requirements and current practices”, *13th European Meeting on Cybernetics and Systems Research*, Vienna (Austria), pp. 1005 - 1008.
- 41 Galante, G.; Lombardo, A. y Passannanti, A., 1998, “Tool-life modelling as a stochastic process”, *International Journal of Machine Tools and Manufacture* **38** (10 - 11), pp. 1361 - 1369.
- 42 Gero, J.S. y Kazarov, V., 2001, “A genetic engineering approach to genetic algorithms”, *Evolutionary Computation* **9** (1), pp. 71 - 92.
- 43 Haber, R.E.; Alique, J.R.; Alique, A.; Hernández, J. y Uribe-Etxebarria, R., 2003, “Embedded fuzzy-control system for machining processes: Results of a case study”, *Computers in Industry* **50**, pp. 353 - 366.
- 44 Herreros, A., 2000, *Diseño de controladores robustos multiobjetivo por medio de algoritmos genéticos* [online], Tesis Doctoral, Valladolid (España): Universidad de Valladolid, [citado: 7-jun-2003], disponible en Internet en <http://www.lania.mx/~ccoello/EMOO/herreros_thesis.ps.gz>.
- 45 Huang, Y. y Liang, S.Y., 2003, “Cutting forces modeling considering the effect of tool thermal property - Application to CBN hard turning”, *International Journal of Machine Tools & Manufacture* **43**, pp. 307 - 315.

-
- 46 Ibnkahla, M., 2001, "Convergence properties and stationary points of the two-layer backpropagation algorithm used for non-linear function modeling", *International Joint Conference on Neural Networks*, Wanshington DC (USA).
- 47 Jawahir, I.S.; Ghosh, R.; Balaji, A.K. y Li, P.X., 2000, "Predictability of tool failure modes in turning with complex grooved tools using the equivalent toolface (ET) model", *Wear* **244**, pp. 94 - 103.
- 48 Jae-Wong, Y. y Min-Yang, Y., 2001, "A study of the relationship between static/dynamic cutting forces and tool wear", *Journal of Manufacturing Science and Engineering* 123 (2001) 196 - 205.
- 49 Jiménez, F.; Gómez-Skarmeta, A.F. y Sánchez, G., 2001, "Un algoritmo evolutivo para optimización multiobjetivo", *IX Conferencia de la Asociación Española para la Inteligencia Artificial*, Gijón (España).
- 50 Kalhori, V., 2001, *Modeling and simulation of mechanical cutting* [online], Doctoral Thesis, Luleå (Suecia): Luleå University of Technology, [citado: 20-nov-2002], disponible en Internet en <<http://epubl.luth.se/1402-1544/2001/28/LTU-DT-0128-SE.pdf>>.
- 51 Kayacan, M.C.; Filiz, I.H.; Sönmez, A.I.; Baykasoglu, A. y Dereli, T., 1996, "OPPS-ROT: An optimised process planning system for rotational parts", *Computers in Industry* **32**, pp. 181 - 195.

-
- 52 Ko, T.J. y Kim, H.S., 1998, “Autonomous cutting parameter regulation using adaptive modeling and genetic algorithms”, *Precision Engineering* **22** (4), pp. 243 - 251.
- 53 Kosilova, A.G. *et al.*, 1985, *Spravochnik tehnologa – mašinstroitelâ* [en ruso] Moscú: Mašinstroenie.
- 54 Kumar Jain, R. y Kumar Jain, V., 2000, “Optimum selection of machining conditions in abrasive flow machining using neural networks”, *Journal of Material Processing Technology* **108**, pp. 62 - 67.
- 55 Kurpati, A.; Azarm, S. y Wu, J., 2002, “Constraint handling improvement for multiobjective genetic algorithms”, *Structural and Multidisciplinary Optimization* **23**, pp. 204 - 213.
- 56 Lee, B.Y. y Tarng, Y.S., 2000, “Cutting-parameter selection for maximizing production rate or minimizing production cost in multistage turning operations”, *Journal of Materials Processing Technology* **105** (1 - 2), pp. 61 - 66.
- 57 Leiva, M.A., 2001, Localización óptima de condensadores en un sistema de distribución eléctrico vía algoritmos genéticos [online], Tesis de Grado, Santiago (Chile): Pontificia Universidad Católica de Chile, [citado 6-ene-2003], disponible en Internet en <<http://www2.ing.puc.cl/power/paperspdf/leivama.pdf>>.
- 58 Leyland, G., 2002, *Multi-objective optimization applied to industrial energy problems* [online], Doctoral Thesis, Lausanne (Suiza): École Polytechnique

- Fédérale de Lausanne, [citado: 1-abr-2004], disponible en Internet en: http://www.lania.mx/~ccoello/EMOO/leyland_thesis.pdf.gz.
- 59 Li, X., 2002, "A brief review: acoustic emission method for tool wear monitoring during turning", *International Journal of Machine Tools & Manufacture* **42**, pp. 157 - 165.
- 60 Li, X.; Djordjevich, A. y Venuvinod, P.K., 2000, "Current-sensor-based feed cutting force intelligent estimation and tool wear condition monitoring", *IEEE Transactions on Industrial Electronics* **47** (3), pp. 697 - 702.
- 61 Li, X. y Nee, A.Y.C., 1996, "Monitoring cutting conditions for tool scheduling in CNC machining", *Manufacturing Systems* **25**, pp. 377 - 383.
- 62 Li, X.P.; Ng, H.H. y Lim, S.C., 1999, "A predictive mapping system for tool wear in metal cutting", *Journal of Materials Processing Technology* **89 - 90**, pp. 279 - 286.
- 63 Liang, M.; Mgwatu, M. y Zuo, M., 2001, "Integration of cutting parameter selection and tool adjustment decisions for multipass turning", *International Journal of Advanced Manufacturing Technology* **17**, pp. 861 - 869.
- 64 Liew, W.Y.H.; Ngoi, B.K.A. y Lu, Y.G., 2003, "Wear characteristics of PCBN tools in the ultra-precision machining of stainless steel at low speeds", *Wear* **254**, pp. 265 - 277.

-
- 65 Lin, J.T.; Bhattacharyya, D. y Kecman, V., 2003, "Multiple regression and neural networks analyses in composites machining", *Composites Science and Technology* **63**, pp. 539 - 548.
- 66 Lin, Z.C. y Yarnag, Y.D., 1997, "Three-dimensional cutting process analysis with different cutting velocities", *Journal of Material Processing Technology* **70**, pp. 22 - 33.
- 67 Liu, X.L.; Wen, D.H.; Li, Z.J.; Xiao, L. y Yan, F.G., 2002, "Cutting temperature and tool wear of hard turning hardened bearing steel", *Journal of Materials Processing Technology* **129** (1 - 3), pp. 200 - 206.
- 68 MacGinley, T y Monaghan, J., 2001, "Modelling the orthogonal machining process using coated cemented carbide cutting tools", *Journal of Materials Processing Technology* **118** (1 - 3), pp. 293 - 300.
- 69 Mackerle, J., 2003, "Finite element analysis and simulation of machining: an addendum. A bibliography", *International Journal of Machine Tools & Manufacture* **43**, pp. 103 - 114.
- 70 Martínez, S., 1986, *Dinámica de Sistemas. Simulación por ordenador*, Madrid (España): Alianza Editorial, ISBN 84-206-0183-7, 185 p.
- 71 Marusich, T.D.; Thiele, J.D. y Brand, C.J., 2001, "Simulation and analysis of chip breakage in turning processes", *Technical Papers* [online], Third Wave Systems, Inc. [citado 11-nov-2003], disponible en la Internet en: <<http://www.thirdwavesys.com/chipbreaking.pdf>>.

-
- 72 Meng, Q; Arsecularatne, J. A. y Mathew, P., 2000, "Calculation of optimum cutting conditions for turning operations using a machining theory", *International Journal of Machine Tools and Manufacture* **40** (12), pp. 1709 - 1733.
- 73 Molinari, A. y Nouari, M., 2002, "Modeling of tool wear by diffusion in metal cutting", *Wear* **252**, pp. 135 - 149.
- 74 Moufki, A.; Devillez, A.; Dudzinski, D. y Molinari, A., 2004, "Thermomechanical modelling of oblique cutting and experimental validation", *International Journal of Machine Tools and Manufacture* **44** (9), pp. 971 - 989.
- 75 Muñoz, A., 1996, *Aplicación de Técnicas de Redes Neuronales Artificiales al Diagnóstico de Procesos Industriales* [online], Tesis Doctoral, Madrid (España): Universidad Pontificia Comillas de Madrid, [citado 4-abr-2004], disponible en Internet en <<http://www.iit.upco.es/wiit/T-Esp-ASI-Nov2000.pdf>>.
- 76 Nefiódov, N. y Osípov, K., 1980, Problemas y ejemplos de corte de metales y herramientas cortantes, Moscú: Editorial Mir.
- 77 Nian, C.Y.; Yang, W.S. y Tarng, Y.S., 1999, "Optimization of turning operations with multiple performance characteristics", *Journal of Materials Processing Technology* **95** (1 – 3), pp. 90 - 96.
- 78 Niranjan Prasad, K. y Ramamoorthy, B., 2001, "Tool wear evaluation by stereo vision and prediction by artificial neural network", *Journal of Material Processing Technology* **112**, pp. 43 - 52.

-
- 79 Oliveira, F.J.; Silva, R.F. y Vieira, J.M., 2003, "Improved wear resistance of Si₃N₄ tool inserts by addition of Al₂O₃ platelets", *Tribology International* **36**, pp 57 - 60.
- 80 Oraby, S. E. y Hayhurst, D. R., 2004, "Tool life determination based on the measurement of wear and tool force ratio variation", *International Journal of Machine Tools and Manufacture* **44** (12 - 13), pp. 1261 - 1269.
- 81 Oxley, P.L.B., 1989, *Mechanics of machining, an analytical approach to assessing machinability*, West Sussex (UK): Ellis Horwood Ltd.
- 82 Poulachon, G.; Moisan, A.; Jawahir, I., 2001, "Tool-wear mechanisms in hard turning with polycrystalline cubic boron nitride tools", *Wear* **250**, pp. 576 - 586.
- 83 Phadke, M. S., 2004, *Introduction To Robust Design (Taguchi Method)* [on-line], iSixSigma Magazine, [citado 20 de enero del 2004], disponible en el WWW en <http://www.isixsigma.com/library/content/c020311a.asp>.
- 84 Qi, H. S. y Mills, B., 2003, "Modelling of the dynamic tool–chip interface in metal cutting", *Journal of Materials Processing Technology* **138** (1 - 3), pp. 201 - 207.
- 85 Quiza, R. y Rivas, M., 2003, "Optimización del proceso de torneado mediante un método basado en algoritmos genéticos", *8va Convención Internacional de las Industrias Metalúrgica, Mecánica y del Reciclaje METANICA'2003* [cd-rom], La Habana, ISSN 1607-6281.
- 86 Quiza, R. y Rivas, M., 2004, "Selección de regímenes de corte para el torneado a través de optimización multiobjetivo", aceptado para publicación en *Centroazúcar*.

-
- 87 Raj, K.H.; Sharma, R.S.; Srivastava, S. y Patvardhan, C., 2000, "Modeling of manufacturing processes with ANNs for intelligent manufacturing", *International Journal of Machine Tools and Manufacture* **40** (6), pp. 851 - 868.
- 88 Ren, X.J.; Yang, Q.X.; James, R.D. y Wang, L., 2004, "Cutting temperatures in hard turning chromium hardfacings with PCBN tooling", *Journal of Materials Processing Technology* **147** (1), pp. 38 - 44.
- 89 Sánchez, G., 2002, *Diseño y evaluación de algoritmos evolutivos multiobjetivo en optimización y modelación difusa* [online], Tesis Doctoral, Murcia (España): Universidad de Murcia, [citado: 13-oct-2003], disponible en Internet en <http://www.jeo.org/emo/tesis_gracia.pdf.gz>.
- 90 Sandvik, 1994, *El mecanizado moderno - manual práctico*, 1ra Edición, Sandviken (Suecia): Sandvik Coromant, Dpto. de Ediciones Técnicas, ISBN 91-972299-2-X.
- 91 Saravanan, R.; Asokan, P. y Vijayakumar, K., 2003, "Machining parameters optimisation for turning cylindrical stock into a continuous finished profile using genetic algorithm (GA) and simulated annealing (SA)", *International Journal of Advanced Manufacturing Technology* **21**, pp. 1 - 9.
- 92 Shatla, M.; Kerk, C. y Altan, T., 2001, "Process modeling in machining. Part II: validation and applications of the determined flow stress data", *International Journal of Machine Tools and Manufacture* **41** (11), pp. 1659 - 1680.
- 93 Shaw, M.C., 1984, *Metal cutting principles - Oxford series in advanced manufacturing*, Oxford (UK): Oxford University Press, ISBN 0-19-859002-4.

-
- 94 Shiraish, M. y Aoshima, S., 1997, "Sensorless in-process measurement instantaneous depth of cutting forces in turning", *American Control Conference*, pp. 155 - 159.
- 95 Sick, B., 2002, "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* **16** (4), pp. 487 - 546.
- 96 Silva, R.G.; Baker, K.J.; Wilcox, S.J. y Reuben, R.L., 2000, "The adaptability of a tool wear monitoring system under changing cutting conditions", *Mechanical Systems and Signal Processing* **14** (2), pp. 287 - 298.
- 97 Soodamani, R. y Liu, ZQ., 2000, "GA-based learning for a model-based object recognition system", *International Journal of Approximate Reasoning* **23**, pp. 85 - 109.
- 98 Sönmez, A.I.; Baykasoglu, A.; Dereli, T. y Filiz, I.H., 1999, "Dynamic optimization of multipass milling operation via geometric programming", *International Journal of Machine Tools & Manufacture* **39**, pp. 287 - 320.
- 99 Stein, J.L. y Huh, K., 2002, "Monitoring cutting forces in turning: A model-based approach", *Journal of Manufacturing Science and Engineering* **124**, pp. 26 - 31.
- 100 Suresh, P.V.S.; Venkateswara Rao, P. y Deshmukh, S.G., 2002, "A genetic algorithms approach for optimization of surface roughness", *International Journal of Machine Tools & Manufacture* **42**, pp. 675 - 680.

-
- 101 Szecsi, T., 1999, "Cutting force modeling using artificial neural networks", *Journal of Material Processing Technology* **92 - 93**, pp. 344 - 349.
- 102 Taylor, F.W., 1907, "On the art of cutting metals", *Transactions of the ASME* **28**, pp. 310 - 350.
- 103 Toscano, G., 2001, *Optimización multiobjetivo usando un micro algoritmo genético* [online], Veracruz (México): Universidad Veracruzana, [citado: 23-oct-2003], disponible en Internet en http://delta.cs.cinvestav.mx/~ccoello/tesis/tesis_toscano.ps.gz
- 104 Van Veldhuizen, D.A. y Lamont, G.B., 2000, "Multiobjective evolutionary algorithms: analyzing the state-of-the-art", *Evolutionary Computation* **8** (2), pp. 125 - 147.
- 105 Vieira, D.A.G.; Adriano, R.L.S.; Krähenbühl, L. y Vasconcelos, J.A., 2002, "Handling constraints as objectives in a multiobjective genetic based algorithm", *Journal of Microwaves and Optoelectronics* **2** (6), pp. 50 - 58.
- 106 Vijayakumar, K.; Prabhakaran, G.; Asokan, P. y Saravanan, R., 2003, "Optimization of multi-pass turning operations using ant colony system", *International Journal of Machine Tools and Manufacture* **43** (15), pp. 1633 - 1639.
- 107 Vleugels, J.; Hari Kumar, K.C. y Van der Biest, O., 2001, "An experimental approach and the prediction of chemical wear by dissolution", *Third International Conference in Metal Cutting and High Speed Machining*, Metz (Francia), pp. 371 - 381.

-
- 108 Wang, J.; Kuriyagawa, T.; Wei, X.P. y Gou, G.M., 2002, "Optimization of cutting conditions using a deterministic approach", *International Journal of Machine Tools & Manufacture* **42**, pp. 1023 - 1033.
- 109 Wilkins, P.; McLachan, S.; Shelton, P. y Walker, M. , 1999, "Tool wear monitoring using the performance index method", *32th ISATA Conference: Simulation, Virtual Reality and Supercomputer Automotive Applications*, Viena (Austria), pp. 403 - 410.
- 110 Wong, T.; Kim, W. y Kwon, P., 2004, "Experimental support for a model-based prediction of tool wear", *Wear* **257** (7 - 8), pp. 790 - 798.
- 111 Yen, Y.-C.; Söhner, J.; Lilly, B. y Altan, T., 2004, "Estimation of tool wear in orthogonal cutting using the finite element analysis", *Journal of Materials Processing Technology* **146** (1), pp. 82 - 91.
- 112 Zeng, X.T.; Zhang, S. y Tang, L.S., 2001, "Multilayered (Ti, Al) ceramic coating for high-speed machining applications", *Journal of Vacuum Science and Technology* **19** (4), pp. 1919 - 1922.
- 113 Zhao, H.; Barber, GC. y Zou, Q., 2002, "A study of flank wear in orthogonal cutting with internal cooling", *Wear* **253**, pp. 957 - 962.
- 114 Zhou, J.M.; Walter, H.; Anderson, H. y Stahl, J.E., 2003, "Effect of chamfer angle on wear of PCBN cutting tool", *International Journal of Machine Tools & Manufacture* **43**, pp. 301 - 305.

- 115 Zuperl, U. y Cus, F., 2003, “Optimization of cutting conditions during cutting by using neural networks”, *Robotics and Computer Integrated Manufacturing* **19**, pp. 189 - 199.

Anexo 1 – Nomenclatura utilizada.

Nota: En la nomenclatura utilizada, los caracteres en **negrita** representan vectores, mientras los que están en *itálica*, variables escalares.

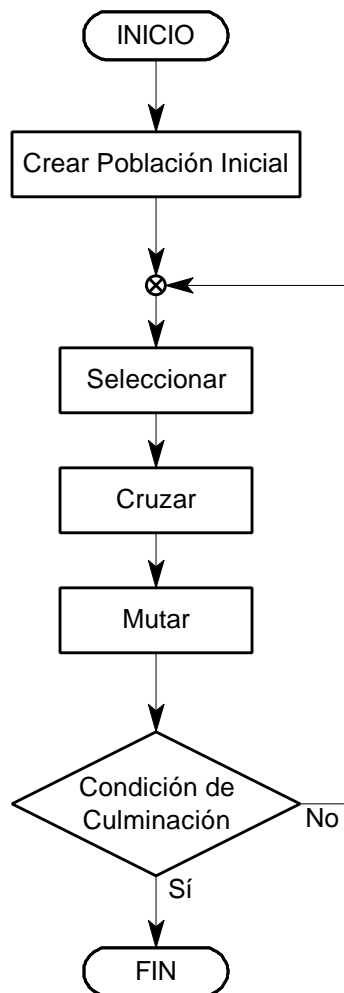
<i>a, b, g, d, e</i>	Exponentes de las expresiones empíricas basadas en regresiones estadísticas (incluyendo la Ley de Taylor).
<i>g_r</i>	Ángulo de ataque de la herramienta [grados].
<i>d_i</i>	Distancia de hacinamiento del i-ésimo individuo en la población del GA.
<i>d_{LIM}</i>	<i>Distancia límite de hacinamiento.</i>
<i>G</i>	Coefficiente de infactibilidad de un individuo en el AG.
<i>z</i>	Precisión de un determinado modelo dentro del modelo combinado [%].
<i>h</i>	Eficiencia de la transmisión del torno [%].
<i>q</i>	Temperatura en la zona de corte [°C].
<i>q_{H-MAX}</i>	Temperatura máxima admisible por el material de la herramienta [°C].
<i>l</i>	Ángulo de inclinación del filo de la herramienta [grados].
<i>x</i>	Vida útil consumida de la herramienta [%].
<i>m</i>	Vector de distancia normalizada de un punto del espacio de las variables de entrada o decisión.
<i>s_{ADM}</i>	Tensión máxima admisible por el material del vástago [MPa].
<i>t, t₀</i>	Tiempo de maquinado, total [min] y de una pasada [min].
<i>t_{CH}, t_{CH0}</i>	Tiempo de cambio del filo, total [min] y para un solo cambio [min].
<i>t_A</i>	Tiempo auxiliar de la operación [min].
<i>t_T</i>	Tiempo total de elaboración [min].
<i>j</i>	Ángulo de posición principal de la herramienta [grados].

Ψ_X	Aproximador funcional basado en el modelo combinado propuesto, implementado para la variable X .
w	Ponderación de un determinado modelo dentro del modelo combinado.
W	Conjunto de valores factibles dentro del espacio de búsqueda en un problema de optimización multiobjetivo.
a_P	Profundidad de corte [mm].
a_{P-H}	Rango de profundidades de corte admisibles por la herramienta.
$a_{P-H}^{MIN}, a_{P-H}^{MAX}$	Valor mínimo y máximo de la profundidad de corte admisible por la herramienta.
b_{VAS}	Ancho del vástago de la herramienta de sección rectangular [mm].
b_{o-i}	Predisposición (bias) del i -ésimo nodo oculto en las redes neuronales.
b_s	Predisposición (bias) del nodo de salida en las redes neuronales.
C, C'	Coeficientes de las expresiones empíricas basadas en regresiones estadísticas (incluyendo la Ley de Taylor).
d_0, d	Diámetro inicial y final de la transición a ejecutar [mm].
d_{VAS}	Diámetro del vástago de la herramienta de sección circular [mm].
f	Avance [mm/rev].
f_H	Rango de avance admisibles por la herramienta.
f_H^{MIN}, f_H^{MAX}	Valor mínimo y máximo del avance admisible por la herramienta.
f_M	Gama de avances del torno.
f_M^{MIN}, f_M^{MAX}	Valor mínimo y máximo del avance en tornos de gama continua.
f_M^i, Nf	i -ésimo valor y cantidad total de avances en tornos de gama discreta.
E	Módulo de elasticidad del material del vástago de la herramienta [MPa].
F_C, F_F	Componentes principal (tangencial) y de avance (axial) de la fuerza de corte [N].
F_{F-MAX}	Fuerza máxima admisible por el mecanismo de avance del torno [N].
$g_i(\mathbf{x})$	Restricción i -ésima en un problema de optimización multiobjetivo.

G	Cantidad de restricciones en un problema de optimización multiobjetivo.
h_{VAS}	Altura del vástago de la herramienta de sección rectangular [mm].
H	Dureza del material elaborado [HB, HRC].
$\mathbf{i}, \mathbf{j}, \mathbf{k}$	Vectores unitarios en las direcciones x , y y z , respectivamente.
J	Momento de inercia de la sección del vástago de la herramienta [mm ⁴].
k	Coefficiente de corrección de los modelos empíricos.
K_C	Cantidad de iteraciones en el algoritmo genético.
l_{VOL}	Longitud del voladizo de la herramienta [mm].
L	Longitud de la superficie a elaborar [mm].
L'	Longitud de entrada de la herramienta [mm].
L''	Longitud de salida de la herramienta [mm].
M	Cantidad de individuos de la población en un algoritmo evolutivo.
M^+, M_{MAX}^+	Cantidad de individuos en la población élite del AG; cantidad máxima de individuos en dicha población.
n	Frecuencia de rotación del husillo [r.p.m.].
n_M	Gama de frecuencias de rotación del husillo del torno.
n_M^{MIN}, n_M^{MAX}	Valor mínimo y máximo de la frecuencia de rotación del husillo en tornos de gama continua.
n_M^i, Nn	i -ésimo valor y cantidad total de frecuencias de rotación del husillo en tornos de gama discreta.
N_D	Cantidad de valores en cada conjunto de datos, bien sea principal, de validación o de comprobación.
N_P	Cantidad de pasadas.
P_C	Potencia de corte [kW].
P_{MOT}	Potencia del motor del torno [kW].
q_i	Elemento i -ésimo dentro de una población de un EA;
Q_i	Población dinámica de la i -ésima generación dentro del AG.

Q_{EST}, Q_{PAR}	Población estática y población élite o paretiana en el AG.
r	Radio de la punta de la herramienta [mm].
R	Rugosidad superficial de la superficie – elaborada [μm].
R_{MAX}	Rugosidad superficial máxima establecida como requisito técnico de la superficie elaborada [μm].
S^{PRI}, S^{VAL}	Distancias calculadas hasta el punto más cercano de los conjuntos principal y de validación.
T	Vida útil de la herramienta [min].
T_{MAQ}	Vida útil de la máquina-herramienta [años].
U_i	Cadena de codificación del i-ésimo individuo de la población en el AG.
V	Velocidad de corte [m/min].
V_H	Rango de velocidades de corte admisibles por la herramienta.
V_H^{MIN}, V_H^{MAX}	Valor mínimo y máximo de la velocidad admisible por la herramienta.
$w_{o-i,j}$	Pesos de las conexiones entre el j-ésimo nodo de entrada y el i-ésimo nodo oculto.
w_{s-i}	Peso de la conexión del i-ésimo nodo de salida con el nodo de la capa oculta.
W_F	Módulo en flexión de la sección de la herramienta de corte [mm^3].
W_E, W_O, W_S	Cantidad de nodos en las capas de entrada, oculta y de salida de una red neuronal.
x	Variable de entrada al sistema “inteligente” propuesto en la tesis. Valor de entrada a un nodo de la red neuronal.
\tilde{x}_i	Valor de la i-ésima entrada normalizada de las neuronas ocultas en la redes neuronales.
$x_{i,j}$	Valor de la j-ésima variable independiente del individuo i-ésimo de una población.

$\hat{x}_{i,j}$	Número correspondiente a cada variable j-ésima del individuo i-ésimo para la codificación en el AG.
X	Cantidad de variables independientes en un problema de optimización multiobjetivos.
y	Variable modelada por el sistema “inteligente” propuesto en la tesis.
\hat{y}_{o-i}	Valor de salida del i-ésimo nodo oculto de las red neuronal MLP.
\hat{y}_s, \hat{y}_s^i	Valor de salida del nodo de salida en las redes neuronales. Ídem para el i-ésimo ejemplo del conjunto de entrenamiento o validación.
y_s^i	Valor real del i-ésimo ejemplo del conjunto de entrenamiento o validación.
$y_b, y_i(\mathbf{x})$	Función objetivo i-ésima en un problema de optimización multiobjetivos.
Y	Cantidad de objetivos en un problema de optimización multiobjetivos.
z_{EL}	Precio de la electricidad [\$/ (kW·h)].
z_{HER}	Precio de la herramienta (para herramientas de placas soldadas) o de una placa (para herramientas de placas intercambiables) [\$].
z_{MAQ}	Precio de compra de la máquina herramienta [\$].
z_{SAL}	Salario del operario [\$/hora].
Z_{AMO}	Costo de amortización [\$].
Z_{EL}	Costo de electricidad [\$].
Z_{HER}	Costo de herramientas [\$].
Z_{SAL}	Costo de salario [\$].
Z_{CUP}, Z_{USD}	Costo total en moneda nacional y en divisa [\$].

Anexo 2 – Diagrama de bloques de un algoritmo genético simple.

Anexo 3 – Deducción de las expresiones para el cálculo de la precisión y la ponderación de los modelos en un punto arbitrario.

Sea representado el diseño experimental en un sistema de coordenadas cartesianas x, y, z ; donde los ejes correspondan a los valores de profundidad de corte, a_p ; avance, f ; y velocidad, V , respectivamente, tal como se muestra en la Fig. A2.1, denotando con $+$ y $-$ los niveles máximo y mínimo de cada variable.

Entonces, cada punto comprendido dentro del rango de validez de las citadas variables, puede escribirse en forma de vector normalizado:

$$\boldsymbol{\mu} = \tilde{a}_p \cdot \mathbf{i} + \tilde{f} \cdot \mathbf{j} + \tilde{V} \cdot \mathbf{k}; \quad (A3.1)$$

donde \mathbf{i} , \mathbf{j} y \mathbf{k} son los vectores unitarios en las direcciones x, y, z ; y

\tilde{a}_p , \tilde{f} y \tilde{V} , los valores de las variables, escalados al rango $[0, 1]$, mediante las expresiones:

$$\tilde{a}_p = \frac{a_p - a_{p-}}{a_{p+} - a_{p-}}; \quad \tilde{f} = \frac{f - f_-}{f_+ - f_-}; \quad \tilde{V} = \frac{V - V_-}{V_+ - V_-}. \quad (A3.2)$$

Utilizando la forma anterior, se escriben los W_{PRI} puntos del conjunto de entrenamiento y los W_{VAL} del conjunto de validación:

$$\boldsymbol{\mu}_1^{PRI}, \boldsymbol{\mu}_2^{PRI}, \dots, \boldsymbol{\mu}_{W_{PRI}}^{PRI}; \quad (A3.3a)$$

$$\boldsymbol{\mu}_1^{VAL}, \boldsymbol{\mu}_2^{VAL}, \dots, \boldsymbol{\mu}_{W_{VAL}}^{VAL}; \quad (A3.3b)$$

Para evaluar la posición relativa del punto considerado, \mathbf{m} , a los conjuntos de entrenamiento y de validación, se definen las distancias S^{PRI} y S^{VAL} , las cuales se calculan como:

$$S^{PRI} = \min(|\boldsymbol{\mu}_1^{PRI} - \boldsymbol{\mu}|, |\boldsymbol{\mu}_2^{PRI} - \boldsymbol{\mu}|, \dots, |\boldsymbol{\mu}_{W_{PRI}}^{PRI} - \boldsymbol{\mu}|); \quad (A3.4a)$$

$$S^{VAL} = \min(|\boldsymbol{\mu}_1^{VAL} - \boldsymbol{\mu}|, |\boldsymbol{\mu}_2^{VAL} - \boldsymbol{\mu}|, \dots, |\boldsymbol{\mu}_{W_{VAL}}^{VAL} - \boldsymbol{\mu}|); \quad (A3.4b)$$




Fig. A3-1 – Representación del rango de validez de las variables en el diseño experimental

Finalmente, la precisión en el punto evaluado, \mathbf{z} , se establece proporcionalmente (ver Fig. A3.2) a los valores cuadráticos medios de las precisiones del modelo para el conjunto de entrenamiento, \mathbf{z}^{PRI} , y de validación, \mathbf{z}^{VAL} , tomando en cuenta las distancias respectivas, según la expresión:

$$\mathbf{z} = \mathbf{z}^{PRI} + \frac{S^{VAL}(\mathbf{z}^{VAL} - \mathbf{z}^{PRI})}{S^{VAL} + S^{PRI}}. \quad (\text{A3.5})$$

Para la determinación de las ponderaciones de cada modelo, estas se establecen proporcionalmente a la función exponencial inversa (ver Fig. A3.3) de su precisión, y de forma tal que la suma de las tres ponderaciones sea igual a 1. O sea que:

$$\mathbf{w}^{REG} = k_1 \exp(-\mathbf{z}^{REG}); \quad (\text{A3.6a})$$

$$\mathbf{w}^{MLP} = k_2 \exp(-\mathbf{z}^{MLP}); \quad (\text{A3.6b})$$

$$\mathbf{w}^{RBF} = k_3 \exp(-\mathbf{z}^{RBF}); \text{ y } \quad (\text{A3.6c})$$

$$\mathbf{w}^{REG} + \mathbf{w}^{MLP} + \mathbf{w}^{RBF} = 1; \quad (\text{A3.7})$$

Considerando que $k_1 = k_2 = k_3$, se tiene que:

$$k_1 = k_2 = k_3 = \frac{1}{\exp(-\mathbf{z}^{REG}) + \exp(-\mathbf{z}^{MLP}) + \exp(-\mathbf{z}^{RBF})}, \quad (\text{A3.8})$$

y de aquí:

$$\mathbf{w}_i = \frac{\exp(-\mathbf{z}^i)}{\exp(-\mathbf{z}^{REG}) + \exp(-\mathbf{z}^{MLP}) + \exp(-\mathbf{z}^{RBF})}. \quad (\text{A3.9})$$




Fig. A3.2 – Representación de la proporcionalidad de la precisión y las distancias a los conjuntos.




Fig. A3.3 – Función exponencial inversa.

Anexo 4 – Características técnicas del portaplacas Sandvik Coromant PTG NR 2525M [Sandvik, 1994].*Tabla A4.1 – Características de técnicas del portaplacas.*

Sistema de fijación:	Por el agujero.
Forma de la placa utilizada:	Triangular.
Ángulo de posición principal:	0° .
Ángulo de incidencia:	0° .
Sentido de la herramienta:	Derecho.
Altura de la sección del mango:	25 mm .
Ancho de la sección del mango:	25 mm .
Longitud de la herramienta:	150 mm .

Anexo 5 – Características técnicas de la plaquita de corte Sandvik Coromant TNMG 22 04 08-PM [Sandvik, 1994].




Fig. A5.1 – Dimensiones principales.

Tabla A5.1 – Datos geométricos y técnicos de la plaquita.

Ángulo de incidencia: 0°

Tolerancia del círculo inscrito: $\pm 0,08$ mm

Radio de la punta: 0,8 mm

Geometría de la placa: PM (para mecanizado medio, dos caras, rompevirutas versátil y multifunción, excelente rendimiento para una amplia área de aplicaciones que van desde acabado hasta desbaste ligero).

Rango de trabajo recomendado: $a_p = 0,50 \dots 6,60$ mm
 $f = 0,15 \dots 0,55$ mm/rev
 $V = 265 \dots 405$ m/min

Anexo 6 – Fotografías del equipamiento empleado.




Fig. A5.1 – Instalación de la cuchilla en el portaherramientas.



Fig. A5.2 – Transductor de desplazamiento Kyowa DT-100




Fig. A5.3 – Amplificador tensométrico ONO SOKKI HT-431.



Fig. A5.4 – Computadora personal IBM Compatible.

Anexo 7 – Ejemplo de datos de las mediciones de fuerzas y desplazamientos, y gráfico correspondiente.

Tabla A7.1 – Ejemplo de mediciones de termo-FEM (ϵ), fuerza de corte tangencial (F_C); y axial (F_F) y desplazamiento (D_x).

Tiempo [s]	$U(\epsilon)$ [V]	$U(F_C)$ [V]	$U(F_F)$ [V]	$U(D_x)$ [V]
0,000	0,940	-0,793	-1,372	1,433
0,001	0,938	-0,813	-1,387	1,433
0,002	0,935	-0,796	-1,414	1,433
0,004	0,930	-0,752	-1,499	1,433
0,005	0,925	-0,764	-1,523	1,433
0,006	0,918	-0,781	-1,506	1,433
0,007	0,911	-0,859	-1,450	1,433
0,009	0,903	-0,774	-1,421	1,433
0,010	0,898	-0,820	-1,414	1,433
0,011	0,889	-0,769	-1,416	1,434
(. . .)				
0,997	1,157	-0,999	-1,489	1,377
0,998	1,165	-0,808	-1,458	1,377
0,999	1,167	-0,771	-1,497	1,377
1,000	1,169	-0,869	-1,677	1,377

Nota: Los valores medidos son los voltajes de las señales correspondientes a las magnitudes.




Fig. A7.1 – Ejemplo de gráfico de mediciones.

Anexo 8 – Calibración de los puentes de Wheatstone para la medición de las fuerzas de corte.

Tabla A8.1 – Datos para la calibración de los puentes de Wheatstone.

Componente axial de la fuerza de corte (F_X)							
m [kg]	F [N]	Carga			Descarga		
		U_1 [V]	U_2 [V]	U_3 [V]	U_1 [V]	U_2 [V]	U_3 [V]
10	98,2	0,36	0,41	0,39	0,39	0,41	0,38
20	196,4	0,61	0,65	0,64	0,63	0,65	0,64
30	294,6	0,84	0,88	0,86	0,84	0,86	0,85
40	392,8	1,08	1,12	1,08	1,06	1,10	1,10
50	491,0	1,30	1,38	0,35	1,30	1,38	1,35
60	589,2	1,55	1,60	1,58	1,52	1,58	1,56
70	687,4	1,75	1,80	1,79	1,75	1,78	1,78
80	785,6	1,90	2,05	2,00	1,90	2,05	2,00

Componente tangencial de la fuerza de corte (F_Z)							
m [kg]	F [N]	Carga			Descarga		
		U_1 [V]	U_2 [V]	U_1 [V]	U_2 [V]	U_1 [V]	U_2 [V]
10	98,2	0,40	0,38	0,40	0,40	0,39	0,38
20	196,4	0,64	0,64	0,64	0,65	0,63	0,62
30	294,6	0,85	0,85	0,85	0,87	0,85	0,85
40	392,8	1,10	1,09	1,10	1,15	1,09	1,08
50	491,0	1,35	1,32	1,35	1,40	1,35	1,30
60	589,2	1,60	1,60	1,58	1,60	1,58	1,55
70	687,4	1,84	1,80	1,78	1,85	1,79	1,78
80	785,6	2,01	2,00	1,96	2,02	2,00	1,98

Modelo de calibración para la fuerza axial: $F_F = 427,3 \cdot U - 73,03$.

Tabla A8.2 – Análisis estadístico del modelo de calibración de F_F .

Coefficiente de Correlación = 0,998011

$R^2 = 0,996025$

Error estándar de los estimados = 14,4911

Tabla A8.3 – Análisis de sensibilidad de los coeficientes para el modelo de F_F .

Parámetro	Estimado	Error Estándar	t	Prob.
Intercepto	-73,0251	5,23246	-13,9562	0,0000
Pendiente	427,324	3,98027	107,36	0,0000

Tabla A8.4 – ANOVA del modelo de F_F .

	Sum. Cuadrados	G. L.	Cdo. Medio	F	Prob.
Modelo	$2,42044 \cdot 10^6$	1	$2,42044 \cdot 10^6$	11526,27	0,0000
Residuales	9659,68	46	209,99		
Total (Corr.)	$2,430 \cdot 10^6$	47			




Fig. A8.1 – Gráfico de observaciones vs. predicciones del modelo de calibración de F_F .

Tabla A8.5 – Errores estimados del modelo de calibración de F_F , 95 % de confiabilidad.

U [V]	F_F [N]			Errores	
	Predicha	Límite Inferior	Límite Superior	Absoluto [N]	Relativo [%]
0,36	80,81	72,84	88,78	7,97	9,9%
0,50	140,64	133,59	147,68	7,04	5,0%
1,00	354,30	349,78	358,82	4,52	1,3%
1,50	567,96	563,13	572,79	4,83	0,9%
2,00	781,62	773,99	789,26	7,63	1,0%

Modelo de calibración para la fuerza tangencial: $F_C = 416,8 \cdot U - 66,15$.

Tabla A8.5 – Análisis estadístico del modelo de calibración de F_C .

Coefficiente de Correlación = 0,998497

$R^2 = 0,996996$

Error estándar de los estimados = 12,5973

Tabla A8.6 – Análisis de sensibilidad de los coeficientes para el modelo de F_C .

Parámetro	Estimado	Error Estándar	t	Prob.
Intercepto	-66.1533	4.49586	-14.7143	0.0000
Pendiente	416.793	3.37318	123.561	0.0000

Tabla A8.7 – ANOVA del modelo de F_C .

	Sum. Cuadrados	G. L.	Cdo. Medio	F	Prob.
Modelo	$2,4228 \cdot 10^6$	1	$2,4228 \cdot 10^6$	11567,24	0,0000
Residuales	7299,85	46	158,692		
Total (Corr.)	$2,4301 \cdot 10^6$	47			




Fig. A8.2 – Gráfico de observaciones vs. predicciones del modelo de calibración de F_C .

Tabla A8.8 – Errores estimados del modelo de calibración de F_C , 95 % de confiabilidad.

U [V]	F_C [N]		Errores		
	Predicha	Límite Inferior	Límite Superior	Absoluto [N]	Relativo [%]
0,36	92,23	85,46	99,00	6,77	7,3%
0,50	142,24	133,59	147,68	8,65	6,1%
1,00	350,64	349,78	358,82	0,86	0,2%
1,50	559,04	554,91	563,16	4,13	0,7%
2,00	767,43	760,99	773,88	6,44	0,8%

Anexo 9 – Calibración del termopar natural para medición de la temperatura en la zona de corte.




Fig. A9.1 – Esquema de la instalación para la calibración del termopar natural.




Fig. A9.2 – Curva de calibración del termopar.

Tabla A9.1 – Valores observados de termo-FEM en el termopar calibrado, e_C ; de la temperatura correspondiente a dichos valores, q_C ; y de termo-FEM del termopar natural, e_N .

Primera medición			Segunda medición			Tercera medición		
e_C [mV]	q_C [°C]	e_N [mV]	e_C [mV]	q_C [°C]	e_N [mV]	e_C [mV]	q_C [°C]	e_N [mV]
3,5	111	1,3	4,2	128	1,5	3,9	121	1,4
8,6	237	2,8	12,7	337	4,0	9,7	264	3,1
16,3	423	5,0	21,1	536	6,3	17,6	453	5,3
23,4	590	7,0	27,1	677	7,9	24,3	611	7,1
32,2	799	9,5	34,7	860	10,2	29,9	743	8,7
39,4	978	11,4	44,4	1106	12,9	36,5	904	10,7
44,4	1107	13,0	50,9	1283	15,1	45,6	1138	13,5
51,3	1294	15,2	----	----	----	51,5	1299	15,4

Modelo de regresión para la temperatura: $q = 1,021 + 84,84 \cdot e_N$

Tabla A9.2 – Análisis estadístico del modelo de calibración de la temperatura.

Coefficiente de Correlación = 0,9999

$R^2 = 0,9998$

Error estándar de los estimados = 5,590

Tabla A9.3 – Análisis de sensibilidad de los coeficientes para el modelo de calibración.

Parámetro	Estimado	Error Estándar	t	Prob.
Intercepto	1,021	2,391	0,4271	0,6737
Pendiente	84,84	0,2550	332,7	0,0000

Tabla A9.4 – Tabla de ANOVA del modelo de calibración.

	Sum. Cuadrados	G. L.	Cdo. Medio	F	Prob.
Modelo	$3,460 \cdot 10^6$	1	$3,460 \cdot 10^6$	$1,107 \cdot 10^5$	0,0000
Residuales	$6,562 \cdot 10^2$	21	$3,125 \cdot 10^1$		
Total (Corr.)	$3,460 \cdot 10^6$	22			




Fig. A9.3 – Gráfico de observaciones vs. predicciones del modelo de calibración.




Fig. A9.4 – Gráfico de residuales vs. predicciones del modelo de calibración.

Tabla A9.5 – Errores estimados del modelo de calibración con 95 % de confiabilidad.

e_c [mV]	q [N]			Errores	
	Predicha	Límite Inferior	Límite Superior	Absoluto [N]	Relativo [%]
2,5	213	209	217	4	1,9 %
5,0	425	422	428	3	0,7 %
7,5	637	635	640	2,5	0,4 %
10,0	849	847	852	2,5	0,3 %
15,0	1274	1269	1278	4,5	0,4 %

Anexo 10 – Datos experimentales del desgaste de la herramienta (experimentos principales).

Tabla A10.1 – Punto Exp. No. 01 ($a_p = 0,5$ mm; $f = 0,15$ mm/rev; $V = 200$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
47,2	0,163	0,159	0,157	0,160	0,003
93,8	0,214	0,206	0,212	0,211	0,004
124,6	0,223	0,224	0,232	0,226	0,005
155,1	0,243	0,241	0,248	0,244	0,004
185,3	0,257	0,260	0,256	0,258	0,002
215,1	0,272	0,268	0,271	0,270	0,002
244,7	0,278	0,285	0,276	0,280	0,005
273,9	0,284	0,292	0,278	0,285	0,007
302,9	0,294	0,298	0,291	0,294	0,004
331,5	0,309	0,306	0,308	0,308	0,002

Tabla A10.2 – Punto Exp. No. 02 ($a_p = 0,5$ mm; $f = 0,15$ mm/rev; $V = 250$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
27,1	0,123	0,119	0,121	0,121	0,002
54,0	0,197	0,187	0,190	0,191	0,005
80,5	0,216	0,227	0,222	0,222	0,005
106,8	0,243	0,244	0,259	0,249	0,009
128,4	0,273	0,269	0,270	0,271	0,002
137,0	0,289	0,274	0,275	0,279	0,009
145,4	0,293	0,287	0,295	0,292	0,004
153,8	0,301	0,311	0,314	0,309	0,007

Tabla A10.3 – Punto Exp. No. 03 ($a_p = 0,5$ mm; $f = 0,15$ mm/rev; $V = 300$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
15,5	0,101	0,098	0,105	0,101	0,004
25,7	0,150	0,145	0,152	0,149	0,003
35,7	0,187	0,174	0,192	0,184	0,008
45,7	0,220	0,229	0,219	0,223	0,004
55,5	0,241	0,244	0,238	0,241	0,002
65,1	0,267	0,261	0,263	0,264	0,003
74,7	0,280	0,290	0,285	0,285	0,004
84,1	0,302	0,311	0,305	0,306	0,004

Tabla A10.4 – Punto Exp. No. 04 ($a_p = 0,5$ mm; $f = 0,25$ mm/rev; $V = 200$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
34,9	0,131	0,129	0,126	0,129	0,002
69,3	0,192	0,189	0,191	0,191	0,001
96,4	0,224	0,216	0,226	0,222	0,005
123,2	0,240	0,248	0,251	0,246	0,005
149,6	0,256	0,268	0,270	0,265	0,006
175,7	0,278	0,271	0,275	0,275	0,003
201,3	0,281	0,287	0,290	0,286	0,004
213,9	0,291	0,297	0,295	0,294	0,002
226,4	0,302	0,307	0,305	0,305	0,002

Tabla A10.5 – Punto Exp. No. 05 ($a_p = 0,5$ mm; $f = 0,25$ mm/rev; $V = 250$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
24,1	0,122	0,118	0,121	0,120	0,002
43,1	0,175	0,169	0,171	0,172	0,003
61,8	0,230	0,223	0,226	0,226	0,003
80,2	0,267	0,244	0,250	0,254	0,010
98,3	0,281	0,298	0,299	0,293	0,008
111,7	0,322	0,324	0,310	0,319	0,006

Tabla A10.6 – Punto Exp. No. 06 ($a_p = 0,5$ mm; $f = 0,25$ mm/rev; $V = 300$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
10,9	0,092	0,098	0,094	0,095	0,003
21,7	0,164	0,161	0,160	0,162	0,002
28,7	0,208	0,200	0,207	0,205	0,004
35,6	0,231	0,242	0,241	0,238	0,005
42,4	0,263	0,253	0,251	0,256	0,005
49,1	0,292	0,286	0,295	0,291	0,004
55,6	0,313	0,310	0,307	0,310	0,002

Tabla A10.7 – Punto Exp. No. 07 ($a_p = 0,5$ mm; $f = 0,35$ mm/rev; $V = 200$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
33,7	0,131	0,137	0,127	0,132	0,004
67,0	0,190	0,205	0,208	0,201	0,008
100,0	0,236	0,247	0,227	0,237	0,008
132,7	0,258	0,260	0,263	0,260	0,002
152,1	0,269	0,285	0,282	0,279	0,007
171,3	0,291	0,295	0,291	0,292	0,002
190,3	0,313	0,309	0,307	0,310	0,002

Tabla A10.8 – Punto Exp. No. 08 ($a_p = 0,5$ mm; $f = 0,35$ mm/rev; $V = 250$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
25,1	0,168	0,172	0,164	0,168	0,003
39,9	0,243	0,218	0,222	0,228	0,011
54,7	0,273	0,265	0,257	0,265	0,007
64,4	0,287	0,271	0,283	0,280	0,007
73,9	0,290	0,295	0,302	0,296	0,005
83,4	0,310	0,305	0,320	0,312	0,006

Tabla A10.9 – Punto Exp. No. 09 ($a_p = 0,5$ mm; $f = 0,35$ mm/rev; $V = 300$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
7,8	0,165	0,164	0,170	0,166	0,003
15,5	0,233	0,236	0,225	0,231	0,004
23,2	0,259	0,261	0,254	0,258	0,003
30,7	0,277	0,276	0,270	0,274	0,003
36,7	0,289	0,281	0,279	0,283	0,004
42,6	0,293	0,295	0,291	0,293	0,002
48,4	0,302	0,307	0,309	0,306	0,003

Tabla A10.10 – Punto Exp. No. 10 ($a_p = 1,25$ mm; $f = 0,15$ mm/rev; $V = 200$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
47,2	0,212	0,220	0,214	0,215	0,003
78,1	0,230	0,255	0,227	0,237	0,012
108,6	0,257	0,261	0,254	0,257	0,003
138,6	0,263	0,266	0,274	0,268	0,004
162,3	0,278	0,278	0,289	0,282	0,005
185,5	0,293	0,291	0,295	0,293	0,002
208,4	0,305	0,303	0,314	0,307	0,005

Tabla A10.11 – Punto Exp. No. 11 ($a_p = 1,25$ mm; $f = 0,15$ mm/rev; $V = 250$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
18,0	0,153	0,161	0,153	0,156	0,004
35,7	0,232	0,245	0,245	0,240	0,006
53,1	0,253	0,257	0,254	0,254	0,002
70,2	0,269	0,262	0,284	0,272	0,009
87,0	0,297	0,300	0,294	0,297	0,002
103,5	0,314	0,319	0,325	0,319	0,004

Tabla A10.12 – Punto Exp. No. 12 ($a_p = 1,25$ mm; $f = 0,15$ mm/rev; $V = 300$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
10,1	0,150	0,148	0,149	0,149	0,001
20,1	0,251	0,246	0,244	0,247	0,003
29,8	0,287	0,266	0,261	0,271	0,011
39,3	0,276	0,281	0,278	0,278	0,002
48,7	0,299	0,289	0,298	0,295	0,004
54,8	0,305	0,310	0,308	0,308	0,002

Tabla A10.13 – Punto Exp. No. 13 ($a_p = 1,25$ mm; $f = 0,25$ mm/rev; $V = 200$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
20,2	0,112	0,115	0,117	0,114	0,002
40,0	0,216	0,213	0,207	0,212	0,004
59,4	0,230	0,230	0,238	0,232	0,004
78,3	0,245	0,256	0,258	0,253	0,006
96,9	0,270	0,274	0,256	0,267	0,008
115,0	0,287	0,272	0,284	0,281	0,006
132,7	0,297	0,294	0,293	0,295	0,002
144,2	0,302	0,309	0,307	0,306	0,003

Tabla A10.14 – Punto Exp. No. 14 ($a_p = 1,25$ mm; $f = 0,25$ mm/rev; $V = 250$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
13,5	0,111	0,115	0,113	0,113	0,002
22,2	0,206	0,211	0,217	0,211	0,005
30,7	0,237	0,239	0,244	0,240	0,003
39,0	0,271	0,266	0,270	0,269	0,002
47,1	0,279	0,275	0,277	0,277	0,002
54,9	0,286	0,283	0,286	0,285	0,001
62,6	0,292	0,297	0,291	0,293	0,003
70,0	0,314	0,305	0,309	0,309	0,004

Tabla A10.15 – Punto Exp. No. 15 ($a_p = 1,25$ mm; $f = 0,25$ mm/rev; $V = 300$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
6,3	0,109	0,109	0,112	0,110	0,002
12,5	0,223	0,229	0,237	0,229	0,006
18,6	0,257	0,261	0,255	0,258	0,002
24,6	0,271	0,273	0,274	0,273	0,001
28,1	0,287	0,288	0,283	0,286	0,002
31,6	0,298	0,294	0,291	0,294	0,003
35,1	0,307	0,309	0,310	0,309	0,001

Tabla A10.16 – Punto Exp. No. 16 ($a_p = 1,25$ mm; $f = 0,35$ mm/rev; $V = 200$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
18,4	0,107	0,108	0,109	0,108	0,001
36,5	0,207	0,204	0,206	0,206	0,001
48,3	0,240	0,233	0,224	0,232	0,007
60,0	0,255	0,256	0,243	0,252	0,006
71,5	0,265	0,260	0,257	0,261	0,003
82,7	0,273	0,272	0,274	0,273	0,001
93,7	0,289	0,279	0,285	0,284	0,004
104,6	0,301	0,289	0,291	0,294	0,005
115,2	0,309	0,300	0,309	0,306	0,004

Tabla A10.17 – Punto Exp. No. 17 ($a_p = 1,25$ mm; $f = 0,35$ mm/rev; $V = 250$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
8,4	0,107	0,104	0,112	0,107	0,003
16,5	0,215	0,205	0,203	0,208	0,005
24,6	0,239	0,241	0,260	0,247	0,009
32,4	0,255	0,279	0,278	0,271	0,011
40,1	0,273	0,283	0,284	0,280	0,005
47,7	0,293	0,292	0,289	0,291	0,002
55,1	0,304	0,306	0,308	0,306	0,002

Tabla A10.18 – Punto Exp. No. 18 ($a_p = 1,25$ mm; $f = 0,35$ mm/rev; $V = 300$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
4,8	0,157	0,140	0,139	0,145	0,008
9,5	0,238	0,230	0,245	0,238	0,006
14,1	0,269	0,259	0,262	0,263	0,004
18,6	0,279	0,268	0,283	0,277	0,006
21,9	0,285	0,288	0,278	0,284	0,004
25,1	0,295	0,293	0,292	0,293	0,001
28,2	0,301	0,306	0,301	0,303	0,002

Tabla A10.19 – Punto Exp. No. 19 ($a_p = 2,0$ mm; $f = 0,15$ mm/rev; $V = 200$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
24,1	0,145	0,160	0,149	0,151	0,008
47,3	0,203	0,216	0,201	0,207	0,008
69,4	0,229	0,228	0,220	0,226	0,005
90,6	0,230	0,237	0,234	0,234	0,004
110,7	0,249	0,241	0,242	0,244	0,005
129,8	0,269	0,253	0,271	0,264	0,010
147,9	0,275	0,260	0,279	0,271	0,010
165,0	0,282	0,297	0,301	0,293	0,010
180,0	0,318	0,306	0,312	0,312	0,006

Tabla A10.20 – Punto Exp. No. 20 ($a_p = 2,0$ mm; $f = 0,15$ mm/rev; $V = 250$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
10,1	0,132	0,129	0,130	0,130	0,002
19,6	0,210	0,213	0,219	0,214	0,005
28,7	0,238	0,236	0,224	0,233	0,008
37,2	0,255	0,251	0,254	0,253	0,002
45,3	0,262	0,260	0,263	0,262	0,002
52,8	0,270	0,272	0,278	0,273	0,004
59,8	0,279	0,279	0,285	0,281	0,003
66,4	0,290	0,299	0,296	0,295	0,005
78,9	0,316	0,311	0,301	0,309	0,007

Tabla A10.21 – Punto Exp. No. 21 ($a_p = 2,0$ mm; $f = 0,15$ mm/rev; $V = 300$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
4,0	0,101	0,104	0,106	0,104	0,003
7,8	0,148	0,151	0,159	0,153	0,006
11,3	0,198	0,202	0,199	0,200	0,002
14,6	0,220	0,236	0,216	0,224	0,010
20,9	0,262	0,258	0,249	0,256	0,007
26,9	0,275	0,273	0,269	0,272	0,003
32,7	0,284	0,287	0,281	0,284	0,003
38,2	0,296	0,294	0,295	0,295	0,001
43,5	0,306	0,308	0,314	0,309	0,004

Tabla A10.22 – Punto Exp. No. 22 ($a_p = 2,0$ mm; $f = 0,25$ mm/rev; $V = 200$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
8,1	0,096	0,104	0,101	0,100	0,004
15,7	0,140	0,155	0,162	0,152	0,011
30,8	0,195	0,201	0,208	0,201	0,007
45,3	0,225	0,227	0,231	0,228	0,003
59,2	0,238	0,249	0,237	0,241	0,007
72,4	0,254	0,253	0,256	0,254	0,001
85,1	0,261	0,268	0,275	0,268	0,007
97,2	0,278	0,276	0,285	0,280	0,005
108,7	0,284	0,282	0,280	0,282	0,002
119,5	0,293	0,294	0,296	0,294	0,002
129,8	0,303	0,318	0,313	0,312	0,008

Tabla A10.23 – Punto Exp. No. 23 ($a_p = 2,0$ mm; $f = 0,25$ mm/rev; $V = 250$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
8,0	0,129	0,129	0,127	0,128	0,001
15,6	0,215	0,223	0,224	0,221	0,005
22,8	0,239	0,236	0,238	0,238	0,002
29,7	0,253	0,244	0,246	0,248	0,005
36,2	0,265	0,259	0,264	0,263	0,003
42,4	0,279	0,273	0,273	0,275	0,003
48,1	0,286	0,284	0,285	0,285	0,001
53,6	0,295	0,296	0,293	0,295	0,002
58,6	0,304	0,311	0,312	0,309	0,004

Tabla A10.24 – Punto Exp. No. 24 ($a_p = 2,0$ mm; $f = 0,25$ mm/rev; $V = 300$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
3,6	0,089	0,079	0,084	0,084	0,005
7,0	0,176	0,173	0,177	0,176	0,002
10,3	0,234	0,206	0,215	0,218	0,014
13,3	0,253	0,253	0,219	0,242	0,020
16,1	0,263	0,252	0,267	0,261	0,008
18,7	0,280	0,282	0,274	0,279	0,004
23,7	0,289	0,286	0,283	0,286	0,003
28,6	0,293	0,292	0,297	0,294	0,003
33,2	0,308	0,311	0,304	0,308	0,004

Tabla A10.25 – Punto Exp. No. 25 ($a_p = 2,0$ mm; $f = 0,35$ mm/rev; $V = 200$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
18,0	0,217	0,185	0,194	0,199	0,017
31,6	0,251	0,241	0,223	0,238	0,014
44,6	0,266	0,253	0,230	0,249	0,018
56,8	0,276	0,266	0,248	0,263	0,014
68,3	0,286	0,274	0,282	0,280	0,006
79,0	0,291	0,288	0,287	0,289	0,002
89,1	0,298	0,295	0,298	0,297	0,002
98,4	0,323	0,310	0,316	0,316	0,006

Tabla A10.26 – Punto Exp. No. 26 ($a_p = 2,0$ mm; $f = 0,35$ mm/rev; $V = 250$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
5,5	0,120	0,109	0,105	0,111	0,008
10,9	0,207	0,203	0,196	0,202	0,006
16,0	0,215	0,225	0,217	0,227	0,020
21,0	0,243	0,243	0,242	0,243	0,001
25,9	0,260	0,262	0,259	0,260	0,002
30,5	0,276	0,280	0,269	0,275	0,005
35,0	0,293	0,287	0,281	0,287	0,006
39,3	0,301	0,299	0,294	0,298	0,004
47,9	0,333	0,300	0,340	0,324	0,021

Tabla A10.27 – Punto Exp. No. 27 ($a_p = 2,0$ mm; $f = 0,35$ mm/rev; $V = 300$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
4,5	0,155	0,150	0,171	0,159	0,011
7,1	0,224	0,210	0,217	0,217	0,007
9,6	0,226	0,226	0,250	0,234	0,014
11,9	0,252	0,264	0,243	0,253	0,011
14,2	0,267	0,248	0,271	0,262	0,012
16,3	0,276	0,257	0,277	0,270	0,011
18,4	0,280	0,271	0,279	0,277	0,005
20,3	0,289	0,284	0,285	0,286	0,003
22,2	0,290	0,296	0,295	0,294	0,003
23,9	0,303	0,310	0,307	0,307	0,004

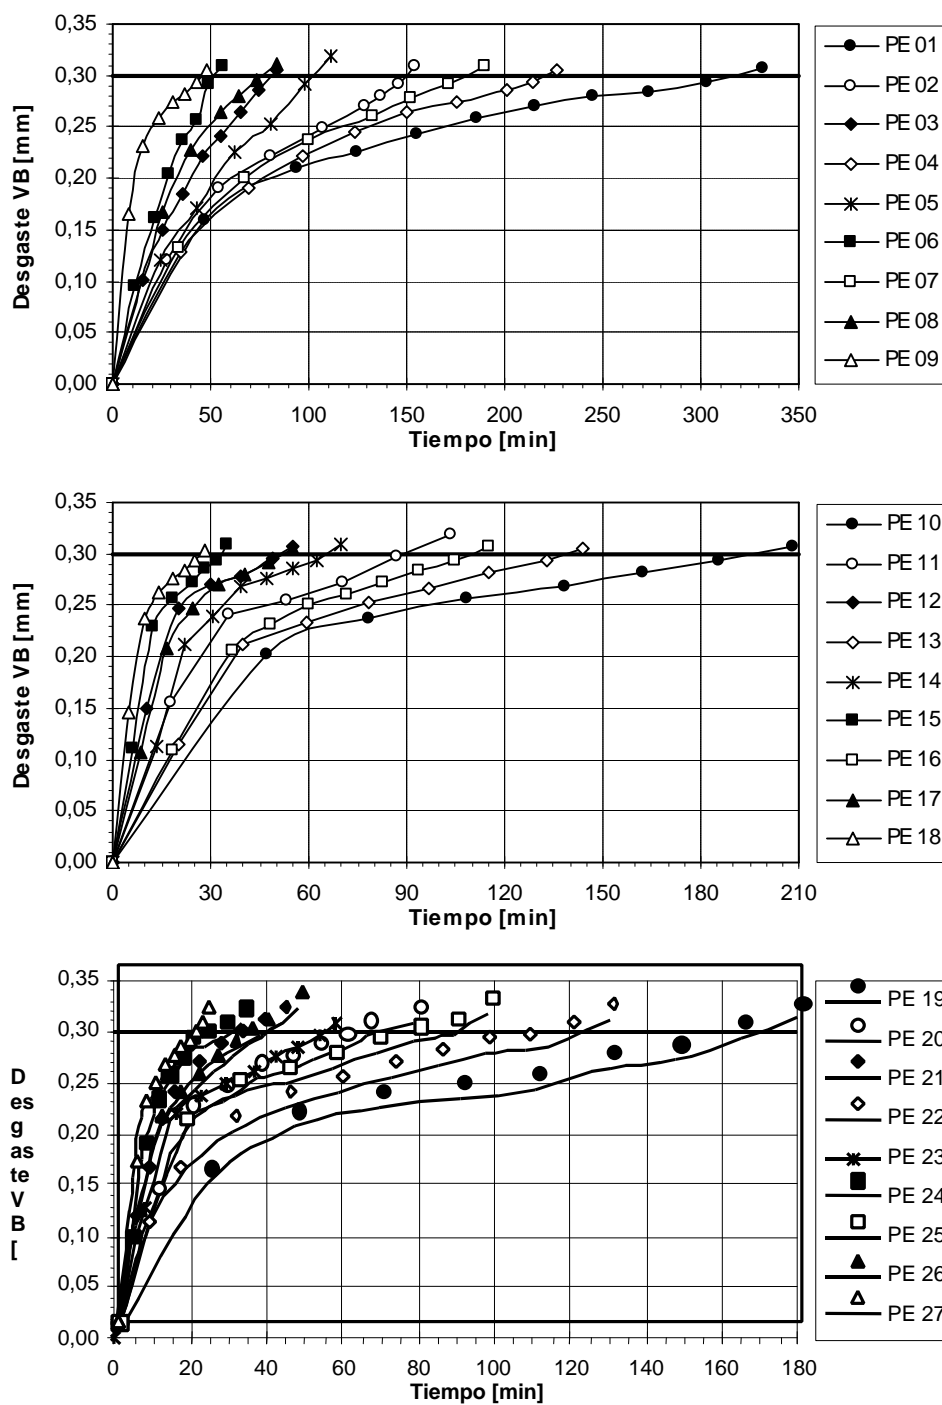


Fig. A10.1 – Gráficos de progreso del desgaste (experimentos principales).

Anexo 11 – Datos experimentales del desgaste de la herramienta (experimentos de validación).

Tabla A11.1 – Punto Exp. No. V1 ($a_P = 0,88$ mm; $f = 0,19$ mm/rev; $V = 225$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
27,9	0,199	0,209	0,197	0,202	0,007
55,4	0,260	0,237	0,254	0,250	0,012
82,3	0,271	0,274	0,259	0,268	0,008
95,5	0,276	0,281	0,265	0,274	0,008
108,5	0,297	0,289	0,279	0,288	0,009
118,7	0,293	0,290	0,296	0,293	0,003
128,7	0,298	0,295	0,299	0,297	0,002
138,5	0,310	0,301	0,309	0,307	0,005

Tabla A11.2 – Punto Exp. No. V2 ($a_P = 0,88$ mm; $f = 0,19$ mm/rev; $V = 275$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
12,4	0,204	0,193	0,210	0,203	0,008
21,5	0,241	0,252	0,240	0,244	0,007
30,4	0,260	0,264	0,274	0,266	0,007
39,2	0,262	0,282	0,279	0,274	0,011
47,7	0,289	0,283	0,288	0,287	0,003
56,0	0,304	0,293	0,278	0,292	0,013
64,2	0,294	0,298	0,294	0,295	0,002
72,2	0,303	0,310	0,305	0,306	0,003

Tabla A11.3 – Punto Exp. No. V3 ($a_P = 0,88$ mm; $f = 0,31$ mm/rev; $V = 225$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
16,2	0,205	0,208	0,212	0,208	0,004
28,9	0,255	0,237	0,243	0,245	0,009
41,3	0,264	0,259	0,250	0,257	0,007
53,3	0,278	0,277	0,268	0,274	0,005
65,1	0,273	0,273	0,287	0,277	0,008
76,5	0,286	0,280	0,296	0,287	0,008
87,6	0,293	0,288	0,301	0,294	0,006
98,4	0,306	0,310	0,316	0,311	0,005

Tabla A11.4 – Punto Exp. No. V4 ($a_p = 0,88$ mm; $f = 0,31$ mm/rev; $V = 275$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
8,8	0,202	0,196	0,187	0,195	0,007
15,4	0,253	0,254	0,243	0,250	0,006
21,8	0,265	0,261	0,252	0,259	0,007
28,1	0,273	0,271	0,277	0,274	0,003
34,2	0,280	0,279	0,285	0,281	0,003
40,3	0,289	0,289	0,291	0,290	0,001
46,2	0,296	0,292	0,297	0,295	0,003
52,0	0,312	0,301	0,315	0,309	0,008

Tabla A11.5 – Punto Exp. No. V5 ($a_p = 1,62$ mm; $f = 0,19$ mm/rev; $V = 225$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
22,7	0,197	0,204	0,195	0,198	0,005
37,3	0,244	0,239	0,233	0,239	0,006
51,4	0,254	0,248	0,264	0,255	0,008
64,8	0,274	0,267	0,273	0,271	0,004
77,7	0,286	0,274	0,276	0,279	0,006
90,0	0,283	0,289	0,284	0,285	0,003
101,7	0,296	0,299	0,295	0,297	0,002
112,9	0,310	0,303	0,304	0,306	0,004

Tabla A11.6 – Punto Exp. No. V6 ($a_p = 1,62$ mm; $f = 0,19$ mm/rev; $V = 275$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
13,0	0,212	0,208	0,224	0,215	0,008
21,2	0,247	0,241	0,265	0,251	0,013
28,9	0,269	0,264	0,267	0,267	0,002
36,2	0,277	0,281	0,273	0,277	0,004
42,9	0,285	0,290	0,289	0,288	0,003
49,3	0,295	0,296	0,289	0,293	0,004
55,1	0,306	0,309	0,302	0,306	0,003

Tabla A11.7 – Punto Exp. No. V7 ($a_p = 1,62 \text{ mm}$; $f = 0,31 \text{ mm/rev}$; $V = 225 \text{ m/min}$).

$t \text{ [min]}$	$V_B \text{ [mm]}$			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
16,2	0,212	0,209	0,204	0,215	0,004
26,7	0,246	0,249	0,244	0,250	0,003
36,8	0,259	0,253	0,264	0,264	0,006
46,6	0,262	0,267	0,275	0,276	0,007
56,0	0,283	0,288	0,285	0,285	0,002
65,0	0,294	0,291	0,295	0,293	0,002
73,8	0,305	0,301	0,310	0,305	0,005

Tabla A11.8 – Punto Exp. No. V8 ($a_p = 1,62 \text{ mm}$; $f = 0,31 \text{ mm/rev}$; $V = 275 \text{ m/min}$).

$t \text{ [min]}$	$V_B \text{ [mm]}$			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
6,8	0,222	0,220	0,208	0,217	0,007
11,8	0,255	0,247	0,250	0,251	0,004
16,5	0,271	0,258	0,270	0,266	0,007
20,9	0,269	0,275	0,279	0,274	0,005
25,2	0,278	0,283	0,279	0,280	0,003
29,3	0,288	0,290	0,289	0,289	0,001
33,1	0,295	0,299	0,298	0,297	0,002
36,7	0,304	0,311	0,314	0,310	0,005




Fig. A11.1 – Gráfico del progreso del desgaste de la herramienta (experimentos de validación).

Anexo 12 – Datos experimentales del desgaste de la herramienta (experimentos de comprobación).

Tabla A12.1 – Punto Exp. No. C1 ($a_P = 1,90$ mm; $f = 0,31$ mm/rev; $V = 270$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
5,6	0,185	0,181	0,200	0,188	0,010
11,1	0,219	0,245	0,232	0,232	0,013
16,3	0,238	0,258	0,243	0,246	0,010
21,2	0,250	0,266	0,269	0,262	0,008
26,0	0,268	0,286	0,274	0,276	0,008
30,6	0,280	0,291	0,292	0,288	0,005
34,9	0,291	0,301	0,298	0,297	0,004
39,1	0,314	0,306	0,308	0,309	0,003

Tabla A12.2 – Punto Exp. No. C2 ($a_P = 1,15$ mm; $f = 0,23$ mm/rev; $V = 285$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
8,6	0,161	0,186	0,181	0,176	0,013
15,7	0,220	0,210	0,239	0,223	0,014
22,5	0,244	0,235	0,249	0,243	0,007
29,2	0,264	0,270	0,265	0,266	0,003
35,7	0,276	0,287	0,278	0,280	0,005
42,1	0,292	0,295	0,293	0,293	0,001
48,3	0,309	0,310	0,303	0,307	0,003

Tabla A12.3 – Punto Exp. No. C3 ($a_P = 1,40$ mm; $f = 0,28$ mm/rev; $V = 230$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
22,0	0,190	0,162	0,193	0,181	0,017
39,7	0,207	0,236	0,236	0,226	0,017
51,1	0,240	0,248	0,244	0,244	0,004
62,1	0,264	0,278	0,263	0,268	0,007
70,5	0,283	0,291	0,279	0,284	0,005
75,6	0,295	0,293	0,291	0,293	0,002
80,5	0,300	0,312	0,304	0,305	0,005

Tabla A12.4 – Punto Exp. No. C4 ($a_p = 1,40$ mm; $f = 0,28$ mm/rev; $V = 230$ m/min).

t [min]	V_B [mm]			$V_{B-MEDIO}$	$S(V_B)$
	Réplica 1	Réplica 2	Réplica 3		
39,8	0,147	0,149	0,165	0,154	0,010
58,8	0,189	0,186	0,199	0,191	0,007
77,6	0,213	0,209	0,216	0,213	0,004
96,0	0,240	0,237	0,249	0,242	0,005
107,4	0,266	0,272	0,267	0,268	0,003
118,6	0,296	0,290	0,294	0,293	0,002
129,7	0,305	0,306	0,312	0,308	0,003




Fig. A12.1 – Gráfico del progreso del desgaste de la herramienta (experimentos de comprobación).

Anexo 13 – Datos experimentales de termo-FEM y valores de temperatura correspondientes.

Tabla 13.1 – Datos experimentales del conjunto principal.

a_p [mm]	f [mm/r.]	V [m/min]	Termo-FEM [mV]			Temperatura [°C]		
			Rép. 1	Rép. 2	Rép. 3	Rép. 1	Rép. 2	Rép. 3
0,50	0,15	200	7,6	7,8	7,4	647	665	628
0,50	0,15	250	8,4	8,8	8,8	714	747	752
0,50	0,15	300	9,9	9,7	9,2	842	825	782
0,50	0,25	200	9,0	8,9	8,7	764	756	739
0,50	0,25	250	10,4	10,9	11,2	887	927	948
0,50	0,25	300	10,6	10,9	10,5	900	922	894
0,50	0,35	200	10,5	10,4	10,4	895	883	887
0,50	0,35	250	12,3	11,7	12,5	1041	991	1063
0,50	0,35	300	13,6	12,9	13,3	1151	1099	1128
1,25	0,15	200	8,6	8,4	8,3	728	712	702
1,25	0,15	250	9,3	9,9	9,5	789	843	808
1,25	0,15	300	10,2	10,6	10,0	870	901	851
1,25	0,25	200	9,9	9,9	9,9	840	844	843
1,25	0,25	250	11,4	11,9	12,3	972	1011	1041
1,25	0,25	300	11,9	12,6	12,4	1011	1067	1057
1,25	0,35	200	11,5	10,9	11,1	976	924	942
1,25	0,35	250	13,1	13,8	12,9	1110	1171	1098
1,25	0,35	300	13,4	13,3	14,1	1137	1130	1195
2,00	0,15	200	10,2	9,7	10,0	865	824	846
2,00	0,15	250	11,0	10,7	10,8	933	911	918
2,00	0,15	300	11,2	11,1	11,8	955	941	1005
2,00	0,25	200	11,0	10,4	10,4	938	885	879
2,00	0,25	250	12,9	12,3	13,0	1097	1047	1107
2,00	0,25	300	13,6	13,1	12,6	1158	1113	1066
2,00	0,35	200	12,8	12,4	11,7	1083	1051	994
2,00	0,35	250	14,0	13,9	13,9	1186	1181	1179
2,00	0,35	300	14,6	15,4	14,7	1237	1307	1245

Tabla 13.2 – Datos experimentales del conjunto de validación.

a_p [mm]	f [mm/r.]	V [m/min]	Termo-FEM [mV]			Temperatura [°C]		
			Rép. 1	Rép. 2	Rép. 3	Rép. 1	Rép. 2	Rép. 3
0,88	0,19	225	9,1	9,4	9,6	773	799	815
0,88	0,19	275	10,7	10,9	11,3	909	926	960
0,88	0,31	225	11,2	11,9	11,7	951	1011	994
0,88	0,31	275	13,2	12,8	12,9	1121	1087	1095
1,62	0,19	225	9,8	9,9	10,3	832	841	875
1,62	0,19	275	11,7	10,8	11,2	994	917	951
1,62	0,31	225	11,5	11,7	11,8	977	994	1002
1,62	0,31	275	13,3	14,2	13,7	1129	1206	1163

Tabla 13.3 – Datos experimentales del conjunto de comprobación.

a_p [mm]	f [mm/r.]	V [m/min]	Termo-FEM [mV]			Temperatura [°C]		
			Rép. 1	Rép. 2	Rép. 3	Rép. 1	Rép. 2	Rép. 3
1,90	0,31	270	14,0	13,0	13,1	1189	1104	1112
1,15	0,23	285	11,7	11,4	11,6	994	968	985
1,40	0,28	230	12,0	11,9	12,4	1019	1011	1053
0,70	0,17	245	9,0	9,2	9,3	765	782	790

Anexo 14 – Modelo de regresión para la vida útil.

Modelo: $\ln(T) = 22,43 - 0,4598 \cdot \ln(a_p) - 0,6963 \cdot \ln(f) - 3,4556 \cdot \ln(V)$ ó

$$T = \frac{5,485 \cdot 10^9}{a_p^{0,4598} \cdot f^{0,6963} \cdot V^{3,456}}$$

Tabla A14.1 – Análisis de sensibilidad de los coeficientes.

Parámetro	Estimado	Error estándar	Estadístico t	Probabilidad
Constante	22,42	0,2686	83,49	0,000
$\ln(a_p)$	-0,4598	0,01393	-33,00	0,000
$\ln(f)$	-0,6963	0,02302	-30,24	0,000
$\ln(V)$	-3,456	0,04837	-71,45	0,000

Tabla A14.2 – Análisis de Varianza.

	Suma de Cdos.	G.L.	Cuadrado Medio	Estadíst. F	Prob.
Modelo	12,35	3	4,1154	2370	0,000
Residuales	0,03995	23	0,001737		
Total	12,39	26			

Tabla A14.3 – Resumen estadístico de la regresión.

Coefficiente R^2	0,9968
Coef. R^2 (ajustado a los G.L.)	0,9964
Error estándar de las estimaciones	0,04167
Estadístico de Durbin-Watson	1,861 (Prob. = 0,2667)




Fig. A14.1 – Gráfico de residuales vs. predicciones.




Fig. A14.2 – Gráfico de observaciones vs. predicciones.

Anexo 15 – Modelo de red neuronal MLP para la vida útil.

A15. 1 – Selección de factores de diseño (parámetros de entrenamiento de la red).

Tabla A11.1 – Factores de diseño.

Factores	Símbolo	Niveles		
		Bajo	Medio	Alto
Velocidad de aprendizaje	LR	0,1	0,3	0,5
Constante de momento	MC	0,1	0,5	0,9
Cantidad de Iteraciones	E_{MAX}	50000	25000	45000
Cantidad de neuronas en la capa oculta	N_H	1	3	5

Tabla A15.2 – Objetivos del diseño.

Objetivos del diseño	Símbolo
Error medio cuadrático de los residuales	$RMSE$
Capacidad de generalización	$C.G.$

Tabla A15.3 – Arreglo ortogonal utilizado: $L9 (3^4)$.

Exp. No.	Factores				Objetivos	
	LR	MC	E_{MAX}	N_H	$RMSE$	$C.G.$
1	0,1	0,1	5000	1	4,0804	0,8812
2	0,1	0,5	25000	3	3,8454	0,5062
3	0,1	0,9	45000	5	3,1160	0,9138
4	0,3	0,1	25000	5	3,5492	0,3158
5	0,3	0,5	45000	1	4,1056	0,2872
6	0,3	0,9	5000	3	3,8138	0,7069
7	0,5	0,1	45000	3	2,9403	0,7647
8	0,5	0,5	5000	5	3,7916	0,7694
9	0,5	0,9	25000	1	4,1377	0,2885

Tabla A15.4 – Influencia de los factores en los objetivos de diseño.

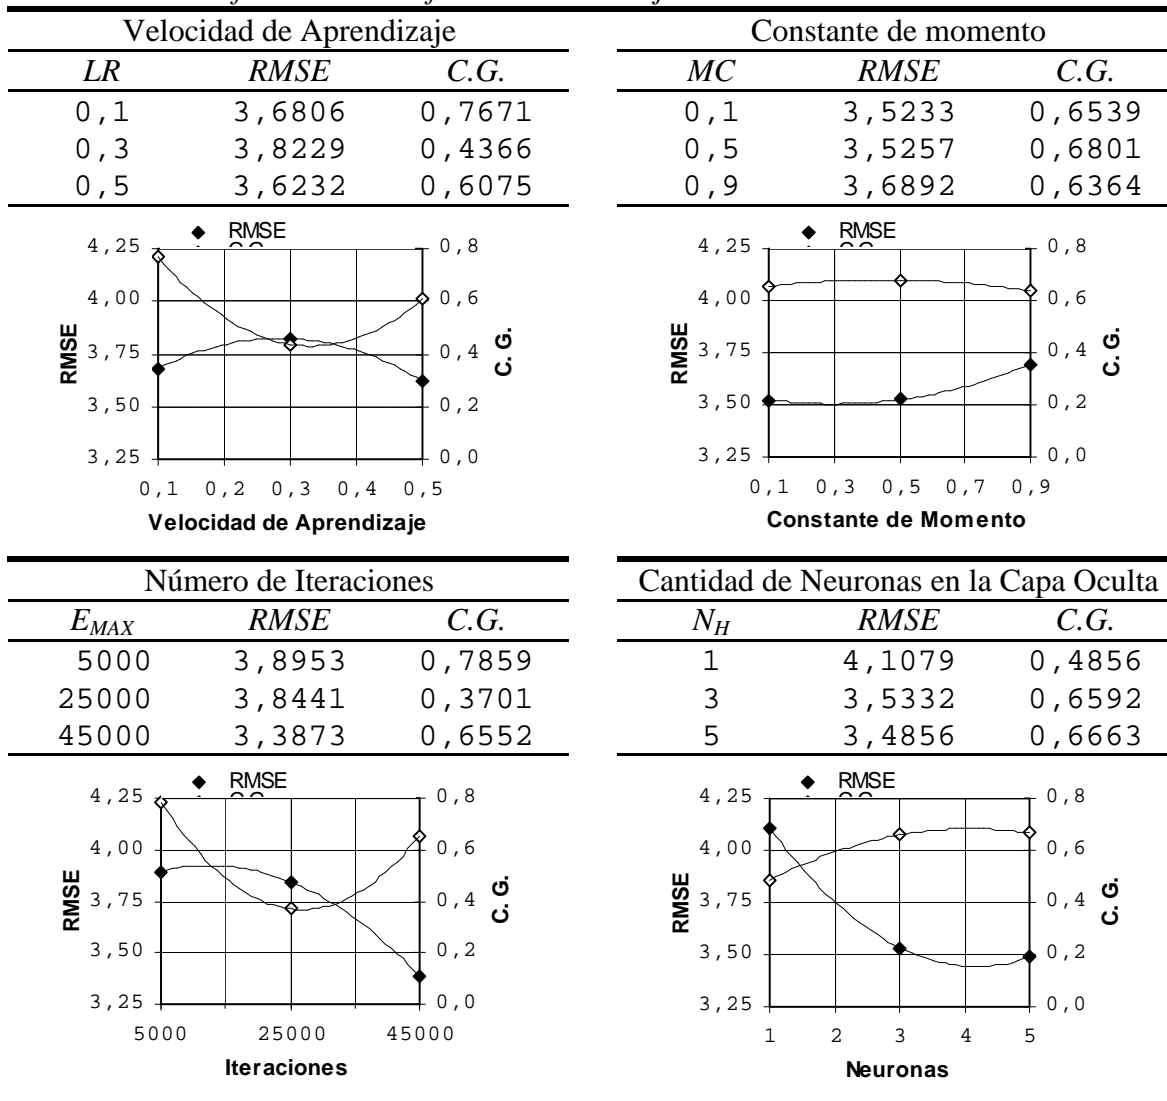


Tabla A15.5 – Niveles seleccionados para los factores de diseño.

Factor de diseño	Símbolo	Valor
Velocidad de aprendizaje	LR	0,1
Constante de momento	MC	0,1
Cantidad de Iteraciones	E_{MAX}	45000
Cantidad de neuronas en la capa oculta	N_H	4

A15. 2 – Entrenamiento y análisis de la red seleccionada.




Fig. A15.1 – Progreso del entrenamiento de la red seleccionada.




Fig. A15.2 – Residuales vs. predicciones de la red seleccionada.




Fig. A15.3 – Observaciones vs. predicciones de la red seleccionada.

A15.3 – Código de la red entrenada (*Visual Basic for Applications*).

```

Public Function T_MLP(Ap As Double, F As Double, _
                    V As Double) As Double
    ' Declaraciones
    Dim X(0 To 2) As Double
    Dim WI(0 To 2, 0 To 3) As Double
    Dim B1(0 To 3) As Double
    Dim L1(0 To 3) As Double
    Dim WL(0 To 3) As Double
    Dim B2 As Double
    Dim I, J As Integer
    Dim S As Double
    ' Datos
    X(0) = (Log(Ap) - Log(0.5)) / (Log(2#) - Log(0.5))
    X(1) = (Log(F) - Log(0.15)) / (Log(0.35) - Log(0.15))
    X(2) = (Log(V) - Log(200)) / (Log(300) - Log(200))
    WI(0, 0)= -0.4095: WI(1, 0)= -0.4737: WI(2, 0)= -1.0627
    WI(0, 1)= 0.5301: WI(1, 1)= -0.293: WI(2, 1)= -1.112
    WI(0, 2)= -1.4377: WI(1, 2)= -0.1613: WI(2, 2)= -0.1603
    WI(0, 3)= -0.998: WI(1, 3)= -0.3514: WI(2, 3)= -0.2637
    B1(0)= 1.1578: B1(1)= 0.191: B1(2)= 0.4636
    B1(3)= -0.8057
    WL(0)= 1.1566: WL(1)= 0.774: WL(2)= 0.4334: WL(3)= 0.5917
    B2 = -0.7545
    ' Capa Oculta
    For I = 0 To 3
        S = B1(I)
        For J = 0 To 2
            S = S + WI(J, I) * X(J)
        Next J
        L1(I) = 1 / (1 + Exp(-S))
    Next I
    ' Capa de Salida
    S = B2
    For I = 0 To 3
        S = S + WL(I) * L1(I)
    Next I
    ' Resultados
    T_MLP = Exp(Log(23.1) + S * (Log(317.2) - Log(23.1)))
End Function

```

Anexo 16 – Modelo de red neuronal RBF para la vida útil.

A16. 1 – Selección de factores de diseño (parámetros de entrenamiento de la red).

Tabla A16.1 – Factores de diseño.

Factores	Símbolo	Niveles		
		Bajo	Medio	Alto
Coefficiente de dispersión	<i>s</i>	0,5	1,0	1,5
Error máximo a obtener	<i>err</i>	0,000	0,005	0,010

Tabla A16.2 – Objetivos del diseño.

Objetivos del diseño	Símbolo
Error medio cuadrático de los residuales	<i>RMSE</i>
Capacidad de generalización	<i>C.G.</i>

Tabla A16.3 – Arreglo ortogonal utilizado: $L9 (3^2)$.

Exp. No.	Factores		Objetivos	
	<i>s</i>	<i>err</i>	<i>RMSE</i>	<i>C.G.</i>
1	0,5	0,000	11,13	0,0469
2	0,5	0,005	11,58	0,0486
3	0,5	0,010	10,65	0,0602
4	1,0	0,000	4,036	0,1167
5	1,0	0,005	5,165	0,2114
6	1,0	0,010	5,165	0,2114
7	1,5	0,000	2,015	0,2453
8	1,5	0,005	3,024	0,5569
9	1,5	0,010	5,985	0,5266

Tabla A16.4 – Influencia de los factores en los objetivos de diseño.

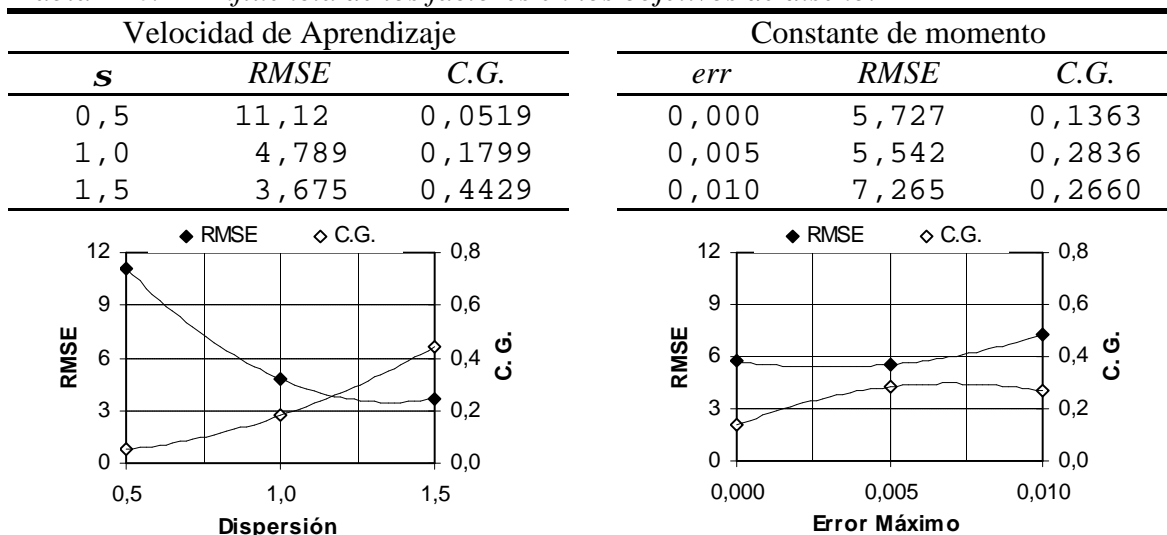


Tabla A16.5 – Niveles seleccionados para los factores de diseño.

Factor de diseño	Símbolo	Selección	
		Nivel	Valor
Coficiente de dispersión	s	Alto	1,5
Error máximo a obtener	err	Medio	0,005

A16. 2 – Entrenamiento y análisis de la red seleccionada.




Fig. A16.1 – Progreso del entrenamiento de la red seleccionada.




Fig. A16.2 – Residuales vs. predicciones de la red seleccionada.




Fig. A16.3 – Observaciones vs. predicciones de la red seleccionada.

A16.3 – Código de la red entrenada (*Visual Basic for Applications*).

```
Public Function T_RBF(Ap As Double, F As Double, _
                    V As Double) As Double

    ' Declaraciones
    Dim X(0 To 2) As Double
    Dim WI(0 To 2, 0 To 9) As Double
    Dim B1 As Double
    Dim L1(0 To 9) As Double
    Dim WL(0 To 9) As Double
    Dim B2 As Double
    Dim I, J As Integer
    Dim S As Double

    ' Datos
    X(0) = (Log(Ap) - Log(0.5)) / (Log(2#) - Log(0.5))
    X(1) = (Log(F) - Log(0.15)) / (Log(0.35) - Log(0.15))
    X(2) = (Log(V) - Log(200)) / (Log(300) - Log(200))
    WI(0, 0) = 0#: WI(1, 0) = 0#: WI(2, 0) = 0#
    WI(0, 1) = 0#: WI(1, 1) = 0#: WI(2, 1) = 0.5503
    WI(0, 2) = 0.661: WI(1, 2) = 0.6029: WI(2, 2) = 1#
    WI(0, 3) = 0.661: WI(1, 3) = 0.6029: WI(2, 3) = 0#
    WI(0, 4) = 0#: WI(1, 4) = 0#: WI(2, 4) = 1#
    WI(0, 5) = 0#: WI(1, 5) = 1#: WI(2, 5) = 0#
    WI(0, 6) = 1#: WI(1, 6) = 0.6029: WI(2, 6) = 0#
    WI(0, 7) = 0.661: WI(1, 7) = 0#: WI(2, 7) = 0#
    WI(0, 8) = 0#: WI(1, 8) = 0.6029: WI(2, 8) = 0.5503
```

```

WI(0, 9) = 1#: WI(1, 9) = 0.6029: WI(2, 9) = 1#
B1 = 0.555
WL(0) = 5.5364: WL(1) = -4.1269: WL(2) = 4.5446
WL(3) = -15.3034: WL(4) = 2.8185: WL(5) = 5.1226
WL(6) = 11.1129: WL(7) = 0.5586: WL(8) = -3.3088
WL(9) = -3.7363
B2 = -0.5584
' Capa Oculta
For I = 0 To 9
    S = 0
    For J = 0 To 2
        S = S + (WI(J, I) - X(J)) ^ 2
    Next J
    S = B1 * S ^ 0.5
    L1(I) = Exp(-(S ^ 2))
Next I
' Capa de Salida
S = B2
For I = 0 To 9
    S = S + WL(I) * L1(I)
Next I
' Resultados
T_RBF = Exp(Log(23.1) + S * (Log(317.2) - Log(23.1)))
End Function

```


Anexo 17 – Código del modelo combinado para la vida útil.

```

Public Function Min(X1 As Double, X2 As Double) As Double
    If X1 < X2 Then Min = X1 Else Min = X2
End Function

Public Function T_Comb(Ap As Double, F As Double, _
    V As Double) As Double
    ' Constantes y definiciones
    Const Ze_reg = 3.9: Const Zv_reg = 3.9
    Const Ze_mlp = 3.3: Const Zv_mlp = 3.6
    Const Ze_rbf = 3.1: Const Zv_rbf = 3.9
    Dim X(0 To 2) As Double
    Dim Dx As Double, Dy As Double, Dz As Double
    Dim Dent As Double, Dval As Double
    Dim TL_reg As Double, TL_mlp As Double, TL_rbf As Double
    Dim Z_reg As Double, Z_mlp As Double, Z_rbf As Double
    Dim W_reg As Double, W_mlp As Double, W_rbf As Double
    ' Normalización de los datos
    X(0) = (Ap - 0.5) / (2# - 0.5)
    X(1) = (F - 0.15) / (0.35 - 0.15)
    X(2) = (V - 200) / (300 - 200)
    ' Cálculo de las distancias
    Dx = Min(X(0), Min(Abs(X(0) - 0.5), Abs(1 - X(0))))
    Dy = Min(X(1), Min(Abs(X(1) - 0.5), Abs(1 - X(1))))
    Dz = Min(X(2), Min(Abs(X(2) - 0.5), Abs(1 - X(2))))
    Dent = Sqr(Dx ^ 2 + Dy ^ 2 + Dz ^ 2)
    Dx = Min(Abs(X(0) - 0.2533), Abs(X(0) - 0.7467))
    Dy = Min(Abs(X(1) - 0.2533), Abs(X(1) - 0.7467))
    Dz = Min(Abs(X(2) - 0.2533), Abs(X(2) - 0.7467))
    Dval = Sqr(Dx ^ 2 + Dy ^ 2 + Dz ^ 2)
    ' Cálculo de los modelos
    TL_reg = 5.485E9 / (Ap^0.4598 * F^0.6963 * V^3.4556)
    TL_mlp = T_mlp(Ap, F, V)
    TL_rbf = T_rbf(Ap, F, V)
    ' Cálculo de las precisiones
    Z_reg = Ze_reg + Dent * (Zv_reg - Ze_reg) / (Dval + Dent)
    Z_mlp = Ze_mlp + Dent * (Zv_mlp - Ze_mlp) / (Dval + Dent)
    Z_rbf = Ze_rbf + Dent * (Zv_rbf - Ze_rbf) / (Dval + Dent)

```

```
' Cálculo de las ponderaciones
W_reg = Exp(-Z_reg)/(Exp(-Z_reg)+Exp(-Z_mlp)+Exp(-Z_rbf))
W_mlp = Exp(-Z_mlp)/(Exp(-Z_reg)+Exp(-Z_mlp)+Exp(-Z_rbf))
W_rbf = Exp(-Z_rbf)/(Exp(-Z_reg)+Exp(-Z_mlp)+Exp(-Z_rbf))
' Cálculo del valor final
T_Comb = W_reg * TL_reg + W_mlp * TL_mlp + W_rbf * TL_rbf
End Function
```

Anexo 18 – Comparación de los modelos para la vida útil.

Tabla A18.1 – Predicciones y errores de los modelos para los el conjunto de experimentos principales.

T [min]	T^* [min]				Error relativo [%]			
	Regres.	MLP	RBF	Comb.	Regres.	MLP	RBF	Comb.
317,2	316,1	315,7	314,0	315,0	0,3	0,5	1,0	0,7
149,6	146,2	149,8	148,2	148,4	2,3	0,1	0,9	0,8
79,4	77,9	79,6	79,2	79,1	1,9	0,2	0,2	0,4
220,2	221,5	222,1	229,4	225,2	0,6	0,9	4,2	2,3
105,0	102,4	102,4	102,7	102,6	2,4	2,4	2,2	2,3
52,4	54,6	54,8	54,6	54,7	4,2	4,8	4,3	4,4
180,8	175,2	174,7	176,4	175,5	3,1	3,4	2,4	2,9
78,7	81,0	79,8	81,2	80,7	3,0	1,5	3,2	2,6
45,5	43,2	43,3	43,5	43,4	5,1	4,8	4,4	4,7
197,0	207,4	203,2	199,7	202,5	5,3	3,2	1,4	2,8
95,3	95,9	94,7	94,7	94,9	0,7	0,6	0,6	0,3
51,8	51,1	49,5	51,1	50,5	1,3	4,4	1,3	2,4
138,5	145,3	143,7	141,4	143,0	5,0	3,8	2,2	3,3
66,3	67,2	65,3	63,8	65,0	1,4	1,5	3,8	1,9
33,4	35,8	34,7	34,4	34,8	7,3	4,1	3,2	4,3
109,9	115,0	113,6	108,0	111,4	4,6	3,4	1,7	1,4
51,4	53,2	51,4	50,3	51,3	3,5	0,1	2,1	0,3
26,7	28,3	27,8	27,6	27,8	6,3	4,5	3,6	4,4
172,5	167,1	166,4	165,4	166,1	3,1	3,5	4,1	3,7
72,7	77,3	77,9	78,2	77,9	6,4	7,3	7,6	7,2
40,9	41,2	40,9	40,8	40,9	0,8	0,1	0,0	0,2
124,7	117,1	118,8	124,5	121,0	6,1	4,7	0,2	3,0
56,1	54,2	54,4	55,8	55,0	3,5	3,0	0,6	2,0
30,9	28,8	29,1	28,9	29,0	6,7	5,8	6,4	6,2
93,8	92,6	94,6	95,3	94,5	1,2	0,9	1,7	0,8
43,6	42,8	43,2	44,3	43,6	1,7	1,0	1,5	0,0
23,1	22,8	23,6	23,5	23,4	1,2	2,2	1,8	1,3

Tabla A18.2 – Predicciones y errores de los modelos para el conjunto de experimentos de validación.





T [min]	T^* [min]				Error relativo [%]			
	Regres.	MLP	RBF	Comb.	Regres.	MLP	RBF	Comb.
133,6	137,6	136,5	138,8	137,5	3,0	2,2	3,9	2,9
68,2	68,8	66,9	67,1	67,5	0,9	1,9	1,7	1,0
93,0	97,9	95,5	94,1	95,8	5,2	2,7	1,2	3,0
49,1	48,9	47,0	45,8	47,2	0,4	4,3	6,8	3,9
107,3	104,0	103,9	107,2	104,9	3,1	3,2	0,1	2,2
52,2	52,0	50,9	50,9	51,2	0,5	2,5	2,6	1,9
69,4	73,9	73,5	74,2	73,8	6,5	5,9	6,9	6,4
34,9	37,0	36,3	35,6	36,3	5,9	4,0	1,9	3,9

Tabla A18.3 – Predicciones y errores de los modelos para el conjunto experimentos de comprobación.

T [min]	T^* [min]				Error relativo [%]			
	Regres.	MLP	RBF	Comb.	Regres.	MLP	RBF	Comb.
37,0	36,6	36,6	36,4	36,5	1,1	1,2	1,6	1,3
45,2	47,1	45,3	44,6	45,5	4,1	0,3	1,3	0,6
78,1	78,7	77,4	76,8	77,5	0,7	0,9	1,6	0,8
124,2	123,1	122,9	124,8	123,7	0,9	1,0	0,5	0,4

Tabla A18.4 – Comparación de los valores máximo y RMS de los diferentes modelos.

Conjunto	Error [%]	Regresión	Red. MLP	Red. RBF	Modelo Combinado
Principal (entrenamiento)	Máximo	7,3	7,3	7,6	7,2
	RMS	3,9	3,3	3,1	3,1
Validación	Máximo	6,5	5,9	6,9	6,4
	RMS	3,9	3,6	3,9	3,5
Comprobación	Máximo	4,1	1,2	1,6	1,3
	RMS	2,2	0,9	1,3	0,8
Total	Máximo	7,3	7,3	7,6	7,2
	RMS	3,8	3,2	3,1	3,0

*a) Conjunto principal**b) Conjunto de validación**c) Conjunto de comprobación**d) Todos los puntos**Fig. A18.1 – Representación gráfica de los errores.*

Anexo 19 – Modelo de regresión para la componente principal (tangencial) de la fuerza de corte.

Modelo: $\ln(F_C) = 8,788 + 1,095 \cdot \ln(a_p) + 0,9167 \cdot \ln(f) - 0,2857 \cdot \ln(V)$ ó

$$F_C = \frac{6555 \cdot a_p^{1,095} \cdot f^{0,9167}}{V^{0,2857}}$$

Tabla A19.1 – Análisis de sensibilidad de los coeficientes.

Parámetro	Estimado	Error estándar	Estadístico t	Probabilidad
Constante	8,788	0,4372	20,10	0,000
$\ln(a_p)$	1,095	0,02268	48,27	0,000
$\ln(f)$	0,9167	0,03748	24,45	0,000
$\ln(V)$	-0,2857	0,07874	-3,629	0,001

Tabla A19.2 – Análisis de Varianza.

	Suma de Cdos.	G.L.	Cuadrado Medio	Estadíst. F	Prob.
Modelo	40,61	3	13,54	980,4	0,000
Residuales	1,063	77	0,01381		
Total	41,67	80			

Tabla A19.3 – Resumen estadístico de la regresión.

Coefficiente R^2	0,9745
Coef. R^2 (ajustado a los G.L.)	0,9735
Error estándar de las estimaciones	0,1175
Estadístico de Durbin-Watson	1,595 (Prob. = 0,026)




Fig. A19.1 – Gráfico de residuales vs. predicciones.




Fig. A19.2 – Gráfico de observaciones vs. predicciones.

Anexo 20 – Modelo de red MLP para la componente principal (tangencial) de la fuerza de corte.

A20. 1 – Selección de factores de diseño (parámetros de entrenamiento de la red).

Tabla A20.1 – Factores de diseño.

Factores	Símbolo	Niveles		
		Bajo	Medio	Alto
Velocidad de aprendizaje	LR	0,1	0,3	0,5
Constante de momento	MC	0,1	0,5	0,9
Cantidad de Iteraciones	E_{MAX}	50000	25000	45000
Cantidad de neuronas en la capa oculta	N_H	1	3	5

Tabla A20.2 – Objetivos del diseño.

Objetivos del diseño	Símbolo
Error medio cuadrático de los residuales	$RMSE$
Capacidad de generalización	$C.G.$

Tabla A20.3 – Arreglo ortogonal utilizado: $L9 (3^4)$.

Exp. No.	Factores				Objetivos	
	LR	MC	E_{MAX}	N_H	$RMSE$	$C.G.$
1	0,1	0,1	5000	1	69,39	0,0075
2	0,1	0,5	25000	3	48,24	0,0291
3	0,1	0,9	45000	5	54,67	0,0062
4	0,3	0,1	25000	5	42,11	0,2958
5	0,3	0,5	45000	1	53,78	0,0193
6	0,3	0,9	5000	3	58,67	0,0093
7	0,5	0,1	45000	3	34,30	0,4016
8	0,5	0,5	5000	5	59,30	0,0103
9	0,5	0,9	25000	1	54,18	0,0179

Tabla A20.4 – Influencia de los factores en los objetivos de diseño.

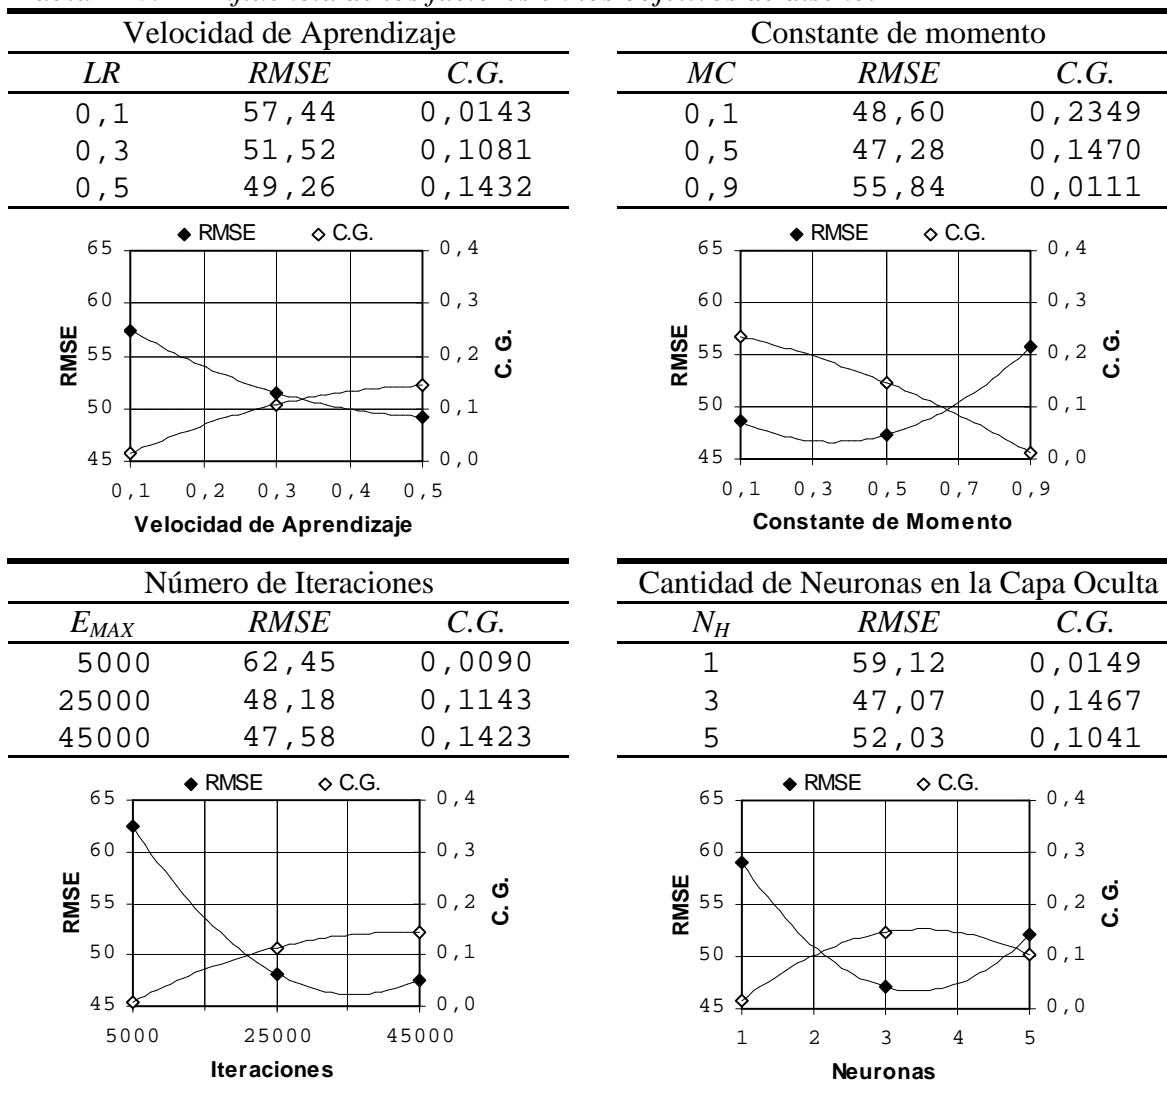


Tabla A20.5 – Niveles seleccionados para los factores de diseño.

Factor de diseño	Símbolo	Selección	
		Nivel	Valor
Velocidad de aprendizaje	LR	Alto	0,5
Constante de momento	MC	Bajo	0,1
Cantidad de Iteraciones	E_{MAX}	Alto	45000
Cantidad de neuronas en la capa oculta	N_H	Medio	3

A20. 2 – Entrenamiento y análisis de la red seleccionada.




Fig. A20.1 – Progreso del entrenamiento de la red seleccionada.




Fig. A11.2 – Residuales vs. predicciones de la red seleccionada.




Fig. A11.3 – Observaciones vs. predicciones de la red seleccionada.

A20.3 – Código de la red entrenada (*Visual Basic for Applications*).

```

Public Function Fc_MLP(Ap As Double, F As Double, _
                      V As Double) As Double
    ' Declaraciones
    Dim X(0 To 2) As Double
    Dim WI(0 To 2, 0 To 2) As Double
    Dim B1(0 To 2) As Double
    Dim L1(0 To 2) As Double
    Dim WL(0 To 2) As Double
    Dim B2 As Double
    Dim I, J As Integer
    Dim S As Double
    ' Datos
    X(0) = (Log(Ap) - Log(0.5)) / (Log(2#) - Log(0.5))
    X(1) = (Log(F) - Log(0.15)) / (Log(0.35) - Log(0.15))
    X(2) = (Log(V) - Log(200#)) / (Log(300#) - Log(200#))
    WI(0, 0) = -2.1971: WI(1, 0) = 0.4291: WI(2, 0) = 0.1216
    WI(0, 1) = 0.7104: WI(1, 1) = 1.298: WI(2, 1) = 0.6329
    WI(0, 2) = 0.126: WI(1, 2) = -0.1207: WI(2, 2) = 1.0519
    B1(0) = 1.8255: B1(1) = -1.5924: B1(2) = 0.342
    WL(0) = -1.0277: WL(1) = 1.1982: WL(2) = -0.8948
    B2 = 1.2824
    ' Capa oculta
    For I = 0 To 2
        S = B1(I)
        For J = 0 To 2
            S = S + WI(J, I) * X(J)
        Next J
        L1(I) = 1 / (1 + Exp(-S))
    Next I
    ' Capa de salida
    S = B2
    For I = 0 To 2
        S = S + WL(I) * L1(I)
    Next I
    ' Resultado
    Fc_MLP = Exp(Log(100#) + S * (Log(1350#) - Log(100#)))
End Function

```

Anexo 21 – Modelo de red neuronal RBF para la componente principal (tangencial) de la fuerza de corte.

A21. 1 – Selección de factores de diseño (parámetros de entrenamiento de la red).

Tabla A21.1 – Factores de diseño.

Factores	Símbolo	Niveles		
		Bajo	Medio	Alto
Coefficiente de dispersión	<i>s</i>	0,5	1,0	1,5
Error máximo a obtener	<i>err</i>	0,000	0,005	0,010

Tabla A21.2 – Objetivos del diseño.

Objetivos del diseño	Símbolo
Error medio cuadrático de los residuales	<i>RMSE</i>
Capacidad de generalización	<i>C.G.</i>

Tabla A21.3 – Arreglo ortogonal utilizado: $L9 (3^2)$.

Exp. No.	Factores		Objetivos	
	<i>s</i>	<i>err</i>	<i>RMSE</i>	<i>C.G.</i>
1	0,5	0,000	62,44	0,2610
2	0,5	0,005	56,13	0,3471
3	0,5	0,010	62,01	0,2973
4	1,0	0,000	17,32	0,8510
5	1,0	0,005	21,71	0,7797
6	1,0	0,010	29,70	0,8470
7	1,5	0,000	15,22	0,5839
8	1,5	0,005	18,32	0,8436
9	1,5	0,010	18,32	0,8436

Tabla A21.4 – Influencia de los factores en los objetivos de diseño.




Tabla A21.5 – Niveles seleccionados para los factores de diseño.

Factor de diseño	Símbolo	Valor
Coeficiente de dispersión	s	1,25
Error máximo a obtener	err	0,005

A21. 2 – Entrenamiento y análisis de la red seleccionada.




Fig. A21.1 – Progreso del entrenamiento de la red seleccionada.




Fig. A21.2 – Residuales vs. predicciones de la red seleccionada.




Fig. A21.3 – Observaciones vs. predicciones de la red seleccionada.

A21.3 – Código de la red entrenada (*Visual Basic for Applications*).

```
Public Function Fc_RBF(Ap As Double, F As Double, _
                    V As Double) As Double

    ' Declaraciones
    Dim X(0 To 2) As Double
    Dim WI(0 To 2, 0 To 13) As Double
    Dim B1 As Double
    Dim L1(0 To 13) As Double
    Dim WL(0 To 13) As Double
    Dim B2 As Double
    Dim I, J As Integer
    Dim S As Double

    ' Datos
    X(0) = (Log(Ap) - Log(0.5)) / (Log(2#) - Log(0.5))
    X(1) = (Log(F) - Log(0.15)) / (Log(0.35) - Log(0.15))
    X(2) = (Log(V) - Log(200)) / (Log(300) - Log(200))
    WI(0, 0) = 1#: WI(1, 0) = 1#: WI(2, 0) = 0.5503
    WI(0, 1) = 0#: WI(1, 1) = 0.6029: WI(2, 1) = 0.5503
    WI(0, 2) = 1#: WI(1, 2) = 0.6029: WI(2, 2) = 0#
    WI(0, 3) = 0#: WI(1, 3) = 1#: WI(2, 3) = 1#
    WI(0, 4) = 0.661: WI(1, 4) = 1#: WI(2, 4) = 0.5503
    WI(0, 5) = 0#: WI(1, 5) = 1#: WI(2, 5) = 0#
    WI(0, 6) = 0.661: WI(1, 6) = 0#: WI(2, 6) = 0.5503
    WI(0, 7) = 1#: WI(1, 7) = 0.6029: WI(2, 7) = 0.5503
    WI(0, 8) = 1#: WI(1, 8) = 0.6029: WI(2, 8) = 1#
```

```

WI(0, 9) = 0#: WI(1, 9) = 1#: WI(2, 9) = 0.5503
WI(0, 10) = 0.661: WI(1, 10) = 0.6029: WI(2, 10) = 0.5503
WI(0, 11) = 1#: WI(1, 11) = 1#: WI(2, 11) = 0#
WI(0, 12) = 0.661: WI(1, 12) = 1#: WI(2, 12) = 0#
WI(0, 13) = 0.661: WI(1, 13) = 0#: WI(2, 13) = 0#
B1 = 0.666
WL(0) = -5.0277: WL(1) = -2.0684: WL(2) = -1.6151
WL(3) = 0.2666: WL(4) = 5.5806: WL(5) = 5.2136
WL(6) = 0.5636: WL(7) = -2.9132: WL(8) = 4.2071
WL(9) = 0.5142: WL(10) = -2.9269: WL(11) = 15.7765
WL(12) = -15.9048: WL(13) = 2.1776
B2 = -0.5537
' Capa oculta
For I = 0 To 13
    S = 0
    For J = 0 To 2
        S = S + (WI(J, I) - X(J)) ^ 2
    Next J
    S = B1 * S ^ 0.5
    L1(I) = Exp(-(S ^ 2))
Next I
' Capa de salida
S = B2
For I = 0 To 13
    S = S + WL(I) * L1(I)
Next I
'Resultados
Fc_RBF = Exp(Log(100#) + S * (Log(1350#) - Log(100#)))
End Function

```

Anexo 22 – Código del modelo combinado para la fuerza tangencial.

```

Public Function Min(X1 As Double, X2 As Double) As Double
    If X1 < X2 Then Min = X1 Else Min = X2
End Function

Public Function Fc_Comb(Ap As Double, F As Double, _
                        V As Double) As Double
    ' Constantes y definiciones
    Const Ze_reg = 9.8: Const Zv_reg = 11.4
    Const Ze_mlp = 7.1: Const Zv_mlp = 4.6
    Const Ze_rbf = 2.9: Const Zv_rbf = 7.1
    Dim X(0 To 2) As Double
    Dim Dx As Double, Dy As Double, Dz As Double
    Dim Dent As Double, Dval As Double
    Dim F_reg As Double, F_mlp As Double, F_rbf As Double
    Dim Z_reg As Double, Z_mlp As Double, Z_rbf As Double
    Dim W_reg As Double, W_mlp As Double, W_rbf As Double
    ' Normalización de los datos
    X(0) = (Ap - 0.5) / (2# - 0.5)
    X(1) = (F - 0.15) / (0.35 - 0.15)
    X(2) = (V - 200) / (300 - 200)
    ' Cálculo de las distancias
    Dx = Min(X(0), Min(Abs(X(0) - 0.5), Abs(1 - X(0))))
    Dy = Min(X(1), Min(Abs(X(1) - 0.5), Abs(1 - X(1))))
    Dz = Min(X(2), Min(Abs(X(2) - 0.5), Abs(1 - X(2))))
    Dent = Sqr(Dx ^ 2 + Dy ^ 2 + Dz ^ 2)
    Dx = Min(Abs(X(0) - 0.2533), Abs(X(0) - 0.7467))
    Dy = Min(Abs(X(1) - 0.2533), Abs(X(1) - 0.7467))
    Dz = Min(Abs(X(2) - 0.2533), Abs(X(2) - 0.7467))
    Dval = Sqr(Dx ^ 2 + Dy ^ 2 + Dz ^ 2)
    ' Cálculo de los modelos
    F_reg = 6555# * (Ap ^ 1.095 * F ^ 0.9167) / (V ^ 0.2857)
    F_mlp = Fc_mlp(Ap, F, V)
    F_rbf = Fc_rbf(Ap, F, V)
    ' Cálculo de las precisiones
    Z_reg = Ze_reg + Dent * (Zv_reg - Ze_reg) / (Dval + Dent)
    Z_mlp = Ze_mlp + Dent * (Zv_mlp - Ze_mlp) / (Dval + Dent)
    Z_rbf = Ze_rbf + Dent * (Zv_rbf - Ze_rbf) / (Dval + Dent)

```

```
' Cálculo de las ponderaciones
W_reg = Exp(-Z_reg)/(Exp(-Z_reg)+Exp(-Z_mlp)+Exp(-Z_rbf))
W_mlp = Exp(-Z_mlp)/(Exp(-Z_reg)+Exp(-Z_mlp)+Exp(-Z_rbf))
W_rbf = Exp(-Z_rbf)/(Exp(-Z_reg)+Exp(-Z_mlp)+Exp(-Z_rbf))
' Cálculo del valor final
Fc_Comb = W_reg * F_reg + W_mlp * F_mlp + W_rbf * F_rbf
End Function
```


Anexo 23 – Comparación de los modelos para la componente tangencial de la fuerza de corte.

Tabla 23.1 – Predicciones y errores de los modelos para los experimentos principales.

F_C [N]	F_C' [N]				Error relativo [%]			
	Regres.	MLP	RBF	Comb.	Regres.	MLP	RBF	Comb.
140	118,6	122,1	135,3	135,1	15,3	12,8	3,3	3,5
107	111,3	104,6	106,8	106,7	4,4	1,9	0,1	0,1
100	105,7	99,5	103,0	102,9	5,7	0,5	3,0	2,9
180	189,5	182,0	188,9	188,8	5,3	1,1	5,0	4,9
167	177,8	167,7	166,8	166,9	6,7	0,6	0,1	0,1
180	168,8	166,8	173,1	173,0	6,2	7,3	3,8	3,9
280	258,0	260,0	272,9	272,7	7,9	7,1	2,5	2,6
260	242,0	245,0	262,2	261,9	6,9	5,8	0,8	0,7
257	229,8	243,9	259,9	259,7	10,5	5,0	1,3	1,2
303	323,6	303,6	312,2	312,1	6,7	0,1	2,9	2,9
287	303,6	269,1	282,3	282,2	5,9	6,1	1,5	1,6
313	288,2	262,4	298,2	297,6	8,0	16,3	4,8	5,0
433	516,9	457,3	436,4	436,7	19,3	5,5	0,7	0,8
417	484,9	424,6	417,0	417,2	16,4	1,9	0,1	0,1
440	460,3	419,9	473,2	472,4	4,6	4,6	7,5	7,4
600	703,6	633,3	594,5	595,2	17,3	5,6	0,9	0,8
587	660,2	583,3	574,7	574,9	12,5	0,6	2,0	2,0
607	626,6	563,0	598,4	597,9	3,3	7,2	1,4	1,4
563	541,4	562,3	563,5	563,4	3,9	0,2	0,0	0,0
500	508,0	511,1	507,6	507,6	1,6	2,2	1,5	1,5
480	482,2	506,2	495,0	495,1	0,5	5,5	3,1	3,1
1037	864,7	872,3	1000,0	998,0	16,6	15,9	3,5	3,7
887	811,3	810,7	871,8	870,8	8,5	8,6	1,7	1,8
870	770,2	796,2	841,5	840,8	11,5	8,5	3,3	3,4
1350	1177,2	1189,6	1381,5	1378,4	12,8	11,9	2,3	2,1
1113	1104,5	1077,0	1152,4	1151,3	0,8	3,3	3,5	3,4
993	1048,4	1020,0	988,1	988,6	5,5	2,7	0,5	0,5

Tabla 23.2 – Predicciones y errores de los modelos para los experimentos de validación.


F_C [N]	F_C' [N]				Error relativo [%]			
	Regres.	MLP	RBF	Comb.	Regres.	MLP	RBF	Comb.
213	264,6	221,8	207,5	220,7	24,0	4,0	2,7	3,5
220	249,9	210,4	215,8	210,9	13,6	4,4	1,9	4,2
383	414,5	357,5	322,9	354,9	8,1	6,7	15,8	7,4
360	391,4	344,6	348,8	345,0	8,7	4,3	3,1	4,2
493	516,2	482,5	493,1	483,3	4,6	2,2	0,0	2,0
443	487,4	463,0	492,5	465,3	9,9	4,4	11,1	4,9
807	808,5	756,9	798,1	760,0	0,2	6,2	1,1	5,8
733	763,5	716,5	759,7	719,8	4,1	2,3	3,6	1,8

Tabla 23.3 – Predicciones y errores de los modelos para los experimentos de comprobación.


F_C [N]	F_C' [N]				Error relativo [%]			
	Regres.	MLP	RBF	Comb.	Regres.	MLP	RBF	Comb.
932	913,9	892,8	946,7	943,0	1,9	4,2	1,6	1,2
362	395,0	348,2	374,4	373,2	9,1	3,8	3,4	3,1
565	623,8	560,8	557,5	557,7	10,4	0,7	1,3	1,3
152	181,5	154,1	150,5	150,6	19,4	1,4	1,0	0,9

Tabla 23.4 – Comparación de los valores máximo y RMS de los diferentes modelos.


Conjunto	Error [%]	Regresión	Red. MLP	Red. RBF	Modelo Combinado
Principal (entrenamiento)	Máximo	19,3	16,3	7,5	7,4
	RMS	9,8	7,1	2,9	2,9
Validación	Máximo	24,0	6,7	15,8	7,4
	RMS	11,4	4,6	7,1	4,6
Comprobación	Máximo	19,4	4,2	3,4	3,1
	RMS	12,0	2,9	2,1	1,8
Total	Máximo	24,0	16,3	15,8	7,4
	RMS	10,4	6,3	4,1	3,2




a) Conjunto principal



b) Conjunto de validación



c) Conjunto de comprobación



d) Todos los puntos

Fig. 23.1 – Representación gráfica de los errores.

Anexo 24 – Modelo de regresión para la componente de avance (axial) de la fuerza de corte.

Modelo: $\ln(F_F) = 12,40 + 1,120 \cdot \ln(a_p) + 0,9444 \cdot \ln(f) - 1,005 \cdot \ln(V)$ ó

$$F_F = \frac{243044 \cdot a_p^{1,120} \cdot f^{0,9444}}{V^{1,005}}$$

Tabla A24.1 – Análisis de sensibilidad de los coeficientes.

Parámetro	Estimado	Error estándar	Estadístico t	Probabilidad
Constante	12,40	0,4065	30,50	0,000
$\ln(a_p)$	1,120	0,02109	53,13	0,000
$\ln(f)$	0,9444	0,03485	27,10	0,000
$\ln(V)$	-1,005	0,07321	-13,73	0,000

Tabla A24.2 – Análisis de Varianza.

	Suma de Cdos.	G.L.	Cuadrado Medio	Estadíst. F	Prob.
Modelo	44,71	3	14,90	1249	0,000
Residuales	0,9190	77	0,01194		
Total	45,63	80			

Tabla A24.3 – Resumen estadístico de la regresión.

Coefficiente R^2	0,9799
Coef. R^2 (ajustado a los G.L.)	0,9791
Error estándar de las estimaciones	0,1092
Estadístico de Durbin-Watson	1,285 (Prob. = 0,000)




Fig. A24.1 – Gráfico de residuales vs. predicciones.




Fig. A24.2 – Gráfico de observaciones vs. predicciones.

Anexo 25 – Modelo de red neuronal MLP la componente de avance (axial) de la fuerza de corte.

A25. 1 – Selección de factores de diseño (parámetros de entrenamiento de la red).

Tabla A25.1 – Factores de diseño.

Factores	Símbolo	Niveles		
		Bajo	Medio	Alto
Velocidad de aprendizaje	LR	0,1	0,3	0,5
Constante de momento	MC	0,1	0,5	0,9
Cantidad de Iteraciones	E_{MAX}	50000	25000	45000
Cantidad de neuronas en la capa oculta	N_H	1	3	5

Tabla A25.2 – Objetivos del diseño.

Objetivos del diseño	Símbolo
Error medio cuadrático de los residuales	$RMSE$
Capacidad de generalización	$C.G.$

Tabla A25.3 – Arreglo ortogonal utilizado: $L9 (3^4)$.

Exp. No.	Factores				Objetivos	
	LR	MC	E_{MAX}	N_H	$RMSE$	$C.G.$
1	0,1	0,1	5000	1	53,72	0,0845
2	0,1	0,5	25000	3	43,37	0,0959
3	0,1	0,9	45000	5	36,96	0,2412
4	0,3	0,1	25000	5	35,22	0,9046
5	0,3	0,5	45000	1	42,35	0,1361
6	0,3	0,9	5000	3	49,12	0,0836
7	0,5	0,1	45000	3	29,16	0,9746
8	0,5	0,5	5000	5	41,18	0,1218
9	0,5	0,9	25000	1	42,30	0,1357

Tabla A25.4 – Influencia de los factores en los objetivos de diseño.

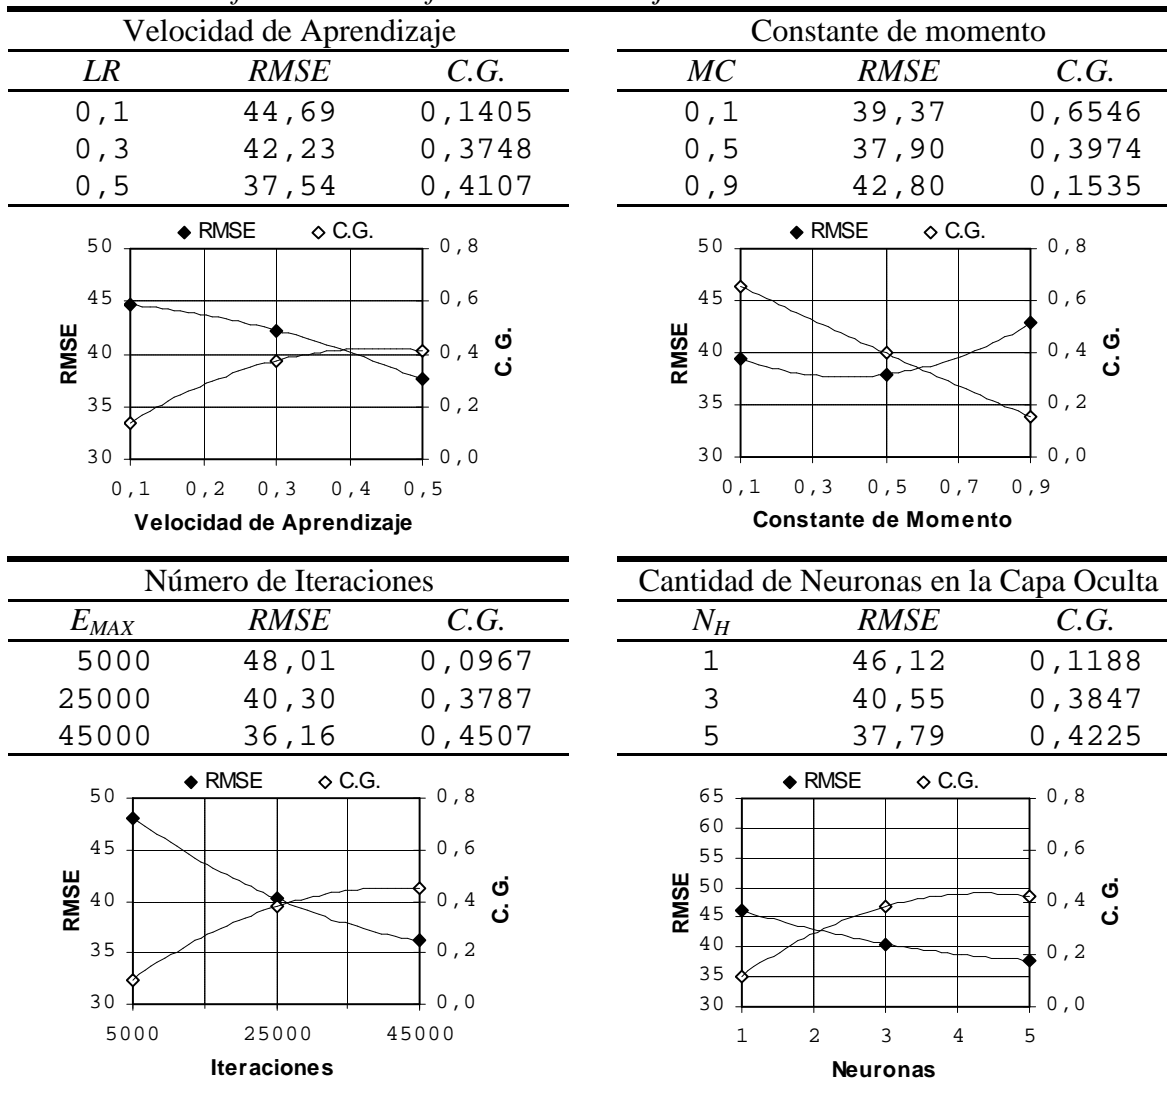


Tabla A25.5 – Niveles seleccionados para los factores de diseño.

Factor de diseño	Símbolo	Valor
Velocidad de aprendizaje	LR	0,5
Constante de momento	MC	0,1
Cantidad de Iteraciones	E_{MAX}	45000
Cantidad de neuronas en la capa oculta	N_H	5

A25. 2 – Entrenamiento y análisis de la red seleccionada.




Fig. A25.1 – Progreso del entrenamiento de la red seleccionada.




Fig. A25.2 – Residuales vs. observaciones de la red seleccionada.




Fig. A25.3 – Predicciones vs. observaciones de la red seleccionada.

A25.3 – Código de la red entrenada (*Visual Basic for Applications*).

```

Public Function Ff_MLP(Ap As Double, F As Double, _
                      V As Double) As Double
    ' Declaraciones
    Dim X(0 To 2) As Double
    Dim WI(0 To 2, 0 To 4) As Double
    Dim B1(0 To 4) As Double
    Dim L1(0 To 4) As Double
    Dim WL(0 To 4) As Double
    Dim B2 As Double
    Dim I, J As Integer
    Dim S As Double
    ' Datos
    X(0) = (Log(Ap) - Log(0.5)) / (Log(2#) - Log(0.5))
    X(1) = (Log(F) - Log(0.15)) / (Log(0.35) - Log(0.15))
    X(2) = (Log(V) - Log(200)) / (Log(300) - Log(200))
    WI(0, 0) = 0.2088: WI(1, 0) = -0.7409: WI(2, 0) = 0.437
    WI(0, 1) = 0.3314: WI(1, 1) = -0.5962: WI(2, 1) = 0.4576
    WI(0, 2) = -0.2085: WI(1, 2) = -0.0469: WI(2, 2) = -1.2946
    WI(0, 3) = -0.6335: WI(1, 3) = -0.7372: WI(2, 3) = -0.7456
    WI(0, 4) = 1.6005: WI(1, 4) = -0.2121: WI(2, 4) = -0.0058
    B1(0) = -0.6319: B1(1) = -0.2965: B1(2) = -0.889
    B1(3) = 0.8272: B1(4) = -1.7522
    WL(0) = -0.2658: WL(1) = -1.0834: WL(2) = 0.7536
    WL(3) = -0.8229: WL(4) = 1.7538: B2 = 0.8317
    ' Capa oculta
    For I = 0 To 4
        S = B1(I)
        For J = 0 To 2
            S = S + WI(J, I) * X(J)
        Next J
        L1(I) = 1 / (1 + Exp(-S))
    Next I
    ' Capa de salida
    S = B2
    For I = 0 To 4
        S = S + WL(I) * L1(I)
    Next I
    ' Resultado
    Ff_MLP = Exp(Log(53#) + S * (Log(1067#) - Log(53#)))
End Function

```


Anexo 26 – Modelo de red neuronal RBF para la componente de avance (axial) de la fuerza de corte.

A26. 1 – Selección de factores de diseño (parámetros de entrenamiento de la red).

Tabla A26.1 – Factores de diseño.

Factores	Símbolo	Niveles		
		Bajo	Medio	Alto
Coefficiente de dispersión	<i>s</i>	0,5	1,0	1,5
Error máximo a obtener	<i>err</i>	0,000	0,005	0,010

Tabla A26.2 – Objetivos del diseño.

Objetivos del diseño	Símbolo
Error medio cuadrático de los residuales	<i>RMSE</i>
Capacidad de generalización	<i>C.G.</i>

Tabla A26.3 – Arreglo ortogonal utilizado: $L9 (3^2)$.

Exp. No.	Factores		Objetivos	
	<i>s</i>	<i>err</i>	<i>RMSE</i>	<i>C.G.</i>
1	0,5	0,000	49,64	0,2559
2	0,5	0,005	34,87	0,6420
3	0,5	0,010	52,03	0,2640
4	1,0	0,000	14,91	0,3623
5	1,0	0,005	17,00	0,3363
6	1,0	0,010	14,69	0,3907
7	1,5	0,000	13,18	0,2793
8	1,5	0,005	17,91	0,2750
9	1,5	0,010	25,56	0,3010

Tabla A26.4 – Influencia de los factores en los objetivos de diseño.




Tabla A26.5 – Niveles seleccionados para los factores de diseño.

Factor de diseño	Símbolo	Valor
Coeficiente de dispersión	s	1,1
Error máximo a obtener	err	0,005

A26. 2 – Entrenamiento y análisis de la red seleccionada.




Fig. A26.1 – Progreso del entrenamiento de la red seleccionada.




Fig. AZ.2 – Residuales vs. predicciones de la red seleccionada.




Fig. AZ.3 – Observaciones vs. predicciones de la red seleccionada.

AZ.3 – Código de la red entrenada (Visual Basic for Applications).

```
Public Function Ff_RBF(Ap As Double, F As Double, _
                      V As Double) As Double

    ' Declaraciones
    Dim X(0 To 2) As Double
    Dim WI(0 To 2, 0 To 12) As Double
    Dim B1 As Double
    Dim L1(0 To 12) As Double
    Dim WL(0 To 12) As Double
    Dim B2 As Double
    Dim I, J As Integer
    Dim S As Double

    ' Datos
    X(0) = (Log(Ap) - Log(0.5)) / (Log(2#) - Log(0.5))
    X(1) = (Log(F) - Log(0.15)) / (Log(0.35) - Log(0.15))
    X(2) = (Log(V) - Log(200)) / (Log(300) - Log(200))
    WI(0, 0) = 1#: WI(1, 0) = 1#: WI(2, 0) = 0#
    WI(0, 1) = 0.661: WI(1, 1) = 1#: WI(2, 1) = 0#
    WI(0, 2) = 1#: WI(1, 2) = 0.6029: WI(2, 2) = 1#
    WI(0, 3) = 0.661: WI(1, 3) = 0.6029: WI(2, 3) = 1#
    WI(0, 4) = 0#: WI(1, 4) = 1#: WI(2, 4) = 0#
    WI(0, 5) = 0#: WI(1, 5) = 0.6029: WI(2, 5) = 0.5503
    WI(0, 6) = 0.661: WI(1, 6) = 0#: WI(2, 6) = 0#
    WI(0, 7) = 0#: WI(1, 7) = 1#: WI(2, 7) = 1#
    WI(0, 8) = 1#: WI(1, 8) = 0.6029: WI(2, 8) = 0#
```

```

WI(0, 9) = 1#: WI(1, 9) = 1#: WI(2, 9) = 0.5503
WI(0, 10) = 0#: WI(1, 10) = 0.6029: WI(2, 10) = 1#
WI(0, 11) = 0.661: WI(1, 11) = 0.6029: WI(2, 11) = 0.5503
WI(0, 12) = 0.661: WI(1, 12) = 0.6029: WI(2, 12) = 0#
B1 = 0.7569
WL(0) = 5.5352: WL(1) = -3.7585: WL(2) = 0.2861
WL(3) = 2.8548: WL(4) = 2.1521: WL(5) = 0.8951
WL(6) = 1.661: WL(7) = 1.0106: WL(8) = 0.9896
WL(9) = -0.7829: WL(10) = -2.0172: WL(11) = -3.0045
WL(12) = -3.047
B2 = -0.2235
' Capa Oculta
For I = 0 To 12
    S = 0
    For J = 0 To 2
        S = S + (WI(J, I) - X(J)) ^ 2
    Next J
    S = B1 * S ^ 0.5
    L1(I) = Exp(-(S ^ 2))
Next I
' Capa de Salida
S = B2
For I = 0 To 12
    S = S + WL(I) * L1(I)
Next I
'Resultados
Ff_RBF = Exp(Log(53#) + S * (Log(1067#) - Log(53#)))
End Function

```

Anexo 27 – Código del modelo combinado para la fuerza de avance.

```
Public Function Min(X1 As Double, X2 As Double) As Double
    If X1 < X2 Then Min = X1 Else Min = X2
End Function
```

```
Public Function Ff_Comb(Ap As Double, F As Double, _
    V As Double) As Double
    ' Constantes y definiciones
    Const Ze_reg = 10.4: Const Zv_reg = 8.4
    Const Ze_mlp = 7.4: Const Zv_mlp = 4.8
    Const Ze_rbf = 3.9: Const Zv_rbf = 9.7
    Dim X(0 To 2) As Double
    Dim Dx As Double, Dy As Double, Dz As Double
    Dim Dent As Double, Dval As Double
    Dim F_reg As Double, F_mlp As Double, F_rbf As Double
    Dim Z_reg As Double, Z_mlp As Double, Z_rbf As Double
    Dim W_reg As Double, W_mlp As Double, W_rbf As Double
    ' Normalización de los datos
    X(0) = (Ap - 0.5) / (2# - 0.5)
    X(1) = (F - 0.15) / (0.35 - 0.15)
    X(2) = (V - 200) / (300 - 200)
    ' Cálculo de las distancias
    Dx = Min(X(0), Min(Abs(X(0) - 0.5), Abs(1 - X(0))))
    Dy = Min(X(1), Min(Abs(X(1) - 0.5), Abs(1 - X(1))))
    Dz = Min(X(2), Min(Abs(X(2) - 0.5), Abs(1 - X(2))))
    Dent = Sqr(Dx ^ 2 + Dy ^ 2 + Dz ^ 2)
    Dx = Min(Abs(X(0) - 0.2533), Abs(X(0) - 0.7467))
    Dy = Min(Abs(X(1) - 0.2533), Abs(X(1) - 0.7467))
    Dz = Min(Abs(X(2) - 0.2533), Abs(X(2) - 0.7467))
    Dval = Sqr(Dx ^ 2 + Dy ^ 2 + Dz ^ 2)
    ' Cálculo de los modelos
    F_reg = 243044# * (Ap^1.12 * F^0.9444) / (V^1.005)
    F_mlp = Ff_mlp(Ap, F, V)
    F_rbf = Ff_rbf(Ap, F, V)
    ' Cálculo de las precisiones
    Z_reg = Ze_reg + Dent * (Zv_reg - Ze_reg) / (Dval + Dent)
    Z_mlp = Ze_mlp + Dent * (Zv_mlp - Ze_mlp) / (Dval + Dent)
    Z_rbf = Ze_rbf + Dent * (Zv_rbf - Ze_rbf) / (Dval + Dent)
```

```
' Cálculo de las ponderaciones
W_reg = Exp(-Z_reg)/(Exp(-Z_reg)+Exp(-Z_mlp)+Exp(-Z_rbf))
W_mlp = Exp(-Z_mlp)/(Exp(-Z_reg)+Exp(-Z_mlp)+Exp(-Z_rbf))
W_rbf = Exp(-Z_rbf)/(Exp(-Z_reg)+Exp(-Z_mlp)+Exp(-Z_rbf))
' Cálculo del valor final
Ff_Comb = W_reg * F_reg + W_mlp * F_mlp + W_rbf * F_rbf
End Function
```

Anexo 28 – Comparación de los modelos para la componente de avance (axial) de la fuerza de corte.

Tabla A28.1 – Predicciones y errores de los modelos para los experimentos principales.

F_F [N]	F_F' [N]				Error relativo [%]			
	Regres.	MLP	RBF	Comb.	Regres.	MLP	RBF	Comb.
103	90,8	92,0	100,8	100,5	12,2	11,0	2,4	2,7
70	72,5	68,2	69,3	69,2	3,6	2,6	1,1	1,1
53	60,4	58,4	56,8	56,8	13,2	9,5	6,5	6,6
140	147,0	152,6	143,2	143,5	5,0	9,0	2,3	2,5
110	117,5	118,1	108,4	108,7	6,8	7,4	1,4	1,2
107	97,8	102,5	96,5	96,7	8,3	3,9	9,5	9,4
227	202,0	211,7	219,8	219,5	10,9	6,6	3,0	3,1
173	161,4	167,7	179,9	179,5	6,9	3,2	3,8	3,5
150	134,4	146,1	153,4	153,2	10,4	2,6	2,3	2,1
233	253,3	236,9	238,9	238,8	8,5	1,5	2,4	2,4
193	202,4	182,1	190,0	189,8	4,7	5,8	1,7	1,8
187	168,5	158,9	173,4	173,0	9,7	14,9	7,1	7,3
333	410,3	382,0	334,9	336,4	23,1	14,6	0,5	0,9
283	327,9	297,7	279,4	280,0	15,7	5,1	1,4	1,2
257	273,0	256,2	282,7	281,9	6,4	0,2	10,1	9,8
473	563,8	516,1	474,2	475,6	19,1	9,0	0,2	0,5
407	450,5	404,0	388,4	389,0	10,8	0,7	4,5	4,3
360	375,1	344,4	356,1	355,7	4,2	4,3	1,1	1,2
447	428,7	464,8	444,2	444,8	4,0	4,1	0,5	0,4
347	342,6	362,2	352,1	352,4	1,2	4,5	1,6	1,6
290	285,3	317,1	289,2	290,0	1,6	9,3	0,3	0,0
843	694,6	740,2	803,4	801,4	17,6	12,2	4,7	5,0
600	555,0	575,3	611,9	610,7	7,5	4,1	2,0	1,8
507	462,1	491,3	505,5	505,0	8,8	3,0	0,2	0,3
1067	954,4	986,1	1097,5	1094,0	10,5	7,6	2,9	2,6
773	762,7	763,0	780,2	779,6	1,4	1,3	0,9	0,8
587	635,0	642,1	569,5	571,7	8,2	9,4	2,9	2,6

Tabla A28.2 – Predicciones y errores de los modelos para los experimentos de validación.

F_F [N]	F_F' [N]				Error relativo [%]			
	Regres.	MLP	RBF	Comb.	Regres.	MLP	RBF	Comb.
160	189,9	166,1	143,1	166,5	18,7	3,8	10,6	4,1
143	155,2	137,1	129,4	137,5	8,3	4,3	9,8	4,1
287	301,4	268,5	232,1	269,2	5,2	6,3	19,1	6,1
233	246,4	222,9	216,7	223,5	5,6	4,5	7,1	4,2
370	376,1	366,2	366,4	366,5	1,6	1,0	1,0	1,0
283	307,4	303,7	315,0	303,8	8,5	7,2	11,2	7,2
607	597,1	571,2	597,5	572,1	1,6	5,8	1,5	5,7
473	488,0	468,5	483,8	469,2	3,1	1,0	2,2	0,9

Tabla A28.3 – Predicciones y errores de los modelos para los experimentos de comprobación.

F_F [N]	F_F' [N]				Error relativo [%]			
	Regres.	MLP	RBF	Comb.	Regres.	MLP	RBF	Comb.
603	594,3	596,1	611,1	598,6	1,4	1,1	1,3	1,4
228	242,0	221,5	227,7	225,1	6,1	2,9	0,2	6,1
418	450,5	417,2	404,2	415,1	7,8	0,2	3,3	7,8
100	121,4	106,4	97,4	102,1	21,4	6,4	2,6	21,4

Tabla A28.4 – Comparación de los valores máximo y RMS de los diferentes modelos.

Conjunto	Error [%]	Regresión	Red. MLP	Red. RBF	Modelo Combinado
Principal (entrenamiento)	Máximo	23,1	14,9	10,1	9,8
	RMS	10,4	7,4	3,9	3,9
Validación	Máximo	18,7	7,2	19,1	7,2
	RMS	8,4	4,8	9,7	4,7
Comprobación	Máximo	21,4	6,4	3,3	2,1
	RMS	11,8	3,6	2,2	1,3
Total	Máximo	23,1	14,9	19,1	9,8
	RMS	10,2	6,6	5,5	3,9

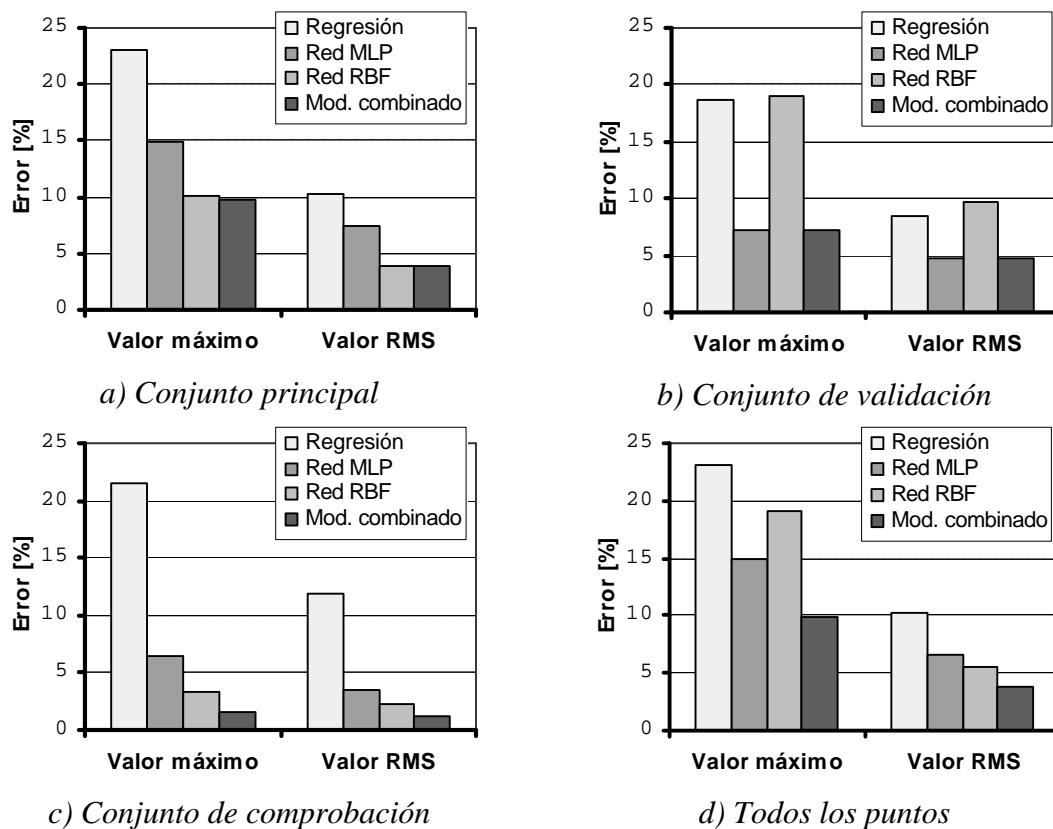


Fig. A28.1 – Representación gráfica de los errores.

Anexo 29 – Modelo de regresión para la temperatura de la zona de corte.

Modelo: $\ln(q) = 4,532 + 0,1243 \cdot \ln(a_p) + 0,3367 \cdot \ln(f) + 0,5063 \cdot \ln(V)$ ó

$$q = 92,94 \cdot a_p^{0,1243} \cdot f^{0,3367} \cdot V^{0,5063}$$

Tabla A29.1 – Análisis de sensibilidad de los coeficientes.

Parámetro	Estimado	Error estándar	Estadístico t	Probabilidad
Constante	4,532	0,1585	28,59	0,000
$\ln(a_p)$	0,1243	0,008222	15,12	0,000
$\ln(f)$	0,3367	0,01359	24,78	0,000
$\ln(V)$	0,5063	0,02854	17,74	0,000

Tabla A29.2 – Análisis de Varianza.

	Suma de Cdos.	G.L.	Cuadrado Medio	Estadíst. F	Prob.
Modelo	2,100	3	0,6999	385,8	0,000
Residuales	0,140	77	0,001817		
Total	2,399	80			

Tabla A29.3 – Resumen estadístico de la regresión.

Coefficiente R^2	0,9376
Coef. R^2 (ajustado a los G.L.)	0,9352
Error estándar de las estimaciones	0,04259
Estadístico de Durbin-Watson	2,177 (Prob. = 0,1831)




Fig. A29.1 – Gráfico de residuos vs. predicciones.




Fig. A29.2 – Gráfico de observaciones vs. predicciones.

Anexo 30 – Modelo de red neuronal MLP para la componente tangencial de la fuerza de corte.

A30. 1 – Selección de factores de diseño (parámetros de entrenamiento de la red).

Tabla A30.1 – Factores de diseño.

Factores	Símbolo	Niveles		
		Bajo	Medio	Alto
Velocidad de aprendizaje	LR	0,1	0,3	0,5
Constante de momento	MC	0,1	0,5	0,9
Cantidad de Iteraciones	E_{MAX}	50000	25000	45000
Cantidad de neuronas en la capa oculta	N_H	1	3	5

Tabla A30.2 – Objetivos del diseño.

Objetivos del diseño	Símbolo
Error medio cuadrático de los residuales	$RMSE$
Capacidad de generalización	$C.G.$

Tabla A30.3 – Arreglo ortogonal utilizado: $L9 (3^4)$.

Exp. No.	Factores				Objetivos	
	LR	MC	E_{MAX}	N_H	$RMSE$	$C.G.$
1	0,1	0,1	5000	1	34,06	0,5099
2	0,1	0,5	25000	3	31,18	0,1319
3	0,1	0,9	45000	5	30,57	0,1730
4	0,3	0,1	25000	5	30,82	0,1386
5	0,3	0,5	45000	1	33,48	0,5695
6	0,3	0,9	5000	3	34,15	0,4977
7	0,5	0,1	45000	3	31,32	0,1209
8	0,5	0,5	5000	5	31,25	0,2955
9	0,5	0,9	25000	1	33,47	0,5752

Tabla A30.4 – Influencia de los factores en los objetivos de diseño.

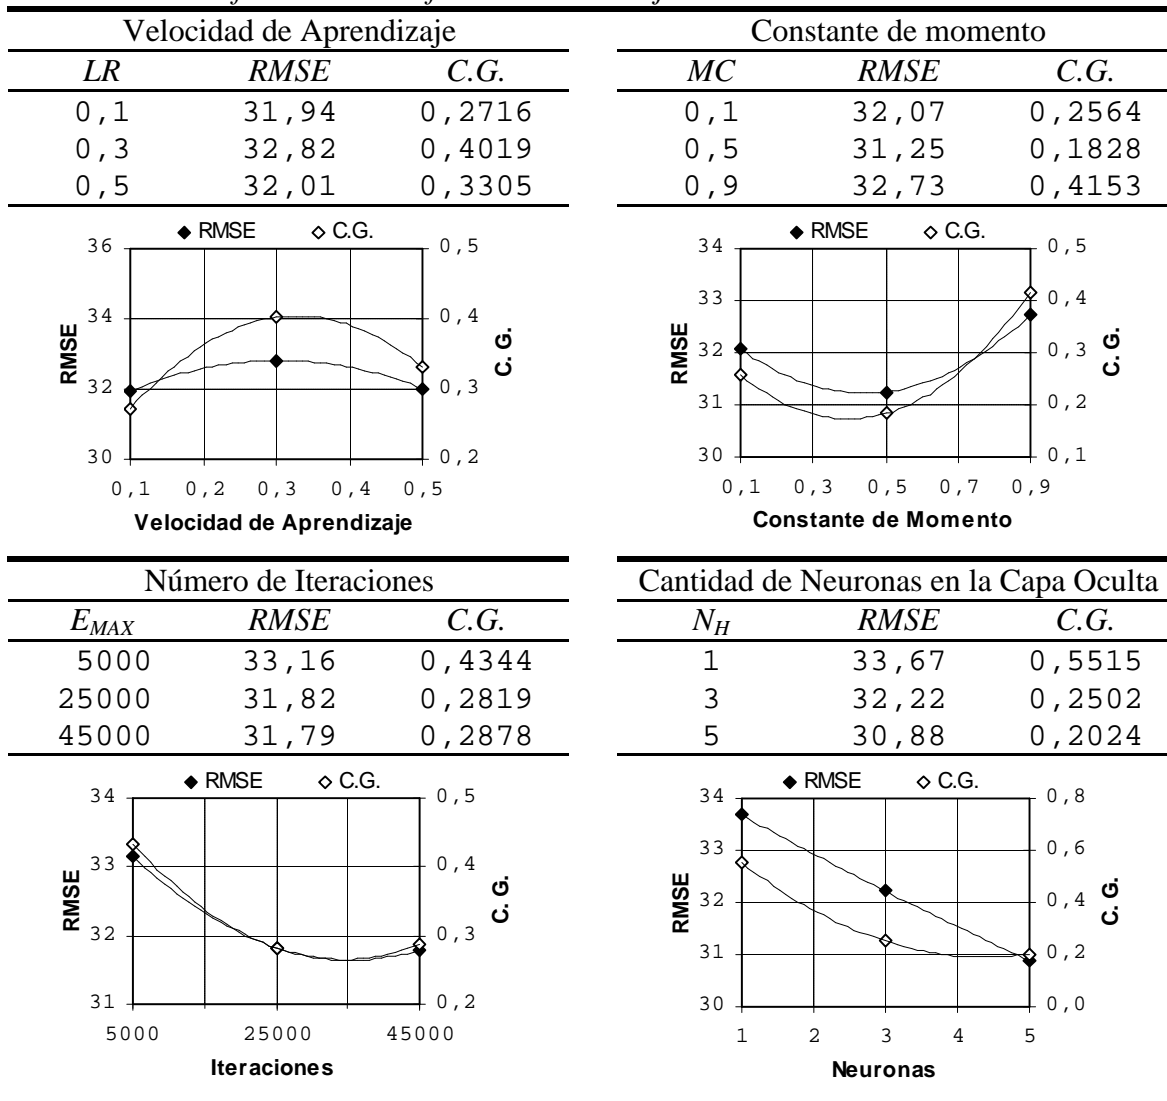


Tabla A30.5 – Niveles seleccionados para los factores de diseño.

Factor de diseño	Símbolo	Selección	
		Nivel	Valor
Velocidad de aprendizaje	LR	Alto	0,3
Constante de momento	MC	Bajo	0,9
Cantidad de Iteraciones	E_{MAX}	Alto	5000
Cantidad de neuronas en la capa oculta	N_H	Medio	3

A30. 2 – Entrenamiento y análisis de la red seleccionada.




Fig. A30.1 – Progreso del entrenamiento de la red seleccionada.




Fig. A30.2 – Residuales vs. predicciones de la red seleccionada.




Fig. A30.3 – Observaciones vs. predicciones de la red seleccionada.

A30.3 – Código de la red entrenada (*Visual Basic for Applications*).

```

Public Function Temp_MLP(Ap As Double, F As Double, _
                        V As Double) As Double
    ' Declaraciones
    Dim X(0 To 2) As Double
    Dim WI(0 To 2, 0 To 2) As Double
    Dim B1(0 To 2) As Double
    Dim L1(0 To 2) As Double
    Dim WL(0 To 2) As Double
    Dim B2 As Double
    Dim I, J As Integer
    Dim S As Double
    ' Datos
    X(0) = (Log(Ap) - Log(0.5)) / (Log(2#) - Log(0.5))
    X(1) = (Log(F) - Log(0.15)) / (Log(0.35) - Log(0.15))
    X(2) = (Log(V) - Log(200)) / (Log(300) - Log(200))
    WI(0, 0) = -0.8793: WI(1, 0) = -0.5371: WI(2, 0) = -0.7853
    WI(0, 1) = -0.4062: WI(1, 1) = -0.842: WI(2, 1) = -0.5405
    WI(0, 2) = -0.9889: WI(1, 2) = -0.5367: WI(2, 2) = -0.642
    B1(0) = -1.1221: B1(1) = 0.773: B1(2) = -2.3853
    WL(0) = -0.9663: WL(1) = -1.8715: WL(2) = 0.0652
    B2 = 1.506
    ' Capa oculta
    For I = 0 To 2
        S = B1(I)
        For J = 0 To 2
            S = S + WI(J, I) * X(J)
        Next J
        L1(I) = 1 / (1 + Exp(-S))
    Next I
    ' Capa de salida
    S = B2
    For I = 0 To 2
        S = S + WL(I) * L1(I)
    Next I
    Temp_MLP = Exp(Log(647#) + S * (Log(1263#) - Log(647#)))
End Function

```

Anexo 31 – Modelo de red neuronal RBF para la componente principal (tangencial) de la fuerza de corte.

A31. 1 – Selección de factores de diseño (parámetros de entrenamiento de la red).

Tabla A31.1 – Factores de diseño.

Factores	Símbolo	Niveles		
		Bajo	Medio	Alto
Coefficiente de dispersión	<i>s</i>	0,5	1,0	1,5
Error máximo a obtener	<i>err</i>	0,000	0,005	0,010

Tabla A31.2 – Objetivos del diseño.

Objetivos del diseño	Símbolo
Error medio cuadrático de los residuales	<i>RMSE</i>
Capacidad de generalización	<i>C.G.</i>

Tabla A31.3 – Arreglo ortogonal utilizado: L9 (3²).

Exp. No.	Factores		Objetivos	
	<i>s</i>	<i>err</i>	<i>RMSE</i>	<i>C.G.</i>
1	0,5	0,000	43,579	0,1382
2	0,5	0,005	29,034	0,6753
3	0,5	0,010	30,165	0,6373
4	1,0	0,000	16,674	0,7533
5	1,0	0,005	17,503	0,8547
6	1,0	0,010	19,889	0,6525
7	1,5	0,000	16,707	0,7439
8	1,5	0,005	17,024	0,6775
9	1,5	0,010	17,024	0,6775

Tabla A31.4 – Influencia de los factores en los objetivos de diseño.




Tabla A31.5 – Niveles seleccionados para los factores de diseño.

Factor de diseño	Símbolo	Valor
Coeficiente de dispersión	s	1,15
Error máximo a obtener	err	0,006

A31. 2 – Entrenamiento y análisis de la red seleccionada.




Fig. A31.1 – Progreso del entrenamiento de la red seleccionada.




Fig. A31.2 – Residuales vs. predicciones de la red seleccionada.




Fig. A31.3 – Observaciones vs. predicciones de la red seleccionada.

A31.3 – Código de la red entrenada (*Visual Basic for Applications*).

```
Public Function Temp_RBF(Ap As Double, F As Double, _
                        V As Double) As Double

    ' Declaraciones
    Dim X(0 To 2) As Double
    Dim WI(0 To 2, 0 To 19) As Double
    Dim B1 As Double
    Dim L1(0 To 19) As Double
    Dim WL(0 To 19) As Double
    Dim B2 As Double
    Dim I, J As Integer
    Dim S As Double

    ' Datos
    X(0) = (Log(Ap) - Log(0.5)) / (Log(2#) - Log(0.5))
    X(1) = (Log(F) - Log(0.15)) / (Log(0.35) - Log(0.15))
    X(2) = (Log(V) - Log(200)) / (Log(300) - Log(200))
    WI(0, 0) = 1#: WI(1, 0) = 1#: WI(2, 0) = 1#
    WI(0, 1) = 1#: WI(1, 1) = 0.6029: WI(2, 1) = 1#
    WI(0, 2) = 1#: WI(1, 2) = 0#: WI(2, 2) = 1#
    WI(0, 3) = 0#: WI(1, 3) = 1#: WI(2, 3) = 1#
    WI(0, 4) = 0.661: WI(1, 4) = 0.6029: WI(2, 4) = 1#
    WI(0, 5) = 0#: WI(1, 5) = 0#: WI(2, 5) = 0#
    WI(0, 6) = 1#: WI(1, 6) = 1#: WI(2, 6) = 0#
    WI(0, 7) = 0#: WI(1, 7) = 0#: WI(2, 7) = 1#
    WI(0, 8) = 0.661: WI(1, 8) = 0.6029: WI(2, 8) = 0#
```

```

WI(0, 9) = 0.661: WI(1, 9) = 1#: WI(2, 9) = 1#
WI(0, 10) = 0#: WI(1, 10) = 1#: WI(2, 10) = 0.5503
WI(0, 11) = 1#: WI(1, 11) = 0#: WI(2, 11) = 0#
WI(0, 12) = 1#: WI(1, 12) = 1#: WI(2, 12) = 0.5503
WI(0, 13) = 0.661: WI(1, 13) = 0#: WI(2, 13) = 0#
WI(0, 14) = 0#: WI(1, 14) = 0.6029: WI(2, 14) = 1#
WI(0, 15) = 0.661: WI(1, 15) = 0#: WI(2, 15) = 1#
WI(0, 16) = 0.661: WI(1, 16) = 1#: WI(2, 16) = 0.5503
WI(0, 17) = 0#: WI(1, 17) = 0.6029: WI(2, 17) = 0#
WI(0, 18) = 0.661: WI(1, 18) = 1#: WI(2, 18) = 0#
WI(0, 19) = 0#: WI(1, 19) = 0.6029: WI(2, 19) = 0.5503
B1 = 0.724
WL(0) = 25.4274: WL(1) = -31.4175: WL(2) = 8.5717
WL(3) = 25.2964: WL(4) = 52.5603: WL(5) = -5.2135
WL(6) = -2.4055: WL(7) = 6.2577: WL(8) = -1.5588
WL(9) = -46.8317: WL(10) = -18.2009: WL(11) = -0.2522
WL(12) = -6.603: WL(13) = 0.293: WL(14) = -33.0916
WL(15) = -16.9019: WL(16) = 17.7046: WL(17) = -0.703
WL(18) = -0.9488: WL(19) = 19.2873
B2 = 3.4721
' Capa oculta
For I = 0 To 19
    S = 0
    For J = 0 To 2
        S = S + (WI(J, I) - X(J)) ^ 2
    Next J
    S = B1 * S ^ 0.5
    L1(I) = Exp(-(S ^ 2))
Next I
' Capa de salida
S = B2
For I = 0 To 19
    S = S + WL(I) * L1(I)
Next I
Temp_RBF = Exp(Log(647#) + S * (Log(1263#) - Log(647#)))
End Function

```

Anexo 32 – Código del modelo combinado para la temperatura.

```
Public Function Min(X1 As Double, X2 As Double) As Double
    If X1 < X2 Then Min = X1 Else Min = X2
End Function
```

```
Public Function Temp_Comb(Ap As Double, F As Double, _
    V As Double) As Double
    ' Constantes y definiciones
    Const Ze_reg = 7.5: Const Zv_reg = 4.2
    Const Ze_mlp = 7.2: Const Zv_mlp = 4.9
    Const Ze_rbf = 1.5: Const Zv_rbf = 5.5
    Dim X(0 To 2) As Double
    Dim Dx As Double, Dy As Double, Dz As Double
    Dim Dent As Double, Dval As Double
    Dim T_reg As Double, T_mlp As Double, T_rbf As Double
    Dim Z_reg As Double, Z_mlp As Double, Z_rbf As Double
    Dim W_reg As Double, W_mlp As Double, W_rbf As Double
    ' Normalización de los datos
    X(0) = (Ap - 0.5) / (2# - 0.5)
    X(1) = (F - 0.15) / (0.35 - 0.15)
    X(2) = (V - 200) / (300 - 200)
    ' Cálculo de las distancias
    Dx = Min(X(0), Min(Abs(X(0) - 0.5), Abs(1 - X(0))))
    Dy = Min(X(1), Min(Abs(X(1) - 0.5), Abs(1 - X(1))))
    Dz = Min(X(2), Min(Abs(X(2) - 0.5), Abs(1 - X(2))))
    Dent = Sqr(Dx ^ 2 + Dy ^ 2 + Dz ^ 2)
    Dx = Min(Abs(X(0) - 0.2533), Abs(X(0) - 0.7467))
    Dy = Min(Abs(X(1) - 0.2533), Abs(X(1) - 0.7467))
    Dz = Min(Abs(X(2) - 0.2533), Abs(X(2) - 0.7467))
    Dval = Sqr(Dx ^ 2 + Dy ^ 2 + Dz ^ 2)
    ' Cálculo de los modelos
    T_reg = 92.94 * Ap ^ 0.1243 * F ^ 0.3367 * V ^ 0.5063
    T_mlp = Temp_MLP(Ap, F, V)
    T_rbf = Temp_RBF(Ap, F, V)
    ' Cálculo de las precisiones
    Z_reg = Ze_reg + Dent * (Zv_reg - Ze_reg) / (Dval + Dent)
    Z_mlp = Ze_mlp + Dent * (Zv_mlp - Ze_mlp) / (Dval + Dent)
    Z_rbf = Ze_rbf + Dent * (Zv_rbf - Ze_rbf) / (Dval + Dent)
```

```
' Cálculo de las ponderaciones
W_reg = Exp(-Z_reg)/(Exp(-Z_reg)+Exp(-Z_mlp)+Exp(-Z_rbf))
W_mlp = Exp(-Z_mlp)/(Exp(-Z_reg)+Exp(-Z_mlp)+Exp(-Z_rbf))
W_rbf = Exp(-Z_rbf)/(Exp(-Z_reg)+Exp(-Z_mlp)+Exp(-Z_rbf))
' Cálculo del valor final
Temp_Comb = W_reg * T_reg + W_mlp * T_mlp + W_rbf * T_rbf
End Function
```

Anexo 33 – Comparación de los modelos para la temperatura.

Tabla A33.1 – Predicciones y errores de los modelos para los experimentos principales.

q [°C]	q' [°C]				Error relativo [%]			
	Regres.	MLP	RBF	Comb.	Regres.	MLP	RBF	Comb.
647	658	644	643	643	1,8	0,4	0,5	0,5
738	737	733	747	747	0,1	0,6	1,3	1,3
816	808	812	811	811	1,0	0,5	0,7	0,7
753	782	773	758	758	3,8	2,7	0,7	0,7
910	875	880	896	896	3,9	3,3	1,5	1,6
922	960	971	933	933	4,1	5,3	1,1	1,2
888	876	875	889	889	1,4	1,5	0,1	0,1
1032	980	990	1035	1035	5,0	4,0	0,3	0,3
1126	1075	1084	1123	1123	4,5	3,7	0,3	0,3
714	738	736	715	715	3,3	3,1	0,1	0,1
813	826	831	817	817	1,5	2,1	0,5	0,5
874	906	913	871	871	3,6	4,4	0,4	0,3
842	876	881	835	835	4,0	4,6	0,9	0,8
1008	981	990	1020	1020	2,7	1,8	1,2	1,2
1045	1076	1079	1041	1041	2,9	3,3	0,4	0,4
947	981	990	950	951	3,6	4,5	0,3	0,3
1126	1099	1102	1123	1123	2,5	2,1	0,3	0,3
1154	1205	1191	1156	1156	4,4	3,2	0,2	0,2
845	782	784	847	846	7,5	7,2	0,2	0,2
921	876	881	913	913	4,9	4,3	0,9	0,9
967	960	964	974	974	0,7	0,3	0,8	0,8
901	929	936	912	912	3,1	3,9	1,3	1,3
1084	1040	1044	1070	1069	4,0	3,6	1,3	1,3
1112	1140	1132	1118	1118	2,5	1,8	0,5	0,5
1043	1040	1047	1034	1034	0,2	0,4	0,8	0,8
1182	1165	1157	1196	1196	1,5	2,1	1,2	1,2
1263	1277	1242	1256	1256	1,1	1,6	0,5	0,5

Tabla A33.2 – Predicciones y errores de los modelos para los experimentos de validación.


q [N]	q' [N]				Error relativo [%]			
	Regres.	MLP	RBF	Comb.	Regres.	MLP	RBF	Comb.
796	812	813	785	804	2,0	2,2	1,3	1,1
931	898	907	879	895	3,5	2,6	5,5	3,9
984	957	966	965	962	2,7	1,8	2,0	2,3
1101	1059	1067	1071	1065	3,8	3,1	2,7	3,3
849	876	882	876	877	3,1	3,8	3,2	3,3
954	969	976	969	971	1,6	2,3	1,6	1,8
991	1033	1040	1045	1038	4,2	4,9	5,4	4,7
1166	1143	1139	1157	1146	2,0	2,4	0,8	1,7

Tabla A33.3 – Predicciones y errores de los modelos para los experimentos de comprobación.


F_F [N]	F_F' [N]				Error relativo [%]			
	Regres.	MLP	RBF	Comb.	Regres.	MLP	RBF	Comb.
1135	1155	1148	1176	1170	1,8	1,1	3,6	3,1
981	1009	1017	1001	1002	2,8	3,6	2,1	2,2
1028	991	999	1014	1009	3,6	2,8	1,4	1,9
780	793	795	772	774	1,7	1,9	1,0	0,8

Tabla A33.4 – Comparación de los valores máximo y RMS de los diferentes modelos.


Conjunto	Error [%]	Regresión	Red. MLP	Red. RBF	Modelo Combinado
Principal (entrenamiento)	Máximo	7,5	7,2	1,5	1,6
	RMS	3,4	3,3	0,8	0,8
Validación	Máximo	4,2	4,9	5,6	4,7
	RMS	3,0	3,1	3,3	3,0
Comprobación	Máximo	3,6	3,5	3,6	3,1
	RMS	2,6	2,5	2,2	2,1
Total	Máximo	7,5	7,2	5,5	4,7
	RMS	3,2	3,2	1,8	1,7




a) Conjunto principal



b) Conjunto de validación



c) Conjunto de comprobación



d) Todos los puntos

Fig. A33.1 – Representación gráfica de los errores.

Anexo 34 – Análisis económico de la solución propuesta.

Tabla A34.1 – Cálculo de los costos de la operación.

Variable del cálculo	Expresión	Variante	
		Propuesta	Actual
Parámetros del régimen de corte			
Profundidad de corte [mm]	a_P	0,5	0,5
Avance [mm/rev]	f	0,3	0,2
Frec. de rotación del husillo [rpm]	n	1000	315
Variables del proceso			
Velocidad de corte	$V = \frac{p \cdot d \cdot n}{1000}$	219,9	69,3
Vida útil de la herramienta [min]	$T = \Psi_T(a_P, f, V)$	142,3	90,0
Tiempo de maquinado [min]	$t = \frac{L}{n \cdot f}$	0,52	2,46
Tiempo auxiliar [min]	t_A	1,30	1,30
Tpo. de cambio de la herr. [min]	$t_{CH} = t_{CH0} \frac{t}{T}$	0,00	0,09
Tpo. total de elaboración t_T [min]	$t_T = t + t_A + t_{CH}$	1,82	3,85
Vida útil consumida [%]	$x = \frac{t}{T}$	0,36	2,73
Fuerza de corte tangencial [N]	$F_C = \Psi_{Fc}(a_P, f, V)$	218	260
Potencia consumida [kW]	$P_C = \frac{F_C \cdot V}{6 \cdot 10^4 \cdot h}$	1,06	0,40
Consumo de electricidad [kW·h]	$A_E = P_C \cdot t$	0,009	0,016
Datos económicos			
Precio de la electric. [\$/ (kW·h)]	z_{ELE}	0,068	
Salario del operario [\$/h]	z_{SAL}	1,32	
Cantidad de filos o afilados	W_{FIL}	6	10
Precio de la herramienta [\$/]	z_{HER}	2,36	7,74
Cambios del portaplacas	W_{PP}	72	–
Precio del portaplaca [\$/]	z_{PP}	157,08	–
Precio de la máquina [\$/]	Z_{MAQ}	3554	
Vida útil de la máquina [años]	T_{MAQ}	10	

Tabla A34.1 – Cálculo de los costos de la operación (cont.).

Variable del cálculo	Expresión	Variante	
		Propuesta	Actual
Costos de la operación			
Costo de la electricidad [\$]	$Z_{ELE} = A_E \cdot z_{ELE}$	0,0005	0,0008
Costo de salario [\$]	$Z_{SAL} = t_T \cdot z_{SAL}$	0,0401	0,0849
Costo de amortización [\$]	$Z_{AMO} = \frac{t_T \cdot Z_{MAQ}}{136800 \cdot T_{MAQ}}$	0,0047	0,0100
Costo de herramienta [\$]	$Z_{HER} = x \left(\frac{z_{HER}}{W_{FIL}} + \frac{z_{PP}}{W_{PP}} \right)$	0,0094	0,0212
Costo subtotal en moneda nac. [\$]	$Z_{CUP} = Z_{ELE} + Z_{SAL} + Z_{AMO}$	0,0454	0,0957
Costo subtotal en divisa [\$]	$Z_{USD} = Z_{HER}$	0,0094	0,0212
Costo total [\$]	$Z_{TOT} = Z_{CUP} + Z_{USD}$	0,0548	0,1169