

UNIVERSIDAD DE MÁLAGA
ESCUELA DE INGENIERÍAS INDUSTRIALES
DEPARTAMENTO DE INGENIERÍA CIVIL, DE MATERIALES Y FABRICACIÓN



UNIVERSIDAD
DE MÁLAGA

APLICACIÓN DE REDES NEURONALES PARA EL ESTUDIO DE LA
INTEGRIDAD SUPERFICIAL DE PIEZAS TORNEADAS EN SECO DE LA
ALEACIÓN DE ALUMINIO UNS A97075

TRABAJO FIN DE GRADO
INGENIERÍA EN DISEÑO INDUSTRIAL Y DESARROLLO DEL PRODUCTO
Málaga, septiembre 2023

Autor. Ignacio REPISO LÓPEZ

Tutores. Dr. D. Sergio MARTÍN BÉJAR

Dr. D. Francisco Javier TRUJILLO VILCHES

Torture the data, and it will confess to anything.

Ronald Coase

Agradecimientos

A mi madre, por ser el eje central de mis *historias*, como esta que hoy termina.

A mi padre, por enseñarme la importancia del diseño a través de unos y ceros porque como dijo Danny Thorpe, “*programar sin una arquitectura o diseño en mente es como explorar una cueva sólo con una linterna: no sabes bien dónde estás, dónde has estado ni hacia dónde vas*”. Y yo me pregunto, ¿acaso existe mejor diseño industrial que este?

A mi hermana, por recordarme que no existe mejor *algoritmo* que aquel que regula los sistemas de nuestro propio organismo, como el nervioso por medio de las verdaderas neuronas. El resto son intentos de plagio sin éxito y que solo en ocasiones, arrojan los resultados que esperamos.

A mis *hermanos de galera* y en especial a Antonio y Hans. Ya podemos gritar como hizo Rodrigo de Triana allá por un 11 de octubre de 1492, cuando a las dos de la mañana exclamó “*¡Tierra, tierra!*” mientras llorando, señalaba dirección a Guanahani (Archipiélago de los Lucayos, Bahamas). Lo demás es historia.

A aquellos que están, aún no estando. En particular, a ti abuela, cuando al comienzo, te dije aquello de *puedo prometer y prometo que trabajaré para llegar a ser algún día, ingeniero*. Al fin y al cabo, no he dimitido.

A todos los que destinan altruistamente horas y horas en el taller *frente a las virutas*. Porque teniendo ya recabados el conjunto de datos experimentales, la labor del *data analyst* es *coser y ejecutar*.

A Javier Trujillo, cotutor de este trabajo por sus sabios consejos y el apoyo brindado durante estos últimos meses. También a Lorenzo Sevilla, por su confianza y sus provechosas correcciones a la comunicación al congreso presentado.

Y por supuesto a Sergio Martín, tutor de este Trabajo Fin de Grado, por su confianza y apoyos imprescindibles.

Cuentan que el poeta Luis Cernuda escribió una vez: “*No sabría decir cuánto le debo, a sus indicaciones, a su estímulo primero; apenas hubiera podido yo, en cuanto poeta, sin su ayuda, haber encontrado el camino*”.

A quien se refería era al gran Pedro Salinas, amigo y mentor de Cernuda. Junto a Salinas han pasado a la historia como constituyentes esenciales del fenómeno que confluyó en la Generación del 27. El madrileño Pedro Salinas es el recuerdo noble de alguien que dice un límite de humanidad, sereno, verdadero, tranquilo y con una enorme vocación de enseñanza.

Por su parte, Luis Cernuda era estudiante de Derecho en la universidad de la capital hispalense. A pesar de que Salinas le impartiera Literatura, no entraron en contacto hasta tiempo después, cuando él ya no era su profesor. Esta ceremonia se ha repetido cientos de veces en el devenir de la historia, al seleccionar entre los textos escritos, aquellos que considera mejores para ofrecérselos a alguien cuya opinión respeta y en cuyo gusto confía lo suficiente como para dejarse influir por él. Cernuda siempre se mostró agradecido ante su maestro.

Cernuda terminó formando parte de esa comunidad de *grandes maestros* con la que tanto soñaba, llegando incluso a ser profesor en la Universidad de Toulouse. Nunca se olvidó de su deuda con su viejo amigo, llegando a recoger en esas palabras su gran admiración por él.

Con Cernuda, comparto la gran suerte que me ha deparado el destino de encontrarme en el camino a Sergio-Salinas. Por las charlas eternas sobre la ingeniería, la vida y el sueño de formar algún día parte de esa *gran comunidad*. Por integrarme y valorarme desde el comienzo. Por seguir compartiendo la pasión por la modelización matemática e Inteligencia Artificial y su aplicación a *la fabricación*.

A todos, gracias[∞],
aunque sólo aparezca mi nombre en él, este trabajo es tanto mío como vuestro.

IGNACIO REPISO LÓPEZ

Málaga, 2023

Resumen

Es innegable el enorme valor añadido del sector productivo que representa la industria aeronáutica reflejado a través de la estricta selección de materiales y los exigentes requisitos en sus procesos de fabricación. Buscando mejorar la relación entre prestaciones mecánicas-densidad y potenciar la maquinabilidad, las aleaciones de aluminio junto a la operaciones de conformado por arranque de viruta resultan candidatos idóneos. En este sentido, la integridad superficial de los elementos estructurales fabricados engloba propiedades relacionadas con la microgeometría, la macrogeometría y las relativas a los factores físico-químicos del material una vez mecanizado. Tratando de optimizar el proceso productivo, suele ser común plantear un análisis profundo de los parámetros de corte sobre dicho conjunto de propiedades, buscando estimar el comportamiento de estos componentes bajo un conjunto de condiciones de fabricación concretas. Por todo esto, este Trabajo Fin de Grado se ocupa de la aplicación de algoritmos *Machine Learning* y en particular, de las Redes Neuronales Artificiales (RNA) para la predicción de diferentes propiedades relacionadas con la integridad superficial en función de los parámetros de corte en procesos de torneado en seco de la aleación de aluminio UNS A97075 de uso aeronáutico. Para ello, se plantea inicialmente una optimización de los principales hiperparámetros que gobiernan el rendimiento del sistema, con objeto de maximizar la calidad del modelo predictivo y su capacidad de generalización, para terminar obteniendo tras estudiar diferentes arquitecturas, la respuesta de las distintas variables de estudio. Una vez obtenido el resultado de las estimaciones, se determinan los parámetros de corte que optimizan el conjunto de propiedades relacionadas con la integridad superficial junto al tiempo de la operación. El uso de RNAs ha demostrado ser una herramienta eficaz para el análisis de regresión planteado, mostrando una notable bondad del ajuste, incluso superior a la de otros de modelos analíticos clásicos abordados comúnmente por trabajos de la literatura.

Palabras clave: Integridad superficial, Rugosidad Superficial, Desviaciones Geométricas, Redes Neuronales Artificiales, Sistemas Expertos, Optimización de Hiperparámetros, Mecanizado en seco, Aleaciones de Aluminio.

Abstract

It is undeniable the enormous added value of the production sector that represents the aeronautical industry reflected through the strict selection of materials and the demanding requirements in their manufacturing processes. In order to optimize the relationship mechanical performance-density and to enhance machinability, aluminum alloys together with metal removal forming operations are ideal candidates. In this sense, the surface integrity of the manufactured structural elements encompasses properties related to microgeometry, macrogeometry and those related to the physical-chemical factors of the material once machined. Trying to optimize the production process, it is common to propose an in-depth analysis of the cutting parameters on this set of properties, seeking to estimate the behavior of these components under a set of specific manufacturing conditions. Therefore, this Final Degree Project deals with the application of Machine Learning algorithms and in particular, Artificial Neural Networks (ANN) for the prediction of different properties related to surface integrity as a function of the cutting parameters in dry turning processes of UNS A97075 aluminum alloy for aeronautical use. For this purpose, an optimization of the main hyperparameters that govern the performance of the system is initially proposed, in order to maximize the quality of the predictive model and its generalization capacity, to finally obtain after studying different architectures, the response of the different study variables. Once the estimation results have been obtained, the cutting parameters that optimize the set of properties related to surface integrity together with the operation time are determined. The use of ANNs has proved to be an effective tool for the regression analysis proposed, showing a remarkable goodness of fit, even superior to that of other classical analytical models commonly addressed by works in the literature.

Keywords: Surface Integrity, Surface Roughness, Geometric Deviations, Artificial Neural Networks, Expert Systems, Hyperparameter Optimization, Dry Machining, Aluminum Alloys.

Índice general

Agradecimientos	i
Resumen	iii
Abstract	v
1. Introducción	1
1.1. Contexto	1
1.2. Objetivos	3
1.3. Organización de la memoria	4
2. Estado del Arte	7
2.1. Introducción	7
2.2. Aleaciones de aluminio	7
2.2.1. Generalidades	8
2.2.2. Aplicaciones en el sector aeroespacial	10
2.3. Estudio de las variables de entrada en el mecanizado de aleaciones de aluminio de uso aeronáutico	13
2.3.1. Introducción	13
2.3.2. Principales problemas durante el mecanizado	13
2.3.3. Influencia de la microestructura y tratamiento térmico de la aleación	15
2.3.4. Herramientas de corte	17
2.3.5. Condiciones de lubricación	18
2.3.6. Parámetros de corte	20
2.4. Estudio de las variables de salida en el mecanizado de aleaciones de aluminio de uso aeronáutico	23
2.4.1. Generalidades	23
2.4.2. Desgaste y vida de la herramienta	24
2.4.3. Fuerza de corte	28
2.4.4. Integridad Superficial	31
2.4.4.1. Desviaciones microgeométricas	32
2.4.4.2. Desviaciones macrogeométricas	35
2.4.4.3. Propiedades físico-químicas	37
2.5. Consideraciones generales de las aleaciones de aluminio	41

2.6. Técnicas de Inteligencia Artificial para la predicción en las operaciones de mecanizado	47
2.6.1. Enfoques más comunes empleados en la actualidad	47
2.6.2. Modelos predictivos	50
3. Conceptos generales y fundamentos de implementación de las RNAs	53
3.1. Introducción	53
3.2. Machine Learning	53
3.2.1. Redes neuronales artificiales y Deep Learning	54
3.2.2. Paradigmas de Aprendizaje	55
3.3. Modelo, estructura e hiperparámetros de una RNA	56
3.3.1. La neurona	58
3.3.2. Función de activación	59
3.3.3. Función de coste	61
3.3.4. Múltiples capas	62
3.3.5. Entrenamiento	62
3.3.6. Preprocesado	64
3.3.7. Hiperparámetros	65
4. Metodología Experimental	67
4.1. Introducción	67
4.2. Planificación y ejecución de los ensayos	69
4.2.1. Variables consideradas en los ensayos	69
4.2.2. Tipos de ensayos	70
4.2.2.1. Ensayos para la caracterización de las desviaciones geométricas	70
4.2.2.2. Ensayos de microdureza superficial	71
4.2.3. Geometría de las probetas	72
4.2.4. Herramienta de corte	73
4.2.5. Valores de los parámetros de corte empleados	74
4.2.6. Evaluación de las desviaciones geométricas	75
4.2.6.1. Evaluación de las desviaciones microgeométricas	75
4.2.6.2. Evaluación de las desviaciones macrogeométricas	76
4.2.7. Evaluación de las propiedades mecánicas	77
4.2.7.1. Ensayos de la microdureza superficial	77
4.3. Enfoque de predicción y optimización de las propiedades relacionadas con la integridad superficial a través de RNAs	80
5. Resultados y discusión	85
5.1. Introducción	85
5.2. Ajuste de Hiperparámetros	85
5.3. Evaluación de las desviaciones microgeométricas	102
5.3.1. Modelado de la rugosidad media aritmética (R_a)	102

5.3.2. Modelado de la máxima altura del perfil de rugosidad (R_z)	105
5.4. Evaluación de las desviaciones macrogeométricas	108
5.4.1. Modelado del paralelismo (PAR)	108
5.4.2. Modelado de la rectitud (STR)	111
5.4.3. Modelado de la oscilación radial (CRO)	114
5.4.4. Modelado de la redondez (RON)	117
5.4.5. Modelado de la concentricidad (CON)	120
5.4.6. Modelado de la cilindridad (CYL)	123
5.5. Evaluación de las propiedades mecánicas	126
5.5.1. Modelado de la microdureza superficial	126
5.6. Validación con modelos analíticos clásicos	129
5.7. Modelado del sistema integral	134
5.8. Optimización de los parámetros de corte	136
6. Conclusiones y trabajos futuros	143
6.1. Introducción	143
6.2. Conclusiones	143
6.3. Líneas futuras de investigación	146
Bibliografía	166
A. Código en Matlab	167
A.1. Análisis del tipo de algoritmo de aprendizaje	167
A.2. Análisis del número de capas ocultas	170
A.3. Selección óptima de lotes para entrenamiento, validación y prueba y análisis del número de neuronas en la capa oculta	172
A.4. Comparación entre modelos	178

Índice de figuras

2.1. Evolución en el uso de materiales en el sector aeronáutico. (a) Imagen original del primer vuelo con motor de la historia (datado el 17 de diciembre de 1903) a los mandos de Orville Wright (tomada de https://www.sociedad aeronautica.org/) Instantánea del posicionamiento en pista para despegue del modelo A380 de Airbus (https://alphacoders.com/).	11
2.2. (a) Formación de nido de viruta y efecto sobre el acabado superficial de la probeta mecanizada (adaptado de [31]). (b) Detalle de la fragmentación de la viruta tras una operación de mecanizado (tomado de https://turntechprecision.com/).	14
2.3. Mecanismo de adhesión secundaria en la cara de desprendimiento de la herramienta (BUL y BUE) (adaptada de https://www.iscar.com/).	26
3.1. Clasificación de algoritmos de IA.	54
3.2. Representación de perceptrón multicapa	57
3.3. Estructura básica de una neurona artificial.	58
4.1. Distinción de las zonas de una probeta para el análisis de las desviaciones geométricas y ensayos a fatiga por flexión rotativa (adaptado de [4]).	72
4.2. Herramienta de corte DCMT 11T308-14 IC20 y representación de ángulos principales de corte (adaptado de https://www.iscar.com/ y [4]).	73
4.3. Sistema de medida de la rugosidad superficial (adaptado de [4]).	76
4.4. Medición de la rugosidad superficial (adaptado de [4]).	76
4.5. Secciones de medida para estudiar las desviaciones geométricas con reloj comparador (adaptado de [4]).	77
4.6. Ensayos de microdureza superficial Vickers [4]. (a) Microdurómetro MATSUZAWA empleado para los ensayos de microdureza. (b) Detalle de la probeta siendo inspeccionada en el microdurómetro.	78

4.7. Ajuste de la huella para obtener el valor de microdureza [4].	79
4.8. Metodología propuesta para la estimación-optimización de propiedades ligadas con la integridad superficial a partir de RNAs.	83
5.1. Distribución del RMSE para los distintos algoritmos de aprendizaje. En las barras de error se muestran los valores máximos ($RMSE_{max}$) y mínimos ($RMSE_{min}$) alcanzados durante el total de iteraciones.	88
5.2. Distribución del RMSE variando el número de capas ocultas. En las barras de error se indican los valores máximos ($RMSE_{max}$) y mínimos ($RMSE_{min}$) obtenidos durante el total de iteraciones.	90
5.3. Histograma del número óptimo de neuronas considerado en la capa oculta ($N_{opt} \in [1, 50]$) que minimiza el RMSE tras el total iteraciones.	93
5.4. Histograma del número óptimo de neuronas considerado en la capa oculta ($N_{opt} \in [1, 20]$) que minimiza el RMSE tras el total de iteraciones.	95
5.5. Distribución del RMSE variando el número de neuronas en la capa oculta ($N \in [0, 50]$) tras el total de iteraciones.	96
5.6. Distribución de la frecuencia de $RMSE_{tr}$ tras el total de iteraciones.	98
5.7. Distribución de la frecuencia de $RMSE_{val}$ (a) y $RMSE_t$ (b) tras el total de iteraciones.	99
5.8. Distribución de la frecuencia de $RMSE_{tot}$ tras el total de iteraciones	100
5.9. Resultados de la regresión obtenidos por la RNA optimizada. En línea en discontinua se muestra el ajuste idóneo (con $R^2 = 1$) en el que los valores de la estimación (\hat{y}_t) corresponderían a los valores medidos (y_t). En línea continua de mayor grosor se muestra el ajuste de la RNA para los datos disponibles.	101
5.10. Variación de la rugosidad media aritmética (R_a) predicha por la RNA en función del avance (f) para cada velocidad de corte (v_c). Las barras de error representan la desviación típica asociada a cada valor estimado.	103
5.11. Familia de curvas de la rugosidad media aritmética (R_a , en μm) para las condiciones de corte (v_c y f).	104
5.12. Variación de la máxima altura del perfil de rugosidad (R_z) predicha por la RNA en función del avance (f) para cada velocidad de corte (v_c). Las barras de error representan la desviación típica asociada a cada valor estimado.	105

5.13. Familia de curvas de la máxima altura del perfil de rugosidad (R_z , en μm) para las condiciones de corte (v_c y f).	107
5.14. Variación del paralelismo (PAR) predicho por la RNA en función del avance (f) para cada velocidad de corte (v_c). Las barras de error representan la desviación típica asociada a cada valor estimado.	109
5.15. Familia de curvas del paralelismo (PAR, en μm) para las condiciones de corte (v_c y f).	110
5.16. Variación de la rectitud (STR) predicha por la RNA en función del avance (f) para cada velocidad de corte (v_c). Las barras de error representan la desviación típica asociada a cada valor estimado.	111
5.17. Familia de curvas de la rectitud (STR, en μm) para las condiciones de corte (v_c y f).	113
5.18. Variación de la oscilación radial (CRO) predicha por la RNA en función del avance (f) para cada velocidad de corte (v_c). Las barras de error representan la desviación típica asociada a cada valor estimado.	114
5.19. Familia de curvas de la oscilación radial (CRO, en μm) para las condiciones de corte (v_c y f).	116
5.20. Variación de la redondez (RON) predicha por la RNA en función del avance (f) para cada velocidad de corte (v_c). Las barras de error representan la desviación típica asociada a cada valor estimado.	117
5.21. Familia de curvas de la redondez (RON, en μm) para las condiciones de corte (v_c y f).	119
5.22. Variación de la concentricidad (CON) predicha por la RNA en función del avance (f) para cada velocidad de corte (v_c). Las barras de error representan la desviación típica asociada a cada valor estimado.	120
5.23. Familia de curvas de la concentricidad (CON, en μm) para las condiciones de corte (v_c y f).	122
5.24. Variación de la cilindridad (CYL) predicha por la RNA en función del avance (f) para cada velocidad de corte (v_c). Las barras de error representan la desviación típica asociada a cada valor estimado.	123
5.25. Familia de curvas de la cilindridad (CYL, en μm) para las condiciones de corte (v_c y f).	125

5.26. Variación de la microdureza superficial (HV 0.05) predicha por la RNA en función del avance (f) para cada velocidad de corte (v_c) para $a_p = 1$ mm. Las barras de error representan la desviación típica asociada a cada valor estimado.	127
5.27. Familia de curvas de la microdureza superficial (HV 0.05) para las condiciones de corte (v_c , f y $a_p = 1$ mm).	128
5.28. Comparación de los resultados para R_a estimados a partir del modelo de la RNA, potencial y RSM.	132
5.29. Resultado de la regresión obtenida por la RNA optimizada para la estimación del conjunto de variables de salida (propiedades micro y macrogeométricas junto a la microdureza superficial). En línea en discontinua se muestra el ajuste idóneo (hipótesis de $R^2 = 1$) en el que los valores de la estimación (\hat{y}_t) coincidirían a los valores medidos (y_t). En línea continua de mayor grosor se muestra el ajuste de la RNA para los datos disponibles.	135

Índice de tablas

4.1. Variables de entrada y salida consideradas.	69
4.2. Dimensiones de una probeta para el análisis de las desviaciones geométricas y ensayos a fatiga por flexión rotativa [4].	72
4.3. Dimensiones de una probeta para ensayos de microdureza [4].	72
4.4. Dimensiones de la herramienta de corte.	74
4.5. Parámetros de corte empleados en los ensayos para la caracterización de las desviaciones geométricas.	75
4.6. Parámetros de corte empleados en los ensayos de microdureza.	75
5.1. Rango de valores de los hiperparámetros según la literatura.	86
5.2. Valores máximos y mínimos del error cuadrático medio correspondiente a cada fase ($RMSE_{tr}$, $RMSE_{val}$ y $RMSE_t$) junto al respectivo número de neuronas ($N \in [1, 50]$).	97
5.3. Valores máximos y mínimos del error cuadrático medio para cada una de las fases ($RMSE_{tr}$, $RMSE_{val}$ y $RMSE_t$) junto al respectivo número de neuronas ($N \in [1, 20]$).	97
5.4. Parámetros del modelo potencial.	130
5.5. Estimadores del modelo RSM.	131
5.6. Coeficientes de determinación (R^2) para los modelos de la RNA, potencial y RSM.	133
5.7. Optimización GRA de los parámetros de corte.	138
5.8. Optimización GRA de los parámetros de corte sin considerar R_a y R_z e incluyendo t_c	140

Capítulo 1

Introducción

1.1. Contexto

El sector aeronáutico y los singulares requisitos en sus procesos de fabricación por condiciones de seguridad y costes, le confieren una dimensión global y un alto interés estratégico dentro del tejido industrial a nivel nacional e internacional. Esta naturaleza estratégica hacen de los proyectos de investigación y las actuaciones en I+D+i un factor clave de competitividad, lo que conlleva la necesidad de optimizar los ciclos y productos hacia una máxima sostenibilidad en sus procesos productivos y una elevada funcionalidad en su aplicación [1].

A nivel estatal, esta industria ha experimentado en las últimas décadas un acelerado ritmo de crecimiento que le ha llevado a situarse entre las principales potencias europeas por niveles de producción y generación de empleo, suponiendo hasta el 4.5% del Producto Interior Bruto industrial [2].

La tendencia actual se centra en el empleo de aleaciones ligeras (de aluminio y titanio principalmente) debido a su excelente ratio densidad-resistencia mecánica en el conformado de componentes estructurales del fuselaje de aeronaves [3]. Ejemplo de ello, se observa en modelos de alta innovación tales como el Airbus 380 y el Boeing 787 que gracias a las propiedades tan características de estos materiales, se consigue reducir su peso y por consiguiente, disminuir el consumo de combustible y la contaminación ambiental generada.

En cuanto a los procesos de fabricación empleados en la manufactura de estos componentes, los sustractivos resultan uno de los más comunes. Dentro de éste, las operaciones de torneado son una de las más utilizadas en la fabricación de elementos de revolución sometidos a elevadas sollicitaciones mecánicas, razón por la cual, el análisis del rendimiento constituye una tarea fundamental para garantizar el cumplimiento de

las exigencias de servicio.

Por otro lado, la situación medioambiental actual ha forzado la necesidad de recurrir a tecnologías productivas con un limitado impacto ambiental sin sacrificar los niveles de competitividad, tratando de alcanzar un equilibrio entre funcionalidad, economía, consumo energético y responsabilidad medioambiental [4]. En el caso de los procesos de mecanizado, se ha mostrado tradicionalmente como práctica común, aplicar procedimientos de lubricación y refrigeración que permiten reducir el efecto de los fenómenos térmicos, pero que, a la vez, generan un impacto negativo en términos ambientales, resultado de la generación de residuos tóxicos con elevados costes de reciclado [5].

Tratando de dar respuesta a esta problemática, se emplean técnicas que eviten y reduzcan su empleo, a través de estrategias *High-Pressure Coolant* (HPC), *Minimum Quantity Lubrication* (MQL) e incluso a partir de su eliminación completa con las técnicas de mecanizado en seco [6]. No obstante, estos procesos de fabricación, debido a los considerables esfuerzos mecánicos y térmicos generados, adolecen de la generación de unas condiciones de corte agresivas que pueden afectar negativamente a la integridad superficial de las piezas mecanizadas, uno de los requisitos de calidad más valorados en este tipo de aplicaciones por su influencia en el rendimiento de la operación de mecanizado.

En este sentido, se justifica la necesidad de profundizar en el estudio de aquellas variables que afectan al rendimiento de estos procesos, centrándose en el análisis de las propiedades macro y micro-geométricas superficiales junto a las físico-químicas en función de los denominados parámetros de corte.

Asimismo, de acuerdo con la “Agenda Estratégica Española de Investigación, Desarrollo e Innovación Aeronáutica, 2019-2030”, presentada por la *Plataforma Tecnológica Aeroespacial Española* (PAE), el foco de atención se centra en la aplicación de tecnologías *Big Data*, *Machine Learning* e Inteligencia Artificial como claves en el diseño, optimización de los ciclos y mantenimiento predictivo de productos y procesos [2].

Dentro de este ámbito, el proyecto, *Expert System for improving surface integrity in sustainable machining of light alloys* (SPAREMETAL) desarrollado por el grupo de investigación TEP933 de Ingeniería de Fabricación de la Universidad de Málaga, trata entre otros objetivos, de determinar las condiciones óptimas de fabricación, que de minimización de las desviaciones geométricas a partir de un conjunto de resultados experimentales haciendo uso de técnicas de aprendizaje automático.

En este contexto se sitúa el presente Trabajo Fin de Grado, centrado en estudiar el nivel de influencia de los parámetros de corte sobre distintas propiedades relacionadas con la integridad superficial de probetas torneadas en seco de la aleación de aluminio

UNS A97075-T6, a través de las *Redes Neuronales Artificiales* (RNA) dentro del paradigma *Deep Learning*.

1.2. Objetivos

El objetivo principal de este Trabajo Fin de Grado es predecir el comportamiento de un conjunto de propiedades, tales como los valores de rectitud (STR), paralelismo (PAR), redondez (RON), concetricidad (CON), oscilación radial (CRO) y cilíndricidad (CYL) como métricas de las desviaciones macro-geométricas originadas durante el proceso de mecanizado en seco sobre la aleación UNS A97075 (Al-Zn), así como, la obtención del perfil de rugosidad de las probetas conformadas a través de la rugosidad media aritmética (R_a) y de la máxima altura del perfil (R_z) y su dureza superficial (HV) en función de los parámetros de corte (velocidad de corte, v_c ; avance, f y profundidad de corte, a_p). Con este análisis, se pretende establecer un sistema experto capaz de evaluar con precisión suficiente, el efecto de las variables independientes (entendidas como parámetros tecnológicos), sobre aquellas variables de salida relacionadas con la integridad superficial. Para ello, se establecen un conjunto de objetivos particulares que permitan alcanzar con éxito el objeto inicial, los cuales se mencionan a continuación.

- (I) Exponer una metodología de optimización, alternativa a las que ya pueden encontrarse en la literatura, de los hiperparámetros que configuran la RNA con objeto de incrementar su precisión y capacidad de generalización. Asimismo, se pretende estudiar el efecto de cada uno de los parámetros influyentes en el rendimiento del sistema (*análisis de sensibilidad*) para poder cuantificarlos, discriminando aquellos con mayor impacto.
- (II) Una vez ejecutados los modelos de RNA óptimos, se pretende comparar los resultados obtenidos con otras tipologías de modelos como el potencial o el Método de Superficie Repuesta para demostrar la eficacia del uso de estos algoritmos y de la metodología propuesta.
- (III) Estudiar cómo afectaría integrar el conjunto de variables de interés junto a los respectivos parámetros de corte, en una única RNA y contrastar los resultados con los modelos individuales obtenidos en apartados previos. Esta comparación permitirá identificar si la agrupación de los atributos proporciona ventajas significativas en términos de eficiencia en comparación con los modelos separados.

- (IV) Conocer analíticamente el valor de los parámetros de corte que minimizan las propiedades micro y macrogeométricas a la vez que maximizan la microdureza superficial del material.

1.3. Organización de la memoria

La memoria de este Trabajo Fin de Grado, se ha estructurado en 6 capítulos.

En primer lugar, durante el CAPÍTULO 1, se presentan los antecedentes que respaldan y definen el marco de este proyecto para terminar exponiendo los objetivos principales perseguidos durante su realización y explicar la estructura de este documento.

A lo largo del CAPÍTULO 2, se lleva a cabo una amplia revisión del estado del arte, centrando el foco de atención en aquellos trabajos que discuten el efecto de los parámetros de corte en las operaciones de mecanizado, sobre la calidad superficial, con especial interés en las aleaciones de aluminio empleadas en el sector aeronáutico. Asimismo, se abordan los criterios de maquinabilidad y algunos de los modelos analíticos para tal efecto. Para concluir este capítulo, se muestran algunos estudios específicos que recurren a técnicas de inteligencia artificial para la predicción de propiedades relacionadas con la integridad superficial.

Seguidamente, el CAPÍTULO 3, introduce y expone conceptos generales y terminología relacionada con el paradigma *Machine Learning* y en particular sobre las RNAs a los que se hará referencia durante sucesivos capítulos.

El CAPÍTULO 4 recoge una descripción precisa de la metodología experimental empleada para la realización de los distintos ensayos, centrándose en las fases y recursos empleados más relevantes. De igual modo, se resume el diseño y desarrollo de la solución propuesta a partir del enfoque de optimización de los hiperparámetros.

Así, el CAPÍTULO 5 presenta y discute los resultados obtenidos para cada una de las variables de estudio consideradas, así como el ajuste de los parámetros que rigen el comportamiento de la RNA. Asimismo, con objeto de evaluar y validar los valores de predicción obtenidos se contrastan con modelos analíticos clásicos. De igual modo, se estudia cómo influye agrupar el conjunto de predictores en una única red neuronal en términos de precisión, comparado con aquellas arquitecturas de una única neurona en la capa de salida. Por último se pretende calcular las condiciones de corte idóneas que permiten maximizar la microdureza superficial y minimizar el resto de propiedades relacionadas con la integridad superficial al mismo tiempo.

Finalmente, el CAPÍTULO 6 sintetiza las conclusiones derivadas del desarrollo de la investigación que ha dado como resultado este proyecto. Además, se incluyen distintas líneas de trabajo que dan pie a continuar profundizando y explorando nuevas vías de estudio.

Capítulo 2

Estado del Arte del mecanizado de aleaciones de aluminio en la industria aeroespacial

2.1. Introducción

Se repasa en este capítulo, los principales antecedentes bibliográficos relacionados con el uso del mecanizado de aleaciones de aluminio en la industria aeroespacial y aeronáutica, analizando los criterios y los modelos paramétricos más utilizados para evaluar su integridad superficial, además de las propiedades de las aleaciones más usadas, para continuar con la investigación sobre cómo se comportan en los mecanizados y los problemas que puedan aparecer, y se realiza también una exploración de las variables de influencia y las consecuencias en el resultado que finalmente se obtenga. Hay bastante información disponible sobre el mecanizado de aleaciones de aluminio, pero es menos abundante en el caso del torneado en seco de aleaciones de aluminio para uso aeroespacial.

2.2. Aleaciones de aluminio

Siendo el aluminio muy abundante, éste no se encuentra como metal en la naturaleza como otros, sino que lo hace combinado con otros (oxígeno) en forma de óxido de aluminio. Desde finales del siglo XIX cuando se empieza a extraer el aluminio (reducción electrolítica) hasta la actualidad, su uso ha ido creciendo de modo exponencial gracias fundamentalmente a su versatilidad y su extenso rango de propiedades mecánicas y físicas [1].

2.2.1. Generalidades

Se destacan algunas propiedades de este material que le otorgan numerosas ventajas [7]: una magnífica relación peso-resistencia (la densidad del aluminio gira alrededor entorno a un tercio de la del acero, el cobre o el latón, y algunas de sus aleaciones tienen resistencias mecánicas superiores a la de algunos aceros estructurales); una gran resistencia a la corrosión (un gran número de las aleaciones de aluminio ofrecen una resistencia a la corrosión excelente en la mayoría de los ambientes); una alta conductividad eléctrica (duplica a la del cobre); alta resistencia mecánica (magnífico como conductores en líneas de alta tensión); alta conductividad térmica (se usa de modo habitual para fabricar intercambiadores de calor, radiadores, evaporadores y cabezas de cilindros); elevada ductilidad y facilidad de conformado (utilizado en muchos procesos de fabricación para su conformado, logrando productos de muchas formas y tamaños, ayudando a lograr procesos de fabricación con costes bajos); facilidad de reciclado; relativo bajo coste; material no ferromagnético (de gran interés para su uso en la industria electrónica y eléctrica); no tóxico (muy usado en la industria alimentaria) y acabados atractivos (aspecto suave y brillante en su acabado natural, además de posibilitar tratamientos para lograr diferentes colores y texturas).

Por otra parte, destacan otras propiedades, que pueden considerarse no positivas [8]. Las aleaciones de aluminio de alta resistencia presentan un módulo elástico bajo en comparación con otros (70 % frente al Titanio y 40 % frente a aceros estructurales); tienen una baja capacidad de soportar elevadas temperaturas (las aleaciones de aluminio tienen la mayoría su punto de fusión a los 535°C y aun pudiendo usarse a temperaturas de hasta 300°C un tiempo escaso, en temperaturas altas y tiempo extenso se suele limitar a 150°C). Por otra parte, aunque tanto el aluminio puro como casi todas las aleaciones presentan una muy buena resistencia a la corrosión, hay determinadas aleaciones usadas en la industria aeroespacial que podrían presentar problemas. Y en relación a las soldaduras, pueden resultar problemáticas en algunas aleaciones de aluminio, por lo que en muchas ocasiones se debe recurrir a técnicas específicas de soldadura.

El aluminio puro es fácil de mecanizarse plásticamente (ductilidad alta y resistencia a la fatiga) y se puede considerar como un metal blando, puesto que tiene una resistencia mecánica menor que gran parte de los metales. Por tanto, es habitual añadirle pequeñas cantidades de distintos elementos para mejorar sus propiedades y de este modo obtener numerosas aleaciones, con comportamientos y características diferentes, que dependerán del tipo y proporción del aleante, y posteriormente incluso pueden someterse a tratamientos térmicos para mejorar sus propiedades mecánicas [7], [9].

Los aleantes principales (con suficiente solubilidad en estado sólido en el aluminio) son el cobre, el magnesio, el silicio, el zinc y, actualmente, el litio; mientras que el cromo

y el manganeso son otros de los aleantes utilizados en las aleaciones, pero con menor grado de solubilidad [8].

Determinados aleantes pueden mejorar alguna de las propiedades de la aleación, aunque no deben empeorar otras, de este modo se necesita lograr un equilibrio adecuado de la presencia y la proporción del aleante y así obtener el comportamiento y las propiedades deseadas en servicio [10], [11]. De modo general las aleaciones se clasifican en forjadas (las más usadas) y moldeadas (para moldeo o fundidas).

Por destacar alguna de las posibles aplicaciones del aluminio y sus aleaciones podemos recoger la aplicación en la industria aeronáutica cuyo principal criterio utilizado para su selección es la baja densidad, las propiedades mecánicas, la facilidad de conformado la resistencia a la corrosión y que permiten tratamientos superficiales, siendo las series más habitualmente usadas las 2XXX y 7XXX [12].

Hay diferentes modos de nombrar a las aleaciones de aluminio, en función generalmente del país [9], siendo las más utilizadas las designaciones de la Asociación del Aluminio (AA, *Aluminum Association*) y el Sistema de Numeración Unificado (UNS, *Unified Numbering System*) [7]. En cualquiera de los casos la fórmula que se utiliza para identificarlas recoge un código con dígitos y letras (identifican el aleante principal), cuál es su composición y en su caso el tratamiento térmico que se le haya aplicado. Por ejemplo, en los supuestos de aleaciones forjadas, el código contiene 4 dígitos, siendo el primero el que se refiere al aleante principal, el segundo el que indique si se refiere a una aleación original o modificaciones obtenidas a partir de ella, y el tercero y cuarto para hacer referencia al % de impurezas (para aleaciones de alta pureza) o para identificar distintos tipos de la aleación [9].

La designación del tratamiento térmico va tras el código que identifica la aleación, a través de una letra que señala el tipo (W, solución y T, estabilizados), junto otros dígitos para indicar otros tratamientos y tensiones [8].

La única diferencia para las aleaciones de aluminio fundidas consiste en la introducción de un punto decimal entre el tercer y cuarto dígito.

La utilización de las aleaciones de aluminio de fundición está creciendo y sobre todo en la industria automovilística, siendo las de base Aluminio-Silicio son las más usadas, ya que ofrecen propiedades muy atractivas para utilizarlas en la fabricación de productos de fundición, como [13]: el bajo punto de fusión; su facilidad de moldeo que permite obtener productos con geometrías complejas (destaca especialmente la serie 3XX.X que también tiene una muy buena soldabilidad); acabados superficiales muy buenos; alta resistencia combinada con elevada tenacidad (la serie 2XX.X tiene una muy buena resistencia a las temperaturas altas, pero su moldeo es más complicado y además

no tiene acabados muy buenos, siendo usadas sobre todo en la industria aeroespacial, en la que son muy importantes las exigencias de bajo peso y alta resistencia). Pero presentan una serie de problemas como las elevadas contracciones en la solidificación (provocando que sea necesario dedicar atención añadida en el diseño de los moldes para salvar tensiones, porosidad y así lograr la dimensiones con los niveles de calidad previstos.

Asimismo, las aleaciones de aluminio para moldeo, en comparación con las forjadas, tienen en términos generales peores propiedades mecánicas por causa de una mayor presencia de impurezas provocando estructuras sea más heterogéneas [9].

2.2.2. Aplicaciones en el sector aeroespacial

El amplio desarrollo de las industrias eléctricas, automovilísticas y aeroespaciales ha provocado un incremento en la utilización de las aleaciones de aluminio, sobre todo la automovilística.

La industria aeroespacial y la del aluminio se han ido desarrollando conjuntamente, favoreciendo que se desarrollen estructuras fiables y resistentes destinadas a los fuselajes de aeronaves y motores [7].

Para la fabricación de componentes estructurales en las aeronaves se necesitan materiales que cumplan los siguientes requerimientos: disponer una relación peso – resistencia mecánica muy buena; presentar una resistencia y durabilidad excelente en condiciones extremas ambientales; que sus costes sean competitivos (tanto la adquisición de los materiales, como los procesos de conformado y mantenimiento); a la vez dichos componentes estructurales tienen que ofrecer gran tenacidad y rigidez, alta resistencia en relación a la aparición-propagación de grietas derivadas de la fatiga junto con una elevada resistencia a la corrosión.

Existen determinadas aleaciones de aluminio de forja que cumplen todos los requisitos antes señalados y por tanto son los materiales que se utilizan mayormente en la construcción de aeronaves (particularizando las series 2000 (Al-Cu) y 7000 (Al-Zn) se corresponden con las más utilizadas en la industria aeroespacial junto con otras de la serie 6000 (Al-Mg-Si), usualmente con algún tratamiento térmico [8].

En función de las propiedades en servicio de la pieza se seleccionará un tipo de aleación concreta. Debido a su alta resistencia, la aleación UNS A92024 envejecida de forma natural (T3) o sin tratamiento térmico, ha venido siendo de modo tradicional la más utilizada en la fabricación del fuselaje de aeronaves.



(a)



(b)

Figura 2.1: Evolución en el uso de materiales en el sector aeronáutico. (a) Imagen original del primer vuelo con motor de la historia (datado el 17 de diciembre de 1903) a los mandos de Orville Wright (tomada de <https://www.sociedad aeronautica.org/>) Instantánea del posicionamiento en pista para despegue del modelo A380 de Airbus (<https://alphacoders.com/>).

Han ido mejorándose sus propiedades, mejor control de las impurezas y porcentaje de aleantes, hasta dar lugar a otras aleaciones como la UNS A92224, la UNS A92324 y la UNS A92524. Esta serie presenta un inconveniente relacionado con una no muy buena resistencia a la corrosión y por tanto suelen revestirse [14]. Por otra parte, necesitan uniones por medios mecánicos debido a su deficiente soldabilidad. De este modo se introduce la serie 6000 (Al-Mg-Si), con soldabilidad mayor y resistencia a la corrosión, aunque con peores propiedades mecánicas [9].

De entre todas las aleaciones de aluminio, la serie 7000 (Al-Zn) con tratamiento térmico es la que ofrece mayor resistencia mecánica, siendo las UNS A97049, UNS A97050, UNS A97075, UNS A97175, UNS A97178 y UNS A97475 las más usadas. Y particularmente, la UNS A97050 tiene una gran resistencia ante la fracturar, una mala soldabilidad, necesitando uniones mecánicas y para reducir los riesgos de corrosión se les aplican tratamiento térmico T7, sacrificando en parte la resistencia mecánica [8], [15].

En relación con la serie 8000 cabe destacar las aleaciones con gran contenido en Litio (UNS A98090, UNS A98091 y UNS A98093) que le aporta baja densidad (10 menos en comparación a las más usadas) y una alta dureza y resistencia a la fatiga, además de una mejora en la soldabilidad. A pesar de su alto precio, su menor tenacidad y ser reactivo y tóxico, todas sus ventajosas propiedades son los argumentos para considerarla como el ideal en la fabricación de las estructuras en aviones.

La necesidad de obtener nuevos materiales ligeros, o mejorar los existentes, que se destinen a la fabricación de las aeronaves, busca satisfacer los siguientes requerimientos. Por una parte, es necesario disminuir fallos estructurales en servicio [16] y así mejorar la seguridad en los vuelos; también existe una altísima competencia en las aerolíneas que implica una política de reducción de costes apoyada en la mejora de la eficiencia del combustible y reducción del peso de los aviones. Es importante destacar que la utilización de materiales ligeros no debiera implicar un incremento en los costes de fabricación y/o mantenimiento superior al ahorro de combustible conseguido.

Entre los nuevos materiales que se han ido destinando en la fabricación de aeronaves están las aleaciones de Titanio, los MMC (*Metal Matrix Composites* o compuestos de matriz metálica), la fibra de vidrio y carbono, las FML (*Fiber Metal Laminates* o estructuras híbridas laminadas combinadas con fibra de vidrio o carbono), entre el que se encuentra el GLARE (*GLass-REinforced aluminium laminate*) [9], [17], [18].

A pesar de ello, las aleaciones de aluminio siguen siendo los materiales más usados en la fabricación de aviones comerciales (por encima del 60) [9], ya que los aviones comerciales forman parte de Proyectos con periodos de vigencia de por lo menos 20 años. Además, en AIRBUS todavía fabrican sus aviones más conocidos (A319 y A320) en estructuras conformada en su mayoría de Aluminio [19].

2.3. Estudio de las variables de entrada en el mecanizado de aleaciones de aluminio de uso aeronáutico

2.3.1. Introducción

La facilidad de conformado es una de las propiedades por la que las aleaciones de aluminio son muy usadas, siendo a su vez el mecanizado uno de procesos de fabricación más utilizados en las estructuras para aeronaves [20], [21].

El rendimiento de los procesos de fabricación está afectado por razones económicas, otras de carácter funcional, cuestiones energéticas y medioambientales.

En el caso del mecanizado, la mejora del rendimiento está muy vinculado al estudio de la maquinabilidad de los materiales [22], [23].


La maquinabilidad de un material depende de muchas variables (el material, la herramienta, los parámetros de corte, la lubricación, ...) afectando a variables de salida (la fuerza de corte, la calidad final, la temperatura del corte, el desgaste y la vida de la herramienta, ...). Además, no hay unanimidad en los criterios que permitan evaluar la maquinabilidad de una determinada aleación, incluidas las aleaciones de aluminio.

2.3.2. Principales problemas durante el mecanizado

Las aleaciones de aluminio están entre las aleaciones con mejor maquinabilidad, muy superior a la de otras aleaciones ligeras (super-aleaciones de níquel o titanio) [24], [25]; requieren fuerzas de corte bajas (comparadas con las necesarias en la mecanización de aceros con similar resistencia mecánica [25]; presentan una conductividad térmica alta de modo que ayuda a evacuar el calor durante el corte, permitiendo utilizar velocidades de corte altas, y una vida de la herramienta muy buena [13], [8].

Por otra parte, también muestran una serie de problemas en su mecanizado. En las aleaciones de aluminio forjadas, se deben tener en cuenta fundamentalmente dos problemas.

En primer lugar, la adhesión de material a la herramienta. A pesar de su conductividad térmica elevada y que facilita la eliminación del calor, su punto de fusión es bajo, sobre los 550°C, pero las temperaturas que se generan en el corte superan normalmente dichos valores, provocando que se funda el material. Una parte de dicho material que se ha fundido se une a la viruta incorporándose o al filo de la herramienta, formándose el filo recocado o BUE, o a la cara de desprendimiento, formándose la capa adherida o



(a)



(b)

Figura 2.2: (a) Formación de nido de viruta y efecto sobre el acabado superficial de la probeta mecanizada (adaptado de [31]). (b) Detalle de la fragmentación de la viruta tras una operación de mecanizado (tomado de <https://turntechprecision.com>).

BUL. Con el inconveniente ya conocido que el BUE provoca la modificación de la forma que inicialmente tiene la herramienta y a su vez repercute en la calidad del acabado y en la vida de la propia herramienta. Por otra parte, el BUE es inestable, tiende a desprenderse, causando pérdida de material y provocando el desgaste de la herramienta [26], [27].

En segundo lugar, en el mecanizado de estas aleaciones la viruta que se obtiene no es homogénea ni regular y ello causa que sea muy difícil establecer vínculos entre la morfología, los parámetros de corte y las variables de salida [28], [29]. Por otra parte, estas aleaciones tienen una gran ductilidad lo que provoca que la viruta, sin fragmentarse, se deforme plásticamente, y aparezca viruta continua, formándose nidos de viruta y provocando numerosas interrupciones durante el mecanizado lo que afecta al acabado superficial del mecanizado [21], [24], [30].

Esto implica un importante problema habitual cuando se pretende automatizar el proceso. Para mejorar el control de estas virutas se actúa en la composición del material que se mecaniza y en la geometría de la propia herramienta.

Los problemas son diferentes cuando nos referimos a las aleaciones de aluminio fundidas, entre las que destacan las series 3XX.X y 4XX.X, siendo el silicio el aleante principal (entre el 17 % y el 23 %), que tiene un punto de fusión bastante mayor que el aluminio (sobre los 1400°C) y una dureza. Las partículas de Silicio se encuentran habitualmente formando granos grandes en la aleación que al ser más duros que los otros elementos de la aleación se dividen al contactar con el filo de corte, y pasan como parte de la viruta que, al deslizarse por la cara de desprendimiento, provoca un deterioro rápido de la herramienta aumentando a su vez y por causa del rozamiento, un rápido crecimiento de la temperatura durante el corte.

Por lo tanto, uno de los grandes problemas a tener en cuenta durante el mecanizado de estas aleaciones es el desgaste de la herramienta. En las fundidas, es la abrasión el mecanismo que predomina en el desgaste y la adhesión en las forjadas.

Además, las aleaciones de Aluminio-Silicio necesitan fuerzas de corte mayores que para las demás aleaciones de aluminio, y provocando más vibración [30], [32], [33].

En relación con la herramienta utilizada en el mecanizado de este tipo de aleaciones, las de carburo se deterioran con rapidez para las aleaciones de Al-Si, recurriéndose a las de diamante policristalino (PCD) y principalmente a las herramientas de carburo recubiertas con diamante, que, aunque su adquisición sea más costosa, ofrecen mayor duración [34], [35].

2.3.3. Influencia de la microestructura y tratamiento térmico de la aleación

La elección de un tipo u otro de adelante y su proporción afectan a la facilidad de éste para ser mecanizado. De hecho, influyen en el control y morfología de la viruta (“*free machining elements*”); en el mecanismo de desgaste predominante; en la vida de las herramientas; en el acabado superficial que se obtiene; en las fuerzas de corte que se requieran y en las vibraciones que se generen.

Por otra parte, referirse a la integridad superficial en el mecanizado es considerar tanto las características geométricas de la superficie como sus propiedades físico-químicas. De hecho, durante el mecanizado, las propiedades de la capa subyacente de la superficie que se está mecanizando se alteran, cambiando la dureza, produciéndose deformación plástica, apareciendo tensiones residuales, entre otras. Estas alteraciones influyen de manera reseñable en la funcionalidad de las piezas obtenidas. Y determinados factores como la dureza y microestructura de las aleaciones, que a su vez se relacionan de modo directo con los tratamientos térmicos usados, influyen directamente en la integridad superficial de los mecanizados [36].

A continuación, se destacan una serie de estudios de maquinabilidad que tienen en consideración cómo las modificaciones antes descritas afectan a estos procesos.

Zander y Sandström [37] plantean un modelo de maquinabilidad en las aleaciones forjadas de aluminio que tiene en consideración la dureza de los materiales, el contenido de Bi y Pb, la ductilidad y la conductividad térmica. De tal modo que a través de su ecuación pone de relieve que, al aumentar la dureza y la conductividad térmica, y al encontrarse presentes “*free machining elements*” se optimiza la maquinabilidad de la aleación, con la dureza como el factor que más influye, y en otro sentido, si se aumenta la ductilidad la maquinabilidad empeora.

Rashad y El-Hossainy [38] estudian cómo evoluciona la calidad del acabado en superficie en relación al avance y a la velocidad de corte, usando herramientas de acero rápido (*High Speed Steel*, HSS), y para la aleación de Al-Zn 7116, con diferentes tratamientos térmicos, concluyendo que se consigue mejor acabado superficial con el tratamiento térmico T9 (más dureza); y si se disminuye la dureza, la calidad del acabado disminuye (si se reduce la dureza, aparece filo recreado, BUE, que empeora el acabado, más acentuado si se aumenta el avance y se reduce la velocidad de corte).

Demir y Gündüz [39] estudian cómo varía la rugosidad media aritmética, R_a , junto con la fuerza de corte, dependiendo de la velocidad de corte en el torneado con herramientas del tipo carburo recubierto, para aleación de Al-Si 6061, con diferentes tratamientos térmicos. Concluyen que, al aumentar la dureza, R_a disminuye según el tratamiento térmico que se aplique. Por otra parte, también afirman que R_a disminuye si se aumenta la velocidad de corte (se reduce el BUE).

Otros estudios analizan la relevancia de la microestructura de la aleación, como Rotella *et al.* [40] que efectúan un análisis de las modificaciones microestructurales producidas cuando se tornea en seco la aleación de Al-Zn UNS A97075-T651 mediante herramientas de carburo recubierto, estudiando en detalle los cambios que sufre la dureza del material si se mecaniza a diferentes velocidades de corte y distintos radios de la herramienta. Concluyen que tanto la velocidad de corte como el radio de la punta de la herramienta afectan a la superficie mecanizada y a la integridad superficial, ya que se observó tanto recristalización dinámica como mayores valores de dureza.

Grum y Kisin [41] realizan estudios sobre lo importante que resulta la microestructura del material para las oscilaciones de la fuerza de corte, al tornear diferentes aleaciones de Al-Si. Obtienen como conclusiones que las aleaciones que compartan parecidas propiedades mecánicas, aunque con diferente estructura granular, tendrán comportamientos distintos en relación a la fuerza de corte en el mecanizado.

Por concluir este apartado, si se desea mejorar el proceso de mecanizado, además de las composiciones químicas de las aleaciones de aluminio, existen otros aspectos que también afectan al resultado final del mecanizado: el tratamiento térmico, la microestructura y la dureza.

2.3.4. Herramientas de corte

La selección de la correcta herramienta de corte es clave para el proceso de mecanizado que debe adecuarse al material que se vaya a mecanizar y a las condiciones concretas de corte y consiste en dos aspectos: su geometría y su material.

La elección adecuada de la geometría y del material de la herramienta son todavía más determinantes para los mecanizados en seco, ya que al no disponerse del efecto del lubricante y del refrigerante de los fluidos de corte, las condiciones de corte son aún más agresivas.

De este modo, los materiales de las herramientas que más se usan para mecanizar aleaciones de aluminio son:

- (I) Los Aceros de Alta Velocidad (HHS o *High Speed Steel*). Usados con eficientes resultados en bastante mecanizados de aleaciones de aluminio, en relación al acabado y a la vida de la herramienta. Debe disponer de un filo permanentemente afilado y la superficie bien pulida con el objetivo de lograr buenos resultados. Como inconveniente, no está recomendado en las aleaciones de aluminio con contenido alto en silicio, como son gran parte de las aleaciones de aluminio fundidas. Al ser tan abrasivo el Si estas herramientas se desgastan rápidamente, acortando bastante su vida y por tanto desaconsejando su uso [13], [7].
- (II) El Diamante Policristalino (PCD o *PolyCrystalline Diamond*). Estas herramientas compuestas de PCD son muy indicadas para mecanizados de aleaciones con gran contenido de silicio. La gran dureza que ofrece les permite soportar el desgaste por abrasión propio de estas aleaciones, y también se suelen usar para mecanizados de las demás aleaciones de aluminio en aquellas aplicaciones en las que se necesiten muy buenos acabados. Tiene un coeficiente de rozamiento bajo que minorra la predisposición a la adhesión, evitando que aparezca BUE, siendo responsable en casi todos los casos en los que aumenta la fuerza de corte, de tal manera que se reduce la calidad de los acabados y se reduce la vida de la herramienta. Como ventaja, destaca que no hay reactividad química entre el diamante y el aluminio, y que una mayor duración de la herramienta compensa el mayor coste de adquisición [13], [7].

(III) Las Herramientas de carburo cementado (WC) con y sin recubrimiento. Las más usadas en mecanizado general. Para mecanizar aleaciones de aluminio permiten emplear velocidades de corte mayores que los HSS, principalmente en aleaciones de Al-Si, y además permite que permanezca el filo más tiempo afilado. Al ser más frágiles que los HSS suelen disponerse con un filo de herramienta mayor y así lograr más robustez, por lo que se usan menores ángulos de desprendimientos que a su vez originan la formación de filo recrecido [13], [7], [30]. Si además se usa con recubrimiento, lo que provoca que empeore conductividad térmica, alcanzando más rápidamente las temperaturas máximas en las zonas de corte, lo que favorece la fusión rápida de la matriz metálica y también el crecimiento del BUL [42], [43]. Últimamente se utilizan herramientas de carburo del tipo cementado recubiertas con una capa fina de diamante o DLC (*Diamond-LikeCarbon*) [44], [43], [45]. Éstas logran mecanizados en aleaciones de aluminio de forja (no aparece BUE) y en aleaciones de fundición con silicio, lográndose muy buenos acabados y vidas de herramientas. De igual modo también se están usando herramientas de cerámica con recubrimiento de diamante [34].

Por otra parte, si analizamos la geometría de la herramienta, puede variar de modo importante dependiendo del tipo de aleación que se mecanice y de los diferentes problemas en su mecanizado. De modo general, es importante un filo muy bien afilado y una superficie lo más pulida posible, con el objetivo de reducir el rozamiento y, de este modo, atenuar el fenómeno de adhesión.

Es recomendable emplear ángulos grandes de desprendimiento para prevenir o al menos retrasar que aparezca filo recrecido, a pesar de que reduzca la robustez del filo. En relación al ángulo de incidencia y para evitar que se debilite el filo, debería ser lo más pequeño posible, hasta un valor mínimo que evite que se produzca el rozamiento de la herramienta con la superficie que se mecaniza.

2.3.5. Condiciones de lubricación

El uso de fluidos de corte adecuados, que ayuden a la evacuación del calor en las zonas de corte y que permitan reducir el rozamiento que se produce entre la viruta y la cara de desprendimiento, favorecen la reducción de fenómenos habituales térmicos en el mecanizado. Nos referimos, por una parte, a que las aleaciones forjadas tienen el problema que se les forme filo recrecido y su adhesión a la herramienta, y por otra, que en las aleaciones de fundición se presenta el inconveniente del desgaste por abrasión causado por las partículas de silicio al deslizarse por la cara de desprendimiento. En el mecanizado de las aleaciones de aluminio se recomienda la utilización de los tipos de

fluidos siguientes [25].

En el caso del mecanizado de las aleaciones de aluminio del tipo forjadas, el aceite soluble mezclado con agua, del 20 % al 30 %, es el que más se utiliza, al ser barato, con buenos niveles de refrigeración y prevenir la aparición de los filos recrecidos. Para aleaciones de alto contenido en Si, se suelen usar los aceites minerales con aditivos ya que se buscan cualidades lubricantes más que refrigerantes [13], [25].

En relación con el cuidado del medioambiente y de la salud laboral y considerando las exigentes normativas al respecto, estos fluidos presentan importantes problemas [46], [47].

Por ello, la industria del mecanizado debe desplegar técnicas que permitan minimizar o incluso eliminar su uso, provocado por los elevados costes del reciclado y de las acciones en materia de prevención de riesgos laborales que se necesitan implantar [48], [49].

Entre las alternativas al uso de los tradicionales fluidos de corte se destaca la técnica llamada “mecanizado en seco” que consiste en un mecanizado realizado en ausencia de fluido de corte, ampliamente usado en el mecanizado de aluminios forjados de gran interés para la industria del sector aeroespacial.

La eliminación completa de los fluidos de corte provoca que las condiciones de corte se vuelvan muy agresivas por la desaparición de las ventajas lubricantes y las refrigerantes de estos fluidos, propiciando que aparezca el ya mencionado filo recrecido, que a su vez provoca un mayor desgaste de la herramienta además de empeorar la calidad y la precisión de las piezas que se obtengan.

Puesto que los resultados que se obtienen mediante las técnicas que buscan reducir la utilización de fluidos de corte (MQL) o eliminarlos (mecanizado en seco, criogénico, refrigeración por aire, ...) no son tan óptimos como los obtenidos usando dichos fluidos de corte, el reto de la tecnología empleada en el mecanizado es fabricar piezas de calidad, en ausencia de fluidos de corte, mediante la mejora de los materiales de las herramientas y de sus recubrimientos además de optimizar las geometrías y los parámetros de corte [50]. Particularmente el mecanizado en seco es de los que peores resultados ofrece, tanto por su acabado como por la temperatura de corte [51].

Por ello, se plantea la necesidad de obtener datos sobre el mecanizado de aleaciones de aluminio para su mecanizado en seco.

2.3.6. Parámetros de corte

Los resultados que se obtienen en el mecanizado, o formulado como los valores de las variables de salida: calidad superficial del acabado, precisión en relación a sus dimensiones, la fuerza, potencia y temperatura de corte, el desgaste y la vida de las herramientas, las vibraciones, ...); son dependientes de manera muy importante de tres de las variables de entrada, llamadas parámetros de corte: velocidad de corte, avance y profundidad de corte.

Según los resultados que se deseen obtener y según otros parámetros (propiedades de los materiales que se vayan a mecanizar, la herramienta usada -material y geometría-, condiciones de lubricación y tipo de operación), se deberán elegir determinados valores para estos parámetros de corte [36], [52].

Por tanto, la optimización de estos parámetros es considerado como uno de los aspectos más importantes en la investigación sobre cómo mejorar los procesos de mecanizado, de modo que se puedan obtener los objetivos deseados para unas condiciones determinadas de mecanizado, siendo esta optimización aún más relevante en los mecanizados en seco.

Se trata a continuación, de analizar los valores que habitualmente se usan para el mecanizado de aleaciones de aluminio forjadas, continuando con el estudio de los criterios de maquinabilidad, prestando especial interés en determinar cómo influyen estos parámetros sobre las variables de salida en las aleaciones de aluminio forjadas de especial interés aeroespacial.

En relación a la velocidad de corte, lo normal es que aplique la mayor posible, para así conseguir la mayor ratio de eliminación de material que sea posible y por tanto lograr incrementar la productividad. Pero, también se debe tener en consideración el incremento del desgaste y por tanto la reducción de la vida útil de la herramienta.

Para las aleaciones de aluminio, dado que su maquinabilidad es muy buena, se pueden elevar las velocidades de corte hasta alcanzar valores bastante altos (900 m/min) no afectando demasiado a la vida de la herramienta. Habitualmente, los límites de la velocidad de corte están limitados por las características de la máquina-herramienta (máxima velocidad de giro, estabilidad, potencia) y por las particularidades del material que se pretenda mecanizar [25], [30].

Los materiales de las herramientas suponen una limitación a la velocidad (si se aumenta la velocidad de corte se incrementa la temperatura de corte que reduce las propiedades mecánicas de los materiales para las herramientas). Pero, en el caso las aleaciones de aluminio, su punto bajo de fusión provoca que las temperaturas altas que se alcancen no sean suficientes para modificar las propiedades de la herramienta, excluyendo a las aleaciones de alto contenido en silicio [33], [53].

De este modo, en mecanizados convencionales de aleaciones de aluminio forjadas se pueden alcanzar hasta los 900 m/min, aunque lo habitual es no superar los 300 m/min [13]. Si nos referimos a las aleaciones de aluminio fundidas, y sobre todo aquellas con alto contenido en silicio, no tratadas térmicamente, utilizando herramientas de carburo metálico, las velocidades se minoran de modo considerable, no recomendándose valores por encima de a 150 m/min (en el caso que se use fluido de corte), y 30 m/min (si se mecaniza en seco). Si se pretende usar velocidades de corte parecidas a las usadas en los mecanizados de aleaciones forjadas se necesitan usar herramientas PCD o carburos recubiertos con una capa fina de diamante [25].

Es importante destacar que, de modo general, al mecanizar aleaciones de aluminio, si se aumenta la velocidad de corte, la fuerza de corte se reduce, no siendo demasiado importante este efecto a partir de 300 m/min.

Es relevante destacar que, al aumentar la velocidad de corte, se incrementa la calidad de las piezas que se obtienen: mejor acabado superficial (a elevadas temperaturas se reduce la posibilidad de formarse BUE) y mejor precisión de las dimensiones de la pieza (se reduce la dilatación térmica de la pieza que se está mecanizando [25], [54].

Puesto que el coeficiente de dilatación del aluminio es alto es necesario que la pieza a mecanizar se mantenga fría (para lograr la precisión en las dimensiones). Y al aumentar la velocidad de corte se ayuda a extraer el calor de la pieza que se mecaniza, al aumentarse el realizado a través de la viruta y la herramienta y al reducirse parte del calor evacuado a través de la pieza.

Por tanto, el MAV, o mecanizado de alta velocidad, es una de las técnicas de mecanizado más usadas la industria aeroespacial y automovilística, en las que se exige elevada calidad y productividad en la fabricación de las piezas requeridas [33], [55], [56].

Destacan como principales ventajas del MAV en relación al mecanizado convencional las siguientes: eliminación de material en ratios elevados; fuerza de corte reducida (apropiado en el mecanizado de aquellas piezas que tengan paredes estrechas); debido a una reducción de la fuerza de corte es posible aumentar los valores de avance mientras aumenta la velocidad de corte, es decir, logra que se eliminen las virutas de tamaño mayores con igual fuerza de corte, aumentando la productividad; no se penaliza en exceso la duración de las herramientas (aunque haya un incremento de la temperatura en las zonas de corte, el aluminio tiene un punto de fusión suficientemente bajo que supone que las temperaturas que se alcancen no sean demasiado altas como para provocar los fenómenos de desgaste que son dependientes de las altas temperaturas (la difusión, la corrosión y la fatiga); y por último, ofrece una calidad de acabado muy buena (el incremento de temperatura en la zona de corte evita que aparezca el BUE).

Como principal inconveniente del MAV tenemos el coste de la máquina-herramienta y el control de vibraciones.

A partir de las conclusiones de Calatoru *et al.* [55] se recomienda utilizar recubrimientos en las herramientas de carburo para su uso en MAV. Estos investigadores pusieron de manifiesto que existe una excepción al criterio general antes citado de que la vida de la herramienta no se ve afectada excesivamente en el MAV.

Concluyen que existe desgaste por difusión en el MAV para la aleación de AL-Zn UNS 97475-T7351 si se utilizan herramientas de carburo (CW-Co) sin recubrimiento, puesto que las temperaturas que se alcanzan ayudan a la reactividad del Cobalto con el Aluminio, originándose un desgaste por difusión, acelerando así que se desgaste la herramienta.

En relación al avance, sucede algo similar a lo que ocurre con la velocidad de corte, es conveniente elegir el valor más alto que sea posible con el objetivo de incrementar la eliminación de material y por tanto la productividad. Pero, es necesario considerar las siguientes limitaciones. Por una parte, se trata del parámetro de corte más influyente en la calidad obtenida del acabado superficial y su incremento está estrechamente unido a la rugosidad superficial que se obtenga. Por otra parte, favorece que aparezca BUL y BUE, repercutiendo por tanto en la calidad deseada. Por último, se destaca que ocasiona un incremento de la fuerza de corte que se necesita, además de las vibraciones. En desbastes se están utilizando valores entre 0,15 y 2 mm/rev, y en acabado valores que van de 0,05 a 0,15 mm/rev [25].

Y en lo referido a la profundidad de corte, si se pretenden igualmente obtener valores altos en relación a la eliminación de material, también debería ser lo más alta posible. Aunque también hay algunas limitaciones: las propiedades mecánicas de las piezas, la generación de vibraciones, la sujeción, el incremento de la fuerza de corte y la potencia necesaria. Es habitual usar valores por debajo de los 6 mm en desbaste, y alrededor a 0,5 mm en el caso de acabados [8], [25].

2.4. Estudio de las variables de salida en el mecanizado de aleaciones de aluminio de uso aeronáutico

2.4.1. Generalidades

La mayoría de los estudios de maquinabilidad de aleaciones de aluminio se centra en criterios como la morfología de la viruta; el desgaste o vida de la herramienta; la fuerza de corte y la calidad superficial. Y, uno de los criterios más generales, la temperatura de corte, no se encuentra, ya que las técnicas y los dispositivos que se requieren para efectuar su evaluación son demasiado complejas de modo que resulta difícil su aplicación en la práctica [57], [58].

Y a pesar de que los criterios citados están interrelacionados, y por tanto se deberían considerar simultáneamente, resulta de tal complejidad que las investigaciones se dirijan a estudiar solo uno o, si se abordan más de uno, no se estudie cómo interactúan entre ellos [59].

En los catálogos y los manuales de los fabricantes es habitual hallar clasificaciones de las aleaciones de aluminio dependiendo de su maquinabilidad, utilizando una letra o número para identificar cada aleación. Suelen ser clasificaciones cualitativas, apoyadas en análisis empíricos, en las que se analiza cómo está dispuesta la viruta y la calidad de acabado, sin analizar cómo se relacionan entre éstas.

De este modo se encuentran clasificaciones como las que aparecen en [25], que asignan una serie de letras desde la A (referidas a una maquinabilidad excelente) hasta la D (maquinabilidad pobre), y números del 1 (maquinabilidad excelente) al 5 (maquinabilidad pobre).

Todas estas clasificaciones coinciden en situar la mejor maquinabilidad para las aleaciones de aluminio que llevan tratamiento térmico y la peor a las endurecidas por deformación.

Por otro lado, cuando se hace referencia a la integridad superficial, se incluyen en ella, propiedades ligadas directamente a la geometría y la precisión dimensional (desviaciones geométricas) junto a otras como la vida a fatiga, la resistencia a la corrosión, la aparición de tensiones residuales o la microdureza superficial entre otras.

Por tanto, se considera que este conjunto de propiedades no deben evaluarse únicamente considerando las variables de entrada en las operaciones de conformado, sino que las variables de salida (propiedades micro y macrogeométricas, así como las físico-químicas) también pueden influir en el resto de variables de salida.

En el desarrollo de este Trabajo Fin de Grado, se evaluará la integridad superficial a partir de las propiedades geométricas y la microdureza superficial (físico-química), de forma que se pueda identificar el nivel de influencia de algunas propiedades sobre otras (variables de salida), además de la influencia de las condiciones establecidas en el proceso de mecanizado en seco (variables de entrada).

2.4.2. Desgaste y vida de la herramienta

Es evidente que uno de los aspectos más relevantes desde un punto de vista de análisis de costes de los procesos de mecanizado es la vida de las herramientas, relacionada directamente con su desgaste, ya que supone un aumento directo del coste del proceso, al ser necesaria su reposición o reafilado y también por el incremento del consumo de energía, afectando además de forma negativa en la calidad de las piezas.

Los factores de los que depende el desgaste son fundamentalmente: el material que se mecaniza, la herramienta de corte (tanto su material y la geometría), la lubricación y los parámetros de corte. Son similares a los determinados en la maquinabilidad de la aleación y por tanto el desgaste o vida útil de la herramienta se utiliza normalmente como criterio de maquinabilidad para las aleaciones metálicas. Tiene un importante inconveniente: medirlo supone una importante dificultad técnica, además del coste y el tiempo que se requiere.

Es por tanto muy importante saber los mecanismos que lo provocan y la zona de la herramienta donde se origina, siendo de especial importancia para los mecanizados en seco [60]. Estudiar los parámetros que influyen sobre estos aspectos permitiría optimizar estos procesos de corte.

En el mecanizado de las aleaciones de aluminio, salvo las que tienen gran contenido en silicio, la duración de la herramienta de corte es adecuada [30], ya que la temperatura que se alcanza en la zona de corte no es demasiado alta por el bajo punto de fusión de este tipo de aleaciones. Aunque se manifiestan otros problemas relacionados con el desgaste y la duración de la herramienta. Los mecanismos de desgaste más habituales son la adhesión y la abrasión [25]. Sólo para MAV, y provocado por las temperaturas alcanzadas tan altas, hay documentados situaciones de desgaste por difusión [55]. El más habitual es el desgaste por adhesión, salvo para las aleaciones de aluminio fundidas con gran contenido en silicio, donde predomina el desgaste por abrasión [8], [25], [30]. En estos casos, tanto el desgaste como la duración de la herramienta se convierten en factores críticos, recomendándose usar herramientas con gran resistencia a la abrasión y al desgaste, como PCD o herramientas de carburo recubiertas de diamante.

Yoshikawa y Nishiyama [61] pusieron de manifiesto lo importante del contenido y tamaño de grano de Si de la aleación A390-T6 con alto contenido en silicio (18 % Si), mediante un estudio del mecanismo por el que se produce el desgaste en las herramientas de carburo cementado recubiertas de diamante en el mecanizado de dicha aleación. De este modo, concluyen que en las aleaciones con grandes de granos de Si, al impactar éstos con la cara de incidencia de las herramientas, este desgaste en incidencia determinará la duración de las herramientas. Este impacto causa de inicio que se pierdan granos en recubrimiento de diamante de las herramientas, continuando con la llegada de grietas, terminando con la eliminación de la capa completa de recubrimiento y agravándose en situaciones de falta de lubricación.

Para lograr mecanizados exitosos de las aleaciones Al-Si, especialmente para el mecanizado en seco, las claves residen en la reducción del desgaste y el aumento de la vida de las herramientas. Por tanto, la mayor parte de las investigaciones en este ámbito pretenden mejorar las propiedades de los materiales de las herramientas y sus recubrimientos [62], [63], mediante una mayor resistencia al proceso de desgaste por abrasión y disponiendo de superficies pulidas y así rebajar los coeficientes de rozamiento [64], o trabajando en la utilización de aleantes (*“free machining elements”*) que funcionen como lubricantes internos de las aleaciones [65].

Para las aleaciones de aluminio forjadas, de interés en el ámbito aeroespacial, el mecanismo que predomina es el desgaste por adhesión [26], [27], [55], [60], [66], [67], [68], actuando además en rangos de temperaturas muy extensos [52]. Se trata de un desgaste en el que las altas temperaturas y presiones actuantes sobre el material que se desea mecanizar (la aleación de aluminio) y la herramienta, provocando que el material (que tiene un punto de fusión menor), se funda, incorporándose a la herramienta (adhesión indirecta causado por fenómenos termomecánicos). La incorporación del material se




Figura 2.3: Mecanismo de adhesión secundaria en la cara de desprendimiento de la herramienta (BUL y BUE) (adaptada de <https://www.iscar.com>).

produce en dos regiones de la herramienta: en el filo, originando el conocido como filo recrecido (BUE o *Built-Up Edge*); y en la cara de desprendimiento, originando la llamada capa adherida (BUL o *Built-Up Layer*).

Antes se consideraba desgaste sólo las alteraciones de las herramientas por pérdida de material, pero actualmente se tienen en cuenta todo tipo de alteración tanto material como geométrica, así que la adhesión indirecta también debe considerarse.

También se debe mencionar que las presiones elevadas originan microsoldaduras del material que se adhiere y el material de las herramientas, y dada la inestabilidad del BUE, éste se desprende fácilmente, causando pérdida de material de las herramientas en su desprendimiento, fenómeno llamado desgaste por adhesión de tipo directo.

A temperaturas bajas predomina el desgaste por adhesión indirecto (por un punto de fusión menor de la aleación que se mecaniza), mientras que a temperaturas altas lo hace el desgaste por adhesión tipo primaria (al aumentar la temperatura van perdiéndose las propiedades del material de la herramienta que es más duro).

La aparición de la capa adherida, BUL, suele asociarse a propiedades mecánicas y térmicas del material que se mecaniza, y la aparición del filo recrecido, BUE suele relacionarse con motivos mecánicos (entre la superficie de contacto de viruta con herramienta surgen fuerzas de adhesión) [69], [70].

Hay bastante discusión sobre la forma en la que tienen su origen y qué fenómenos lo desencadenan el BUL y el BUE en las aleaciones de aluminio, [71], [72].

Carrilero *et al.* [27] concluyen es un estudio que los mecanismos que dan lugar a la aparición de BUE y BUL son diferentes en el mecanizado en seco de la aleación de Al-Cu UNS A92024, usando herramientas de WC-Co recubiertas de TiN. Mediante diferentes ensayos a velocidades de corte situados entre los 40 y los 170 m/min y aplicando avances desde 0,05 a 0,3 mm/rev, y con una profundidad de corte constante en 2 mm., repetidos

para tiempos de corte de 1 s y 10 s; usando técnicas de microscopía electrónica, se mide el espesor de la capa de material adherido en las cercanías del filo y en la cara de desprendimiento de la herramienta. Los resultados manifiestan diferencias de espesores del material adherido para los ensayos de 10 s respecto a los de 1 s de duración.

En los 10 s aparece una multicapa de material que se extiende desde el filo por la cara de desprendimiento de la herramienta. No hay una reducción progresiva de espesor, pero sí una reducción del BUE a medida que se aumenta la velocidad de corte. En cambio, en los ensayos de 1 s, la capa de material adherido extendida desde el filo a la cara de desprendimiento mantiene un espesor bastante uniforme; repitiéndose los resultados en las diferentes combinaciones de avances y velocidades del ensayo. También estudian cómo está compuesto el material adherido, hallándose diferencias dependiendo la zona estudiada en la herramienta y la duración de los ensayos. Al inicio del corte la subida rápida de temperatura provoca la fundición de la matriz de aluminio del material que se mecaniza, que se une al filo y a la cara de desprendimiento de las herramientas, apareciendo el BUL casi inmediatamente causado por un fenómeno termomecánico. Ya desarrollado el BUL, el Al que se ha acumulado provoca un aumento de la conductividad térmica en la herramienta y una reducción de la dureza en las zonas de corte, originando a su vez que se reduzca la temperatura de corte respecto al inicial no alcanzándose la temperatura de fusión del Al. En dicho momento se inicia la formación del BUE, en una composición cercana a la de la aleación, formándose por tanto mediante un mecanismo de tipo mecánico.

List *et al.* [66] realizaron análisis de los mecanismos de desgaste al mecanizar en seco la aleación Al-Cu UNS A92024, mediante herramientas WC-Co sin recubrimiento, llegando a la conclusión de dichos mecanismos son diferentes según el rango de velocidad de corte utilizada, en contraposición a lo recogido en [27]. Concluyen que, a baja velocidad de corte, prevalecen efectos mecánicos (aparición de BUE), y a velocidades altas imperan efectos termomecánicos (formación de BUL y reducción de BUE), y simultáneamente se produce desgaste por difusión.

Sánchez *et al.* [26] estudiaron mecanismos por los cuales se forman BUL y BUE en el mecanizado en seco de aleaciones del tipo Al-Cu UNS A92024 y Al-Zn UNS A97050. En los ensayos cortos ($t < 10$ s) hay coincidencia con lo recogido por [27] y para los de $t > 10$ s, se muestran cambios en la morfología del material que se adhiere a las herramientas. No existiendo diferencias en el espesor entre los materiales adherido junto al filo y los adheridos en la cara de desprendimiento (BUL y BUE tienen igual espesor).

Gómez Parra *et al.* [73] analizan cuales son los mecanismos para la formación de BUL y BUE además de cómo influyen en la calidad del acabado superficial en el mecanizado en seco de aleaciones UNS A92024 y UNS A97050. Coinciden con [26], [27]

indicando que primero se origina la formación de BUL por fenómenos termomecánicos, de composición cercana al Al puro, para luego formarse el BUE, de composición cercana a la aleación que se mecaniza, por motivos mecánicos, detectándose también un segundo BUL consecuencia de la extrusión del BUE.

Estos autores también analizan cómo influyen los parámetros de corte en la aparición de BUL y BUE, concluyendo que la intensidad de dichos fenómenos crece al crecer el avance.

Además, encuentran la relación entre cómo evoluciona el BUL y el BUE y cómo varía la calidad superficial durante todo el mecanizado (evaluación realizada mediante R_a), detectándose reducciones en R_a en los periodos en los que aumenta el espesor de BUE, causando que se reduzca el ángulo de posición del filo de las herramientas dando lugar a que se reduzca R_a .

Gökkaya [68] estudia evolución de BUE en los mecanizados en seco de las aleaciones Al-Cu UNS A92014-T4, utilizando herramientas tipo carburo metálico sin recubrir. Su conclusión mantiene que al aumentar las velocidades de corte se reduce la aparición de BUE, por las altas temperaturas que se generan, y por tanto recomiendan usar velocidades más altas, del orden de 500 m/min para prevenir que aparezca filo recrecido y de este modo lograr el mejor acabado superficial.

2.4.3. Fuerza de corte

La maquinabilidad y la fuerza de corte se encuentran estrechamente vinculadas, por ello se ha convertido en un criterio de maquinabilidad muy usado en los mecanizados de aleaciones metálicas y, en consecuencia, para las aleaciones de aluminio. Para simplificar los estudios, se suelen fijar determinados parámetros de entrada (herramienta de corte empleada, materiales a mecanizar y condiciones de lubricación). Por tanto, el análisis de la fuerza de corte como criterio de maquinabilidad se centra en el análisis de como influyen los parámetros de corte: avance, profundidad de corte y velocidad de corte.

Las aleaciones de aluminio generalmente se mecanizan aplicando fuerzas de corte relativamente pequeñas, comparándolo con otras aleaciones metálicas, teniendo en cuenta las buenas propiedades mecánicas que poseen estas aleaciones. De este modo, para las aleaciones de aluminio, que tengan propiedades mecánicas parecidas a las de determinados aceros, se necesita un 35 % de la fuerza de corte que se necesite para el mecanizado de estos aceros, permitiendo aplicar niveles de eliminación de material mayores para una de fuerza de corte similar [25], [30].

En el proceso de mecanizado de la mayor parte de las aleaciones de aluminio, cuando la velocidad de corte es más baja, es cuando se alcanzan los valores más altos de la

fuerza de corte, mostrando una tendencia a que la fuerza de corte decrezca si se aumenta la velocidad [8], [25], [30]. Y habitualmente, se conoce como límite entre el mecanizado convencional y el MAV, o mecanizado de alta velocidad, a la situación en la que la fuerza de corte ya no se reduce si se aumenta la velocidad de corte [8].

En relación a la profundidad de corte y al avance, ambas están estrechamente vinculadas a la sección de la viruta y, consecuentemente, con la cantidad de material eliminado. Por tanto, al aumentar la profundidad de corte se producen incrementos en la fuerza de corte [25].

Por otra parte, si se aumenta el avance se incrementan las fuerzas de corte, en mayor magnitud que si nos referimos al aumento derivado de incrementos de la velocidad de corte [74], [75], [76], [77], [78].

Carrilero *et al.* [75], [76] estudian cómo evoluciona la fuerza de corte en función de la velocidad de corte y el avance, en el mecanizado en seco de las aleaciones de AlCu UNS A92024-T351, de interés aeroespacial, utilizando herramientas de WC-Co recubiertas de TiN. Como resultado de estos estudios se concluye que el avance es el parámetro más influyente sobre la fuerza de corte, recomendando la utilización de velocidades de corte altas y avances bajos.

En [76] también se estudia la calidad del acabado superficial, mediante la rugosidad aritmética media (R_a), en función del avance y de la velocidad de corte, mostrando resultados con tendencias muy similares a las que se obtiene para la fuerza de corte. Esta conclusión aconseja encontrar una correlación entre R_a y F_c , y por consiguiente usar la calidad del acabado como criterio de maquinabilidad, calculando su valor mediante la fuerza de corte que es más fácil de medir.

En este sentido, estos autores [77] ofrecen un modelo paramétrico para la fuerza de corte y R_a de tipo potencial

$$\begin{cases} F_c = C_1 v_c^n f^m, \\ R_a = C_2 v_c^x f^y. \end{cases} \quad (2.1)$$

Considerando v_c como la velocidad de corte, f como el avance, y n , m , x , y , C_1 y C_2 como constantes.

Y un modelo paramétrico de tipo potencial que relaciona la fuerza de corte con R_a , del siguiente modo,

$$R_a = C_3 F_c^b, \quad (2.2)$$

siendo C_3 y b constantes.

Sebastián *et al.* [74], y Salguero *et al.* [78], también ofrecen modelos como los expresados en el par de ecuaciones de (2.3), pero obteniendo valores, realizando el ajuste por regresión lineal múltiple de los valores obtenidos experimentalmente, para los exponentes y para las constantes, en escala log-log,

$$\begin{cases} F_c = 2,96v_c^{-0,14} f^{0,78}, \\ R_a = 7,60v_c^{-4} F_c^{1,55}. \end{cases} \quad (2.3)$$

Gökkaya [68] hace un análisis de cómo evoluciona la fuerza de corte dependiendo de la velocidad de corte y del avance, en el mecanizado en seco de la aleación de Al-Cu UNS A92014-T4, usando herramientas de WC-Co sin recubrimiento. Obtienen resultados mostrando que los valores de la fuerza de corte más altos se logran con avances de 0,3 mm/rev, reduciéndose la fuerza de corte al disminuir el avance. En relación a la velocidad de corte, la influencia es menor que lo que ocurre con el avance, mostrando una reducción suave y progresiva de la fuerza de corte al aumentar la velocidad de corte.

Mabrouki *et al.* [79] realizaron un estudio parecido para el mecanizado en seco de la aleación UNS A92024-T351, con herramientas de carburo sin recubrimiento, velocidades de corte desde 200 a 800 m/min y avances desde 0,3 mm/rev a 0,5 mm/rev, y usando modelos de predicción basados en el Método de Elementos Finitos, comparando resultados entre los valores de la simulación y los obtenidos de modo experimental, hallándose similitudes entre ambos.

En general se puede concluir que la fuerza de corte en los mecanizados de aleaciones de Aluminio presenta comportamientos dependientes casi siempre de las condiciones de corte impuestas. Teniendo el avance mayor influencia que la velocidad de corte, y por tanto recomendándose utilizar velocidades de corte altas y avances bajos con el objeto de obtener las fuerzas de corte menores que sean posibles.

2.4.4. Integridad Superficial

Como ya se ha comentado, el acabado superficial repercute de modo muy importante en las características en servicio de las piezas que hayan mecanizado y en su aspecto final [80], [81].

Por otra parte, las operaciones de mecanizado producen una modificación superficial de las piezas por cambios en las propiedades mecánicas y metalúrgicas de las piezas que se mecanizan [82]. Por tanto, el estado final de la superficie que se mecaniza dependerá de numerosos factores interrelacionados entre sí, afectando además al rendimiento funcional de las piezas.

Griffiths [83] recoge hasta cinco mecanismos en los mecanizados: los mecánicos, los químicos, los mecánico-térmicos, los térmicos y los termo-mecánicos. Alguno de dichos mecanismos aparecen en todos los mecanizados, generando superficies características (cambiando la integridad superficial), que obedecen a las condiciones que se hayan aplicado en el proceso [84], [85], [86].

Normalmente, los estudios relacionados con los mecanizados que afectan a la integridad de la pieza, se orientan hacia la observación de cómo influyen las variables de entrada en los mecanizados (parámetros de corte, características de herramientas de corte), o también según las condiciones de la lubricación o la refrigeración, indistintamente de los materiales que sean objeto de mecanización [87], [88], [89], [90].

Así, se estudiará cómo el mecanizado es capaz de afectar a propiedades de la integridad superficial (macrogeométricas, microgeométricas y físico-químicas) en las piezas mecanizadas.

Con este objetivo, para continuar, se realizarán evaluaciones de distintos estudios que se han llevado a cabo sobre los procesos de mecanizado para aleaciones de aluminio de uso aeronáutico, sobre todo, para los que se haya comprobado una alteración de las distintas propiedades que puedan afectar a la integridad superficial.

2.4.4.1. Desviaciones microgeométricas

Siendo la calidad del acabado superficial (medida en función de R_a) uno de los criterios más usados de la integridad superficial (propiedades microgeométricas) en el mecanizado de las aleaciones metálicas [91]; para las aleaciones de aluminio, puede estudiarse evaluando cómo los parámetros de corte influyen sobre R_a , y en estos casos el avance es el parámetro de corte con una influencia mayor.

En [92] se estudia cómo influyen los parámetros de corte en R_a para los casos de mecanizado en seco de las aleaciones de aluminio y cobre, concluyendo que, en los casos de profundidad de corte lo suficientemente importantes, R_a se comporta proporcional al avance, obteniéndose una rugosidad específica de comportamiento periódico con longitud de onda igual al avance.

Carrilero *et al.*, en [76], analizan cómo evoluciona R_a según el avance y la velocidad de corte, en los torneados en seco de la aleación de Al-Cu UNS A92024 y tratamiento térmico T351, usando herramientas metálicas duras con recubrimiento. Analizando los valores que se obtienen para R_a , demuestran que el avance es el parámetro de corte con mayor influencia, al igual que [92], siendo la velocidad de corte un parámetro con mucha menor influencia.

Por otra parte, en [77], sujeto a condiciones idénticas a las de [76] y con la misma aleación, analiza la evolución de R_a dependiendo de la velocidad de corte y del avance, obteniéndose resultados similares a [76]. Por otra parte, proponen algunos modelos paramétricos de tipo potencial que permiten evaluar R_a en función del avance y de la velocidad de corte,

$$R_a \propto v_c^n, \quad R_a \propto f^m, \quad (2.4)$$

siendo n , valor dependiente del avance y m , valor dependiente de la velocidad de corte. Proponiendo el modelo tipo potencial siguiente

$$R_a \propto v_c^n f^m, \quad (2.5)$$

siendo n y m constantes. Por otra parte, ofrecen un modelo paramétrico para evaluar R_a en función de la fuerza de corte como el recogido en [2.2]

Sebastián *et al.* [74] y Salguero *et al.* [78] también trabajan, en las mismas condiciones que se exponen en [76] y [77], la aleación UNS A92024, y coinciden en las conclusiones obtenidas en [77], y proponen el siguiente modelo potencial

$$R_a = Cv_c^x f^y. \quad (2.6)$$

Los valores obtenidos en los exponentes demuestran la existencia de una gran dependencia de R_a respecto del avance y menor respecto de la velocidad de corte. En cambio, obtienen, para el exponente de la velocidad de corte, un valor positivo, mostrando el aumento de R_a con la velocidad de corte, que no es lo habitual en el torneado de las aleaciones metálicas. Por otra parte, también logran los exponentes en la ecuación paramétrica (2.2), que permite relacionar la fuerza de corte con R_a , de igual modo a lo expuesto en (2.3).

Sebastián *et al.* [93] en su estudio, de la misma aleación y condiciones, añade el análisis de la evolución de R_z (referida a la altura máxima del perfil de rugosidad), obteniendo como resultado que, en términos generales, el factor más influyente sobre R_a y R_z es el avance. Además, logran modelos paramétricos potenciales para R_a y R_z , parecidos a lo recogido en (2.6).

Otro de los aspectos influyentes en el acabado en estas aleaciones es la aparición de BUE. En términos generales, en los procesos de mecanizado de las aleaciones metálicas, la aparición de BUE está asociada a malos acabados superficiales, pero en el caso mecanizado de aleaciones de aluminio forjadas la aparición de BUE, en ciertas circunstancias, genera una mejora de R_a .

De este modo, Rubio *et al.* [94] realizan ensayos para la aleación UNS A97050 de torneado en seco, usando herramientas WC-Co y con recubrimiento de TiN, con velocidades de corte desde 43 a 170 m/min, avances de 0,05 a 0,03 mm/rev y profundidad constante de corte en 2 mm; y ensayos para una longitud de mecanizado de 175 mm. Muestran como resultados que el parámetro que más influye sobre R_a es el avance, de modo que aumenta R_a al aumentar el avance, obteniéndose también los peores resultados para R_a al tomar el valor de 0,3 mm/rev.

Así, todo cambio en la geometría de las herramientas que influya en el ángulo de posición principal κ_r provocará cambios en R_a . En este análisis, los resultados que se obtienen para la aleación UNS A97050 se comparan con los logrados para la aleación UNS A92024, hallándose preferencias de $R_a = f(L)$ parecidas, pero los valores absolutos de R_a son mayores para la aleación UNS A97050 (debido a una formación mayor de BUE en el mecanizado de UNS A92024 favoreciendo así la reducción de R_a).

También se estudia la morfología de la viruta, hallándose que en avances bajos se obtienen virutas más largas y flexibles, con mayor propensión al enredo y a la formación de nidos de viruta, incrementándose la posibilidad de deteriorarse la superficie mecanizada. Y en avances altos, la viruta es más dura y dura, que desde el punto de vista de la integridad de la pieza es más conveniente.

Gómez Parra *et al.* [73] llevó a cabo un trabajo similar para las aleaciones UNS A92024 y UNS A97050, con profundidades de corte de 1 mm y tiempos de mecanizado constantes de 120 s. Se obtienen resultados como los detallados en [94], lo que implica una independencia de $R_a = f(L)$ en relación a la profundidad de corte.

Por otra parte, Rashad y El-Hossainy [38] estudian el comportamiento de R_a dependiendo de los parámetros de corte, en el torneado en seco de las aleaciones UNS A97116, para distintos tratamientos térmicos y herramientas de HSS. Los resultados que se obtienen señalan una evidente dependencia de R_a frente al avance, tendiendo a crecer R_a con el avance.

Por otra parte, la dependencia es menor con la velocidad de corte. También hay una gran dependencia respecto a la profundidad de corte, aumentando R_a con la profundidad de corte.

Por último, concluyen que los resultados peores de R_a se consiguen en las aleaciones que no han recibido tratamiento térmico, y los mejores cuando poseen tratamientos térmicos que dan mayor dureza a la pieza. Por tanto, el mejor comportamiento para esta propiedad geométrica, se consigue en el torneado de la aleación UNS A97116 con tratamiento térmico T9, eligiendo el avance y la profundidad menor posible, y la mayor velocidad de corte.

En el estudio realizado en [68] se analiza la evolución de R_a con los parámetros de corte, en el mecanizado en seco de las aleaciones UNS A92014 con T4, usando herramientas WC-Co sin recubrimiento. Se obtienen resultados que muestran una gran dependencia de R_a con el avance, incrementándose R_a al aumentar el avance. En relación a la velocidad de corte, hay una menor dependencia y se muestra una evolución casi constante. Sólo hay un leve incremento de R_a cuando se pasa de 200 a 300 m/min y un leve descenso cuando se pasa de 300 a 500 m/min, y se consiguen los resultados óptimos a 500 m/min.

El autor concluye que los mejores resultados se alcanzan para avances bajos y velocidades de corte altas.

Finalmente, la mayoría de los estudios, están de acuerdo en que el factor definitivo en el resultado de R_a es el avance. Al incrementarse el avance se comprueba que R_a empeora. En cuanto a la velocidad de corte, en términos generales se recomienda utilizar velocidades de corte altas para conseguir mejores valores de R_a .

En lo que respecta a la aparición de BUE y sus consecuencias sobre R_a , se puede afirmar que, en general, se logran valores más bajos de R_a cuando no hay BUE. Y también se puede afirmar que, en términos generales, las propiedades geométricas mejoran si se reduce el avance y se aumenta la velocidad de corte.

2.4.4.2. Desviaciones macrogeométricas

Lo habitual es que los requisitos que se imponen a las piezas torneadas estén relacionados con el acabado a nivel microgeométrico mediante la exigencia de obtener valores máximos de R_a . Aunque los requisitos de nivel macrogeométrico (requisitos de forma), también son importantes, ya que afectan directamente a la funcionalidad. Por otra parte, al igual que con la rugosidad superficial, lo mecanizados en seco también causan desviaciones mayores de la forma, lo que afecta a la calidad de la pieza. Pero, hay pocos estudios que usen las desviaciones en la forma (rectitud, redondez, paralelismo...) como criterio dentro de la integridad superficial en las aleaciones de aluminio forjadas usadas en la industria aeroespacial.

Marcos *et al.* [95] hacen un estudio de cómo evoluciona la redondez, dependiendo de la velocidad de corte y del avance, en el torneado en seco de aleaciones tipo Al-Cu UNS A92024-T74511, con herramientas WC-Co y recubrimiento de TiN. Hicieron varios ensayos con velocidades de corte desde 43 a 170 m/min, avances desde 0,05 a 0,3 mm/rev y una profundidad constante de corte fijada en 2 mm. Los resultados muestran que para valores de avance altos, 0,3 mm/rev, y valores de corte bajos, entre 43 y 85 m/min, se obtienen las más importantes desviaciones. Y para velocidades de corte de 85 a 170 m/min, los resultados que se obtienen se igualan en todos los avances aplicados. De este modo, recomiendan usar velocidades de corte altas y avances bajos para alcanzar las más pequeñas desviaciones de redondez, que coincide con el criterio general a proceder en las desviaciones microgeométricas.

Los resultados proponen buscar un modelo paramétrico, que logre prever las desviaciones de redondez dependiendo de los parámetros de corte, de tipo potencial y que se basen en la ecuación de Taylor, a lo que hay que reseñar que muchos autores no hallan un buen ajuste entre modelo potencial y resultados experimentales.

Por esta causa, se busca otro modelo, de tipo exponencial,

$$\text{RON} = C e^{\sum_{i=1}^2 \sum_{j=1}^2 K_{ij} f^i v_c^{yj}}, \quad (2.7)$$

siendo RON las desviaciones de redondez, f el avance, v_c la velocidad de corte y K_{ij} , C e y constantes.

Sánchez Sola *et al.* [96] hacen un estudio parecido, sobre las desviaciones de oscilación radial que se producen en el torneado en seco de la aleación Al-Zn UNS A97050 y T74511, utilizando herramientas WC-Co y recubrimiento TiN. Los resultados que se obtienen muestran tendencia para la redondez similares a [95], lográndose las desviaciones más pequeñas para avances más bajos y velocidades de corte más altas. También obtienen un modelo paramétrico exponencial, parecido a (2.7),

$$\text{CRO} = C e^{\sum_{i=1}^2 \sum_{j=1}^2 K_{ij} f^i v_c^{yj}}, \quad (2.8)$$

siendo CRO las desviaciones de oscilación radial, f el avance, v_c velocidad de corte y C e y constantes.

Sánchez Sola *et al.* [97] estudiaron las desviaciones de forma (rectitud, redondez y paralelismo) en el torneado en seco de la aleación UNS A92024 con T3, usando herramientas WC-Co con TiN. En relación a la redondez, se logran los mejores resultados para avances pequeños, y velocidades de corte altas, concordando con [95], [96], y mostrando una tendencia al aumento de las desviaciones cuando se aumenta el avance y se reduce la velocidad de corte. También se comprueban mayores diferencias en las desviaciones cuando se varían las velocidades de corte en avances bajos, existiendo una tendencia a converger en avances altos, cuando varía la velocidad de corte.

Sobre las desviaciones de la rectitud y el paralelismo, se comporta de modo diferente a la redondez, las desviaciones menores se logran, resultando bastante curioso, para los avances más altos y las velocidades de corte más altas.

De los ensayos realizados por estos autores se infiere que para velocidades de corte bajas las desviaciones de forma crecen al aumentar el avance, coincidiendo con lo recogido en relación a la redondez, la oscilación radial y la rugosidad superficial. Pero en los casos de velocidades de corte mayor, las desviaciones tienden a decrecer cuando aumenta el avance. Y por otra parte, a avances bajos las desviaciones convergen, y al aumentar el avance, las desviaciones presentan una mayor divergencia.

Justifican esta falta de coincidencia en las tendencias de las desviaciones macrogeométricas por la forma que se miden estas desviaciones: la rectitud y el paralelismo se miden siguiendo una dirección longitudinal, y como consecuencia si aumenta R_a (aumenta el avance) habrá un aumento de las desviaciones de rectitud y paralelismo; por otra parte, la redondez y la oscilación radial no son medidas en dirección longitudinal, no estando por tanto afectadas por las modificaciones geométricas de las herramientas.

Consiguen modelos paramétricos exponenciales como los recogidos en (2.7) y (2.8),

$$DF = C e^{\sum_{i=1}^2 \sum_{j=1}^2 K_{ij} f^i v_c^{yj}}, \quad (2.9)$$

siendo DF las desviaciones de forma; RON, la redondez; STR, la rectitud; PAR, el paralelismo; f avance, v_c velocidad de corte y C e y constantes.

En [21] se realiza un estudio paramétrico de las desviaciones de forma (rectitud, redondez, paralelismo y oscilación radial) durante el mecanizado en seco de las aleaciones UNS A92024 y A97050, usando herramientas de carburo con recubrimiento, obteniéndose resultados coincidentes con [95], [96], [97].

También lleva a cabo una comparativa entre resultados obtenidos en UNS A92024 y en UNS A97050. Tanto la redondez como la oscilación radial presentan tendencias similares para las dos aleaciones, aunque la UNS A97050 muestra un intervalo de variación más pequeño que para la UNS A92024. Pero la rectitud y paralelismo parecen tener un comportamiento distinto, mostrando tendencias distintas con el avance en función de la velocidad de corte usada, no existiendo un dominio evidente del avance y se debe tener en cuenta en combinación con la velocidad de corte.

2.4.4.3. Propiedades físico-químicas

Aunque las propiedades mecánicas son importantes en la funcionalidad de los elementos estructurales en las aeronaves, hay pocos estudios de cómo influyen los parámetros de corte en estas propiedades, comparándolo con las características de la calidad relacionadas con la geometría, sobre todo en los casos concretos del mecanizado en seco de la aleación UNS A97075.

Pero últimamente ha aumentado la importancia de estos estudios tanto a nivel de la capa superficial como debajo de la capa superficial primera, puesto que puede influir en las condiciones de servicio de la pieza mecanizada [98].

Los procesos de mecanizado modifican normalmente los estados metalúrgicos del material de la pieza, y además pueden afectar de modo negativo al rendimiento funcional de las piezas ya mecanizadas, e incluso pueden afectar en ciertas condiciones al comportamiento en servicio de las mismas, reduciendo por tanto su fiabilidad.

Ya que las condiciones del mecanizado repercuten en las características de la capa existente bajo la superficie primera, se necesita estudiar para optimizar los procesos de mecanizado además de mejorar la funcionalidad de la pieza, de modo que se reduzcan los posibles fallos imprevistos [99], [100].

Ahora se realiza una revisión de la bibliografía sobre los estudios existentes analizando cómo influyen distintas variables de los procesos de mecanizado en las propiedades físico-químicas y mecánicas de su superficie, al mecanizar estas aleaciones, en concreto sobre la microdureza superficial frente a otros como las tensiones residuales, la resistencia a tracción o el comportamiento a fatiga.

Se conoce que los mecanizados conllevan modificaciones en la capa superficial, cambiando su microestructura sobre todo por el efecto de las altas temperaturas y por las acciones de tipo mecánico debido a la modificación de la geometría de las piezas [101].

De este modo, los procesos de conformado cambian la microdureza superficial en las aleaciones de aluminio, ya sea por la deformación plástica que tiene lugar en la superficie después del mecanizado, o por la modificación del tamaño de grano o porque aparezcan nuevos cristales causado por acciones térmicas [102], [103].

La microdureza superficial de componentes estructurales es de interés en el sector aeronáutico ya que para asegurar la idoneidad portante de los elementos estructurales durante más tiempo se requiere una resistencia alta al desgaste [8].

Las condiciones de corte en los mecanizados tienen gran importancia tanto sobre aspectos térmicos del proceso, como por las acciones mecánicas durante la eliminación de material, sobre todo en las condiciones del mecanizado en seco [104], [105].

Queda patente por tanto que las condiciones de mecanizado afectan a las condiciones superficiales de las piezas mecanizadas por los efectos termomecánicos causados en el corte, y por tanto se justifica plenamente la necesidad de estudiar la microdureza superficial.

En relación a la aleación de aluminio UNS A96062, Kurkute y Chavan [106] realizaron ensayos con distintos avances y velocidades de corte, aplicando diferentes fuerzas durante los torneados y diversas número de pasadas aplicadas, con el objetivo de conseguir condiciones de mecanizado óptimas para una rugosidad superficial (R_a) baja y una microdureza superficial (HV) elevada. Se utilizaron velocidades de corte con valores

entre 10 y 50 m/min, y avances con valores entre 0.40 y 0.80 mm/rev, y se obtuvieron valores óptimos en velocidad de avance con valor intermedio (0.50 mm/rev) y velocidades de corte altas (80 m/min). También se establece un modelo potencial relacionando la microdureza y el avance, la velocidad de corte, la fuerza aplicada y el número de pasadas.

Respecto a la aleación UNS A96061, Akkurt [107] le aplica distintos mecanizados no convencionales y otros convencionales, considerando operaciones de fresado. En su análisis observa que en todos los mecanizados ensayados, la microdureza disminuye en la capa más superficial de la pieza mecanizada respecto al material de partida. Dicha reducción queda justificada por el proceso térmico ligado al mecanizado, puesto que éste efecto es más importante en las superficies con más irregularidades, y en consecuencia, menor microdureza superficial.

Para la aleación UNS A97075 y en relación a cómo influyen los parámetros de corte en la microdureza de piezas mecanizadas, Surya y Viswanath en [108] realizan distintas pruebas mecanizando en seco, realizando modificaciones de la velocidad de corte (50, 100, 200 y 300 m/min) y las profundidades de corte (0.3, 0.6 y 0.9 mm), y fijando el avance (0.05 mm/rev). En sus resultados se observa que al aumentar la velocidad de corte se reduce la microdureza superficial, y al aumentar la profundidad de corte también se reduce la microdureza, pero con una influencia inferior que para el caso de la velocidad de corte, que lo atribuyen a la generación y la disipación de calor en la superficie mecanizada.

Rotella *et al.* [40] evaluaron la profundidad alcanzada por la modificación de la microestructura partiendo de la microdureza superficial. Realizaron ensayos de dureza logrando distintas profundidades de la capa superficial (hasta de 500 μm), y observaron cómo baja la microdureza hasta que se estabiliza en los casos de mayores profundidades. También ensayaron torneados en seco de la aleación UNS A97075-T651, teniendo como variables de entrada: velocidad de corte (180, 320 y 720 m/min) y radio de la punta de la herramienta (0.4, 0.8 y 1.2 mm). Obtienen resultados demostrando que los incrementos en las velocidades de corte provocan una modificación mayor en la microestructura superficial de las piezas mecanizadas que a velocidades de corte bajas, y que las herramientas de corte con mayor radio de punta también provoca una reducción mayor del tamaño de grano al aumentar la superficie de contacto de la herramienta con la pieza mecanizada, lo que provoca valores más altos de la microdureza superficial.

Análogamente, Campbel *et al.* en [109] estudiaron, para la aleación UNS A97075-T651, la modificación de la microestructura considerando la microdureza superficial. Realizaron torneados con un avance de 0.076 mm/rev, y con velocidades de corte de 360, 540 y 720 mm/min, cambiando el ángulo de desprendimiento de las herramientas entre 0 y 15°, concluyendo que al aumentar la velocidad de corte se genera una profundidad

mayor en la modificación de la microestructura de las piezas mecanizadas, además un menor ángulo de desprendimiento de la herramienta provoca además un incremento de la temperatura en el mecanizado y, por consiguiente, una modificación mayor de su microestructura. También establece, en contra a lo recogido por Rotella et al. en [40], que en las zonas próximas a la superficie, es menor la microdureza, hasta alcanzar una profundidad de unos 50 μm , en los que se tiende a estabilizar la microdureza más altos que los iniciales, y por tanto a homogeneizar su microestructura.

En Martin *et al.* [6], se estudia la influencia de los parámetros de corte (v_c y f) en la microdureza. Los resultados más altos de HV se obtuvieron cuando se aplicó el rango intermedio de valores de velocidad de corte (en torno a 60 m/min) y avance (0,10 y 0,15 mm/rev).

Estos resultados pueden explicarse considerando el efecto que f y v_c producen sobre la microestructura superficial. Por un lado, los incrementos de f suelen producir una mayor deformación plástica en la superficie mecanizada debido a efectos mecánicos (endurecimiento por deformación), mientras que los efectos térmicos suelen ser menores [110]. Por lo tanto, se obtiene una microestructura de grano más fino, dando lugar a incrementos HV.

Por otro lado, los incrementos de v_c dan lugar a una mayor temperatura en la zona de corte [108]. El calor producido es disipado de la zona de corte a través de la viruta, la herramienta y la pieza. A altas velocidades de corte, la mayor parte de la energía se disipa a través de la viruta. Para velocidades de corte bajas (40-60 m/min), la energía disipada por la viruta es menor; por lo tanto, el calor disipado a través de la herramienta y la pieza aumenta. Este hecho se traduce en un aumento del tamaño de grano y una reducción de la v_c [40]. Cuando se incrementa el v_c (dentro de este rango bajo), este efecto se hace más relevante.

Por consiguiente se puede concluir que tras las investigaciones analizadas, los torneados en seco, generan una modificación de la microestructura en la superficie de la piezas mecanizadas. Dicha modificación supone una variación en la microdureza superficial de la pieza, en la que la velocidad de corte juega un papel relevante.

En otro sentido, aunque el avance sea un parámetro en el que se presta gran interés en la industria, no influye de modo importante, ya que afecta a diversas variables a considerar en los mecanizados como la fuerza de corte, que influye a su vez en características térmicas asociadas a los mecanizados. Aún así, los estudios que se encuentran están realizados en un intervalo de velocidades de corte muy altas, y por tanto, los efectos térmicos es posible que predominen sobre los mecánicos.

No obstante, existen escasos estudios en los que se analice dicha influencia en velocidades de corte bajas. Se debe considerar que estas aleaciones son habitualmente usadas en los componentes estructurales de las aeronaves, híbridadas con otros diversos materiales, como los CFRP, o compuestos poliméricos reforzados con fibra de carbono o aleaciones de titanio, formando FML o compuestos laminados (*Fiber Metal Laminates*). La velocidad de corte usada en estos casos es más baja, estando condicionada por los otros materiales. Es conveniente analizar si los efectos térmicos predominan sobre los mecánicos, y se pueden encontrar tanto crecimientos como reducciones de la microdureza superficial, según la combinación de velocidades de corte y avances que se utilicen.

Igualmente, se comprueba que el efecto que supone la profundidad de corte tampoco se ha analizado en un intervalo de valores amplio en una aplicación industrial, para las aleaciones del tipo UNS A97075, y habitualmente se usan profundidades de corte bajas. Por tanto, es de interés analizar cómo influye el avance en la microdureza superficial de las piezas torneadas, de la profundidad de corte, como las sinergias existentes entre los 3 parámetros de corte.

2.5. Consideraciones generales de las aleaciones de aluminio

Tal y como recoge [4] y cuyas conclusiones se comparten en este trabajo como punto de partida esencial, las cuales se aplican y se citan puesto que en el estudio de la integridad superficial se suele realizar un abordaje basado en el rendimiento funcional de las piezas torneadas mediante el análisis de propiedades fisicoquímicas y geométricas, estableciéndose una metodología experimental en el desarrollo de los ensayos que se realizan para estudiar la influencia de la velocidad de corte y del avance en distintas propiedades de la integridad superficial.

El análisis de los resultados de los experimentos que se llevan a cabo considera variables de salida como: morfología de las virutas, el desgaste de las herramientas, desviaciones geométricas, rugosidad superficial, dureza superficial y el comportamiento a fatiga.

Las principales conclusiones que alcanza son las que se mencionan a continuación.

En lo referente al análisis realizado de la morfología viruta, ésta presenta una fragmentabilidad baja y una alta predisposición a crear nidos, influenciado por la velocidad de corte alta y de avance baja. Además, el alto contenido en Zn de la aleación UNS A97075 aumenta su plasticidad y por tanto penaliza la fragmentabilidad.

También se analiza el desgaste de la herramienta y concluye que la adhesión indirecta es el mecanismo de desgaste principal, en la cara de desprendimiento y en el filo de corte, BUL y BUE, y que los incrementos en la velocidad de corte y del avance benefician dicho desgaste. Pero con velocidades de corte baja, el BUL es poco significativo.

Para estudiar el acabado superficial se utilizaron R_a y R_z . Los valores obtenidos de R_a convergían con estudios previos similares. R_z , al igual que ocurre con R_a , está afectado sobre todo por el avance. Se obtiene una relación entre R_a y f tipo potencial, y por otra, entre R_z y f se aprecia una propensión a la linealidad. Si se sometían a corrosión, las condiciones de corte influían en R_a y R_z de modo similar a las previas a dicho proceso de corrosión, aunque aumentaba la dispersión de las medidas realizadas sobre todo en R_z . Al aumentar el tiempo de corte de la herramienta, se muestra una tendencia a reducir R_a por el cambio en la geometría de corte al aparecer BUE en la herramienta, en cambio para simultáneos valores bajos de v_c y altos de f , se estabiliza R_a .

Se estudiaron cómo influían las condiciones de corte, v_c y f , en las desviaciones macrogeométricas. El incremento en los parámetros de corte provocaba aumento de las desviaciones STR (rectitud), CRO (oscilación radial), RON (redondez) y CYL (cilindricidad) sobre todo en CYL. En cambio, no se vieron influencias evidentes de estos los parámetros en las desviaciones de PAR (paralelismo), CON (concentricidad) y TCRO (oscilación radial total), sólo se observaron en combinaciones de v_c y f altos. En relación a la probeta que se mecanizaba, se comprobó que su rigidez era un parámetro a considerar en el análisis de las desviaciones. Se propusieron modelos paramétricos potenciales para desviaciones STR, CRO y RON, que permitían prever su comportamiento en función de v_c y f , con buenos ajustes al resultado experimental. Al analizar la influencia del desgaste en las desviaciones macrogeométricas se concluyó que al modificarse la geometría del corte debido al BUE, aparece una consecuencia positiva en las desviaciones de STR, CRO y RON, en cambio para PAR, CON, TCRO y CYL, no se evidencia tal influencia. Pero si se aumenta el tiempo de corte de la herramienta (por adhesión de material al filo de corte) se produce una reducción de las desviaciones geométricas.

En lo que respecta a la microdureza superficial, generalmente se observa su incremento tras el mecanizado, sin depender de los valores de v_c y f que le fueron aplicados. Para f y v_c bajos prevalecen los efectos mecánicos sobre los térmicos, provocando una microestructura con grano más fino en relación a la pieza no mecanizada y causando un aumento de la microdureza. Para f y v_c intermedios, a pesar de que los efectos térmicos se incrementan, no son suficientes como para compensar los mecánicos que tienen más relevancia, provocando una estructura de grano más fina e incrementándose el valor de la microdureza. Y, en el caso de f y v_c altos, los efectos térmicos son más importantes que los mecánicos, lo que provoca que se reduzca el tamaño de grano.

Para analizar el comportamiento a fatiga se trabajó con un banco de ensayo de fatiga por flexión rotativa. Se realizó el estudio de cómo influyen v_c y f sobre el comportamiento a fatiga en la aleación de aluminio UNS A97075, realizando ensayos y aplicando cuatro cargas de diferente valor. En los análisis de fractura se observaron que las microgrietas se generan en la superficie de la muestra y van creciendo hasta alcanzar la rotura frágil por fatiga. Por otra parte, un incremento de v_c y f afecta negativamente a la fatiga del material, y es v_c el parámetro de corte que más influye. Se proponen distintos modelos paramétricos, relacionando el comportamiento a fatiga con los parámetros de corte y la carga aplicada, y siguiendo un modelo potencial. Se destaca la propuesta de un modelo paramétrico que incluyen el número de ciclos como $N = g(S, v_c, f)$. Se observó que, en los casos de valores bajos de S , es más representativa la influencia de los parámetros de corte en N y para S (la carga aplicada en la sección de fractura) con valores altos, N converge, teniendo v_c y f menos influencia en el comportamiento a fatiga estudiado. También concluye en este aspecto que la sección de rotura no se origina en la sección de máxima tensión, sino en zonas cercanas, aunque sometidas a una S . Por ello, se propusieron nuevos modelos paramétricos de más robustez, adaptando S dependiendo de la sección en la se produce la fractura. Estos modelos corrigen la importancia de los parámetros de corte en el comportamiento a fatiga (incrementos de f provocan peores comportamientos a fatiga), y son más conservadores a los primeros en los que se usaba S en su valor máximo, según la carga que fuese aplicada. Por último, estos modelos descubren una mayor influencia de v_c y f , y una reducción de la influencia de S .

Igualmente en [1] se realizan una serie de conclusiones tanto generales como particulares que son referencias transcendentales en este trabajo que nos ocupa, de las que nos hacemos eco y que se mencionan a continuación, ya que a través de un análisis paramétrico del mecanizado en seco de la aleación UNS A97075 expone de manera ordenada todo un conjunto de resultados de los que se destacan los siguientes.

Se confirma que en los procesos de mecanizado la corriente actual es reducir o eliminar el uso de fluidos de corte utilizando principalmente el mecanizado en seco, que aunque respeta positivamente al medioambiente, las condiciones de corte son muy agresivas, influyendo negativamente en el resto de aspectos del rendimiento. Esta es la razón por la que se necesita profundizar en el análisis y mejora de estos procesos y poder así incrementar el rendimiento bajo estas condiciones. Se comprueba que la mayoría de estudios están centrados en mejorar las herramientas de corte usadas y en buscar combinaciones de parámetros de corte que resulten óptimos. Se ha observado que los análisis orientados a la mejora del rendimiento están estrechamente conectados con el estudio de la maquinabilidad de las aleaciones. Si se considera la maquinabilidad como la facilidad que dispone una aleación para mecanizarse, ésta depende de muchas variables dificultando su estudio.

En el estudio de las operaciones de mecanizado de las aleaciones se emplean tanto métodos analíticos como experimentales. La aplicación de los métodos analíticos resulta complicada debido al gran número de variables que entran en juego en los mecanizados, por ello es habitual recurrir a simplificaciones, que si bien pueden facilitar su aplicación, también ocasionan situaciones y resultados irreales, por ello los métodos más usados sean los experimentales. Éstos últimos pretenden modelizar paramétricamente para predecir, basados en un criterio determinado y en función de variables de entrada, el comportamiento de la maquinabilidad. Pueden estar fundamentados en técnicas de experimentación tradicional, FbF (*Factor by Factor*), o en diseño de experimentos, DoE (éste se desaconseja su uso en el mecanizado de ciertas aleaciones, aunque puedan suponer ventajas por el número de ensayos requeridos).

Se ha comprobado que los modelos de tipo potencial y de tipo polinómico son los más frecuentes y se suelen basar en la evaluación de alguna de las variables de salida, en función normalmente de los parámetros de corte (v_c , f y a_p). Los tipo potencial suelen ser más robustos que los polinómicos (se suelen basar en DoE), cuando se pretender interpretar la evolución de la variable que explica la maquinabilidad en función de las variables de entrada. Se comprueba mediante las fuentes analizadas que entre los criterios de evaluación de la maquinabilidad más usados se encuentra el basado en la calidad del acabado superficial del mecanizado, que a su vez depende de propiedades fisicoquímicas de la superficie de las piezas y de sus topologías geométricas. Se comprueba que habitualmente al referirse a la calidad de acabado superficial se hace referencia a desviaciones geométricas de las piezas en relación a las especificaciones en el diseño a escala micro y macrogeométrica. Se observa que las desviaciones microgeométricas son las más usadas, siendo la rugosidad media aritmética, R_a , la variable más usada para evaluar dichas desviaciones microgeométricas.

Se comprueba que las aleaciones de aluminio tienen un conjunto de características que las sitúan como ideales para ser utilizadas en la industria aeroespacial, siendo la relación densidad-resistencia mecánica idónea para su uso en la fabricación de los componentes estructurales de las aeronaves. El mecanizado es el proceso de fabricación más usado para la fabricación de estas piezas. Por otra parte, muchas de las aleaciones de aluminio tienen una excelente maquinabilidad, pero su mecanizado no está a salvo de determinados problemas. En las aleaciones de aluminio para fundición (no son usadas habitualmente para la industria aeroespacial) se observan significativos problemas de desgaste por abrasión en las herramientas de corte debido a su gran contenido en silicio. Por otra parte, en las que son para forja, se presentan dos problemas principales, los relacionados con la morfología de la viruta y con el desgaste por adhesión en la herramienta.

Se pone de manifiesto que irregularidad en la viruta impide usarla como criterio de maquinabilidad, así como la importante tendencia a enredarse en las herramientas y las piezas causando problemas en la continuidad de los procesos y en los resultados. Y en relación a los problemas de desgaste por adhesión, se observa que estas aleaciones tienen una importante tendencia a que aparezca desgaste por adhesión indirecta, que originan BUL y BUE, y por consiguiente alteran la geometría de la herramienta que a su vez influye en la calidad del acabado superficial.

La calidad de acabado superficial es de los criterios de maquinabilidad más utilizados. La calidad superficial se suele evaluar a través de las desviaciones microgeométricas de la superficie que se mecaniza. Por otra parte, la variable que más se usa para evaluar en términos microgeométricos la maquinabilidad, es R_a o rugosidad media aritmética, siendo numerosos los análisis de maquinabilidad que se basan en el estudio de la evolución de R_a dependiendo de variables de entrada al proceso como puedan ser los parámetros de corte.

Se comprueba que el avance es, de entre los parámetros de corte, el que tiene una mayor influencia sobre R_a , y por tanto sobre la maquinabilidad. La dependencia respecto de la velocidad de corte es menor. En cuanto a la profundidad de corte, su influencia sobre el valor de R_a es reducida, aunque las investigaciones al respecto son escasas. Según los pocos estudios a este respecto, hay una menor relación entre desviaciones de forma y maquinabilidad.

Se observa la existencia de pocos estudios sobre determinados aspectos del mecanizado en seco, como los que tratan sobre la influencia de la profundidad de corte en R_a , cómo evoluciona R_a con la longitud de mecanizado o el tiempo de corte, la integridad superficial basada en el estudio de las desviaciones de forma y sobre los que se afirma que resultaría importante continuar investigando. En definitiva, hay pocos estudios

sobre ciertas propiedades de la integridad superficial para la aleación de aluminio UNS A97075 sometida a procesos de mecanizado en seco.

En este trabajo se elaboró una metodología experimental realizando diferentes ensayos de mecanizado, analizando cómo influyen los parámetros de corte en la morfología de la viruta, el en el desgaste de las herramientas y en la calidad de acabado superficial de los mecanizados, evaluándolo en términos macro y microgeométricos. Los ensayos que se llevaron a cabo permitieron determinar que la morfología de la viruta tiene una fragmentabilidad baja, una importante tendencia a crear nidos de viruta, que al enredar en la herramienta y en la pieza, alteran la continuidad del proceso y el aspecto superficial de la pieza mecanizada. Las herramientas muestran generalmente desgaste por adhesión indirecta en el filo en la cara de desprendimiento (aparición de BUE y BUL), dependiendo su intensidad y velocidad de aparición del avance que se aplique, de modo al aumentar el avance se incrementa la cantidad de material que se adhiere a la herramienta. Se observan indicios de desgaste por abrasión en la cara de incidencia y en la cara de desprendimiento de la herramienta, siendo de intensidad menor que el desgaste por adhesión. También se demuestra que el avance es el factor más determinante en R_a , de tal modo que R_a tiende a crecer al aumentar el avance, pero está menos influenciado por la velocidad y la profundidad de corte.

Se obtienen un conjunto de modelos paramétricos tipo potencial, que logran aproximar el valor de R_a en función de parámetros de corte aplicados, incorporando de modo novedoso variables como la profundidad o el tiempo de corte. Se propone un criterio de maquinabilidad basado en la calidad superficial, usando como variable de evaluación a R_a . Los resultados que se logran al evaluar las desviaciones de forma como la rectitud, el paralelismo, la oscilación radial y la redondez, ponen de manifiesto que el avance no influye tanto sobre estas desviaciones como R_a , parecida a la que ofrece presenta la velocidad de corte sobre dichas desviaciones. De este modo, la tendencia general de las desviaciones de forma es a la convergencia, al variar los valores de v_c y f .

Se logran un conjunto de ecuaciones paramétricas para predecir cómo se comportan las desviaciones de forma dependiendo de la velocidad de corte y del avance, siendo el modelo exponencial el que mejor se ajusta. También concluye indicando que, para las aleaciones menos estudiadas, caso de la aleación UNS A97075, se plantea la necesidad de realizar más estudios que logren mejorar el rendimiento de su mecanizado en seco.

2.6. Técnicas de Inteligencia Artificial para la predicción en las operaciones de mecanizado

A continuación, se repasa el estado del arte con los principales estudios que utilizan diferentes técnicas para resolver problemas del mecanizado y específicamente los relacionadas con las condiciones superficiales, comparándolas entre sí para finalmente centrarnos en aquellas que hacen uso de la inteligencia artificial para este mismo propósito. Técnicas comunes más utilizadas

2.6.1. Enfoques más comunes empleados en la actualidad

Aunque se han usado comúnmente técnicas estadísticas para desarrollar modelos aplicando metodologías que se basan en el diseño de experimentos y el análisis de correlación, con lo que se conseguía reducir el número de experimentos y de datos, los modelos estadísticos clásicos, regresión lineal simple y la regresión múltiple, no han ofrecido resultados buenos para estos problemas [111].

De las técnicas de Inteligencia Artificial (IA) más usadas, se encuentran las Redes Neuronales Artificiales (RNAs) con distintos algoritmos de entrenamiento como:

- (I) *Backpropagation*, con buenos resultados en la operación de fresado [112].
- (II) Lógica borrosa (LB),
- (III) Sistemas neuroborrosos,
- (IV) y más recientemente los algoritmos genéticos (AGs).

El principal inconveniente de los estudios que utilizan métodos de modelado empírico y técnicas de regresión es la falta de rigurosidad en la evaluación de los experimentos [113].

A continuación, se recopilan los trabajos que según la bibliografía consultada han ofrecido técnicas innovadoras para predecir la rugosidad, centrándonos en los más recientes (a partir del año 2000).

En [114] se realizó un estudio de la correlación entre las variables de un proceso de torneado: velocidad de corte y de avance, valor promedio RMS de señales acústicas emitidas y una de las variables de estado del proceso (R_a , R_z y R_{max}). Se experimentó mecanizando acero tipo AISI1054, con herramienta de carburo y en un torno 5HP. Tras los sucesivos ensayos y mediciones concluyeron que la velocidad de corte, la fuerza y

el promedio RMS están fuertemente correlacionados con los parámetros del acabado superficial.

Es obligado mencionar a uno de los grupos de investigación más importantes que realizan sus estudios sobre la predicción del acabado superficial Online, Universidad de Iowa, dirigidos por el Dr. J. Chen. Se pretende destacar a continuación cuatro trabajos realizados por este grupo sobre el acabado superficial y los estados de las herramientas en torneados y fresados.

Lee and Chen, en [115], utilizaron la técnica neuroborrosa con el objetivo de predecir en el torneado la rugosidad superficial. Demuestran en su trabajo la importancia de las vibraciones entre la herramienta y la pieza a mecanizar durante el proceso de corte en la predicción de la rugosidad superficial. Usando el coeficiente de correlación de Pearson demostraron que el eje X (dirección radial de vibración) era la variable más importante en el pronóstico del acabado superficial.

En [116] se propuso un sistema que permitiese, en un fresado, identificar la rugosidad óptima mediante el diseño de experimentos de Taguchi. Los resultados permitieron calcular el valor medio de rugosidad superficial con un nivel de confianza del 95 %.

Yang *et al.*, en [117] proponen un sistema de control adaptativo en operaciones de fresado, basado en el esquema de entrenamiento neuroborroso de [118]. Utilizaba 2 subsistemas, uno para realizar la predicción de R_a en proceso y el otro para el control de la tasa de avance basado en el R_a que se había predicho.

En [119] desarrollaron un sistema que predijera la rugosidad superficial en torneados usando acelerómetros mediante técnicas de regresión múltiple.

Otros investigadores como [120], desarrollaron modelos de regresión lineal con el objetivo de predecir la rugosidad superficial en un torneado basándose en las vibraciones de la máquina y la herramienta y en los parámetros de corte. Presentaron cuatro modelos distintos para predecir R_a , R_t , R_{sk} (usado para medir la simetría de la superficie). Usaron técnicas de regresión lineal y análisis de la correlación. Llegaron a la conclusión de que aquellos modelos que dependen de los parámetros de corte y de las vibraciones de las herramientas son más correctos que los que sólo dependían de los parámetros de corte.

Chien and Chou, en [121], desplegaron una RNA algoritmo genético y un AG que incorporaba a búsqueda de condiciones óptimas de corte con el objetivo de maximizar la TAM sujeto a restricciones de acabado superficial asociado a la vida de la herramienta en un fresado en seco de acero inoxidable. Estos autores partieron de un estudio previo recogido en [122] que utilizan RNAs para obtener un modelo predictivo que prevea los esfuerzos de corte y el acabado superficial de la pieza para unas condiciones específicas de corte. En este nuevo trabajo intentaban predecir la vida de la herramienta mediante la

velocidad de corte y una vez localizada ésta se usaba un modelo con AG para conseguir la TAM y las condiciones óptimas de corte.

Feng y Wang, en [123], realizaron un trabajo focalizado en un modelo empírico que prediga la rugosidad superficial en torneados. Comparaban un modelo de RNA con uno de regresión lineal utilizando las mismas entradas-salidas en los dos modelos. Utilizaron el modelo de predicción del acabado superficial $R_a = g(f, r)$, siendo f el avance y r el radio de la herramienta. De la regresión se dedujo que la dureza de la pieza y la profundidad de corte no suponen un efecto importante en la rugosidad si actúan de modo individual. Sin embargo, la dureza unida con el avance y el radio de la herramienta, como la profundidad de corte unida con la velocidad, sí tenían un efecto importante en la rugosidad. Para el caso del modelo con RNAs, se utilizó backpropagation y arquitectura 5-10-1. Se utilizaron el error absoluto máximo, el error absoluto mínimo y la raíz del error cuadrático medio como métricas para evaluar el modelo. Concluyeron que el modelo de RNAs tenía menos errores que el correspondiente error del modelo de regresión, aunque en los resultados que se obtuvieron en cada modelo no había diferencias importantes.

En [124] se desarrolló una aplicación con el objetivo de supervisar la rugosidad superficial basado en redes neuronales. Entrenaron la red neuronal con 250 datos, la estructura tenía 28 entradas (incluían parámetros del proceso, características de las herramientas, propiedades del material y vibraciones de la máquina), con 20 capas ocultas, y como salida R_a .

Asimismo, en [125] se propone una app *ad hoc* para determinar los parámetros de corte que dan lugar a determinados valores de R_a y de otras propiedades relacionadas con la integridad superficial.

Las herramientas más usadas en los trabajos más recientes e importantes para predecir R_a son las RNAs y la regresión lineal o múltiple. Dentro de las RNAs, el modelo más común para predecir R_a son las *feed-forward backpropagation neural networks* y las de base radial [126], [127], [128], [129].

2.6.2. Modelos predictivos

Tal y como recoge en [130], medir la calidad superficial de piezas torneadas presenta como principal problema que se necesita evaluar “*post-proceso*”, con instrumental de sensibilidad micrométrica, lo que supone pérdidas de tiempo (se necesita retirar la pieza de la línea de producción para inspeccionarla). Además de necesitar técnicas estadísticas para el control de calidad ya que es imposible medir todas las piezas producidas.

Este inconveniente se suele resolver mediante la aplicación de métodos que midan la rugosidad “*en proceso*”, como los de tipo óptico con láser (sin contacto) pero que requieren restricciones de uso difíciles de aplicar. Otra alternativa es plantear modelos para la conducta de la rugosidad a partir de variables del proceso de corte mediante técnicas estadísticas o de IA.

Los modelos son una imagen abstracta de una parte de la realidad, con elementos que la representan y con las relaciones que existen ellos. Al construir modelos se revelan relaciones y características de las mismas no previstas. Por otra parte, los modelos utilizan hipótesis que resultan de la simplificación tras prescindir de ciertas variables y por tanto dejan de considerarse factores de la realidad.

La utilización del *Machine Learning* en los procesos de mecanizado están proporcionando mejoras importantes, en términos de eficiencia, costes, calidad final del producto y gestión medioambiental, a través de los procesos de determinación de los parámetros de corte óptimos.

Entre los diferentes aspectos del proceso de mecanizado, *Machine Learning* puede aplicarse al desgaste de herramientas, al consumo de energía, a determinar las fuerzas de corte o a la predicción de las desviaciones geométricas de las piezas que se mecanizan. Existen estudios que muestran cómo de acertadas son las predicciones que se realizan mediante IS en estos procesos (como la tabla en relación a la precisión alcanzada en estudios previos de implementación de *Machine Learning* a procesos de mecanizado, extraída de [131]). Se puede concluir que la aplicación de la Inteligencia Artificial en procesos de mecanizado es cada vez de uso más generalizado gracias a la precisión al realizar predicciones mejorando la eficiencia de todo el proceso de producción.

En relación a artículos publicados relacionados con la utilización de las RNAs en el campo del mecanizado se encuentran estudios que utilizan estructuras y algoritmos muy variados. En cuanto a la estructura hay casos con una sola capa oculta, artículos [132], [133], [134], [135], [136], y otros con dos capas ocultas [137], [138], [139]. En cuanto a los algoritmos de la RNA en [140] se comparan las RNAs como las RNNs (*Recurrent Neural Networks*), FNNs (*Feedforward Neural Networks*) o GNNs (*Graph Neural Networks*), siendo mayoritarios las FNNs. En el estudio de [141] se analiza el uso de distintas funciones de activación comparando los resultados.

Entre toda la información disponible se destaca a modo de resumen el esquema elaborado en [125] con los artículos más destacados en relación a la aplicación de las Redes Neuronales Artificiales al mecanizado de aleaciones de aluminio (véase la tabla resumen de artículos de aplicación de RNAs a aleaciones de aluminio, extraída de [125]).

La predicción del acabado superficial es prácticamente imposible de modelar analíticamente ya que hay variables del proceso que no se pueden reflejar en las ecuaciones físicas. Ello implica que los modelos analíticos, o deterministas, realizan una predicción teórica, no real, al no incorporar todas las características del proceso.

Por otra parte, los modelos empíricos que se basan en observaciones directas presentan como inconveniente que, si los ensayos que se realizan basados en el modelo no se hacen con la rigurosidad científica necesaria y a partir de un diseño de experimentos adecuado, serán modelos irreales.

Al modelar estadísticamente se pueden ver las variables que lo integran ya que son modelos explícitos a diferencia de las redes neuronales. Ante la respuesta de qué es mejor, la conclusión es que hay problemas en los que lo que funciona mejor es una red neuronal y otros en los que lo hace mejor el modelo estadístico, por lo que resultaría interesante probar ambas metodologías.

En conclusión, para la evaluación de la rugosidad superficial de piezas mecanizadas en seco, se enfrentan desafíos relacionados con la necesidad de mediciones “*post-proceso*”, lo que conlleva interrupciones en la producción y la aplicación de métodos *in situ* para monitorizar esta propiedad. La solución se ha buscado a través de modelos estadísticos y de Inteligencia Artificial, como el *Machine Learning*, que ofrecen mejoras en la eficiencia, costos y calidad de productos en procesos de mecanizado.

La utilización del *Machine Learning* en procesos de mecanizado abarca diversos aspectos, como el desgaste de herramientas, el consumo de energía, las fuerzas de corte y la predicción de desviaciones geométricas en piezas. Diversos estudios han demostrado que la implementación de estas técnicas proporciona predicciones precisas, mejorando la eficiencia global de los procesos de producción. En particular, se han explorado el

uso de RNAs en este campo, con diversas topologías y algoritmos de aprendizaje. Estos enfoques son complementarios, y mientras que las RNAs pueden capturar relaciones no lineales y ocultas, los modelos estadísticos aportan explícitamente información sobre las variables involucradas en el proceso.

La combinación de modelos estadísticos y redes neuronales ofrece enfoques prometedores para abordar los retos que suponen la estimación y optimización de la rugosidad y otras propiedades relacionadas con la integridad superficial en operaciones de mecanizado, permitiendo mejorar significativamente la calidad del ajuste.

Capítulo 3

Conceptos generales y fundamentos de implementación de las RNAs

3.1. Introducción

En este capítulo, se presenta una exhaustiva descripción de los conceptos y terminología fundamentales relacionados con el paradigma del *Machine Learning* [142], [143], [144], con especial interés en la RNAs y en las tipologías de aprendizaje, funciones de activación, funciones de coste, algoritmos de aprendizaje y otros hiperparámetros fundamentales, necesarios para afrontar el capítulo 5 Resultados y discusión.

3.2. Machine Learning

El Aprendizaje Automático o *Machine Learning*, como parte de la Inteligencia Artificial, pretende desarrollar técnicas, algoritmos y modelos computacionales que permita automatizar la adquisición de nuevo conocimiento, intentando encontrar patrones, relaciones y estructura en los datos. El machine learning al igual que la estadística inferencial se basa en el análisis de datos, pero el primero tiene en consideración la complejidad computacional del problema, que en muchas ocasiones son del tipo NP-duro, de modo que la mayor parte de la investigación en machine learning se enfoque en encontrar soluciones alcanzable a estos problemas. Son numerosas sus aplicaciones, desde la clasificación de secuencias genéticas, prospecciones de mercado, reconocimiento óptico, motores de búsqueda, etc. Arthur Samuel (1959) acuñó este concepto como *la capacidad para aprender sin ser programado explícitamente*.




Figura 3.1: Clasificación de algoritmos de IA.

3.2.1. Redes neuronales artificiales y Deep Learning

Son modelos computacionales con una estructura en varias capas y nodos que se conectan entre sí y que recuerda la estructura de interconexión de las neuronas del cerebro. En 1943 ya se presenta el modelo de neurona artificial concebido por McCulloch y Pitts. El comportamiento de una red se define por el modo que se conectan sus nodos y por la calidad, o peso, de sus conexiones. Estos pesos se ajustan de modo automático durante el proceso de entrenamiento según un criterio de aprendizaje determinado hasta que esta red realice la tarea que se desee de modo correcto. Son en definitiva un tipo de aprendizaje automático que se inspira en las neuronas de los animales que colaboran entre sí para producir un estímulo de salida, utilizando modelos matemáticos con capacidad para resolver problemas de mayor o menor complejidad de un modo suficientemente eficaz.

A continuación se describen dos ejemplos de uso de redes neuronales. En las compañías eléctricas para prever de modo preciso la carga de sus redes, asegurando su fiabilidad y optimizando la eficiencia de sus generadores eléctricos; en el sector sanitario, mediante su aplicación en la detección de patologías y guía en la clasificación de tumores dependiendo de la uniformidad de masas, tamaños de células y otros factores.

Las redes de *Deep Learning* se corresponden con redes neuronales que disponen de muchas capas de neuronas conectadas, y en cualquier caso, se trata de una metodología de *Machine Learning*.

3.2.2. Paradigmas de Aprendizaje

A continuación se detallan las técnicas más habituales de aprendizaje en el *Machine Learning*.

- (I) Aprendizaje supervisado. En este caso las redes se entrenan para generar las salidas deseadas en respuesta a entradas, resultando idóneas en el modelado y control de sistemas dinámicos, clasificación de datos y predicción de sucesos. El algoritmo utilizado genera una función que establece la correspondencia entre las entradas y las salidas que se desean. Se trata de un aprendizaje muy utilizado en investigación biológica.

Dentro del paradigma de aprendizaje supervisado encontramos aplicaciones como la clasificación y la regresión (también llamada aproximación de función). También es aplicable a datos secuenciales como el reconocimiento del habla, de gestos y de texto.

- (a) Clasificación. Corresponde a un subtipo de machine learning supervisado donde un algoritmo, partiendo de ejemplos de datos etiquetados, aprende a clasificar otras observaciones nuevas, de modo que el sistema etiqueta o clasifica una serie de objetos en determinadas clases, utilizando como conocimiento otros ejemplos de objetos etiquetados anteriormente.
- (b) Regresión. En los modelos de regresión se describen la relación existente entre una variable salida (respuesta) y una o varias variables de entrada (valor etiquetado).

- (II) Aprendizaje no supervisado. Las redes neuronales no supervisadas son entrenadas considerando que la propia red neuronal realice un autoajuste continuo según las nuevas entradas. Son usadas para predecir información a partir de datos de entrada de los que no se disponen de respuestas con etiquetas. En estos casos, el sistema debe poder reconocer patrones para poder etiquetar las nuevas entradas.

Dentro del paradigma de aprendizaje no supervisado encontramos aplicaciones como el agrupamiento, la estimación de distribuciones estadísticas, la compresión de datos y el filtrado bayesiano de spam.

- (a) *Clustering*, o análisis por agrupamiento, en el que se clasifican las observaciones en clusters o grupos, de modo que las de cada grupo se parezcan entre sí según determinados criterios (una medida de similitud específica) y la separación entre los diferentes grupos (similitud entre los miembros de cada grupo). Se trata de un enfoque de aprendizaje no supervisado en el que

se utilizan redes neuronales para analizar datos a modo de exploración y poder así encontrar patrones ocultos. Supone por tanto agrupar datos por semejanza. Se están utilizando el estudio de secuencias de genes y análisis de mercados.

- (b) Reconocimiento de patrones. Su funcionamiento se basa en la clasificación de los datos de entrada en clases según determinadas características consideradas clave, y se puede realizar tanto por clasificación supervisada como no supervisada. Es esencial en las aplicaciones de las redes neuronales en visión artificial, reconocimiento de voces, procesamientos de señales de radar, etc. En el caso de visión artificial, se usan técnicas de reconocimiento de patrones supervisado que permite realizar a su vez el reconocimiento óptico de caracteres u OCR. Para el procesamiento de imágenes y la visión artificial, se usan técnicas de reconocimiento de patrones no supervisado con el objetivo de detectar objetos y segmentar imágenes.

- (III) Aprendizaje por refuerzo. En este caso el algoritmo debe aprender a través de la retroalimentación o *feedback* obtenida en respuesta a sus acciones previas, es decir en base a ensayo error. El modelo cuando toma una decisión recibe una penalización o recompensa en función de si se acerca o no al objetivo. De este modo, este tipo de aprendizaje intenta que se maximicen las recompensas a lo largo de todo el proceso teniendo en cuenta todos los resultados anteriores, Tiene como inconveniente que puede llegar a ser lento hasta adquirir el entrenamiento requerido.

3.3. Modelo, estructura e hiperparámetros de una RNA

El modo más habitual de representar la estructura de una red neuronal es usando capas o layers, que a su vez están formadas por neuronas. Cada una de las neuronas es capaz de realizar una operación básica y se conecta a otras neuronas de la capa anterior y siguiente aplicando pesos, con el objetivo de regular qué información se propaga de una a otra neurona.

La primera capa de una red neuronal se denomina capa de entrada (*input layer*) y es la que recibe los datos cuyo valor son los predictores; la(s) capa(s) intermedia(s), capa oculta o *hidden layer*, recibe valores desde la capa de entrada que han sido ponderados por pesos (las conexiones entre nodos); y la última capa, *output layer*, compone los valores salientes de la capa intermedia para formar la predicción.




Figura 3.2: Representación de perceptrón multicapa de $(L + 1)$ capas con D unidades de entrada y C unidades de salida. La capa oculta l^{th} contiene $m^{(l)}$ unidades ocultas.

Es muy habitual representar la estructura de las redes neuronales como un modelo de regresión lineal. Para $l = 1$, la primera capa oculta, se tiene que

$$z^{(1)} = W^{(0)} \cdot \mathbf{x} + b^{(0)}, \quad (3.1)$$

$$a^{(1)} = \sigma(z^{(1)}). \quad (3.2)$$

Para $l = 2, 3, \dots, L - 1$, las capas ocultas intermedias,

$$z^{(l)} = W^{(l-1)} \cdot a^{(l-1)} + b^{(l-1)}, \quad (3.3)$$

$$a^{(l)} = \sigma(z^{(l)}), \quad \text{para } l = 2, 3, \dots, L - 1. \quad (3.4)$$

Para $l = L$, la última capa oculta,

$$z^{(L)} = W^{(L-1)} \cdot a^{(L-1)} + b^{(L-1)}, \quad (3.5)$$

$$a^{(L)} = \sigma(z^{(L)}). \quad (3.6)$$

Para la capa de salida,

$$\mathbf{y} = \sigma(z^{(L)}). \quad (3.7)$$

Sea $\mathbf{x} = [x_1, x_2, \dots, x_D]$ el vector de entrada con D características, $W^{(l)}$ la matriz de pesos de la capa l a la capa $l + 1$, donde $l = 0, 1, 2, \dots, L - 1$, $b^{(l)}$ el vector de sesgo (*bias*) de la capa $l + 1$, donde $l = 0, 1, 2, \dots, L - 1$, $a^{(l)}$ es el vector de activaciones de la capa $l + 1$, donde $l = 0, 1, 2, \dots, L - 1$, $z^{(l)}$ es el vector de valores antes de aplicar la función de activación en la capa $l + 1$, donde $l = 0, 1, 2, \dots, L - 1$ capas ocultas intermedias,

$\mathbf{y} = [y_1, y_2, \dots, y_C]$ es el vector de salida con C neuronas, como puede verse en la figura 3.2 y σ , la función de activación.

Las neuronas de la capa de entrada simbolizan los valores de los predictores, los conectores reproducen los coeficientes de regresión, denominados pesos en terminología de redes, y la neurona de salida representa el valor que se predice. Pero para que esta representación se corresponda con la ecuación de un modelo lineal faltaría el *bías* del modelo y las operaciones matemáticas (sumas y productos) que suceden en las neuronas para combinar los predictores y los pesos.

3.3.1. La neurona

Se trata de la unidad funcional en los modelos de redes. En cada neurona suceden dos operaciones: la suma ponderada de las entradas de esa neurona (cada valor x_D , se multiplica por el peso $W^{(i)}$ asociado, y se suma al *bias* correspondiente) para posteriormente aplicarle una función de activación, σ , obteniéndose así el valor de salida.




Figura 3.3: Estructura básica de una neurona artificial.

Como se puede ver en la ecuación (3.1) hasta la (3.6) y atendiendo a la figura 3.3, analíticamente, el valor neto de entrada de una neurona se corresponde con la suma de los valores que le entran que se ponderan con el peso de las conexiones, y se le suma el sesgo correspondiente.

De forma genérica para varias capas ocultas y considerando y_k como la salida en la unidad de salida k , x_i la entrada en la unidad de entrada i , $w_{ji}^{(l)}$ los pesos entre las unidades de la capa $l - 1$ y la capa l , $b_j^{(l)}$ los sesgos (*biases*) de la capa l , $\sigma^{(l)}$ es la función de activación de la capa l , y M_l es el número de unidades (neuronas) en la capa l , se tiene que,

$$y_k = \sigma^{(L)} \left(\sum_{j_L=1}^{M_L} w_{kj_L}^{(L)} \cdot \sigma^{(L-1)} \left(\sum_{j_{L-1}=1}^{M_{L-1}} w_{j_L j_{L-1}}^{(L-1)} \cdot \dots \right. \right. \quad (3.8)$$

$$\left. \left. \cdot \sigma^{(2)} \left(\sum_{j_2=1}^{M_2} w_{j_3 j_2}^{(3)} \cdot \sigma^{(1)} \left(\sum_{i=1}^{M_1} w_{j_2 i}^{(2)} \cdot x_i + b_{j_2}^{(2)} \right) + b_{j_3}^{(3)} \right) + \dots + b_{j_{L-1}}^{(L-1)} \right) + b_{j_L}^{(L)} \right)$$

En la capa de entrada, en la que sólo se desea incorporar el valor de predictores, la función de activación es la identidad (la salida es igual a la entrada), y en la capa de salida, la función de activación que se suele utilizar es la identidad para problemas de regresión y la función *softmax* para los supuestos de clasificación.

3.3.2. Función de activación

La función de activación determina la información que se propaga de una capa a la siguiente (*forward propagation*), convirtiendo el valor neto de entrada a la neurona (combinación de la entradas, los pesos y *bias*), en otro valor nuevo. Y aquí radica, al combinar funciones de activación no lineales y múltiples capas, el mayor potencial de estos modelos de redes para aprender relaciones no lineales. La mayoría de funciones de activación transforman la entrada neta en un valor que se encuentra en el intervalo $(0, 1)$ o en $(-1, 1)$. Si la salida de la función de activación, valor de activación, es cero, se indica que la neurona está inactiva, puesto que no traslada ninguna información a las neuronas siguientes.

Se verán a continuación tres funciones de activación más usadas.

- (I) Función de activación ReLu (*Rectified Linear unit*), que aplica una transformación no lineal simple, activando la neurona únicamente si el *input* se encuentra por encima de cero, aumentando de forma lineal el valor de salida con el de entrada y en caso que esté por debajo de cero, su valor de salida es cero. Es decir, retiene sólo los valores positivos descartando los negativos. Es la función de activación más usada obteniendo resultados buenos para diversas aplicaciones, ya que su gradiente (derivada) es constante o cero, lo que evita el problema denominado *vanishing gradients* que limita la capacidad de aprendizaje del modelo.

$$\text{ReLU}(x) = \text{máx}(0, x). \quad (3.9)$$

- (II) Función de activación sigmoide, que transforma valores que se encuentran en el intervalo $(-\infty, +\infty)$ a valores del rango $(0, 1)$. Fue muy utilizada en los principios de estos modelos, pero actualmente se está prefiriendo la función ReLU. En las neuronas de la capa de salida en los modelos de clasificación binaria, la función sigmoide sigue siendo que más se utiliza ya que su salida se puede interpretar como probabilidad.

$$\text{sigmoide}(x) = \frac{1}{1 + \exp(-x)}. \quad (3.10)$$

- (III) La función de activación Tangente hiperbólica Tanh, similar a la sigmoide, con la salida acotada al intervalo $(-1, 1)$.

$$\tanh(x) = \frac{1 - \exp(-2x)}{1 + \exp(-2x)}. \quad (3.11)$$

3.3.3. Función de coste

La función de coste (l), conocida también como función de pérdida o *loss function*, se encarga de calcular la diferencia entre el valor real y predicho a través de la red. Por tanto, las predicciones de la red con mejores cuanto más se acerca el valor de coste a cero y alcanzando el cero si las predicciones son idénticas al valor real. Normalmente la función de coste se calcula para un conjunto de datos mediante el promedio de las observaciones y se utiliza para realizar el entrenamiento del modelo.

En función de la tipología del problema, regresión o clasificación, se utiliza una determinada función de coste. En caso de regresión, el error cuadrático medio y el error absoluto medio, son las más usadas y en los de clasificación se suelen utilizar la función *log-loss* (llamada también *logistic loss* o *cross-entropy loss*).

- (I) Error cuadrático medio. El error cuadrático medio (MSE o *Mean Squared Error*) es la función de coste que con diferencia más se usa en los problemas de regresión. Para una determinada observación i , el error cuadrático se calcula el cuadrado de la diferencia entre el valor predicho y el valor real,

$$\ell_i(W, b) = (\hat{y}_i - y_i)^2. \quad (3.12)$$

La función de coste se suele escribir en la notación $\ell(w, b)$ haciendo referencia de este modo a su dependencia de los pesos y *bias* del modelo, puesto que éstos son los que determinan el valor de las predicciones i , y habitualmente se encuentra multiplicada por $\frac{1}{2}$ (sólo a los efectos de simplificar el cálculo de la derivada),

$$\ell_i(W, b) = \frac{1}{2} (\hat{y}_i - y_i)^2. \quad (3.13)$$

Y para cuantificar el error cometido por el modelo de todo el conjunto de datos, basta con promediar el error de las n observaciones,

$$\text{MSE} = \mathcal{L}(W, b) = \frac{1}{n} \sum_{i=1}^n \ell_i(W, b) = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2. \quad (3.14)$$

En relación con el MSE es más robusto ante los *outliers*, ya que el entrenamiento se ve menos afectado por posibles datos anómalos del entrenamiento. Al entrenar un modelo usando el error medio absoluto como función de coste, este modelo aprende a predecir la mediana de la variable respuesta.

- (II) Error medio absoluto. El error medio absoluto (MAE o *Mean Absolute Error*) es la función de coste que promedia el error absoluto de las predicciones,

$$\text{MAE} = \mathcal{L}(W, b) = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i|^2. \quad (3.15)$$

Al entrenar un modelo usando el error cuadrático medio como la función de coste, este modelo aprende a predecir la media de la variable de salida.

3.3.4. Múltiples capas

Los modelos de redes neuronales con una sola capa (*Single-Layer Perceptron*) sólo solo son capaces de aprender simples patrones. Si se combinan muchas capas ocultas, al modelo de red se le puede instruir con relaciones bastante más complicadas entre los predictores y la variable respuesta. Estas estructuras son conocidas como perceptrón multicapa (MLP o *MultiLayer Perceptron*), y se le puede considerar como el primer modelo de *deep learning*. La estructura del perceptrón multicapa la forma varias capas de neuronas oculta, estando conectada cada neurona a todas las neuronas de la capa anterior y posterior. Siendo no rigurosamente necesario, las neuronas de una misma capa suelen usar la misma función de activación.

Si se combinan múltiples capas ocultas y funciones no lineales de activación, los modelos de redes podrían aprender casi cualquier tipo de patrón.

3.3.5. Entrenamiento

Entrenar una red neuronal es ajustar el valor del conjunto de pesos y bias de modo que se prediga con el menor error posible (minimizando el coste). De este modo, el modelo puede identificar los predictores con mayor influencia y de qué modo están relacionados entre ellos y con la variable respuesta.

Intuitivamente entrenar una red neuronal supone:

- (I) Iniciar la red con valores aleatorios para los pesos y *bias*.
- (II) Calcular el error cometido por la red en su predicción para cada observación del entrenamiento (x, y) y calcular el promedio de dichos los errores en todas las observaciones.
- (III) Localizar la influencia que han tenido cada uno de los pesos y *bias* en el error de esta predicción.
- (IV) Cambiar levemente los pesos y *bias* en la dirección adecuada con el objetivo de reducir el error.

(v) Repitiendo estos pasos hasta lograr la bondad suficiente de la red.

Pero implementar estos pasos requiere combinar el algoritmo de retropropagación (*backpropagation*) y la optimización por descenso de gradiente (*gradient descent*).

La mayoría de los algoritmos emplean alguna forma de descenso de gradiente, usando la propagación hacia atrás para calcular los gradientes reales. Esto se consigue mediante la derivada de la función de coste respecto a los parámetros de la red, para después cambiar los parámetros en una dirección relacionada al gradiente.

- (I) *Backpropagation*. También denominado algoritmo de propagación hacia atrás que resuelve eficazmente el problema de o-exclusivo, y en general el problema del entrenamiento rápido de redes neuronales de múltiples capas (Werbos, 1975). Es el algoritmo que permite medir cómo influye cada peso y *bias* en sus predicciones. Utiliza la regla de la cadena (*chain rule*) para calcular el gradiente (o vector formado por las derivadas parciales de una función) que para las redes se refiere a la derivada parcial del error respecto a uno de los parámetros (el peso o *bias*), midiendo cuánta *influencia* tiene dicho parámetro en el error que se ha cometido. De este modo se identifican cuáles pesos de la red hay que cambiar para optimizarla. A continuación se determina cuánto y cómo se modifican (optimización).
- (II) Descenso de gradiente. El descenso de gradiente (*gradient descent*) es un algoritmo de optimización que logra minimizar una función realizando actualizaciones de sus parámetros en la trayectoria negativa de su gradiente. En la aplicación a las redes neuronales, este algoritmo permitirá ir modificando los pesos y *bias* y así lograr el objetivo de reducir su error. Puesto que el cálculo del error de un modelo, si consideramos todas las observaciones en cada iteración, es muy costoso en términos computacionales, hay una opción denominada llamada gradiente estocástico (SGD, *Stochastic Gradient Descent*), que consiste en la división del conjunto de entrenamiento en lotes (*batch*), actualizando los parámetros de la red con cada uno. Así, en vez de esperar para evaluar todas las observaciones y así actualizar los parámetros, es posible ir progresivamente actualizando. Una pasada completa de iteraciones en todos los *batch* se denomina época.

3.3.6. Preprocesado

Cuando se entrenan los modelos de redes neuronales, es conveniente realizar por lo menos dos transformaciones diferentes en los datos:

- (I) Binarización (*One hot encoding*). El *one-hot-encoding* o binarización consiste en crear otras nuevas variables dummy en cada nivel de las variables cualitativas. Por ejemplo, si se trabaja con una variable denominada color con niveles rojo, verde y azul; se deberá convertir en tres nuevas variables (c_{rojo} , c_{verde} y c_{azul}), que tendrán todas el valor 0 salvo aquella que coincide con la observación concreta, que tomará el valor 1.
- (II) Estandarización y escalado. Si se trabaja con predictores numéricos, la escala y la varianza pueden tener una importante influencia en el modelo. De tal modo que si no se igualan de algún modo los predictores, los que se midan en una escala más alta o tengan más varianza tendrán más dominio en el modelo a pesar de que no sean los más relacionados con la variable respuesta. Se utilizan habitualmente dos estrategias:
 - (a) Centrado, que consiste en restar a cada valor la media del predictor al que pertenece. El resultado es que todos los predictores tendrán una media de cero.
 - (b) Normalización o estandarización, que consiste en transformar los datos para que los predictores estén en la misma escala. Y puede ser una normalización *Z-score*, que divide cada predictor por su desviación típica tras haberse centrado (los datos tendrán una distribución normal) o estandarización max-min, que transforma los datos para que estén en el intervalo $[0, 1]$.

Es importante destacar que no es conveniente estandarizar variables tras haber sido binarizadas.

3.3.7. Hiperparámetros

Como se ha visto, las redes neuronales y debido a su importante flexibilidad pueden generar modelos capaces de aprender relaciones complejas, pero, pueden padecer con facilidad el problema del sobreajuste u *overfitting*. Para minimizar este inconveniente se pueden configurar adecuadamente sus hiperparámetros. A continuación, se verán los más importantes.

- (I) Número y tamaño de capas. La complejidad y la capacidad de aprendizaje de un modelo de red neuronal está determinada de modo significativo por la arquitectura de la red, su número de capas y neuronas en cada capa. La capa de entrada tendrá tantas neuronas como predictores y la de salida tendrá una neurona para los problemas de regresión y tendrá tantas salidas como clases en los casos de problemas de clasificación. Estos valores se suelen fijar de modo automático según el conjunto de entrenamiento, y el usuario sólo especifica habitualmente el número de capas intermedias u ocultas y su tamaño. A mayor número de neuronas y capas, mayor será la complejidad de relaciones que el modelo puede aprender. Por otra parte, ya que cada neurona se conecta con pesos a las otras neuronas de las capas anteriores y posteriores, se aumenta el número de parámetros para aprender y consecuentemente el tiempo de entrenamiento.
- (II) *Learning rate*. El *learning rate* o ratio de aprendizaje determina cuánto de rápido podrán cambiar los parámetros de un modelo al optimizarse o al aprender. Es uno de los hiperparámetro más difíciles de determinar, por depender mucho de los datos y por interaccionar con los otros hiperparámetros. Si el ratio de aprendizaje fuese muy grande, el proceso de optimización podría ir pasando de una región a otra sin ser capaz de aprender. Si fuese muy pequeño, el proceso de entrenamiento podría tardar mucho y no llegaría a finalizar. Las recomendaciones son:
 - (a) Usar un *learning rate* lo más pequeño posible sin superar las limitaciones temporales que se dispongan.
 - (b) No usar un *learning rate* constante durante todo de entrenamiento. Es conveniente usar valores grandes al principio y pequeños al final.

Capítulo 4

Metodología Experimental

4.1. Introducción

Se considera fundamental establecer una metodología experimental que, partiendo del equipamiento y material del que se dispone, permita diseñar y llevar a cabo un conjunto de ensayos para determinar las interrelaciones entre las propiedades que definen a la integridad superficial de las piezas mecanizadas (macrogeométricas, microgeométricas y físico-químicas), así como estudiar cómo influyen las condiciones de mecanizado en propiedades mecánicas como la microdureza superficial de la aleación de aluminio UNS A97075-T6.

En este apartado del trabajo se describe la metodología experimental que ha sido necesaria para estos análisis.

- (I) Planificación de ensayos. Se identifican los materiales, el equipamiento que se va a emplear y las variables de entrada y salida de los ensayos que son necesarias para ejecutarlos adecuadamente. Se escogen, de valores de entrada, los parámetros de corte del proceso y, para variables de salida, las propiedades que afecten a la integridad superficial de las piezas mecanizadas (rugosidad superficial, desviaciones macrogeométricas, y propiedades físico-químicas y/o mecánicas). También se definen los tipos de ensayos que se llevarán a cabo según el objeto de estudio.
- (II) Ejecución de ensayos. Consiste en la realización de los ensayos necesarios para lograr los objetivos que se plantean y otras acciones como:
 - (a) la definición geométrica de las probetas usadas;
 - (b) las características de geometría necesaria para cada operación de mecanizado;
 - (c) las condiciones de corte y las características de las herramientas usadas (geometría y material);

- (d) las desviaciones microgeométricas y macrogeométricas:
- para la evaluación del perfil de la rugosidad superficial, se han utilizado como parámetros, la rugosidad media aritmética, R_a y la máxima altura del perfil, R_z ; además de analizar su influencia en el resto de variables de salida.
 - Para la evaluación de desviaciones macrogeométricas, se miden las desviaciones geométricas creadas en el mecanizado y el procedimiento usado para medirlas y el análisis de cómo influyen en las otras variables de salida.
- (e) de entre las propiedades mecánicas se consideran en su evaluación y su análisis, la microdureza superficial.
- (III) Justificación del modelo de RNA y enfoque de optimización de los hiperparámetros. Tratando de optimizar la precisión del modelo de regresión obtenido de las respectivas redes neuronales, se describen las fases a seguir desde la disposición de los datos de partida hasta la implementación final de la arquitectura idónea.
- (IV) Análisis y evaluación de resultados. Tras la fase experimental, se estará en disposición de realizar el análisis y discusión de los resultados durante el capítulo 5, que incluye el estudio matemático de los resultados logrados en los ensayos, para desarrollar modelos de redes neuronales eficientes y óptimas en función de determinados hiperparámetros previamente obtenidos que permitan relacionar variables de entrada (parámetros de corte) con variables de salida (el conjunto de variables relacionadas con la integridad superficial), y comparando los resultados con otros modelos no basados en redes neuronales.

La metodología experimental empleada en este trabajo en cuanto a la recogida y tratamiento de los datos, se basa en la de 4, cuyos resultados ya mencionados, estudian igualmente la integridad superficial en procesos de mecanizado en seco de aleaciones de aluminio para uso aeronáutico.

4.2. Planificación y ejecución de los ensayos

4.2.1. Variables consideradas en los ensayos

Debido al elevado número de variables (tanto de entrada como de salida), que intervienen en los procesos de mecanizado y con el objetivo de simplificación de los análisis, se mantienen fijo el valor de algunas variables de entrada, y otras podrán tomar distintos valores, para estudiar la influencia en las variables de salida que se consideran.

En la tabla siguiente se muestran las variables de entrada (tanto fijas como las que pueden modificarse) y las variables de salida.

Variables de entrada		Variables de salida
<i>Fijas</i>	<i>No fijas</i>	
Material Geometría y material de la hta. Condiciones de lubricación (seco)	v_c , f y a_p	Prop. geométricas (macro y micro) Prop. físico-químicas

Tabla 4.1: Variables de entrada y salida consideradas.

El material que se analiza es una aleación de aluminio-zinc UNS A97075-T6, muy usada en la fabricación de componentes estructurales en el sector aeronáutico.

Se establecen distintas geometrías de probeta, según el tipo de ensayo, teniendo en consideración las normas (ISO o UNE) que afecten al ensayo o a la variable que se analiza.

También se establece la herramienta de corte, material y geometría, para realizar todos los ensayos con una única tipología de herramienta de corte.

Se fija también el tipo de operación de mecanizado, el torneado, por ser fácil de observar y tomar medidas, además de que la mayoría de ensayos de propiedades mecánicas que se realizan necesitan geometrías de revolución que se obtienen fácilmente a través del torneado.

El mecanizado se realizará en seco (ausencia de fluidos de corte). Por su parte, las variables consideradas como parámetros de corte son las siguientes:

- (I) velocidad de corte (v_c);
- (II) avance (f);
- (III) profundidad de corte (a_p).

Las variables de salida que se han considerado son:

- (I) desviaciones microgeométricas (R_a y R_z);
- (II) desviaciones macrogeométricas (PAR, STR, CRO, RON, CON, CYL);
- (III) microdureza Superficial (HV).

4.2.2. Tipos de ensayos

Para evaluar las variables de salida se realizan distintos tipos de ensayos mecánicos, por un lado los encargados de determinar las desviaciones geométricas y por otro lado, los centrados en estudiar la microdureza superficial.

4.2.2.1. Ensayos para la caracterización de las desviaciones geométricas

Con estos ensayos se pretende valorar cómo influyen los parámetros de corte en el comportamiento de las desviaciones geométricas del material. Se realizan diversos ensayos de las piezas mecanizadas aplicando distintos valores de parámetros de corte.

Se han aplicado variaciones de v_c y f , mientras se mantenía constante a_p , ya que según estudios previos a_p es el parámetro que menos influye en el perfil de rugosidad de piezas torneadas.

Tanto la ejecución de los ensayos como el diseño de la probeta se realizaron según la norma ISO 1143:2010 de ensayos a fatiga de flexión rotativa en materiales metálicos [145] y la norma ISO 12107:2012 en relación al análisis de datos y proyección estadística de los ensayos a fatiga para materiales metálicos [146], con el objetivo de obtener el número de ensayos que se debían realizar en cada conjunto de parámetros de corte, puesto que el objetivo último era el estudio de la vida a fatiga.

De este modo, se llevaron a cabo las siguientes acciones:

- (I) el control geométrico de la probeta torneada para comprobar el cumplimiento de los requisitos de diseño.
- (II) La observación del estado de la herramienta cuando se finaliza cada operación de torneado, para conocer cómo influyen los parámetros de corte en el desgaste de la misma y la influencia en el comportamiento a fatiga.
- (III) El análisis de la morfología de la viruta creada en el mecanizado, clasificando los tipos de viruta según los parámetros de corte.
- (IV) El perfil de rugosidad obtenido en la pieza, determinando la calidad superficial mediante la rugosidad aritmética media (R_a) y la altura máxima del perfil (R_z), y estudiando cómo influyen los parámetros de corte.
- (V) La evaluación de las desviaciones macrogeométricas producidas en el proceso de torneado: rectitud, paralelismo, redondez, concentricidad, oscilación racial, oscilación radial total, y cilindricidad de las probetas torneadas.

4.2.2.2. Ensayos de microdureza superficial

En estos ensayos se evalúan cómo influyen los parámetros de corte, v_c , f y a_p , en la dureza superficial de las piezas mecanizadas. Se selecciona Vickers como ensayo de dureza superficial, muy usado en piezas mecanizadas, conforme a la norma UNE-EN ISO 6507-1:2018 sobre *Materiales metálicos. Ensayo de dureza Vickers. Parte 1: Método de ensayo* [147].

Tras mecanizar la probeta según las condiciones establecidas se realiza:

- (I) el control geométrico de la pieza torneada para comprobar el cumplimiento de los requisitos de diseño.
- (II) El ensayo Vickers de microdureza a baja carga, considerando la influencia de los parámetros de corte en el resultado final.

4.2.3. Geometría de las probetas

A continuación, se muestra la geometría de diseño para el ensayo de fatiga. Por otro lado, el diseño de la probeta para los ensayos de microdureza presenta una forma cilíndrica resultado de una única operación de cilindrado. Las dimensiones de cada zona para las probetas de ambos ensayos se recogen en las tablas 4.2 y 4.3 respectivamente en función del diámetro (D_z) y longitud (L_z) correspondientes.




Figura 4.1: Distinción de las zonas de una probeta para el análisis de las desviaciones geométricas y ensayos a fatiga por flexión rotativa (adaptado de [4]).

Zonas	D_z [mm]	L_z [mm]
Empotrada	15	30
Calibrada	7.5	25
Apoyada	15	65
Total	-	167

Tabla 4.2: Dimensiones de una probeta para el análisis de las desviaciones geométricas y ensayos a fatiga por flexión rotativa [4].

Zonas	D_z [mm]	L_z [mm]
Total	17	65

Tabla 4.3: Dimensiones de una probeta para ensayos de microdureza [4].

En cuanto a la geometría de las probetas empleadas para estudiar las desviaciones geométricas (y posterior ensayos de fatiga por flexión rotativa) viene establecida en la norma ISO 1143:2010 [145]. Se selecciona la denominada geometría *Cylindrical smooth specimen*, puesto que es la admite una tensión mayor en la sección esperada de rotura de la probeta, entre las distintas geometrías que plantea la norma.

El ensayo a fatiga se realiza situando una carga en un extremo, y quedan establecidas tres zonas diferentes según la figura 4.1.

De acuerdo con la figura 4.1, es posible distinguir:

- (I) la zona empotrada, la más cercana al plato de garras, con una sujeción equivalente a un empotramiento de una estructura.
- (II) La zona calibrada intermedia, correspondiendo con la zona más probable de rotura en los ensayos a fatiga.
- (III) Y la zona apoyada, en el extremo contrario a la probeta, encontrándose apoyada en el contrapunto en el torneado, llamada así por el paralelismo con el apoyo de una estructura.

Según la norma UNE-EN ISO 6507-1:2018 [147] no se indican requisitos ni dimensionales ni geométricos en la probeta destinada para ensayo, pero sí recoge que en caso de superficies curvas se necesitará un ajuste del valor que se obtiene, si la huella que se genera en el ensayo alcanza unas determinadas dimensiones. Por tanto, buscando la simplicidad, se elige una geometría cilíndrica (15 mm de diámetro) y 65 mm de longitud, para no tener que llevar a cabo ningún de ajuste de acuerdo a la norma.

4.2.4. Herramienta de corte

La geometría final de las probetas se obtiene mediante mecanizado en un CNC, seleccionando como herramienta de corte una placa neutra de carburo de wolframio en matriz de cobalto, sin recubrimiento, marca SECO, y referencia ISO DCMT 11T308-14 IC20. En la siguiente figura se recogen las características de esta herramienta.




Figura 4.2: Herramienta de corte DCMT 11T308-14 IC20 y representación de ángulos principales de corte (adaptado de <https://www.iscar.com> y [4]).

L (mm)	IC (mm)	S (mm)	RE (mm)	D_1 (mm)
11.60	9.52	3.97	0.80	4.40

Tabla 4.4: Dimensiones de la herramienta de corte.

Dichas herramientas se colocan en un portaherramientas con sección 16 x 16 mm, y referencia SDNCN 1616H1, con un ángulo principal de filo de corte (κ_r) de 62.5°.

Las misma condiciones se aplican en cada uno de los ensayos que se realizan (microdureza y desviaciones geométricas), mecanizando en una misma dirección, y tanto en operaciones de acabado como en las de desbaste. En la de acabado se utiliza un filo de corte nuevo de los dos que tiene una herramienta.

4.2.5. Valores de los parámetros de corte empleados

Para los desbastes se utilizan condiciones de corte fijas con $v_c = 60$ m/min y $f = 0,20$ mm/rev, y una $a_p = 1$ mm. Con estas condiciones se logra eliminar una tasa grande de material sin producir importantes vibraciones en el mecanizado y sin desgaste excesivo en la herramienta de corte.

Para las operaciones de acabado, se establecen distintas condiciones de corte según el tipo de ensayo mecánico para el que se fabrica la probeta (microdureza y desviaciones).

Se utilizan parámetros de corte utilizados comúnmente en las operaciones de mecanizado a nivel industrial para estas aleaciones.

Aunque estas aleaciones se puede mecanizar a velocidades de corte altas (MAV) [148], al mecanizarse híbridados con otros materiales (como titanio u otros materiales de matriz polimétrica con fibra de carbono, CFRP) que no soportan altas velocidades, dichos valores deben bajarse.

Además, ya que las probetas torneadas tienen diámetros muy pequeños, seleccionar velocidades de corte muy altas ocasionaría que se utilizaran velocidades de giro de cabezal muy altas lo que podía generar niveles de vibraciones altos, distorsionando los resultados.

En los ensayos de fatiga y evaluación de las desviaciones microgeométricas y de forma, se fija un único valor de profundidad de corte por el número alto de ensayos y su duración de acuerdo con la siguiente tabla.

v_c (m/min)	f (mm/rev)	a_p (mm)
	0.05	
40	0.10	
60	0.15	1
80	0.20	

Tabla 4.5: Parámetros de corte empleados en los ensayos para la caracterización de las desviaciones geométricas.

En los ensayos de dureza, se han usado distintas condiciones de corte, combinando variaciones de velocidad de corte, de avance y de profundidad de corte, también según la tabla 4.5.

Después se realiza un estudio aumentando la profundidad de corte y considerando valores de v_c y f más altos. Con este aumento se persigue evaluar si se suscitan variaciones en relación a los resultados obtenidos a partir en los ensayos previos, motivando la necesidad de futuros estudios que cuantifiquen como influyen estos parámetros de corte en la microdureza.

v_c (m/min)	f (mm/rev)	a_p (mm)
	0.05	
40	0.10	
120	0.15	1.5
	0.20	

Tabla 4.6: Parámetros de corte empleados en los ensayos de microdureza.

4.2.6. Evaluación de las desviaciones geométricas

4.2.6.1. Evaluación de las desviaciones microgeométricas

En las probetas mecanizadas se realizan mediciones a escala microgeométrica, capturando el perfil de rugosidad, considerando como parámetros para evaluar estas desviaciones la rugosidad media aritmética (R_a) y la máxima altura del perfil (R_z), dada la influencia de estos parámetros en la aparición de microgrietas y, en consecuencia, en las propiedades mecánicas de las piezas.

Se utiliza el rugosímetro tipo portátil de la marca MITUTOYO y modelo SURFTEST SJ-210, conectado con el sistema de avance, que se encuentra disponible en los laboratorios de Metrología en el Área de Ingeniería de Procesos de Fabricación de la Universidad de Málaga como puede verse en la figura 4.3.

Para la medición, se tienen en consideración las especificaciones de la norma UNE EN-ISO 4288:1998 [149].




Figura 4.3: Sistema de medida de la rugosidad superficial (adaptado de [4]).

Para las probetas usadas en los ensayos de microdureza, las medidas de rugosidad se llevan a cabo en el tramo que se encuentra a 32 mm del extremo de apoyo, en el contrapunto del torno. Se toman dichas medidas en 4 generatrices en posiciones equidistantes, siendo los resultados finales de R_a y de R_z los calculados mediante el valor promedio de las 4 medidas (figura 4.4).




Figura 4.4: Medición de la rugosidad superficial (adaptado de [4]).

4.2.6.2. Evaluación de las desviaciones macrogeométricas

Las mediciones se realizan directamente con la probeta montada en el torno. Una vez mecanizada, y por causa del incremento térmico que padece la probeta al mecanizarse, se deja enfriar para que la pieza, mientras se está realizando la medida, no se vea expuesta a dilataciones térmicas, que provocaría errores de medición.

Después se monta un reloj-comparador (mod. STANDARD GAGE), con división de escala 0.001 mm, en el porta-herramientas del torno, con desplazamiento en el eje Z. Además de medir las probetas, se controla la rigidez y oscilación radial total del eje de

la herramienta y los carros, para evaluar cómo contribuyen a las desviaciones de forma. Se comprueba que estas desviaciones tienen un orden de magnitud muy por debajo a las que se obtienen cuando varían los parámetros de corte.

Se toman medidas en distintas zonas de la probeta; en la zona apoyada se toman medidas en 3 secciones que se encuentran separadas 20 mm entre ellas como puede verse en la figura 4.5; en la zona calibrada se toman medidas en 6 secciones, con 4 mm de separación entre ellas; y en la zona empotrada se toman medidas en 3 secciones, separadas por 10 mm. Además, para cada sección se toman medidas de desviaciones para cada 30° de giro.




Figura 4.5: Secciones de medida para estudiar las desviaciones geométricas con reloj comparador (adaptado de [4]).

Los resultados que se obtienen se tratan matemáticamente y así se logran las diferentes desviaciones macrogeométricas, peculiares en las piezas de revolución.

Entendiéndose por PAR, el paralelismo; STR, la rectitud; CRO, la oscilación radial; RON, la redondez; CON, la concentricidad y CYL, la cilindricidad.

4.2.7. Evaluación de las propiedades mecánicas

En el estudio de la integridad superficial en piezas mecanizadas, el estudio de la influencia de las condiciones de mecanizado sobre las propiedades mecánicas toma especial interés. En este apartado se expone la metodología experimental que se emplea para la realización de este análisis.

4.2.7.1. Ensayos de la microdureza superficial

La microdureza superficial es una de las propiedades mecánicas de mayor interés por la influencia que ésta puede suponer para otras propiedades mecánicas [150].

En relación a la metodología usada para evaluar la probable influencia de los parámetros de corte en la microdureza superficial de las piezas mecanizadas en seco y la aleación de referencia estudiada, se tornean distintas probetas. Y el ensayo para la microdureza se realiza con un microdurómetro (MATSUZAWA, mod. MXT 70) como puede observarse en la figura 4.6, que presenta información sobre las longitudes de las 2 diagonales y el valor de la dureza (expresada en unidades de kg/mm^2).




Figura 4.6: Ensayos de microdureza superficial Vickers [4]. (a) Microdurómetro MATSUZAWA empleado para los ensayos de microdureza. (b) Detalle de la probeta siendo inspeccionada en el microdurómetro.

Se realizan ensayos Vickers, muy usado en estudios de microdureza para estos materiales [151] con carga de 0.05 kgf (HV 0.05), y valores de carga entre 0.01 y 0.20 kgf, según norma UNE-EN ISO 6507-1:2018 sobre *Materiales metálicos. Ensayo de dureza Vickers. Parte 1: Método de ensayo* [147].

Se fija una generatriz tras la que se realizan 4 indentaciones. Los ensayos se realizan en puntos separados por 10 mm, considerando la primera a 15 mm del borde de la probeta. El valor de dureza se obtiene promediando los valores de las cuatro indentaciones como puede verse en la figura 4.7.




Figura 4.7: Ajuste de la huella para obtener el valor de microdureza [4].

Tras realizar los ensayos de dureza, se toman muestras de las probetas torneadas mecanizadas realizando un análisis SEM del borde de la probeta, de modo que se pueda lograr una imagen de la microestructura superficial para analizar cómo influye el mecanizado en la superficie de la probeta.

Si se consideran todas las combinaciones de los parámetros de corte usadas en el torneado de las distintas muestras y las repeticiones realizadas del ensayo, se realizan 80 ensayos de microdureza en total.

4.3. Enfoque de predicción y optimización de las propiedades relacionadas con la integridad superficial a través de RNAs

La propuesta del enfoque para predecir algunas de las propiedades relacionadas con la integridad superficial (propiedades micro y macrogeométricas) junto a la microdureza superficial (como propiedad mecánica) presentada en este Trabajo Fin de Grado, puede representarse como el flujo de

datos \longrightarrow *estimación/predicciones* \longrightarrow *optimización* \longrightarrow *decisiones*.

Como decisor, se busca resolver un problema de inferencia en el que se pretende encontrar la solución óptima de los parámetros de corte que maximicen la microdureza y minimicen el conjunto de desviaciones de forma y la rugosidad superficial. Para ello, será necesario previamente la estimación de los parámetros de corte (v_c , f y a_p) que conducen a ciertos valores de las propiedades ligadas a la integridad superficial, basada en la distribución del conjunto de datos experimentales recabados. El objetivo último es poder responder a la siguiente cuestión: *¿Qué condiciones de trabajo durante el mecanizado en seco de la aleación UNS A97075-T6 logran mejorar la integridad superficial?* Para ello, la metodología abarca dos frentes.

En primer lugar, es necesario estimar las propiedades relacionadas con la integridad superficial. Con este objetivo, se recurren a las Redes Neuronales Artificiales a través del MATLAB *Neural Network Toolbox library*. La arquitectura de partida es la de *Feedforward Neural Network* (FNN), con un máximo de tres entradas (los parámetros de corte) y una salida (las propiedades que conforman la integridad superficial). La fórmula que se destina para las labores de entrenamiento, validación y prueba es de un 70-15-15 (%) respectivamente.

Previo a optimizar los principales hiperparámetros de las RNA, se procede a una revisión del Estado del Arte para conocer el valor de estos parámetros que determinan el rendimiento del modelo predictivo para casos con *outputs* y condiciones similares. Partiendo de esta referencia, se plantea la posibilidad de optimizar el algoritmo de aprendizaje, número de capas y neuronas ocultas óptimos para una mismo lote aleatorio de *training*, *validation* y *test* con el fin de aislar la influencia de los datos.

Para reducir la variabilidad de los resultados, se repite el proceso 200 iteraciones. La métrica empleada para la comparación entre modelos es la Raíz del Error Cuadrático Medio (RMSE, *Root-Mean-Square Error*) que puede definirse como

$$\text{RMSE} = \sqrt{\frac{1}{T} \sum_{t=1}^n (\hat{y}_t - y_t)^2}, \quad (4.1)$$

donde \hat{y}_t es el valor predicho por el modelo (*model computed value*), y_t es el valor real ensayado (*measured value*), y n es el número total de observaciones. Su elección frente a otras como MAE o MSE se justifica a partir del hecho que proporciona información físicamente interpretable del problema de regresión planteado (expresada en μm , indica en qué grado se desvía la estimación del valor real), además de que es fácilmente derivable y no penaliza los errores tanto como MSE debido a la raíz cuadrada.

Una vez valorada la influencia de la topología de la RNA, en una segunda fase, fijados todos los hiperparámetros anteriores excepto el número de neuronas en la capa oculta (que varía de 1 a 50), se pretende estudiar cómo afecta al sistema, variar los datos destinados a cada una de las fases hasta encontrar ciertas combinaciones de valores para entrenamiento y validación-test que arrojen una mejora significativa en la precisión del modelo. Tras ejecutar el algoritmo, se comprueba que algunas combinaciones de ensayos resultan más productivas si se destinan a ciertas fases y que por tanto mejoran la calidad del sistema. Este criterio de diseño, como se comprobará, prevalece sobre la elección del resto de hiperparámetros (*the higher the quality of the training data is, the better will the machine learning model be*, [152]).

Superadas las dos primeras fases y optimizada la arquitectura de la RNA para cada una de las variables de estudio, se comparan la estimaciones obtenidas con modelos analíticos tradicionales como los modelos potenciales y el de la Metodología de Superficie Respuesta con objeto de validar los resultados del modelo de aprendizaje automático. Para ello se recurre al coeficiente de determinación (R^2),

$$R^2 = \frac{\sum_{t=1}^T (\hat{y}_t - \bar{y})^2}{\sum_{t=1}^T (y_t - \bar{y})^2}, \quad (4.2)$$

con \bar{y} entendida como la media de la observación y .

En una tercera fase dentro del bloque de la predicción a partir de RNAs y de la optimización de los principales hiperparámetros del modelo, se estudia qué calidad presentaría un modelo como el obtenido tras alcanzar secuencialmente la fase 2 frente (con una única salida) a uno que integrase tantas salidas como variables se buscan predecir. En este apartado, se valoran las diferencias entre ambas opciones.

Habiendo decidido cómo resolver el problema de estimación a partir de un modelo de RNA optimizado, cabe *fixar* la arquitectura idónea. Para ello, existen dos opciones. Bien se almacenan los valores de los pesos y *bias* del modelo en cuestión en variables auxiliares (*e.g.* `w_imput`, `w_hidden`, `bias_imput`, `bias_hidden`) como

```
w_imput ← net.IW{1,1};
w_hidden ← net.IW{2,1};
bias_imput ← net.b{1};
bias_imput ← net.b{2};
```

o bien se fija el valor de las semillas responsable de la inicialización aleatoria de los pesos en cada ejecución (*e.g.* `semilla_fija`) a partir de

```
RandStream.setGlobalStream(RandStream('mrg32k3a', 'Seed', semilla_fija));
```

conservando en ambos, los *arrays* óptimos de los valores destinados a cada una de las fases, previamente calculados

```
optimal_train_index ← net.divideParam.trainInd;
optimal_val_index ← net.divideParam.valInd;
optimal_test_index ← net.divideParam.testInd;
```

fijando el valor de la semilla, se consigue *congelar* el modelo obtenido de la RNA, eliminando por completo la variabilidad de la predicción calculada por el algoritmo tras cada ejecución. Sin embargo, conservando el valor de los pesos y *bias* de la arquitectura óptima, se reduce en gran medida la fluctuación de las estimaciones obtenidas en cada ejecución pero sigue existiendo cierta variación.

Por último, teniendo fijado el sistema que predice con suficiente precisión el valor de los parámetros de corte que dan lugar a ciertos resultados de las variables de interés, se está en disposición de optimizar analíticamente los *inputs* que maximizan y minimizan simultáneamente distintas propiedades de la integridad superficial y poder tomar las decisiones oportunas tras haber respondido a la pregunta planteada al inicio.

Las fases que integran el enfoque propuesto pueden verse reflejadas en la figura [5.3](#) a modo de *visual abstract*.

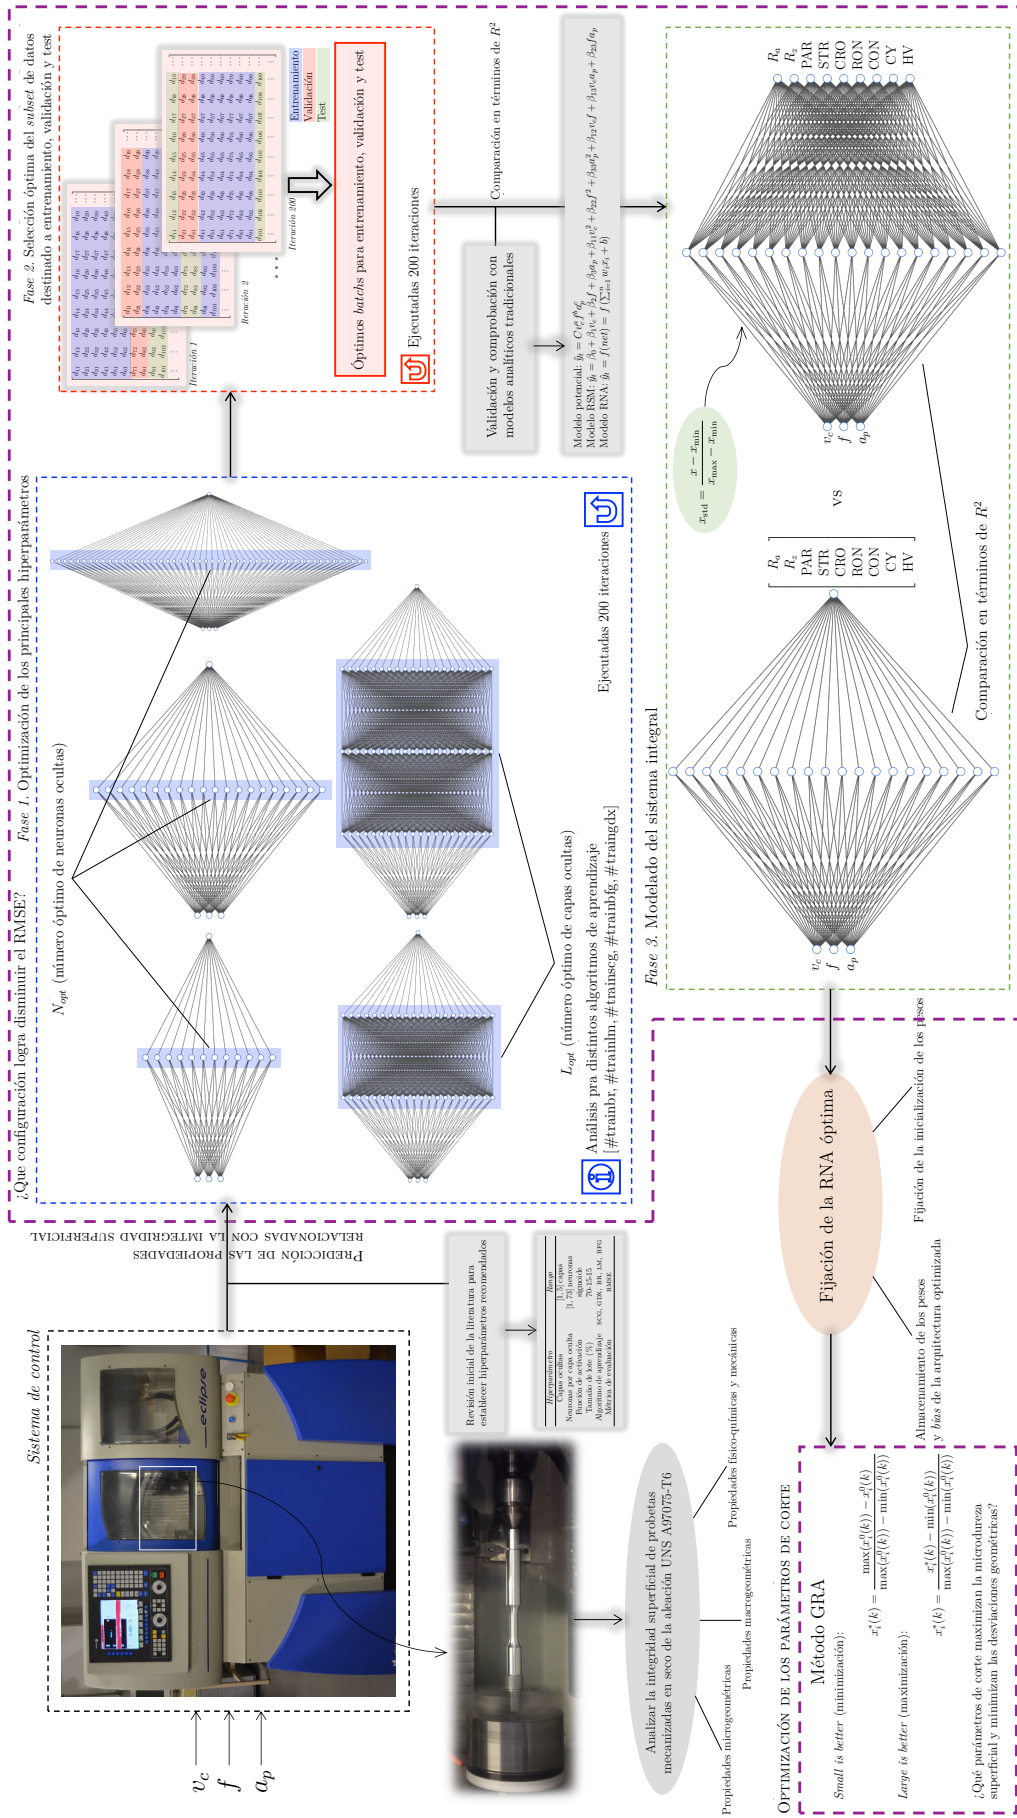


Figura 4.8: Metodología propuesta para la estimación-optimización de propiedades ligadas con la integridad superficial a partir de RNAs.

Capítulo 5

Resultados y discusión

5.1. Introducción

En este capítulo se presentan y discuten los resultados obtenidos tras la optimización de los principales hiperparámetros de las RNA empleadas para predecir el conjunto de propiedades micro y macrogeométricas junto las mecánicas a partir de la microdureza superficial en función de los parámetros de corte (v_c , f y a_p). Para ello, se exponen gráficamente diferentes familias de curvas de nivel que relacionan las condiciones de corte con los valores estimados de los predictores. Asimismo, a fin de validar los resultados obtenidos, se contrastan con modelos matemáticos clásicos como el potencial o la metodología de superficie de respuesta (RSM) que explican con otro nivel de ajuste, el comportamiento de las variables de interés. Para terminar, se incluye la integración de la familia de propiedades relacionadas con la integridad superficial en una única red neuronal y se compara su rendimiento con los modelos individuales obtenidos en apartados previos junto a la optimización de los parámetros de corte.

5.2. Ajuste de Hiperparámetros

Una de las etapas clave que enfrenta un proyecto *Deep Learning* es la de seleccionar la configuración de los hiperparámetros que gobiernan el proceso de aprendizaje del sistema, tratando de aumentar en rendimiento computacional y precisión (*tuning hyperparameters*) [153], [154], [155]. Esto implica explorar y analizar la influencia del conjunto de parámetros de control (*v.g.* número de capas ocultas y neuronas en cada una de ellas, función de activación, algoritmos de aprendizaje, optimizador, tasa de aprendizaje, el tamaño de lote o el *momentum* entre otros), por lo que suele tratarse de un tarea costosa en cuanto al número de ejecuciones requeridas.

Para el caso del presente proyecto, se ha planteado desarrollar una metodología que trate de determinar algunos de los hiperparámetros a nivel de estructura y topología de la RNA de mayor influencia en la precisión final arrojada por el modelo, más allá de la búsqueda manual basada en un proceso *trial-and-error* [156]. No obstante, la naturaleza estocástica de estos algoritmos complica la posibilidad de obtener patrones o comportamientos generales de las variables relacionadas con la arquitectura y el aprendizaje al verse influenciados por la aleatoriedad en la sección de los datos destinados para entrenamiento o incluso debido variaciones internas en el entorno de desarrollo de ejecución y en ocasiones, no se llegan a resultados concluyentes [157].

Tratando de dar respuesta a esta problemática y aplicando este enfoque al modelado de la rugosidad media aritmética (R_a), previamente se exponen los valores extremos (máximos y mínimos) de cada uno de estos atributos con resultados satisfactorios de acuerdo con la literatura. En la siguiente tabla se muestra el rango para cada hiperparámetro con su respectiva referencia.

Hiperparámetro	Rango	Referencia
Capas ocultas	[1, 5] capas	[158], [159]
Neuronas por capa oculta	[1, 73] neuronas	[160], [161]
Función de activación	sigmoide	[161], [159], [127]
Tamaño de lote (%)	70-15-15	[162], [163]
Algoritmo de aprendizaje	SCG, GDX, BR, LM, BFG	[158], [163]
Métrica de evaluación	RMSE	[164], [163]

Tabla 5.1: Rango de valores de los hiperparámetros según la literatura.

El primer lugar, suponiendo como arquitectura de partida una red de una sola capa oculta (SLFN, *Single Hidden Layer Feedforward Neural Network*) cuyas variables de entrada sean los parámetros de corte (v_c y f) y de salida la rugosidad superficial (R_a), con 10 neuronas¹ (N), un 70 % de los datos destinados a entrenamiento, un 30 % para validación y prueba a partes iguales y como funciones de activación logística, la sigmoide (entre la capa de entrada y la oculta) y la lineal (entre la capa oculta y la de salida), se pretende determinar qué algoritmo de aprendizaje resulta más idóneo. Para ello y haciendo uso de la función implementada por Matlab (`dividein`) para garantizar que los valores destinados a entrenamiento, validación y test son los mismos para todos los casos, se ensayaron las 5 arquitecturas, *Bayesian Regularization* (BR), *Levenberg–Marquardt* (LM), *Scaled Conjugate Gradient Backpropagation* (SCG), *quasi-Newton Backpropagation* (BFG) y *Gradient Descent* (GDX) para un total de 200 iteraciones.

¹Dentro del intervalo recomendado por la literatura mostrado en la tabla 5.1 y el óptimo según [158].

De acuerdo con la propia documentación de Matlab [144], en general, en problemas de aproximación de funciones, para redes no excesivamente complejas, el algoritmo de *Levenberg-Marquardt* tendrá la convergencia más rápida. Esta ventaja es especialmente notable si se requiere un entrenamiento muy preciso. En muchos casos, `trainlm` es capaz de obtener errores cuadráticos medios más bajos que cualquiera de los otros algoritmos probados. Sin embargo, a medida que aumenta el número de pesos de la red, su capacidad se ve reducida. Además, los requisitos de almacenamiento que precisa son mayores que los de los demás algoritmos probados. De forma similar, `trainbr` actualiza los valores de peso y sesgo de acuerdo con la optimización *Levenberg-Marquardt*. No obstante, minimiza una combinación lineal de errores cuadráticos y pesos en lugar del error cuadrático medio como este último. También modifica la combinación lineal para que, al final del entrenamiento, la red resultante tenga buenas calidades de generalización.

Por otro lado, los algoritmos de gradiente conjugado, en particular `trainscg`, opera bien en una amplia variedad de problemas, en particular para redes con un gran número de pesos. El algoritmo SCG es casi tan rápido como el algoritmo LM en problemas de aproximación de funciones (más rápido para redes grandes). Estos algoritmos exigen unos requisitos de memoria relativamente modestos.

Asimismo, el rendimiento de `trainbfg` es similar al de `trainlm` y no requiere tanto almacenamiento, pero la potencia de cálculo que demanda aumenta proporcionalmente con el tamaño de la red, ya que ha de calcularse el equivalente a una matriz inversa para cada una de las iteraciones.

Por último, el algoritmo de tasa de aprendizaje variable (`traingdx`) suele ser mucho más lento que los otros métodos, precisando de unos requisitos de almacenamiento moderados y resultando idóneo para aplicaciones en las resulta más conveniente converger lentamente (*e.g. early stopping*, donde se podrían obtener resultados incoherentes si el algoritmo converge demasiado rápido al sobrepasar el punto en el que se minimiza el error en el conjunto de validación). En la figura 5.1 se muestra la distribución del RMSE para los distintos algoritmos de aprendizaje.

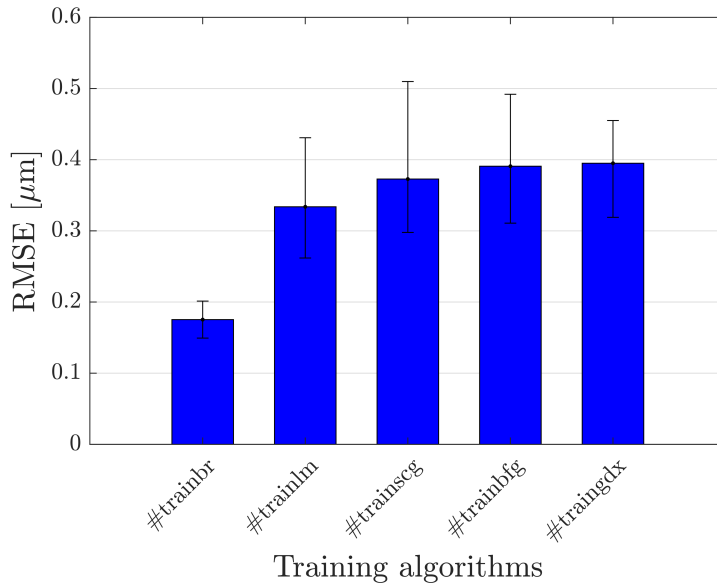


Figura 5.1: Distribución del RMSE para los distintos algoritmos de aprendizaje. En las barras de error se muestran los valores máximos (RMSE_{max}) y mínimos (RMSE_{min}) alcanzados durante el total de iteraciones.

Como puede observarse, la función de entrenamiento de regularización Bayesiana es la que mejor comportamiento muestra, con un valor del RMSE medio de $0.1753 \mu\text{m}$ frente a los métodos de Levenberg–Marquardt, Retropropagación de gradiente conjugado escalado, quasi-Newton y Retropropagación del gradiente descendente con 0.3338 , 0.3728 , 0.3908 y $0.3950 \mu\text{m}$ respectivamente. A pesar de la variabilidad de los resultados obtenidos tras ejecutar repetidas veces el código, se observa que el valor de RMSE_{max} es cuantitativamente inferior a la del resto de casos (del orden de 5 veces), especialmente con respecto a los algoritmos de SCG y de BFG (igual ocurre para el RMSE_{min}). La precisión obtenida con estos dos últimos junto al GDX es muy similar y la diferencia entre ellos es prácticamente despreciable en comparación al LM y especialmente al BR.

Por tanto, una vez analizada la influencia de los métodos empleados en el entrenamiento y generalización del modelo, se ha optado por seleccionar el de Regularización Bayesiana (`trainbr`) para la optimización del resto de los hiperparámetros.

Uno de los parámetros críticos para determinar la arquitectura idónea de la red es el número de capas ocultas [165] propia de la topología del Perceptrón Muticapa, cuyo efecto tiene una influencia directa en la calidad de la predicción de la variable de salida en un problema de regresión como este.

A priori, parece probable razonar que las redes de aprendizaje profundo (*Deep Learning*, a partir de 3 capas ocultas) sean capaces de inferir características más complejas y mostrar una precisión relativamente mayor que aquellas SLFN. Es por ello, por lo que, para problemas complejos en masa de datos a varios niveles de varios niveles de abstracción, aumentar la escala de la red añadiendo más capas, pueda resultar un método efectivo. En este sentido, se han desarrollado gran número de metodologías que buscan reducir el tiempo de entrenamiento y ejecución en CPU a la vez que maximizar la calidad de la predicción [166], [167], [168], [169], [170]. En ellos se demuestra que para la mayoría de problemas complejos no lineales, dos capas ocultas resulta más que suficiente. Incluso se puede optar a una tercera si el criterio principal de diseño es el de alcanzar una precisión mínima lo suficientemente elevada.

Por tanto, normalmente (para pequeños *datasets*) se puede considerar que con una o dos capas ocultas, en función de la complejidad del problema, el sistema es capaz de predecir con suficiente calidad. De hecho, aumentar innecesariamente el número de capas puede resultar improductivo al conducir a sobreajuste (*overfitting*), al aumentar por tanto el número de neuronas, lo hace el número de mínimos locales (así como la varianza) con la consiguiente pérdida de generalización. Para tratar de reducir la varianza; es necesario suavizar los *outputs* de la red, lo que puede llevar al aumento del sesgo y que el error de generalización vuelva a dispararse (*underfitting*). De ahí, la importancia del equilibrio entre sesgo y varianza [171]. En cualquier caso, en caso de incrementar el número de capas es conveniente hacerlo siguiendo la regla piramidal; es decir, el número de neuronas por capa deberá ir disminuyendo hasta la capa de salida.

En la figura 5.2 se muestra la distribución que sigue el RMSE al variar el número de capas ocultas (*hidden layers*) desde 1 (SLFN) hasta 10 tras 200 ejecuciones manteniendo constante los sets de datos destinados a entrenamiento, validación y prueba. A partir del ensayo de las 2000 redes ejecutadas, se observa que más de dos capas ocultas desfavorece el resultado de la estimación obtenida.




Figura 5.2: Distribución del RMSE variando el número de capas ocultas. En las barras de error se indican los valores máximos ($RMSE_{max}$) y mínimos ($RMSE_{min}$) obtenidos durante el total de iteraciones.

El modelo que mayor rendimiento presenta es el de 2 capas ocultas (con un valor de $RMSE=0.1844 \mu m$) cercano al de una sola capa ($RMSE=0.1872 \mu m$). A partir de 2 capas esta métrica crece linealmente, para 3 y 4 capas (pasando de 0.3987 a $0.5032 \mu m$). A partir de 4 capas, el valor del error se mantiene constante e independiente del número de capas ($RMSE=0.5032 \mu m$) hasta que vuelve a incrementarse para 10 capas ocultas ($RMSE=0.5530 \mu m$).

Atendiendo a los valores máximos y mínimos del error que reflejan el rango de incertidumbre, y al comparar los modelos de una y dos capas ocultas, se observa que el modelo de una sola capa oculta presenta una menor dispersión de los valores extremos ($RMSE_{max} = RMSE_{min} = 0,022 \mu m$) en comparación con el modelo de dos capas ocultas ($RMSE_{max} = RMSE_{min} = 0,03 \mu m$). Esta menor dispersión sugiere una mayor consistencia y estabilidad en las predicciones del modelo de una sola capa oculta. Asimismo es preciso resaltar una mayor variabilidad observada en los modelos de 3 y 10 capas ocultas. Estos modelos muestran una dispersión más amplia de los valores extremos del RMSE, con $RMSE_{max} = RMSE_{min} = 0,151 \mu m$ y $RMSE_{max} = RMSE_{min} = 0,111 \mu m$, respectivamente. Este mayor nivel de incertidumbre puede indicar una sensibilidad más pronunciada a la influencia del resto de hiperparámetros influyentes o una capacidad limitada para generalizar correctamente nuevos datos. Por otro lado, la dispersión nula de los valores de RMSE alcanzados para el rango de 4 a 9 capas refleja una buena confiabilidad de los resultados obtenidos.

Por tanto y a pesar de que el modelo de dos capas ocultas muestra un ligero aumento en el rendimiento en términos de RMSE (0.1872 μm frente a 0.1844 μm), esta mejora es marginal y constituye una diferencia inferior al 1.5 % en precisión. Esta pequeña diferencia de mejora no justifica una mayor complejidad y tiempo de ejecución asociados con el modelo de dos capas, lo que respalda la elección de utilizar una sola capa oculta en el diseño de la red.

Otro de las variables cruciales para garantizar un buen comportamiento de la red, es el número óptimo de neuronas en la capa oculta (N_{opt}). Al igual ocurría con el número de capas ocultas, un número excesivamente bajo puede llevar a un ajuste insuficiente al carecer el modelo de complejidad [172]. Por el contrario, demasiadas neuronas pueden desencadenar un sobreajuste y aumentar innecesariamente el tiempo de entrenamiento. Para ello, diversos trabajos han tratado de establecer aproximaciones empíricas a partir del número del número de neuronas en las capas de entrada (N_x) y salida (N_y) como el que propone [158] de acuerdo con,

$$N_{opt} \sim \frac{2(N_x + N_y)}{3}, \quad N_{opt} < 2N_x, \quad N_{opt} \sim \sqrt{N_x N_y}. \quad (5.1)$$

Tal y como se ha descrito en el capítulos anteriores, la arquitectura que comparten todas las redes que predicen las propiedades micro y macrogeométricas así como las propiedades físico-químicas cuentan con una capa de entrada de dos neuronas (los parámetros de corte, v_c y f) y una neurona en la de salida (la variable objetivo). Luego, de acuerdo con esta sugerencia, $N_{opt} = 2$. En caso de diseñar una red cuyas salidas, cuyo conjunto de las variables respuesta sean todas las que se analizan en el presente proyecto, el número óptimo de neuronas sería $N_{opt} = 8$. Por otro lado, siguiendo las recomendaciones de [173], N_{opt} vendrá igualmente dado a modo de *thump rule*,

$$N_x < N_{opt} < N_y, \quad N_{opt} \sim \frac{2}{3}N_x + N_y, \quad N_{opt} < 2N_y. \quad (5.2)$$

En este caso, el $N_{opt} = 3$ para las redes de una neurona en la capa de salida y $N_{opt} = 17$ en caso de querer predecir el conjunto completo de propiedades relacionadas con la integridad superficial en un único sistema. En este sentido, diversas investigaciones se han enfocado en el complejo reto que supone cuantificar la influencia de esta variable en el precisión final de las variables predictoras [174], [175], [176], como el famoso algoritmo de Garson [177] que, al igual que este trabajo, se centra en identificar el nivel de importancia relativa de cada uno de los atributos influyentes en el comportamiento de la red y poder servir de técnica selectora de las características idóneas. Asimismo, otras metodologías se ayudan de árboles de decisión [178] o añadiendo neuronas una por una hasta verificar hasta que el error pasa a ser considerablemente pequeño (SOA, *Sequential*

Orthogonal Approach) [179] o a partir de la *elbow rule* [180] que trata de obtener el número óptimo de nodos y épocas de entrenamiento que brinden el mejor equilibrio entre la precisión de la red, el tiempo de entrenamiento y el riesgo de sobreajuste del modelo, pasando a depender en la mayoría de casos de la experiencia del diseñador.

Durante las últimas dos décadas, como ya se han visto, se han desarrollado varios modelos que tratan de determinar el número idóneo de neuronas ocultas, siendo buena parte de ellos de carácter heurístico; no obstante no existe una teoría unificadora para determinar el número necesario para la aproximación de una función dada en una sola capa oculta [174]. En la práctica, se ha demostrado que el número de nodos ocultos depende en gran medida de la complejidad de la función que se pretende aproximar, el número de entradas y salidas y principalmente del número de muestras de entrenamiento, del nivel de ruido en ellas y del algoritmo de entrenamiento.

Tratando de desarrollar un enfoque alternativo a los ya presentes en la literatura y determinar, de forma aislada, si es posible establecer una correlación entre la minimización de este hiperparámetro y la maximización de la capacidad de generalización de la red, se ejecutaron un total de 10.000 redes neuronales tras variar el número de neuronas en la capa oculta de 1 a 50 e iterar este proceso 200 veces.

Del conjunto de RNAs operadas, la figura 5.3 muestra aquellas combinaciones agrupadas por número común de neuronas ocultas (de 1 a 50) en las que se detuvo la fase de entrenamiento al minimizarse la métrica del RMSE. Los resultados revelan que el número de neuronas más frecuente es $N = 42$ (en el 7% de los casos); es decir, manteniendo el resto de hiperparámetros ya mencionados constantes, considerando como variable de salida la rugosidad aritmética (R_a), para un mismo set de datos de entrenamiento, evaluación y prueba, ejecutar el sistema con dicho número de neuronas es la opción que probabilísticamente está asociado a un menor RMSE.

Además muestra un resultado coherente con el comportamiento teórico. Un número de neuronas excesivamente reducido o desproporcionado puede ocasionar problemas de *underfitting* o *overfitting* respectivamente, de ahí que la zona central (en torno a $N = 40$ neuronas) sea la que mayor repetibilidad muestra. Resulta necesario mencionar que diseñar el sistema con dicho número de nodos en la capa oculta no garantiza una precisión notablemente superior del resultado final, ni si quiera que del total de las redes ensayadas, la óptima converja para dicho número de neuronas, como se comentará más adelante.

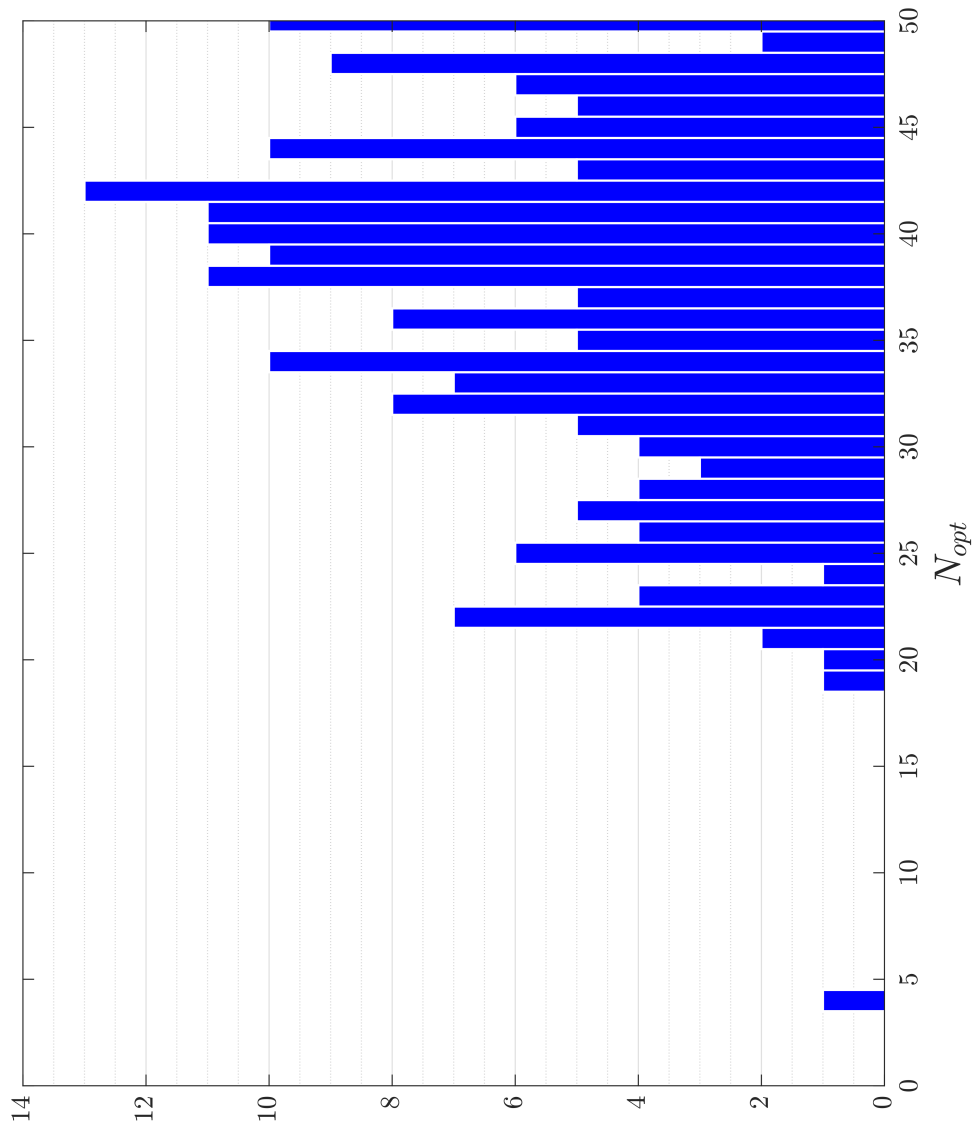


Figura 5.3: Histograma del número óptimo de neuronas considerado en la capa oculta ($N_{opt} \in [1, 50]$) que minimiza el RMSE tras el total iteraciones.

Tratando de limitar el número de neuronas en la capa oculta para economizar en tiempo de ejecución, de acuerdo con los resultados obtenidos tras revisar la literatura [176], [181] y siguiendo las recomendaciones de [182] que demuestra que la mayoría de problemas no lineales pueden resolverse con menos de 50 nodos ocultas con precisión suficiente, se repite el proceso iterando para N comprendido entre 1 y 20.

Mientras que en la figura 5.3, los casos que mostraban 20 neuronas o menos representaban un 4.5% del total, al ejecutar de nuevo la red para un número de neuronas más reducido, se obtiene un comportamiento exponencial donde la mayoría de valores se concentran para N comprendido entre 15 y 20 neuronas (63%) que apuntan a que el comportamiento mejora conforme éste crece.




Figura 5.4: Histograma del número óptimo de neuronas considerado en la capa oculta ($N_{opt} \in [1, 20]$) que minimiza el RMSE tras el total de iteraciones.

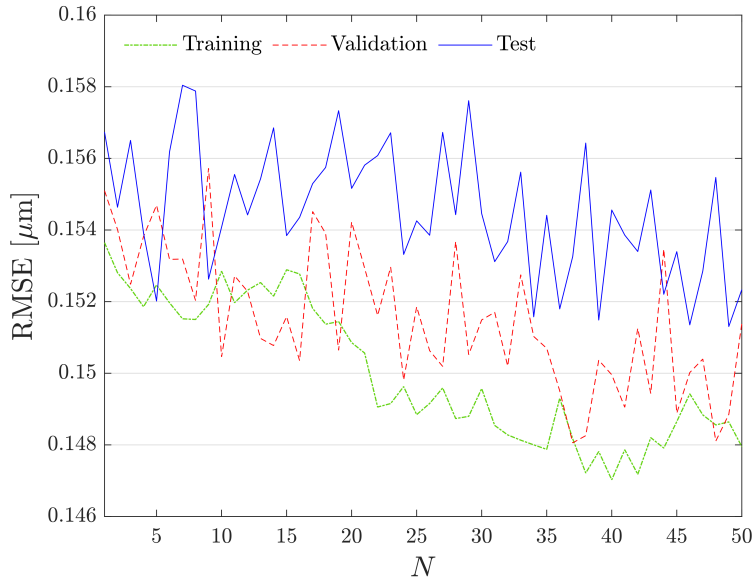


Figura 5.5: Distribución del RMSE variando el número de neuronas en la capa oculta ($N \in [0, 50]$) tras el total de iteraciones.

Una vez obtenidos los histogramas para distintos intervalos de número de neuronas y analizado su comportamiento, se pretende estudiar la evolución que sigue el RMSE del total de redes ejecutadas (para N comprendida entre 1 y 50 neuronas), considerando el resultado de esta métrica como la suma ponderada por los respectivos ratios destinados a cada fase,

$$\text{RMSE} = \frac{70}{100} \cdot \text{RMSE}_{tr} + \frac{15}{100} \cdot \text{RMSE}_{val} + \frac{15}{100} \cdot \text{RMSE}_t, \quad (5.3)$$

donde RMSE_{tr} , RMSE_{val} , RMSE_t representan el error de entrenamiento, validación y prueba respectivamente que proporcionan una sencilla interpretación física de la calidad de la aproximación (expresada en μm).

Como puede verse en la figura 5.5, el RMSE total alcanza un mínimo cercano a 0.148 μm correspondiente para 37 neuronas (dentro del intervalo más frecuente mostrado en el histograma de la figura 5.3). Asimismo, el error en la fase de entrenamiento es menor que el cometido en la validación, y a su vez, este último, menor que el de prueba, lo que puede considerarse como un indicador positivo en términos de generalización del modelo al evitar el sobreajuste. De igual modo, la tendencia de las tres curvas es a disminuir sin un límite claro, no llegando a evidenciarse ninguno de los fenómenos que revelen deficiencias en el proceso de aprendizaje.

En base a los histogramas de las figuras 5.3 y 5.4, los valores de RMSE globales para el número de neuronas óptimo obtenido para ambos casos (42 y 20 respectivamente) corresponden aproximadamente a 0.151 μm y 0.149 μm en comparación al mínimo correspondiente para 37 neuronas. De nuevo, las ligeras diferencias entre ellos en la calidad del ajuste, no justifican duplicar el número de neuronas y con ello el coste de cálculo necesario, considerándose $N_{opt} = 20$ válido para inferencia.

Una vez considerado el número óptimo de neuronas junto al resto de parámetros propios de la arquitectura del sistema y tal y como se ha mencionado en capítulos anteriores, con objeto de almacenar y fijar la combinación de valores (del total de RNAs calculadas) destinados a entrenamiento, validación y prueba que maximicen la precisión de las predicciones. Tras explorar el espacio de soluciones, en la tabla 5.2 se muestra el RMSE máximo y mínimo alcanzado, acompañado del correspondiente número de neuronas en la capa oculta (N).

N	RMSE_{tr} (μm)	RMSE_{val} (μm)	RMSE_t (μm)	RMSE_{tot} (μm)
22	0.1264	0.1555	0.2143	0.1439
50	0.2080	0.1976	0.1889	0.2035

Tabla 5.2: Valores máximos y mínimos del error cuadrático medio correspondiente a cada fase (RMSE_{tr} , RMSE_{val} y RMSE_t) junto al respectivo número de neuronas ($N \in [1, 50]$).

Como puede observarse, el valor mínimo del RMSE ($\text{RMSE}_{min} = 0,1439$) es considerablemente menor a los obtenidos anteriormente como resultado de la optimización de los hiperparámetros propios de la topología, lo que conlleva a considerar la importancia de garantizar una óptima selección de las muestras destinadas a entrenamiento 183 frente al ajuste de otras variables implicadas. La mejora, en términos de minimización del RMSE, puede cifrarse en 29.28% con respecto al valor pésimo. Asimismo, se alcanza para $N = 22$ lo que contrasta con el número óptimo de neuronas calculado previamente ($N_{opt} = 42$) y con el correspondiente al valor mínimo alcanzado en la figura 5.5 ($N_{opt} = 37$), reforzando que no existen más que algunas pautas y consideraciones comunes, como las ya mencionadas, para fijar este parámetro.

Repetiendo el proceso de optimización para el número de neuronas en el rango de 1 a 20 a fin de observar qué mejora introduce este enfoque, se obtuvieron los resultados que se muestran en la tabla 5.3.

N	RMSE_{tr} (μm)	RMSE_{val} (μm)	RMSE_t (μm)	RMSE_{tot} (μm)
20	0.1426	0.1868	0.1204	0.1459
1	0.1999	0.1980	0.2324	0.2045

Tabla 5.3: Valores máximos y mínimos del error cuadrático medio para cada una de las fases (RMSE_{tr} , RMSE_{val} y RMSE_t) junto al respectivo número de neuronas ($N \in [1, 20]$).




Figura 5.6: Distribución de la frecuencia de RMSE_{tr} tras el total de iteraciones.

El nivel de mejora en este último análisis es de un 28.66 % respecto del caso más desfavorable. La diferencia que supone con respecto al estudio ampliado en un rango entre 1 y 50 neuronas es de a penas un 0.62 % e implica poder reducir los recursos computacionales necesarios significativamente (del orden de un 60 %). A efectos de simplicidad, es evidente que resulta más interesante limitar el algoritmo para 20 neuronas. No obstante, resulta de interés académico, estudiar cómo se comporta la distribución del RMSE_{tr} medio obtenido tras ejecutar el conjunto de redes neuronales cuyo N oscila entre 1 y 50 neuronas, 200 iteraciones. Para ello, suele ser común la representación por medio de histogramas que reflejen la frecuencia de las métricas de evaluación, en este caso el RMSE [184], [185], [186].

Como se ilustra en la figura 5.6, el valor de RMSE_{tr} correspondiente al mínimo alcanzado que se resume en la tabla 5.2 es inferior al umbral de 0.1332 μm , justificándose la eficacia de la metodología presentada en este proyecto. Por otro lado, atendiendo a la distribución gaussiana que presenta, el valor más frecuente obtenido en la fase de entrenamiento representa un 22.63 % del total, mientras que los errores inferiores y superiores a los límites extremos constituyen un 0.51 % y 0.88 % respectivamente.

En cuanto al RMSE_{tr} para el mínimo hallado en el intervalo de N de 1 a 20 de la tabla 5.6 es un 12.82 % superior al mínimo para 50 neuronas y de acuerdo a la distribución de esta métrica, el 21 % del conjunto de redes neuronales operadas mostraron un error igual o inferior a éste.

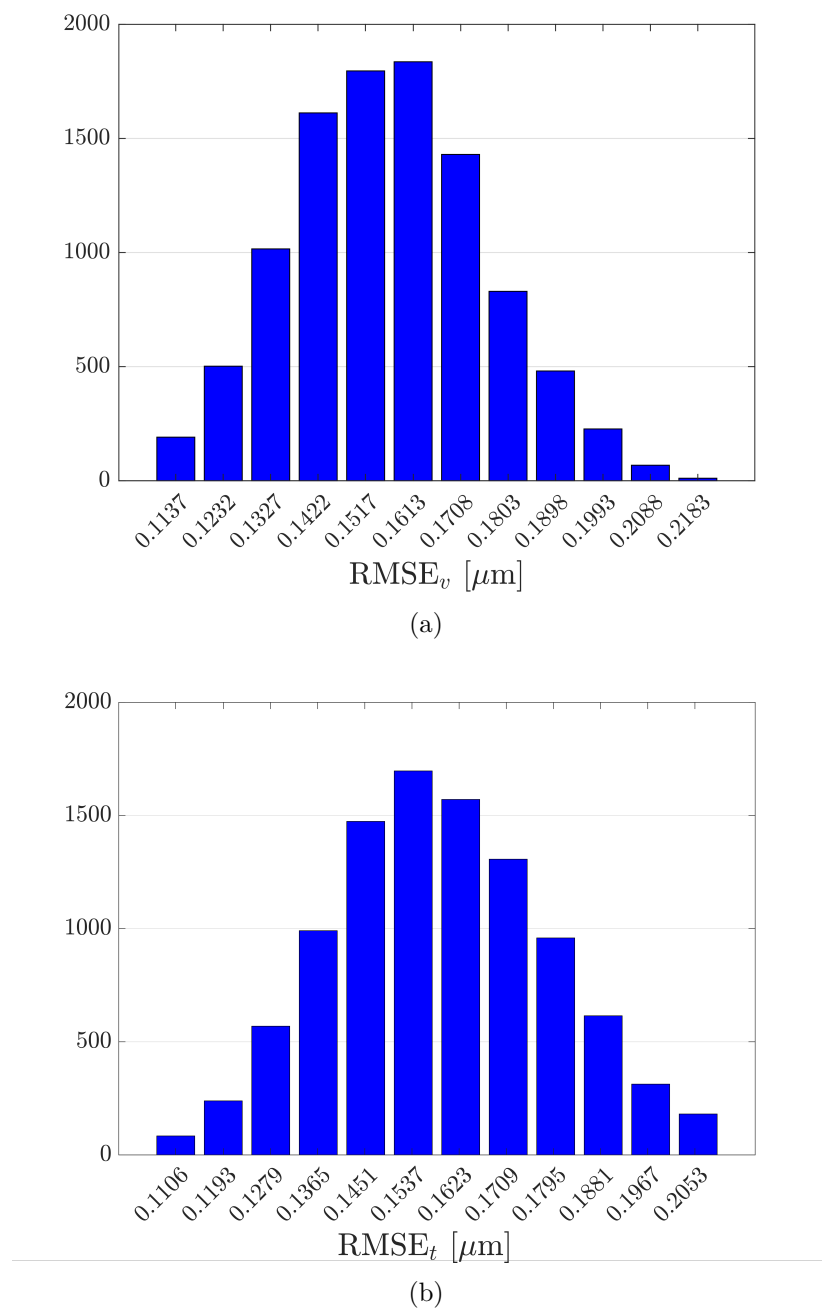


Figura 5.7: Distribución de la frecuencia de $RMSE_{val}$ (a) y $RMSE_t$ (b) tras el total de iteraciones.

No ocurre igual para la distribución igualmente normal de los errores en validación y prueba mostrados en (a) y (b) de la figura 5.7 respectivamente donde el $RMSE_{val}$ y $RMSE_t$ que corresponde al $RMSE_{tot}$ mínimo para 50 neuronas exceden los límites inferiores en ambos casos. Mientras que para la fase de validación, el 51.17% del total de redes barridas presentaron un error de igual magnitud o inferior, en la fase de prueba, se sobrepasó el límite superior que presentaron de media. Esto sugiere que existen combinaciones no mapeadas que consiguen reducir aún más el valor mínimo

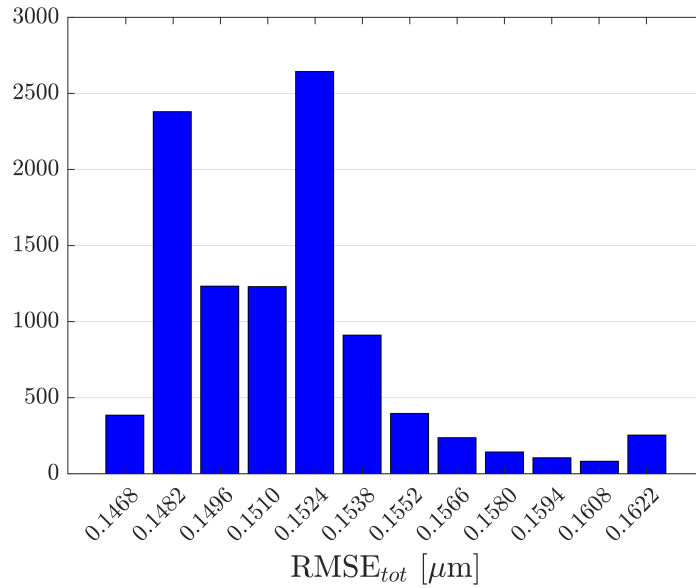


Figura 5.8: Distribución de la frecuencia de $RMSE_{tot}$ tras el total de iteraciones

de $RMSE_{tot}$ obtenido. Por otro lado, al comparar los resultados de $RMSE_{val}$ y $RMSE_t$ correspondientes al óptimo calculado para el intervalo de 1 a 20 neuronas, el 92.13 % presentó un error inferior, sin embargo, tan solo el 3.23 % lo hizo para la fase de test, lo que supone que la calidad de los datos destinados para evaluar el rendimiento del sistema (empleados en la fase de prueba) fueron cuantitativamente mejores que los usados en el ensayo para el rango de 50 neuronas en la capa oculta.

Analizando la distribución que sigue el $RMSE_{tot}$ se observa que al considerar esta variable como la suma ponderada del resto ya estudiadas de acuerdo a la ecuación (5.3), el histograma deja de adoptar la forma de campana tan evidente en el resto de casos. Considerando los resultados de $RMSE_{tot}$ más favorables de la tabla 5.6, se observa que tanto los rangos analizados de 50 y 20 neuronas, ambos valores se encuentran por debajo del límite inferior de la figura 5.8 en un 1.98 % y 0.61 % respectivamente. Asimismo, buena parte de los resultados (en torno a un 87.83 %) presentó un error inferior al valor medio mientras que solo un 2.54 % presentó un $RMSE_{tot}$ máximo superior al medio en un 4.74 %. En consecuencia, el enfoque de optimización propuesto en este trabajo puede considerarse válido para reducir los niveles de RMSE en cada una de las fases dentro de los límites inferior o superior estudiados.

Una vez que se han optimizado los hiperparámetros y se han identificado los conjuntos de datos que muestran un rendimiento óptimo entre todas las redes evaluadas, se han registrado los índices correspondientes a cada uno de estos conjuntos, junto con los vectores de pesos y sesgos respectivos. Este enfoque permite fijar los hiperparámetros y asignar los datos destinados a cada tarea de entrenamiento, validación y prueba, lo cual

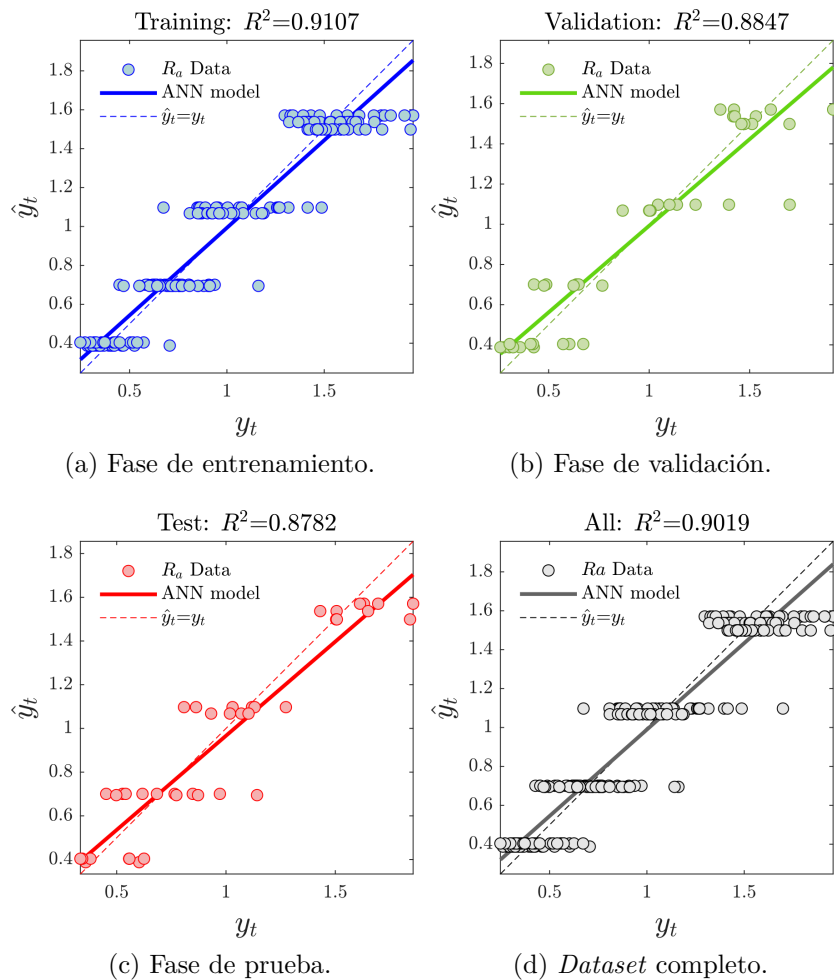


Figura 5.9: Resultados de la regresión obtenidos por la RNA optimizada. En línea en discontinua se muestra el ajuste idóneo (con $R^2 = 1$) en el que los valores de la estimación (\hat{y}_t) corresponderían a los valores medidos (y_t). En línea continua de mayor grosor se muestra el ajuste de la RNA para los datos disponibles.

mejora el rendimiento del sistema y reduce la aleatoriedad y la variabilidad de la red neuronal. De esta manera, se establece una metodología sólida para obtener resultados coherentes y confiables en futuras ejecuciones del modelo.

La figura 5.9 muestra los ajustes de regresión de la RNA óptima para cada una de las fases y para el set de datos completo. El coeficiente de determinación para la fase de entrenamiento resulta superior al de validación y prueba en un 2.94 % y 3.70 % respectivamente. El resultado obtenido para el conjunto global de datos es coherente con la gráfica 5.5 y la tabla 5.2. Como se discutirá más adelante, los resultados alcanzados evidencian una mejora notable gracias a la optimización en comparación con diferentes enfoques, incluyendo el potencial o la Metodología de la Superficie de Respuesta (RSM), ampliamente analizados en la literatura [187], [188], [189]. Por tanto, se pone de manifiesto, la necesidad de la optimización aplicada al conjunto de variables

de estudio, tanto en términos de rendimiento como por la mejora en precisión introducida en comparación con otros modelos y metodologías tradicionales.

5.3. Evaluación de las desviaciones microgeométricas

Una vez estudiados los factores de influencia en el comportamiento de las RNAs junto al enfoque de optimización presentado, se procede al análisis de los resultados obtenidos respecto de la calidad del acabado superficial, evaluada a partir de las mencionadas desviaciones microgeométricas en términos de la rugosidad media aritmética (R_a) y de la máxima altura del perfil de rugosidad (R_z).

5.3.1. Modelado de R_a

En este sentido, la figura 5.10 recoge gráficamente los valores estimados de la rugosidad media aritmética en función de f para cada v_c .

Como se observa, para valores de f comprendidos entre 0.05 y 0.10 mm/rev apenas se distingue más que una ligera variación tanto para f como para v_c . Concretamente para $f = 0,05$ a 0.06 mm/rev las curvas para 60 y 80 m/min son prácticamente idénticas y las diferencias con la de 40 m/min son muy sutiles. No obstante, se identifica un crecimiento considerable de R_a de $f = 0.01$ a 0.02 mm/rev.

Asimismo para la curva correspondiente a la velocidad de corte más elevada (80 m/min), puede verse que la variable objetivo R_a se duplica (pasando de 0.7 a 1.4 μm). Por el contrario, este incremento se ve ligeramente reducido para el rango medio de velocidades (40-60 m/min), donde la rugosidad crece en un 98 % (de 0.73 a 1.45 μm) y un 87.5 % (de 0.8 a 1.5 μm) respectivamente. Asimismo se observa una tendencia clara que indica que mayores velocidades de corte se corresponden con menores valores de R_a . Como se puede apreciar en la literatura [190] y en la propia figura, el atributo f resulta ser el parámetro de corte más condicionante, cuyo crecimiento implica que también lo haga en R_a , principalmente a partir de $f = 0.10$ mm/rev. No obstante, el efecto de v_c en R_a para dicho rango de avances es considerablemente más limitado. Como era de esperar, el comportamiento general de la variable objetivo es consistente con los trabajos publicados hasta la fecha sobre el mecanizado en seco de aleaciones de aluminio [191], [192].




Figura 5.10: Variación de la rugosidad media aritmética (R_a) predicha por la RNA en función del avance (f) para cada velocidad de corte (v_c). Las barras de error representan la desviación típica asociada a cada valor estimado.

Por otro lado, con respecto a la desviación típica asociada a cada valor de R_a estimado, se observa un resultado una buena consistencia, en términos generales, de los resultados obtenidos. Para el avance máximo ($f = 0.2$ mm/rev) se observa cierta dispersión y mayor variabilidad para las tres curvas de velocidades por igual.

Asimismo, a fin de observar fácilmente las condiciones de cortes que se ajustan a un valor determinado de R_a , la figura 5.11 muestra una familia de curvas acompañado de un mapa de color como puede verse en trabajos similares encontrados al revisar la literatura [193], [194], [195].

Para las curvas de nivel correspondientes a $R_a = 0.5$ a 0.6 μm , la tendencia del avance es a disminuir conforme crece la velocidad de corte de manera potencial. Sin embargo, a partir de $R_a = 0.7$ μm , el incremento de v_c está asociado a un aumento de f de forma prácticamente lineal con una ligera pendiente. Por otro lado, de forma similar a como ocurre en la figura 5.10, a menor v_c y mayor f , mayor es el resultado de R_a y viceversa.




Figura 5.11: Familia de curvas de la rugosidad media aritmética (R_a , en μm) para las condiciones de corte (v_c y f).

5.3.2. Modelado de R_z




Figura 5.12: Variación de la máxima altura del perfil de rugosidad (R_z) predicha por la RNA en función del avance (f) para cada velocidad de corte (v_c). Las barras de error representan la desviación típica asociada a cada valor estimado.

La figura [5.12](#) muestra la variación de la máxima altura del perfil de rugosidad (R_z) obtenida por la RNA previamente optimizada, dependiente de f para cada v_c .

Como puede verse, el comportamiento de las tres curvas con respecto a f resulta eminentemente lineal con una tendencia ascendente. Al igual sucedía en la figura [5.10](#) para R_z , a bajos valores de avance (de $f = 0.05$ a 0.10 mm/rev), se produce una variación discreta según v_c . En especial, para $f = 0.05$, las curvas correspondientes a 60 y 80 m/min pueden considerarse coincidentes. Sin embargo, puede percibirse un aumento más notable de R_z de $f = 0.01$ a 0.02 mm/rev.

De igual modo, estudiando la variación de R_z para la curva de 60 m/min, la máxima altura del perfil de rugosidad crece en un 264% (de 2.8 a 7.4 μm), frente al crecimiento en un 255% (de 2.75 a 7 μm) y 238% (de 3.2 a 7.6 μm) para las velocidades de 80 m/min y 40 m/min respectivamente. Asimismo, de nuevo, valores superiores de v_c están asociados a resultados mayores de R_z , siendo f igualmente el factor de mayor influencia.

En el mecanizado en seco de esta aleación de aluminio, el desgaste indirecto de la herramienta por adherencia suele ser consecuencia de los efectos termo-mecánico a altos f . Sin embargo, el efecto de v_c resulta más condicionante a bajos valores de f , dando lugar a la formación de filo recrecido (BUE) para velocidades de corte más elevadas.

No obstante, los bajos valores de v_c aplicados en este trabajo han hecho menos evidente este efecto y que la influencia de v_c sobre R_a y R_z sea prácticamente insignificante [196], [94].

En cuanto a la barras de error correspondientes a la desviación típica para cada valor de R_z calculado, se observa un comportamiento más robusto para los valores de f comprendidos entre 0.1 y 0.15 mm/rev donde existe mayor número de instancias disponibles en el conjunto de datos registrado, en comparación a los extremos.

Por otro lado, el comportamiento de R_z obtenido por la RNA está en consonancia con análisis similares de la literatura relacionados con modelos paramétricos de la rugosidad superficial en el mecanizado en seco de las aleaciones de aluminio de la familia 2000 y 7000 [6], [197].

De igual modo a la familia de curvas de nivel para R_a de la figura 5.11, en la figura 5.13 se puede ver que la variación según v_c puede considerarse con cierto grado de curvatura para $R_z = 3 \mu\text{m}$ y prácticamente lineal a partir de $R_z = 4 \mu\text{m}$.

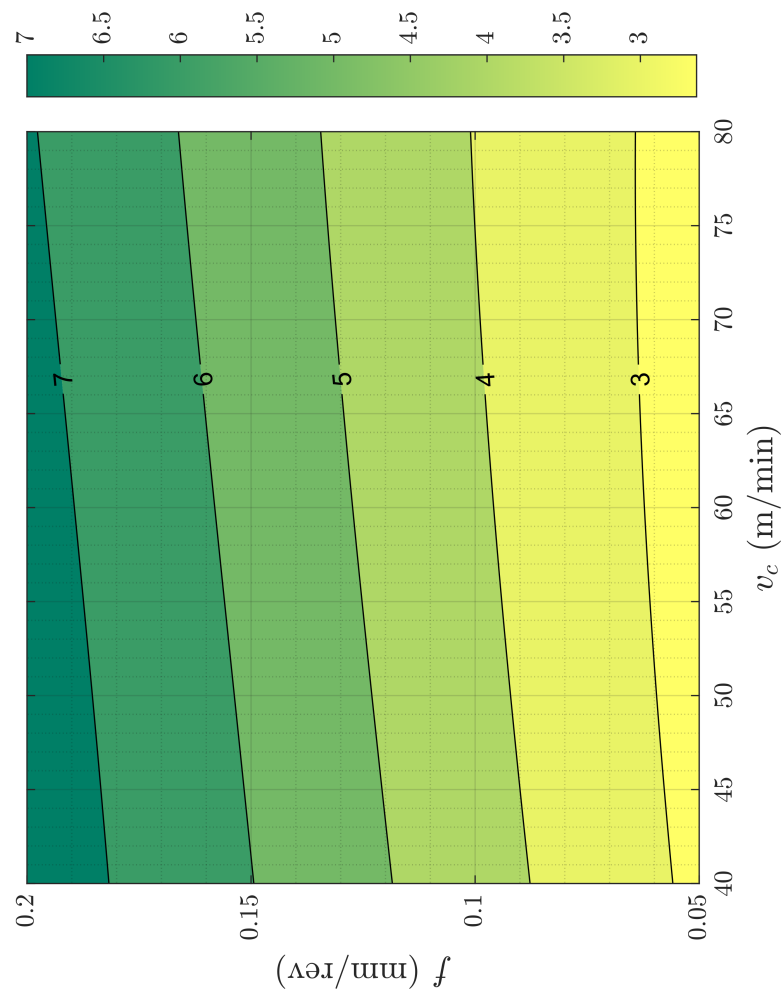


Figura 5.13: Familia de curvas de la máxima altura del perfil de rugosidad (R_z , en μm) para las condiciones de corte (v_c y f).

5.4. Evaluación de las desviaciones macrogeométricas

En el apartado previo se han expuesto y discutido los resultados correspondientes a las desviaciones microgeométricas. A lo largo de esta sección, se pretenden analizar los resultados de las desviaciones de forma, como el paralelismo (PAR), la rectitud (STR), la oscilación radial (CRO), la redondez (RON), la concentricidad (CON) y la cilindricidad (CYL) que junto al resto de propiedades microgeométricas y físico-químicas, pueden ser utilizadas como variables evaluadoras en un criterio de maquinabilidad basado en la integridad superficial [1].

5.4.1. Modelado del paralelismo (PAR)

En la figura 5.14 se muestran los valores de PAR en función de los parámetros de corte (v_c y f). En términos generales, se observa una leve tendencia de crecimiento del paralelismo según f de forma lineal. En cuanto al efecto de la v_c resulta de igual modo bastante reducido, observando un suave incremento, conforme aumenta este valor.

En cuanto al crecimiento de PAR para las tres curvas de acuerdo con f es muy similar, siendo de un 2.33 % (38.6 a 39.5 μm) para v_c de 80 m/min, un 2.39 % (37.65 a 38.55 μm) para v_c de 60 m/min y un 2.44 % (36.8 a 37.7 μm) para v_c de 40 m/min. Este comportamiento obtenido por la RNA optimizada, están respaldados por los resultados obtenidos en trabajos similares para el mismo rango de f y v_c [4] donde la influencia del f en el PAR es insignificativa, tendiendo a mantenerse prácticamente constantes independientemente de los valores de velocidad de corte ensayados. De igual modo, como puede verse para un bajo rango de f (0.05-0.10 mm/rev) para $v_c = 40$ m/min se han obtenido mejores resultados que para mayores valores de velocidad (60-80 m/min). Asimismo, según la variación de PAR de la figura, resulta evidente que los valores pésimos de desviaciones se encuentran para f y v_c máximos.

En lo referente a la dispersión de los valores a partir de la desviación típica que muestran las barras de error, se observa una escasa variabilidad en contraste al que muestra el modelo predictivo de [3], a pesar del bajo coeficiente de correlación que muestra este conjunto de datos, tal y como se discutirá en apartados posteriores.




Figura 5.14: Variación del paralelismo (PAR) predicho por la RNA en función del avance (f) para cada velocidad de corte (v_c). Las barras de error representan la desviación típica asociada a cada valor estimado.

Por otro lado, la figura 5.15 muestra el conjunto de curvas correspondientes a los valores de PAR en función de v_c y f . La tendencia general es a crecer conforme lo hace la v_c y a disminuir cuando se incrementa f . Como bien, se comenta en 4 para el mismo conjunto de resultados experimentales, para bajos valores de v_c (40 m/min) y altos de f (0.15-0.20 mm/rev), se percibe una tendencia a disminuir la respuesta de PAR, lo que concuerda con la figura 5.14.




Figura 5.15: Familia de curvas del paralelismo (PAR, en μm) para las condiciones de corte (v_c y f).

5.4.2. Modelado de la rectitud (STR)




Figura 5.16: Variación de la rectitud (STR) predicha por la RNA en función del avance (f) para cada velocidad de corte (v_c). Las barras de error representan la desviación típica asociada a cada valor estimado.

En la figura 5.16 se ilustran los resultados obtenidos de STR para el rango de valores de los parámetros de corte (v_c y f) ensayados. En este caso, sí resulta perceptible una mayor influencia de las condiciones de corte en comparación a la variación que sigue el PAR en la figura 5.14, apreciándose que a medida que f se incrementa, también lo hace STR. Por otro lado, los valores mayores de STR se obtienen, de forma independiente al f , para $v_c = 80$ m/min.

De igual modo, como puede observarse, a bajos valores de f (de 0.05 a 0.10 mm/rev) las curvas correspondientes a $v_c = 40-60$ m/min, presentan escasas diferencias y el efecto de v_c sobre STR no se muestra significativo. Sin embargo, a partir de $f = 0,01$ mm/rev se evidencia mayor dependencia de esta variable sobre la respuesta de STR para las tres curvas. Asimismo, a pesar de que a valores bajos de v_c no se observe su influencia sobre la desviación de rectitud, manteniéndose relativamente constante, los resultados máximos se obtienen al combinar un alto valor de v_c (80 m/min) con altos de avance (0.15-0.20 mm/rev).

Siendo f igualmente, el parámetro más influyente, para la curva de v_c de 60 m/min, STR crece un 338% (pasando de 3.4 a 11.5 μm), mientras que la de 40 m/min, lo hace en un 317% (de 3 a 9.5 μm) y la correspondiente a 80 m/min, un 317% (de 5 a 14.5 μm). Conforme a lo esperado, el comportamiento de STR es coherente con trabajos análogos de la literatura [3].

En lo que se refiere a la dispersión de los resultados obtenidos para STR, se observa que aumenta para bajos (0.05-0.10 mm/rev) y en especial, altos (0.15-0.20 mm/rev) rangos de f , resultando más evidente su efecto para altos valores de v_c (60 y 80 m/min). Esto puede explicarse en base a una mayor disponibilidad de datos para valores intermedios de f (0.10-0.15 mm/rev) sumado a que el aumento de este parámetro provoca mayor adhesión del material en la cara de desprendimiento de la herramienta [4] lo que afecta de forma negativa a los resultados obtenidos. Además, para intervalos elevados de v_c y f , se observa que la formación de filo recrecido se estabiliza, resultando la variación de la rectitud menos sensible a éste y más a otros factores como las vibraciones generadas durante el proceso de conformado que contribuyen a una mayor dispersión de las muestras recogidas.

Paralelamente, la figura [5.17] muestra la familia de curvas de los valores predichos por la RNA para STR en función de v_c y f . Al contrario de como ocurría para el PAR de la figura [5.15], los valores óptimos de desviación se obtienen para bajos valores de f y v_c . Así, la tendencia general que se prueba es a aumentar STR conforme lo hace f para una misma v_c , lo que resulta compatible de acuerdo con los resultados de la figura [5.16]. Por otro lado, fijado el valor de la desviación, si se aumenta v_c , será necesario disminuir de forma lógica f y viceversa.

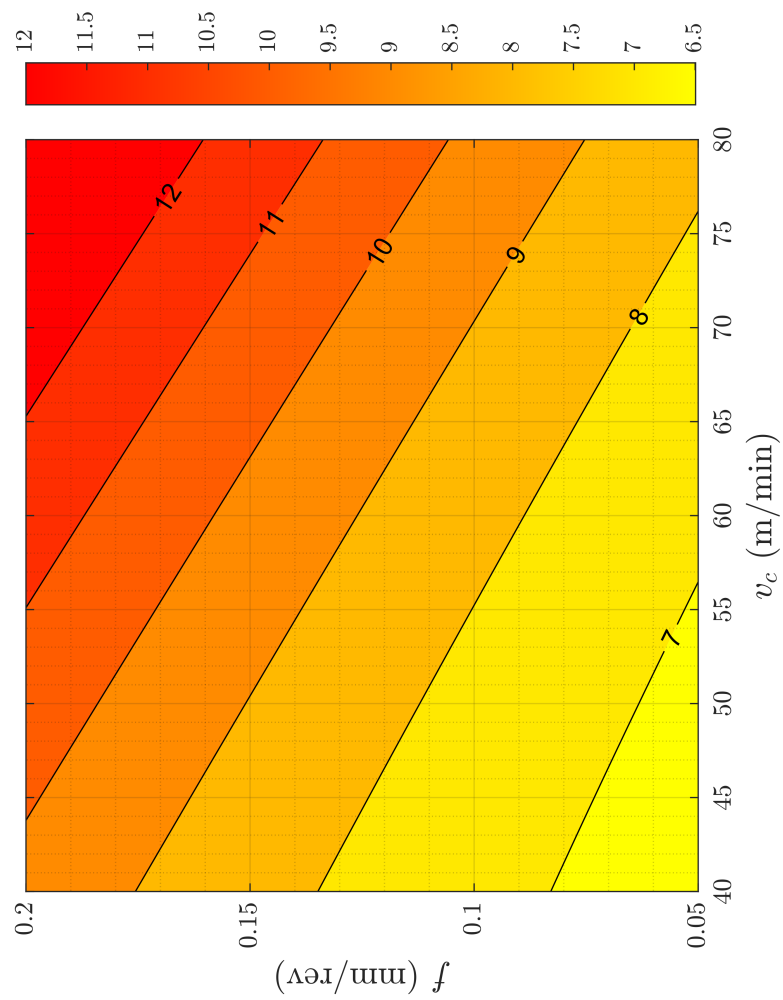


Figura 5.17: Familia de curvas de la rectitud (STR, en μm) para las condiciones de corte (v_c y f).

5.4.3. Modelado de la oscilación radial (CRO)




Figura 5.18: Variación de la oscilación radial (CRO) predicha por la RNA en función del avance (f) para cada velocidad de corte (v_c). Las barras de error representan la desviación típica asociada a cada valor estimado.

En la figura [5.18](#) se muestran los valores estimados de CRO a partir del conjunto de ensayos realizados sobre las respectivas probetas en función de v_c y f . En general y como viene siendo habitual para el resto de desviaciones, el parámetro f parece ser el más influyente, observándose una tendencia cuasilineal de crecimiento de CRO según f , de forma independiente al valor de v_c .

Tratando de evaluar el nivel de influencia de f sobre la respuesta de la oscilación radial, para la curva de v_c de 40 m/min, CRO crece un 69.64% (pasando de 28 a 47.5 μm), frente a la de 60 m/min que lo hace en un 63.33% (de 30 a 49 μm) y la correspondiente a 80 m/min, que se incrementa en un 57.81% (de 32 a 50.5 μm). Según lo previsto, el comportamiento de CRO se corresponde con investigaciones similares documentadas en la literatura [\[3\]](#), [\[187\]](#) que usan el mismo conjunto de datos. No obstante, los resultados obtenidos muestran algunas discrepancias con los obtenidos por otros autores en la misma aleación e igualmente mecanizando en seco con condiciones de corte similares [\[198\]](#), [\[199\]](#). Los resultados de dichos trabajos revelan que CRO es poco sensible a la variación de los parámetros de corte. No obstante, la esbeltez de las probetas ensayadas por [\[4\]](#) de donde proceden los datos empleados, hace más notable la influencia de las condiciones de corte sobre CRO, obteniéndose mayor valores de desviación en comparación a las probetas rígidas.

Por otro lado, esta tendencia resulta menos perceptible para v_c , obteniendo los mayores valores de esta propiedad para la curva de 80 m/min. Por tanto, es evidente que la combinación de altos valores de los parámetros de corte (v_c y f) generan los resultados pésimos de CRO. Este comportamiento puede explicarse a partir de los elevados niveles de vibración que se experimentan al trabajar en dichas condiciones durante el mecanizado.

Respecto a la desviación típica de las predicciones, sugieren un comportamiento robusto y estable para el rango intermedio de f (0.10-0.15 mm/rev). Sin embargo para los valores extremos ($f < 0.1$ mm/rev y $f > 0.15$ mm/rev), la longitud de las barras de error indican una mayor dispersión con respecto al valor medio y una mayor variabilidad de los resultados.

De forma similar al resto de desviaciones de forma, la figura 5.19 muestra la familia de curvas de nivel que representan los valores estimados por la RNA para CRO en relación a los parámetros de corte (v_c y f). En este caso, los valores mínimos de CRO se encuentran para bajos valores de f y medio-altos de v_c , frente al mostrado por STR y PAR en las figuras 5.17 y 5.15. Cabe destacar que excepto la curva de CRO=25 μm , la tendencia general refleja el hecho de que si se pretende fijar el valor de la oscilación radial, un aumento de v_c está asociado a una disminución de f . No sucede igual para CRO=25 μm , donde si crece v_c también deberá hacerlo f si se pretende mantener constante el valor de concentricidad. Este hecho puede deberse a una baja calidad de los datos experimentales de esta desviación macrogeométrica que dificulta poder generalizar de manera efectiva.




Figura 5.19: Familia de curvas de la oscilación radial (CRO, en μm) para las condiciones de corte (v_c y f).

5.4.4. Modelado de la redondez (RON)




Figura 5.20: Variación de la redondez (RON) predicha por la RNA en función del avance (f) para cada velocidad de corte (v_c). Las barras de error representan la desviación típica asociada a cada valor estimado.

Según la figura 5.20, para bajos valores de f (0.05-0.10 mm/rev) tan solo se observan pequeñas variaciones de RON en función de v_c . En concreto, para dicho rango, las curvas de 60 y 80 m/min pueden considerarse prácticamente idénticas. No obstante, a partir de $f = 0,10$ mm/rev, se observa un crecimiento potencial notable.

A diferencia de los resultados mostrados en 4, sí se observa una influencia clara del parámetro f sobre el comportamiento de esta desviación. Como puede verse, altos valores de f (0.20 mm/rev) acompañados de altos valores de v_c (60-80 m/min) dan lugar a valores pésimos de RON. Al igual que para el resto de desviaciones de forma, este hecho puede deberse por un lado, a un aumento de la temperatura del mecanizado (mayores valores de los parámetros de corte generan fuerzas de corte de mayor intensidad), a las vibraciones (responsables de posibles fluctuaciones en las trayectorias de corte), la deformación elástica de las probetas durante el proceso y al propio desgaste de la herramienta que también se ven afectados por el incremento de las condiciones durante el torneado y que provocan un aumento de RON.

Con el objetivo de evaluar la variación según f , para la curva correspondiente a 80 m/min, RON experimenta un aumento del 265.63% (de 12.8 a 34 μm) en comparación a la de 60 m/min que muestra un crecimiento de un 258.19% (de 12.2 a 31.5 μm) y la de 40 m/min en la que se incrementa el valor de la respuesta un 241.67% (de 12 a 29 μm). El análisis de los resultados obtenidos se alinea con las conclusiones de 4 para el

mismo conjunto de datos.

En cuanto a la desviación típica de los valores de RON estimados por la RNA, al igual sucedía para CRO, apuntan a un comportamiento consistente en el rango intermedio de f (0.10-0.15 mm/rev). No obstante, para valores inferiores y superiores de f , se observa una mayor dispersión en las barras de error, lo que indica una mayor fluctuación de los resultados respecto al valor medio.

Asimismo, en la figura [5.21](#) se representa la familia de curvas de los valores calculados de RON en función de los parámetros de corte (v_c y f). De forma análoga a los obtenidos para CRO en la figura [5.19](#), los valores más favorables de RON se obtienen al disminuir f y aumentar v_c . La influencia de los parámetros de corte sobre la respuesta de RON se encuentra en consonancia con la mostrada en la figura [5.20](#). Un incremento en v_c deberá estar acompañado de una disminución de f para mantener constante el valor de RON correspondiente.




Figura 5.21: Familia de curvas de la redondez (RON, en μm) para las condiciones de corte (v_c y f).

5.4.5. Modelado de la concentricidad (CON)




Figura 5.22: Variación de la concentricidad (CON) predicha por la RNA en función del avance (f) para cada velocidad de corte (v_c). Las barras de error representan la desviación típica asociada a cada valor estimado.

En la figura 5.22 se grafican los valores determinados por la RNA para CON en función de v_c y f . Como tendencia general, puede observarse que f sigue siendo el parámetro más influyente. De este modo, el aumento de f conlleva un incremento proporcional de CON.

En contraste con los resultados mostrados en [4], no puede considerarse despreciable la influencia de v_c sobre la respuesta de esta desviación. Como se puede apreciar, la combinación de altos valores de f y v_c afectan negativamente al comportamiento de CON debido al efecto de las alteraciones en las condiciones de corte de partida (una mayor sección de viruta y ángulo de cizalladura) junto al desprendimiento de BUE y BUL que causan inestabilidades y vibraciones durante el proceso de corte.

Por otro lado, con el fin de evaluar la influencia de f en CON, para la curva de 40 m/min, se observa un crecimiento de la variable de estudio en un 72.04% (de 9.3 a 16 μm) frente a la de 60 m/min que lo hace en un 53.6% (de 12.5 a 19.2 μm) y la correspondiente a la de 80 m/min que aumenta un 46.10% (de 15.4 a 22.5 μm). A diferencia del modelo obtenido en [4], la pendiente de variación de CON según f resulta muy similar independientemente del valor de v_c .

La desviación típica de los valores de CON determinados por la RNA muestra un comportamiento robusto en el rango intermedio de f (0.08-0.17 mm/rev), de forma similar a lo que se observó para RON y CRO en las figuras 5.20 y 5.18 respectivamente. Sin embargo, para valores de f que exceden dicho rango, se aprecia una dispersión ligeramente superior en las barras de error que sugieren una mayor variabilidad en los resultados obtenidos en comparación con el valor promedio.

Además, la figura 5.23 muestra la familia de curvas de nivel para RON estimados por la RNA de acuerdo con los parámetros de corte (v_c y f). En este caso, el comportamiento de la desviación parece seguir una tendencia menos predecible. En general y como bien se refleja en 5.22, aumentar f y v_c conlleva a resultados pésimos de CON. Asimismo, a partir de $v_c = 60$ m/min, un crecimiento de f y v_c están asociados a un incremento de CON.




Figura 5.23: Familia de curvas de la concentricidad (CON, en μm) para las condiciones de corte (v_c y f).

5.4.6. Modelado de la cilindridad (CYL)




Figura 5.24: Variación de la cilindridad (CYL) predicha por la RNA en función del avance (f) para cada velocidad de corte (v_c). Las barras de error representan la desviación típica asociada a cada valor estimado.

La figura [5.24](#) muestra los valores obtenidos por la RNA para CYL en función de los parámetros de corte (v_c y f). En este caso, la influencia de f resulta especialmente notable en comparación a otras desviaciones como bien se refleja en [4](#). La tendencia general que se percibe es de crecimiento de CYL según f de forma independiente a v_c . Con el objetivo de analizar su efecto, para la curva de 40 m/min, se aprecia un crecimiento de CYL de un 93 % (de 30 a 57.9 μm) en comparación a la de 60 m/min que aumenta en un 89.35 % (de 33.8 a 64 μm) y la de 80 m/min que se incrementa en un 84.7 % (de 37.9 a 70 μm).

Como bien puede verse, los peores resultados de CYL se obtienen al combinar el mayor f (0.20 mm/rev) con elevadas v_c (60-80 m/min). A diferencia de los modelos de regresión estudiados en [4](#), la variación de CYL de acuerdo con f resulta homogénea para todo el rango estudiado y para las tres curvas de v_c evaluadas. Asimismo, CYL, frente a las desviaciones de CRO y RON, muestra una sensibilidad superior al cambio según f en comparación a v_c . Este hecho puede explicarse, teniendo en cuenta que CYL contempla tanto la influencia de las desviaciones obtenidas en una generatriz (en sentido longitudinal de la probeta) como las desviaciones obtenidas en cada una de las secciones.

La desviación típica de los valores predichos de CYL por la RNA exhibe un comportamiento consistente en el rango intermedio de f (0.10-0.15 mm/rev), similar a lo observado para el resto de desviaciones de forma (CRO, RON, CON mostrados en las figuras [5.18](#), [5.20](#), [5.22](#) respectivamente). No obstante, para valores de f extremos, se evidencia un aumento de la dispersión de los resultados, reflejado a partir del incremento de las barras de error, lo cual sugiere una mayor variabilidad en las estimaciones obtenidas con respecto al valor medio.

Por último, la figura [5.25](#) recoge el conjunto de curvas de nivel para CYL determinados por la RNA a partir de los parámetros de corte (v_c y f). De forma similar a los resultados obtenidos para CRO y RON, los valores óptimos de desviación se obtienen para bajos registros de v_c y f lo que concuerda con lo mostrado en la figura [5.24](#).




Figura 5.25: Familia de curvas de la cilindridad (CYL, en μm) para las condiciones de corte (v_c y f).

5.5. Evaluación de las propiedades mecánicas

Las propiedades mecánicas y físico-químicas relativas a la superficie de los componentes estructurales empleados en el sector aeronáutico desempeñan un papel fundamental dentro de la familia de variables que constituyen el concepto de integridad superficial. En este apartado, se aborda el análisis del efecto de los parámetros de corte (v_c , f y a_p) sobre la microdureza superficial Vickers (HV) durante el proceso de conformado de material por arranque de viruta.

5.5.1. Modelado de la microdureza superficial

La figura 5.26 representa los valores de microdureza superficial obtenidos para cada una de las combinaciones de los parámetros de corte empleados (v_c , f y $a_p = 1$ mm) al aplicar una carga de 0.05 Kgf (HV 0.05) como bien se describió en el Capítulo 4 de la metodología experimental. Cabe mencionar que se han descartado los valores correspondientes a $v_c = 120$ m/min debido a la gran dispersión de las muestra. Al igual que para las desviaciones de forma, la influencia de f en la microdureza, prevalece sobre la de v_c . Tratando de evaluar su relación con HV, para la curva correspondiente a 40 m/min, se observa un decrecimiento de un 3.86 % (de 181.2 a 174.2 μm), mientras que la de 60 m/min disminuye un 3.52 % (de 184.4 a 177.9 μm) y la de 80 m/min, se reduce un 3.10 % (de 187.3 a 181.5 μm).

A diferencia de los resultados discutidos en 4, sí puede apreciarse un efecto claro de los parámetros de corte sobre la respuesta de la microdureza, observándose que los resultados pésimos se alcanzan al trabajar a bajos valores de f y altos de v_c . Además, como tendencia general y de forma independiente al valor de v_c adoptado, se observa un decrecimiento ligeramente potencial conforme se incrementa f . No obstante, un aumento de la velocidad de corte conduce a un crecimiento de la microdureza superficial de las probetas mecanizadas.

Este comportamiento, contrasta con el obtenido en 4 justificado en base a que un aumento de f conlleva un aumento de la deformación plástica (fomentando el endurecimiento por deformación) y una disminución del tamaño de grano lo que resulta por tanto, en un aumento de la microdureza superficial. Sin embargo, un incremento del avance puede estar asociado igualmente a un crecimiento de la temperatura a partir del calor disipado por fricción entre la herramienta y la pieza de trabajo lo que provoca efectos adversos en la microestructura, como el crecimiento del tamaño de grano o la recristalización que junto al desgaste mecánico del inserto de corte conducen a una disminución de la microdureza. No obstante, el resultado obtenido puede atribuirse a

una limitación de la capacidad de generalización del modelo debida a una gran dispersión de los datos experimentales.




Figura 5.26: Variación de la microdureza superficial (HV 0.05) predicha por la RNA en función del avance (f) para cada velocidad de corte (v_c) para $a_p = 1$ mm. Las barras de error representan la desviación típica asociada a cada valor estimado.

En cuanto a la dispersión de los valores obtenidos para la microdureza respecto al valor medio, se observa que se incrementa suavemente para bajos (0.05-0.08 mm/rev) y algo más para altos (0.18-0.20 mm/rev) rangos de f , resultando más evidente su influencia para bajos valores de v_c (40 y 60 m/min). Esto, como ya se ha analizado para algunas de las desviaciones de forma, puede deberse a una mayor disponibilidad de datos para valores intermedios de f (0.10-0.15 mm/rev).

Por último, la figura 5.27 ilustra la familia de curvas de nivel de los valores estimados por la RNA para la microdureza superficial (HV 0.05) en función de v_c y f para $a_p = 1$ mm. Como puede observarse, los valores pésimos se encuentran para bajos de f y altos de v_c lo que coincide con la figura 5.26.




Figura 5.27: Familia de curvas de la microdureza superficial (HV 0.05) para las condiciones de corte (v_c , f y $a_p = 1$ mm).

5.6. Validación con modelos analíticos clásicos

Los resultados obtenidos para el conjunto de propiedades micro y macrogeométricas junto a la microdureza superficial como métrica de las propiedades mecánicas y físico-químicas plantean la posibilidad de recurrir a modelos analíticos clásicos como los paramétricos potenciales o el Método de Superficie de Respuesta que permiten relacionar las variables de interés con los parámetros de corte. Como bien recogen trabajos recientes [125], son varios los desarrollos a través de publicaciones científicas realizados por el grupo de investigación TEP933 mediante los cuáles, tratan de predecir el comportamiento de algunas de las principales desviaciones de forma [3], [199] y la rugosidad superficial [196].

En este sentido y comenzando por caracterizar R_a y R_z analíticamente, cabe definir las según el siguiente par de ecuaciones [5.4] y [5.5] respectivamente,

$$R_a = \frac{1}{L_m} \int_0^{L_m} |f(x)| dx = \frac{\sum_{i=1}^n R_i}{n} \approx 10^3 \frac{f^2}{32r}, \quad (5.4)$$

donde L_m es la longitud básica o de medición, tomada para calcular el parámetro de rugosidad y $|f(x)|$ es la función que representa el perfil de rugosidad para un determinado sistema de referencia. Además de expresar la rugosidad media aritmética como la altura de un rectángulo cuya área sea igual a la suma absoluta de las áreas delimitadas entre el perfil de rugosidad y la línea media, es posible definirla igualmente a partir de un muestreo sobre dicho perfil obteniendo una serie R_i , cuya variable hace referencia a la ordenada en valor absoluto de un cierto punto i respecto a la línea media junto a n que corresponde al total de puntos tomados. Asimismo para operaciones de torneado puede establecerse una relación funcional de referencia que contempla los factores geométricos y los relativos a la geometría de la herramienta de corte (a partir del avance, f y del radio de la punta, r). Análogamente para la máxima altura del perfil es válido expresar según las normas JIS/ISO que

$$R_z = \frac{\sum_{i=1}^5 p + \sum_{i=1}^5 v}{10}; \quad (5.5)$$

es decir, como la diferencia entre el promedio de las alturas de los cinco picos (p) más altos y la altura promedio de los cinco valles (v) más profundos medidos en la dirección de la amplificación vertical dentro de la L_m evaluada. No obstante, en la práctica se recurren a modelos funcionales, como los ya mencionados, que permitan identificar el nivel de influencia de cada uno de las variables de régimen de corte involucradas en las propiedades que se pretenden estimar con una precisión y coste de cálculo razonables.

Los modelos paramétricos de naturaleza potencial de forma particular para R_a pero igualmente extrapolable a R_z , así a como cualquiera de las desviaciones de forma (DF) o a la microdureza superficial que se pretenden calcular, suponen que la variable respuesta está ligada a los parámetros de corte a partir de una relación de este tipo

$$R_a v_c^{-a} f^{-b} = C, \quad (5.6)$$

siendo C , a y b constantes desconocidas. El objetivo que se plantea es el de estimar los parámetros a , b y C , concretando el ajuste de la función potencial $R_a = C v_c^a f^b$. Para ello, basta plantear un ajuste lineal equivalente y auxiliar tras aplicar logaritmos,

$$\log(R_a) = \log(C v_c^a f^b) = \log(C) + a \log(v_c) + b \log(f), \quad (5.7)$$

donde el signo y magnitud de las pendientes a y b , permiten por un lado, evidenciar la correlación positiva o negativa de v_c y f sobre R_a y por otro, indicar el nivel de dependencia de los parámetros de corte sobre la variable dependiente. En la siguiente tabla se muestran los resultados obtenidos para cada una de las constantes de la ecuación (5.6) como sigue.

\hat{y}_t	C	a	b
R_a	5.305	0.087	0.997
R_z	15.505	0.124	0.785
PAR	11.278	0.175	-0.169
STR	4.171	0.608	0.914
CRO	33.124	0.352	0.625
RON	71.360	0.068	0.735
CON	2.729	0.637	0.515
CYL	34.433	0.370	0.560
HV 0.05	251.817	-0.070	-0.007

Tabla 5.4: Parámetros del modelo potencial.

Para el caso particular de la microdureza, considerando a_p como otro predictor, es necesario contemplar un cuarto parámetro $c = -0,391$. Por otro lado, se recurre al Método de Superficie Respuesta para proporcionar un segundo modelo estadístico-predictivo tras establecer el valor de los factores cuantitativos que optimizan la variable respuesta, con el que comparar los resultados obtenidos de la RNA.

Siguiendo los pasos de [200] para la aproximación de R_a como función de respuesta de los parámetros de corte, puede considerarse el modelo de regresión polinómica de segundo orden (cuadrático completo) que es descrito como sigue

$$\begin{aligned}
 R_a &= \beta_0 + \sum_{i=1}^k \beta_i X_i + \sum_{i=1}^k \beta_{ii} X_i^2 + \sum_{i<j}^k \beta_{ij} X_i X_j + \varepsilon_{ij} = \\
 &= \beta_0 + \beta_1 v_c + \beta_2 f + \beta_{11} v_c^2 + \beta_{22} f^2 + \beta_{12} v_c f,
 \end{aligned}
 \tag{5.8}$$

donde β_0 es una constante, β_i son los coeficientes de regresión para los términos de primer orden, β_{ii} los correspondientes para los términos cuadráticos puros, β_{ij} para los términos de producto cruzado estimados mediante el método de mínimos cuadrados, X_i y X_j representan las variables codificadas (los parámetros de corte) y ε_{ij} denota el error de predicción. De forma similar a [201], el valor de los estimadores para cada respuesta obtenidos de Minitab se resume en la siguiente tabla.

\hat{y}_t	β_0	β_1	β_2	β_{11}	β_{22}	β_{12}
R_a	0.407	-0.01334	5.51	0.000132	13.81	-0.0141
R_z	0.13	-0.0026	41.99	0.000170	-13.3	-0.0881
PAR	80.9	-0.945	-330	0.00442	140	4.20
STR	24.8	-0.781	-40.7	0.00585	34	1.585
CRO	31.6	-0.787	107	0.00465	-765	5.19
RON	4.1	0.341	-64.9	-0.00410	480	1.565
CON	7.4	-0.254	81.3	0.00151	-599	2.425
CYL	49.7	-1.02	-7	0.0066	-379	6.03
HV 0.05	154.4	0	563	0.0031	-1764	-1.46

Tabla 5.5: Estimadores del modelo RSM.

En la siguiente figura [5.28] se muestran los valores para R_a , sirva como referencia para discutir las diferencias obtenidas entre modelos (ANN, potencial y RSM), en función de f para cada v_c . Como puede verse, se obtienen resultados consistentes y similares para los tres modelos estudiados.

En cuanto a las curvas de $v_c = 40$ m/min, el modelo potencial junto al RSM y el obtenido a partir de la RNA coinciden e incluso llegan a solaparse para bajos valores de f (0.05-0.10 mm/rev). A partir de este valor, el modelo potencial se distancia de la estimación a partir de la red neuronal, sin embargo, este último muestra una gran semejanza con el ajuste planteado por el RSM para altos valores de f (0.15-10.20 mm/rev).




Figura 5.28: Comparación de los resultados para R_a estimados a partir del modelo de la RNA, potencial y RSM.

Para el rango intermedio de v_c (60 m/min) y medio de f (0.10-0.15 mm/rev) se observan ligeras diferencias entre los tres modelos y solo para valores especialmente bajos y altos ($f < 0,1$ mm/rev y $f > 0,15$ mm/rev) se asemejan notablemente entre ellos. De forma similar ocurre para $v_c = 80$ m/min, para valores medio-altos de f (0.10-0.20 mm/rev), se evidencian valores diferentes de R_a , no obstante, para f inferiores (0.05-0.07 mm/rev), las diferencias se reducen considerablemente y se obtienen resultados muy parecidos.

Comparando entre modelos, el modelo obtenido de la RNA, para un mismo valor de f (salvando el rango de $f < 0,10$ mm/rev), al reducir v_c se obtienen mayores de R_a . No sucede igual para el potencial y el correspondiente al RSM, donde el comportamiento es justo el opuesto, mayores valores v_c están asociados a incrementos de rugosidad superficial. Ambos comportamientos pueden explicarse en base a los siguientes factores.

En ciertas situaciones, un incremento significativo de v_c puede resultar en un aumento del valor de R_a . Esto puede deberse por un lado, a un mayor desgaste de la herramienta debido a una mayor fricción y temperatura generada durante el proceso de mecanizado a velocidades más altas y por otro, a las vibraciones inducidas. No obstante, una velocidad de corte mayor puede conducir a un acabado superficial óptimo en cuanto a una reducción del impacto de asperezas o irregularidades superficiales de la probeta junto a una disminución del tiempo de corte (y por consiguiente menor rozamiento).

En la tabla 5.6 que se muestra a continuación, se presentan los coeficientes de determinación (R^2) de los resultados obtenidos por los modelos de la RNA, potencial y RSM para estudiar las diferencias en la bondad del ajuste y de precisión que implican recurrir a unos u a otros.

R^2	Modelos	RNA	Potencial	RSM
	R_a	0.901	0.791	0.787
	R_z	0.842	0.709	0.680
	PAR	0.365	0.144	0.291
	STR	0.749	0.646	0.574
	CRO	0.518	0.445	0.358
	RON	0.706	0.562	0.499
	CON	0.455	0.211	0.223
	CYL	0.390	0.361	0.346
	HV 0.05	0.211	0.204	0.071

Tabla 5.6: Coeficientes de determinación (R^2) para los modelos de la RNA, potencial y RSM.

En todos los casos el ajuste del modelo de la RNA optimizada mejora a ambos analíticos. De entre todos ellos, el que mayor coeficiente de determinación presenta es para R_a que supone un 14.85% de mejora con respecto al pésimo (RSM). Tras él, para R_z , STR y RON, la precisión del algoritmo de aprendizaje automático puede considerarse igualmente buena (0.706-0.842). En un tercer nivel, pueden agruparse a CRO y CON (0.455-0.518). Y finalmente, CYL, PAR y HV (0.211-0.365) presentan un ajuste de baja calidad.

Mientras que para algunas variables de estudio, el comportamiento del modelo predictivo de la RNA mejora cuantitativamente la calidad del ajuste frente a los analíticos (véase PAR, RON y CON), en otros casos, la diferencia entre modelos se reduce (como CYL o HV). Este hecho, puede atender a varias razones. Por un lado, a la complejidad del modelo. Las RNA son modelos más flexibles y permiten reflejar satisfactoriamente relaciones complejas de carácter no lineal entre las variables de entrada y salida. Esto supone una ventaja cuando la variables de interés guardan dependencias no lineales con los parámetros de corte.

Por otro lado, se encuentra la necesidad de disponer de un conjunto de datos suficiente para una correcta generalización. Si el *dataset* de la variable en cuestión es relativamente reducido, es posible que el modelo potencial o RSM arroje una precisión similar e incluso mejor al de la RNA. Esto se suma a los supuestos de los modelos analíticos estudiados de linealidad, normalidad, homocedasticidad, independencia de errores, ortogonalidad, rotabilidad y uniformidad entre otros. Si alguno de estos principios no se cumplen, los modelos clásicos pueden tener dificultades para llevar a cabo un buen ajuste, mientras

que las redes neuronales pueden adaptarse mejor a las características reales de los datos sin la necesidad de cumplir necesariamente el conjunto de dichas exigencias.

5.7. Modelado del sistema integral

Tratando de ver cómo se comportaría una RNA que reuniera como variables de entrada, los parámetros de corte (v_c , f y a_p) y de salida, todas aquellas variables de interés estudiadas a lo largo de los apartados previos (propiedades micro y macrogeométricas junto a la microdureza superficial como propiedad mecánica), a lo largo de esta sección, se exponen los resultados alcanzados.

En primer lugar, la arquitectura de la red planteada es de 3-20-9. La elección del número idóneo de neuronas para este caso, se fundamenta en las conclusiones derivadas del apartado [5.2](#) sobre el ajuste de los hiperparámetros. Para tal efecto, a continuación se muestra \mathcal{D} que denota el *dataset* resultado de fusionar todos los anteriores parciales en uno único que opera de $\mathbb{R}^3 \rightarrow \mathbb{R}^9$ como se muestra,

$$\mathcal{D} = \begin{pmatrix} v_c & f & a_p & R_a & R_z & PAR & STR & CRO & RON & CON & CYL & HV \\ 40 & 0,05 & 1 & 0,409 & 2,546 & 44 & 2,1 & 32 & 7 & 15,81 & 19,41 & 183,39 \\ 40 & 0,05 & 1,5 & 0,312 & 2,129 & 35,6 & 3,14 & 36 & 7 & 17,57 & 35,8 & 180,18 \\ 40 & 0,1 & 1 & 0,583 & 2,546 & 45 & 9,38 & 23 & 15,4 & 7,49 & 35,09 & 186,38 \\ \vdots & \vdots & \vdots & \ddots & \ddots & \ddots & \ddots & \ddots & \ddots & \ddots & \ddots & \vdots \\ 60 & 0,05 & 1 & 0,332 & 2,507 & 35,5 & 1,61 & 14 & 8 & 5,36 & 12,19 & 151,43 \\ 60 & 0,1 & 1 & 0,488 & 2,718 & 35,8 & 5,54 & 28 & 26,1 & 11,93 & 49,98 & 204,2 \\ \vdots & \vdots & \vdots & \ddots & \ddots & \ddots & \ddots & \ddots & \ddots & \ddots & \ddots & \vdots \\ 80 & 0,15 & 1 & 1,007 & 4,681 & 32,5 & 12,56 & 21 & 14,7 & 7,08 & 62,86 & 195,25 \\ 80 & 0,2 & 1 & 1,512 & 7,004 & 48,2 & 30,55 & 61 & 28,1 & 23,13 & 94,21 & 200,45 \end{pmatrix}. \quad (5.9)$$

Previo a su ejecución, resulta fundamental la normalización del conjunto de datos (\mathcal{D}) por variables, de acuerdo con la ecuación [5.10](#).

$$x_{\text{norm}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}}, \quad \text{con } x_{\text{norm}} \in [0, 1]. \quad (5.10)$$

Donde x_{norm} es el valor normalizado de la característica x , x denota el valor original del atributo que se desea normalizar, y x_{\min} junto a x_{\max} representan el valor mínimo y máximo respectivamente del vector del parámetro correspondiente.




Figura 5.29: Resultado de la regresión obtenida por la RNA optimizada para la estimación del conjunto de variables de salida (propiedades micro y macrogeométricas junto a la microdureza superficial). En línea en discontinua se muestra el ajuste idóneo (hipotético de $R^2 = 1$) en el que los valores de la estimación (\hat{y}_t) coincidirían a los valores medidos (y_t). En línea continua de mayor grosor se muestra el ajuste de la RNA para los datos disponibles.

La razón principal, es la de evitar escalas variables (al disponer de varias salidas con rangos muy dispares, véase como ejemplo, R_a frente a HV, es especialmente conveniente). De este modo, por un lado, se acelera la convergencia (el gradiente de la función de pérdida puede actualizarse de manera más eficiente durante el proceso de descenso de gradiente) y por otro lado, permite prevenir de problemas de desbordamiento y saturación (*overfitting* y *underfitting*), favoreciendo una correcta generalización y mejora del rendimiento del modelo (al eliminar las diferencias de escala entre características, el modelo se vuelve menos sensible a pequeñas variaciones en los datos y puede capturar satisfactoriamente patrones más generales).

En la figura [5.29](#) se muestra el ajuste de regresión a partir del modelo de RNA obtenido para la combinación de la familia de parámetros que se pretenden estimar. El coeficiente de determinación obtenido es de $R^2 = 0,8162$. Como puede verse en la tabla [5.6](#) se encuentra cercano al mejor resultado alcanzado para modelo de la red neuronal (R_a), mostrando menos de un 10 % de diferencia entre ambos.

Los resultados obtenidos, reflejan una mejora considerable en precisión con respecto a la predicción individual para algunas variables que mostraron un coeficiente de determinación especialmente bajo (*e.g.*, CYL, PAR o HV). Esto puede atender a varias razones. Al combinar la familia de variables, se dispone de una mayor capacidad de representación ya que se consigue reducir el ruido de las muestras experimentales derivadas de errores en la toma de datos durante la metodología experimental, sumado al aumento de número de datos disponibles para el entrenamiento del sistema. Asimismo, cuando todas las variables de entrada y salida se agrupan en una sola red, es posible que

las relaciones entre diferentes variables de salida proporcionen información cruzada y se beneficien mutuamente, incrementándose igualmente la capacidad de generalización.

5.8. Optimización de los parámetros de corte

En este último apartado, una vez conocidas las predicciones del conjunto de variables de interés tras la optimización de la arquitectura de la RNA, se pretende calcular los parámetros de cortes óptimos que logran minimizar el conjunto de propiedades micro y macrogeométricas y maximizar las propiedades mecánicas como la microdureza superficial simultáneamente a partir del *Grey Relational Analysis* (GRA).

Para ello, se comienza normalizando el valor de cada uno de los parámetros a través de la secuencia de datos obtenida mediante la siguiente ecuación,

$$y_{pq} = \frac{x_{pq} - \min(x_{pq})}{\max(x_{pq}) - \min(x_{pq})}. \quad (5.11)$$

Se escoge el valor de referencia (R) seleccionando el valor máximo de y_{pq} de todas las secuencias de datos, según

$$R = \max(y_{pq}). \quad (5.12)$$

Se calcula la variación de los valores normalizados (Δ_{pq}) con el valor de referencia mediante la ecuación

$$\Delta_{pq} = |y_{pq} - R|. \quad (5.13)$$

Posteriormente, se procede al cálculo de un coeficiente identificador (ξ_{pq}) cuyos valores se hallan comprendidos en el rango $[0, 1]$ con uso de la ecuación

$$\xi_{pq} = \frac{\min(\Delta_{pq}) + 0,5 \cdot \max(\Delta_{pq})}{\Delta_{pq} + 0,5 \cdot \max(\Delta_{pq})}. \quad (5.14)$$

Finalmente se calcula el valor del GRC, obtenida de la media de los coeficientes identificadores, a partir de

$$\text{GRC} = \frac{\sum_{i=1}^n \xi_{pq}}{n}. \quad (5.15)$$

Asimismo, se busca *small is better* (minimización), haciendo uso de

$$x_i^*(k) = \frac{\max(x_i^0(k)) - x_i^0(k)}{\max(x_i^0(k)) - \min(x_i^0(k))}, \quad (5.16)$$

análogamente para *large is better* (maximización),

$$x_i^*(k) = \frac{x_i^*(k) - \min(x_i^0(k))}{\max(x_i^0(k)) - \min(x_i^0(k))}. \quad (5.17)$$

De forma experimental, existen 12 combinaciones (correspondientes a las 3 v_c por los 4 valores de f descritos en la Metodología). Cuando se optimiza habitualmente se emplean solo los resultados experimentales. Sin embargo, tratando de invertir el sentido de las estimaciones de la RNA (parámetros de corte \rightarrow propiedades de la integridad superficial), se estudian un total de 1270 combinaciones (resultado de predecir el comportamiento para valores de v_c desde 40 a 80 m/min en incrementos de 1 m/min, para f comprendido entre 0.05 y 0.2 mm/rev en saltos de 0,005 mm/rev y bajo un valor de $a_p = 1$ mm) que permiten ajustar de forma más precisa las condiciones óptimas de fabricación.

Tras ello, como se muestra en la tabla [5.7](#), se obtiene que los valores idóneos de las condiciones de corte son $v_c = 40.000$ m/min, $f = 0.050$ mm/rev, $a_p = 1.000$ mm, para los que se obtiene como propiedades, los valores de $R_a \simeq 0.367$ μm , $R_z \simeq 2.823$ μm , $\text{PAR} \simeq 33.807$ μm , $\text{STR} \simeq 2.503$ μm , $\text{CRO} \simeq 24.701$ μm , $\text{RON} \simeq 11.350$ μm , $\text{CON} \simeq 9.676$ μm , $\text{CYL} \simeq 28.811$ μm , $\text{HV} \simeq 181.050$. Lo que resulta evidente, para valores mínimos de f se obtienen los valores óptimos de desviaciones y rugosidad superficial. Así como para v_c , un incremento de éste, tiende a mejorar el comportamiento a microdureza. Este efecto no es lo suficientemente importante como el que supone valores de v_c bajos sobre las desviaciones geométricas.

v_c m/min	f mm/rev	STR μm	RON μm	CON μm	CYL μm	CRO μm	PAR μm	R_a μm	R_z μm	HV -	GRC -	Rank -
40.000	0.050	2.503	11.350	9.676	28.811	24.701	33.807	0.368	2.823	181.046	0.826	1
40.000	0.055	2.722	11.737	9.243	29.358	24.935	33.696	0.395	2.973	181.084	0.808	24
40.000	0.060	2.944	12.142	8.866	29.934	25.219	33.585	0.424	3.126	181.122	0.791	53
40.000	0.065	3.172	12.566	8.552	30.540	25.553	33.473	0.454	3.280	181.159	0.774	91
40.000	0.070	3.403	13.008	8.308	31.177	25.936	33.362	0.485	3.436	181.197	0.758	129
40.000	0.075	3.640	13.470	8.139	31.846	26.363	33.251	0.517	3.593	181.235	0.742	175
40.000	0.080	3.881	13.951	8.051	32.547	26.830	33.140	0.550	3.752	181.272	0.727	216
40.000	0.085	4.127	14.452	8.043	33.282	27.329	33.028	0.585	3.912	181.310	0.712	244
40.000	0.090	4.378	14.974	8.110	34.052	27.851	32.917	0.621	4.073	181.348	0.697	278
40.000	0.095	4.635	15.516	8.237	34.856	28.385	32.806	0.657	4.234	181.385	0.683	310
40.000	0.100	4.896	16.078	8.407	35.697	28.916	32.695	0.695	4.397	181.423	0.669	341
40.000	0.105	5.162	16.661	8.597	36.573	29.429	32.584	0.735	4.560	181.461	0.656	366
40.000	0.110	5.433	17.263	8.783	37.486	29.908	32.473	0.775	4.723	181.498	0.644	402
40.000	0.115	5.710	17.886	8.950	38.436	30.337	32.362	0.816	4.887	181.536	0.632	423
40.000	0.120	5.992	18.528	9.085	39.422	30.703	32.251	0.858	5.050	181.574	0.622	454
40.000	0.125	6.278	19.190	9.186	40.446	30.996	32.140	0.901	5.213	181.612	0.612	482
40.000	0.130	6.571	19.869	9.255	41.505	31.215	32.030	0.945	5.376	181.649	0.603	505
40.000	0.135	6.868	20.566	9.303	42.601	31.367	31.919	0.989	5.538	181.687	0.595	533
40.000	0.140	7.170	21.280	9.344	43.733	31.472	31.808	1.034	5.700	181.725	0.587	548
40.000	0.145	7.477	22.010	9.398	44.899	31.566	31.698	1.079	5.860	181.763	0.580	582
40.000	0.150	7.789	22.754	9.483	46.099	31.696	31.587	1.125	6.020	181.800	0.573	599
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
80.000	0.200	15.237	31.490	19.847	83.510	60.250	34.638	1.495	7.074	185.560	0.462	1062

Tabla 5.7: Optimización GRA de los parámetros de corte.

En un sector industrial como el aeronáutico y aeroespacial, los tiempos de fabricación resultan claves para la competitividad, por lo cual, es una variable que debería considerarse en el proceso de fabricación. Además, es habitual considerar unos valores de tolerancias exigidas en los acabados superficiales de las piezas mecanizadas. En este sentido, suele tomarse una tolerancia máxima para R_a de 1.600 μm . Como todos los ensayos realizados presentan una R_a inferior a este valor, podría dejarse fuera esta variable del proceso de optimización (junto a R_z) tratando de dar mayor importancia en el proceso a otras variables de salida, como pueden ser la microdureza (HV) y los tiempos de corte (t_c). Por estos motivos, se vuelve a realizar el análisis de la optimización de las variables de desviaciones macrogeométricas, microdureza y tiempos de mecanizado.

Para ello y tratando de obtener una solución distinta a la obvia, se minimiza el tiempo de corte (t_c).

Es bien conocido que el tiempo de corte por pasada (sin incluir tiempos muertos) en una operación de torneado (t_c) puede expresarse como el cociente entre N' (el número de revoluciones necesarias por pasada) y N (el número de revoluciones por minuto). Es decir,

$$t_c = \frac{N'}{N} = \frac{l}{f \cdot \frac{v_c}{\pi d}}, \quad (5.18)$$

siendo v_c y f la velocidad de corte y el avance, l , el recorrido o desplazamiento en la dirección del avance y d , el diámetro de la probeta mecanizada. Por tanto, es posible expresar t_c como

$$t_c = \frac{C(l, d)}{fv_c}, \quad (5.19)$$

entendiéndose C como una constante que depende de la geometría de la pieza. Al optimizar, se normalizan los valores de las variables de interés, por tanto, es lógico afirmar que si se minimiza el inverso del producto de los parámetros de corte, $\min\left(\frac{1}{fv_c}\right)$, se optimiza la operación de mecanizado al minimizar el t_c para cualquier geometría.

Como se ilustra en la tabla [5.8](#), se obtienen como valores óptimos, $v_c = 52.000$ m/min, $f = 0.050$ mm/rev, $a_p = 1.000$ mm, para los que se tienen como propiedades macrogeométricas, los valores de PAR $\simeq 35.060$ μm , STR $\simeq 2.999$ μm , CRO $\simeq 20.289$ μm , RON $\simeq 11.329$ μm , CON $\simeq 8.444$ μm , CYL $\simeq 32.000$ μm , HV $\simeq 182.077$. De nuevo, se tiene que para bajos valores de f (parámetro de corte más influyente), se optimizan la familia de variables relacionadas con la integridad superficial.

v_c m/min	f mm/rev	STR μm	RON μm	CON μm	CYL μm	CRO μm	PAR μm	HV -	t_c -	GRC -	Rank
40.000	0.050	2.503	11.350	9.676	28.811	24.701	33.807	181.046	0.500	0.730	17
40.000	0.055	2.722	11.737	9.243	29.358	24.935	33.696	181.084	0.455	0.724	23
40.000	0.060	2.944	12.142	8.866	29.934	25.219	33.585	181.122	0.417	0.719	46
40.000	0.065	3.172	12.566	8.552	30.540	25.553	33.473	181.159	0.385	0.713	69
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
51.000	0.175	10.484	26.872	14.793	59.276	46.463	32.174	182.935	0.112	0.558	881
51.000	0.180	10.839	27.675	15.654	60.720	47.877	32.063	182.973	0.109	0.553	913
51.000	0.185	11.197	28.480	16.520	62.171	49.059	31.952	183.011	0.106	0.549	937
51.000	0.190	11.556	29.286	17.356	63.626	49.910	31.842	183.048	0.103	0.545	960
51.000	0.195	11.916	30.091	18.128	65.082	50.373	31.731	183.086	0.101	0.543	976
52.000	0.200	12.383	30.913	19.029	67.167	50.971	31.724	183.209	0.096	0.539	1002
52.000	0.050	2.999	11.329	8.444	32.000	20.289	35.060	182.077	0.385	0.734	1
52.000	0.055	3.242	11.727	8.280	32.709	21.491	34.949	182.115	0.350	0.724	25
52.000	0.060	3.491	12.144	8.304	33.452	22.780	34.837	182.152	0.321	0.713	67
52.000	0.065	3.745	12.580	8.514	34.229	24.143	34.726	182.190	0.296	0.702	136
52.000	0.070	4.003	13.034	8.901	35.042	25.565	34.614	182.228	0.275	0.690	217
52.000	0.075	4.267	13.509	9.437	35.890	27.025	34.503	182.266	0.256	0.678	267
52.000	0.080	4.537	14.003	10.081	36.775	28.497	34.391	182.304	0.240	0.666	310
52.000	0.085	4.811	14.517	10.775	37.696	29.954	34.280	182.341	0.226	0.654	354
52.000	0.090	5.091	15.052	11.454	38.654	31.363	34.168	182.379	0.214	0.643	394
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
80	0.2	15.2372	31.4899	19.8472	83.5098	60.2496	34.6384	185.5599	0.0625	0.556820131	888

Tabla 5.8: Optimización GRA de los parámetros de corte sin considerar R_a y R_z e incluyendo t_c .

En este caso, se obtiene un mayor valor de v_c debido al tiempo de mecanizado (t_c). Al tener valores menores de t_c con mayores v_c , tiende a aumentar el valor de v_c para la solución óptima. Sin embargo, el efecto que tiene f sobre las desviaciones macrogeométricas sigue siendo predominante y a pesar de que un incremento de f conduce a una reducción de t_c su efecto no prevalece sobre el del conjunto de las desviaciones.

Capítulo 6

Conclusiones y trabajos futuros

6.1. Introducción

Durante este último capítulo, se pretende realizar un juicio crítico y discusión de los resultados obtenidos, aunando las conclusiones claves derivadas del proyecto y posibles líneas futuras de desarrollo.

6.2. Conclusiones

Como conclusión principal del presente Trabajo Fin de Grado cabe destacar que la utilización de redes neuronales artificiales (RNAs) para la obtención de un modelo predictivo de regresión que describa el comportamiento y evolución de las desviaciones micro y macrogeométricas junto a la microdureza superficial (como métrica de las propiedades mecánicas del material) en función de los parámetros de corte (v_c , f y a_p) durante el proceso de mecanizado en seco de la aleación de aluminio UNS A97075 ha demostrado resultar una herramienta eficaz.

Asimismo, pueden extraerse las siguientes conclusiones resultado de cada uno de los capítulos que conforman este trabajo.

En primer lugar, del CAPÍTULO 2, tras la revisión de las técnicas de Inteligencia Artificial para predecir ciertas propiedades relacionadas con la calidad superficial, se concluye que las RNAs es una de las estrategias más recurrentes dentro del paradigma *Machine Learning* (con algoritmos de entrenamientos de tipo *backpropagation*, lógica borrosa y AGs) junto a las técnicas estadísticas de regresión lineal y análisis de la correlación, ante la imposibilidad de afrontar analíticamente el modelado de estas variables que no pueden verse reflejadas en ecuaciones físicas.

Sin embargo, se evidenció una falta de trabajos que aborden la estimación de la familia de propiedades macrogeométricas y, aún más, que lo hagan de manera conjunta para las variables geométricas (a escala micro y macro) y la microdureza superficial. En este sentido, este proyecto trata de cubrir este *gap* y contribuir a disponer de un sistema experto que permita predecir, con suficiente precisión, las condiciones óptimas de fabricación asociadas a determinados valores umbrales ligados a la integridad superficial.

Por otra parte, en base a los conceptos fundamentales sobre Aprendizaje Automático, abordados en el CAPÍTULO 3, a lo largo del CAPÍTULO 5, se planteó con éxito, la optimización de algunos de los principales hiperparámetros a nivel de estructura y topología de la RNA (número de capas y neuronas ocultas, naturaleza del algoritmo de aprendizaje y subconjunto de datos destinados a entrenamiento, validación y prueba que arrojan mayor nivel de precisión). Partiendo de los valores de referencia encontrados en la literatura y tras completar los pasos de la metodología descritos en el CAPÍTULO 4 se demostró que el algoritmo de Regularización Bayesiana como método de entrenamiento, con una capa oculta para una arquitectura SLFN con 20 neuronas, la función de activación sigmoide y lineal para la capa oculta y de salida respectivamente y como lotes de datos óptimos destinados para cada una de las fases (70-15-15 %), aquellos que se obtuvieron como resultado de ejecutar 10^4 modelos distintos de RNAs para diferentes combinaciones de hiperparámetros, se consiguió reducir significativamente la métrica de RMSE (un máximo de un 29.28 % para R_a con respecto al caso más desfavorable).

Si bien es cierto que la mejora que introduce el enfoque propuesto es considerable (especialmente para las propiedades microgeométricas) y genera un impacto positivo en la calidad de las predicciones futuras, es necesario sopesar el beneficio que supone frente al coste computacional que requiere. Por un lado, si los requisitos de diseño exigen altos niveles de precisión en las estimaciones de los parámetros de corte que generan ciertos valores de propiedades geométricas o de microdureza superficial, el coste computacional puede estar justificado (más aún para este sector industrial que dispone de recursos sobradamente capaces de acometer dichas tareas). Asimismo, es importante considerar, la escalabilidad y capacidad de adaptación del algoritmo para configurar otros hiperparámetros con mayor y menor número de iteraciones. En este caso, para la prueba de 10^4 modelos de RNAs (de 1 a 50 neuronas en la capa oculta) frente a la de $4 \cdot 10^3$ (de 1 a 20 neuronas), el nivel de mejora aportado es marginal (cifrado en un 2.12 %) en relación al tiempo de cálculo supuesto. De donde puede concluirse que un enfoque que estudie en torno a dicho número de neuronas ocultas para $1 - 2 \cdot 10^2$ iteraciones puede resultar buena opción para equilibrar precisión-costes (*trade-off*).

También se puede deducir que además de todos los ajustes de los hiperparámetros que configuran el sistema, la selección óptima de las muestras destinadas a entrenamiento, validación y prueba junto a un buen criterio de preprocesamiento de los datos para prescindir de los espurios, son cruciales para mejorar la calidad del modelo predictivo de la red neuronal. Sin embargo, no existe un valor único del número de capas o de neuronas ocultas que pueda garantizar una mejora significativa del ajuste. No obstante, una elección errónea de estos (valores excesivamente altos o bajos) puede conducir a errores durante el entrenamiento.

Una vez mejorada la capacidad de generalización del modelo de la RNA, controlados los problemas de *underfitting* y *overfitting* y minimizada la variabilidad de las estimaciones obtenidas tras cada ejecución, se recoge gráficamente la evolución de las variables de interés relacionadas con la integridad superficial en función de f (desde 0.05 a 0.20 mm/rev) para cada respectivo valor de v_c (desde 40 hasta 80 m/s). Además, con el objetivo de invertir el compartimiento habitual del sistema y predecir los parámetros de corte óptimos asociados a determinados valores de desviaciones micro y macrogeométricas o de microdureza superficial, se han obtenido un conjunto de familias de curvas de nivel que representan la distribución de estas propiedades en función de las condiciones de corte (v_c y f). De este modo y de forma complementaria a trabajos recientes discutidos tras revisar la literatura que proponen un aplicativo para afrontar dicha tarea, es posible disponer de una herramienta precisa, sencilla y visual para la optimización del proceso de mecanizado en seco de la aleación UNS A97075.

Por otro lado, se ha comprobado que la bondad del ajuste de los modelos generados por la RNA supera en todos los casos a la alcanzada para otros analíticos clásicos (potencial y RSM). De todos ellos, el coeficiente R^2 se incrementó considerablemente para PAR, RON y CON. Por su parte, del conjunto de variables estudiadas, R_a fue la que mejor ajuste presentó. Como puede verse gráficamente, la distribución obtenida a partir de los tres enfoques resultó ser muy similar, lo que revela que los resultados del modelo de aprendizaje automático fueron consistentes dentro del rango de valores de los parámetros de corte empleados durante el entrenamiento.

Como se detectó durante el Estado del Arte, pocos trabajos tratan de abordar simultáneamente en un único sistema, el estudio del comportamiento de las propiedades microgeométricas (R_a y R_z), las macrogeométricas (PAR, STR, CRO, RON, CON y CYL) y la microdureza superficial (HV) en función de los parámetros de corte (v_c , f y a_p). Otro de los objetivos resueltos de este proyecto fue integrar los modelos individuales (cuyo *output*, cada una de las propiedades) en uno global capaz de reflejar posibles sinergias e influencias entre variables. El resultado obtenido tras la normalización del conjunto de datos experimentales, reflejó un buen coeficiente de determinación

($R^2 = 0.8162$) del modelo integral, cercano al de R_a (con menos de un 10 % de diferencia entre ambos).

Paralelamente, con el propósito de hallar los parámetros de corte óptimos que logren tanto minimizar las propiedades micro y macrogeométricas como maximizar la microdureza superficial, se empleó el enfoque GRA. Los resultados obtenidos señalaron de forma lógica, que bajos valores de f (0.05 mm/rev) acompañados de v_c (52 m/min) y a_p (1 mm) permiten cumplir las exigencias planteadas.

En definitiva, los resultados derivados de este Trabajo Fin de Grado ponen de manifiesto la eficacia de la metodología planteada de optimización de los hiperparámetros que controlan el rendimiento del modelo predictivo a partir de RNAs, ofreciendo un conjunto de familias de curvas de nivel para identificar fácilmente los parámetros de corte vinculados a determinados valores de propiedades relacionadas con la integridad superficial, la comparación con modelos analíticos tradicionales, la agrupación en un sistema único de todas las variables previamente mencionadas y haber afrontado satisfactoriamente la optimización de los parámetros de corte para minimizar las desviaciones de forma junto a la rugosidad superficial y potenciar simultáneamente la microdureza superficial.

6.3. Líneas futuras de investigación

Una vez alcanzado este punto, cabe reflexionar sobre lo que dijo el gran Sócrates, *cuanto más sabes, más te das cuenta de que no sabes nada*. Los resultados obtenidos son prometedores para seguir estudiando la influencia de los parámetros de corte en los procesos de mecanizado sostenible de aleaciones similares a la estudiada en este proyecto y explorar otras alternativas relacionadas.

En primer lugar, se abre la posibilidad de aumentar el número de ensayos experimentales recabados con el objetivo de incrementar la capacidad de generalización del modelo propuesto y poder seguir mejorando la calidad del ajuste de regresión. Asimismo, puede interesar ampliar el conjunto de variables de entrada y de salida, considerando el ángulo de posición principal (κ_r), el ángulo de ataque, el efecto del material de la plaquita de corte y su radio de punta (r_ϵ) sobre las fuerzas de corte puestas en juego, temperaturas generadas, vibraciones inducidas, desgaste de la herramienta y consumo específico de energía durante la operación.

De igual modo, podría resultar interesante estudiar el comportamiento que presentan otros materiales de uso común en el sector aeronáutico y aeroespacial, tales como las aleaciones de aluminio UNS A97050, A92024, A92014 o las de titanio Ti-6Al-4V y Ti-6242S. Igualmente, se podría experimentar con otros procesos de fabricación como el fresado, el taladrado, el rectificado o incluso para AWJC (*Abrasive Water-Jet Machining*), profundamente abordados por algunos de los miembros del grupo de investigación de Ingeniería de Fabricación de la UMA (TEP933).

Además, la metodología de optimización de los principales hiperparámetros presentada en este Trabajo Fin de Grado se diseñó con vistas a poder completarse a partir de la incorporación de otros parámetros como el *learning rate*, el *momentum*, la inicialización de los pesos, probando diferentes funciones de activación y topologías como las MLP (*Multi Layer Perceptron*) o RBF (*Radial Basis function*) con realimentación (*e.g.* Jordan Elman), SOM (*Self-Organizing Map*) o las famosas redes de Hopfield. Siendo posible analizar para estas nuevas configuraciones y un mayor número de ejecuciones, el nivel de mejora de precisión aportado en función del tiempo de cálculo precisado.

Bibliografía

- [1] FJ Trujillo Vilches. «Análisis paramétrico del mecanizado en seco de la aleación UNS A97075». Tesis doct. PhD Thesis, University of Málaga, 2013.
- [2] Confederación Española de Organizaciones Empresariales. Consejo del Transporte y Logística. Departamento de Asuntos Regulatorios y Europeos. *El transporte aéreo: aportación a la economía española y propuestas para la mejora de su competitividad*. Inf. téc. 2019.
- [3] Sergio Martín Béjar et al. «Parametric analysis of macro-geometrical deviations in dry turning of UNS A97075 (Al-Zn) alloy». En: *Metals* 9.11 (2019), pág. 1141.
- [4] Sergio Martín-Bejar. «Análisis Paramétrico del comportamiento a fatiga de piezas torneadas en seco de la aleación UNS A97075 (Al-Zn)». Tesis doct. PhD Thesis, University of Málaga, 2020.
- [5] Gyanendra Singh Goindi y Prabir Sarkar. «Dry machining: A step towards sustainable machining – Challenges and future directions». En: *Journal of Cleaner Production* 165 (2017), págs. 1557-1571. ISSN: 0959-6526. DOI: <https://doi.org/10.1016/j.jclepro.2017.07.235>. URL: <https://www.sciencedirect.com/science/article/pii/S0959652617316918>.
- [6] Sergio Martín-Bejar et al. «Cutting speed and feed influence on surface micro-hardness of dry-turned UNS A97075-T6 alloy». En: *Applied Sciences* 10.3 (2020), pág. 1049.
- [7] ASM International. Handbook Committee. *ASM handbook*. Vol. 13. ASM international, 1990.
- [8] Flake C Campbell Jr. *Manufacturing technology for aerospace structural materials*. Elsevier, 2011.
- [9] IJ Polmear. «Wrought aluminium alloys». En: *Light alloys* (2005), págs. 97-204.
- [10] Christian Vargel. *Corrosion of aluminium*. Elsevier, 2020.
- [11] LF Mondolfo. «Aluminium alloys: structure and properties, Butter Worths, London, 1». En: *Ausgabe, S 72* (1976).

- [12] Christian Vargel, M Jacques y MP Schmidt. «Corrosion of aluminium. 2004». En: *Elsevier* ().
- [13] Myer Kutz. *Materials and Mechanical Design*. John Wiley & Sons, 2006.
- [14] C Luo et al. «Observations of intergranular corrosion in AA2024-T351: The influence of grain stored energy». En: *Corrosion Science* 61 (2012), págs. 35-44.
- [15] SA Barter, L Molent y RJH Wanhill. «Typical fatigue-initiating discontinuities in metallic aircraft structures». En: *International Journal of Fatigue* 41 (2012), págs. 11-22.
- [16] L B Vogelesang y Ad Vlot. «Development of fibre metal laminates for advanced aerospace structures». En: *Journal of materials processing technology* 103.1 (2000), págs. 1-5.
- [17] JS Robinson, A O'Donovan y RC Wimpory. «Uphill Quenching to Reduce Residual Stress in Aluminium Alloy 7449 Hollow Structures». En: *Experimental Mechanics* 62.8 (2022), págs. 1411-1420.
- [18] Chinmaya R Dandekar y Yung C Shin. «Modeling of machining of composite materials: a review». En: *International Journal of Machine tools and manufacture* 57 (2012), págs. 102-121.
- [19] J Clos. «Plan estratégico para el sector aeronáutico español en el periodo 2008-2016». En: *Madrid: Centro para el Desarrollo Tecnológico Industrial. Recuperado de: https://www.cdti.es/recursos/publicaciones/archivos/43134_257257200791039.pdf* (2007).
- [20] Victor Songmene et al. «Machining and machinability of aluminum alloys». En: *Alum. Alloys Theory Appl* (2011), págs. 377-400.
- [21] JM Sánchez Sola. «Análisis paramétrico del mecanizado de aleaciones de aluminio: relación con la topografía de las muestras mecanizadas». Tesis doct. UNED. Universidad Nacional de Educación a Distancia, 2004.
- [22] Moises Batista Ponce et al. «ENERGY LIFECYCLE MANAGEMENT. A NEW CONCEPT FOR MANAGING THE ENERGY EFFICIENCY IN MANUFACTURING PROCESSES.» En: *Annals of DAAAM & Proceedings* (2011).
- [23] Jorge Salguero et al. «Sustainable Manufacturing in Aerospace Industry—Analysis of the Viability of Intermediate Stages Elimination in Sheet Processing». En: *Advanced Materials Research* 107 (2010), págs. 9-14.
- [24] Lai-Zhe Jin y Rolf Sandström. «Machinability data applied to materials selection». En: *Materials & Design* 15.6 (1994), págs. 339-346.

- [25] ASM Handbook. «Vol. 16: Machining, ASM International». En: *Materials Park, OH* (1995).
- [26] JM Sánchez et al. «Microstructural characterisation of material adhered over cutting tool in the dry machining of aerospace aluminium alloys». En: *Journal of Materials Processing Technology* 164 (2005), págs. 911-918.
- [27] MS Carrilero et al. «A SEM and EDS insight into the BUL and BUE differences in the turning processes of AA2024 Al–Cu alloy». En: *International Journal of Machine Tools and Manufacture* 42.2 (2002), págs. 215-220.
- [28] JM Sánchez Sola et al. «Estudio morfológico de la viruta en el torneado en seco de aleaciones de aluminio: relación con la calidad superficial». En: *Perspectiva de la investigación sobre materiales en España en el siglo XXI*. Servicio de Publicaciones. 2006, págs. 179-182.
- [29] J Raposo Barrada y M Marcos Bárcena. «Fabricación Lean y Conformado de Materiales Compuestos de Matriz Polimérica Termoestable». En: *Libro de Actas* (), pág. 51.
- [30] Edward M Trent y Paul K Wright. *Metal cutting*. Butterworth-Heinemann, 2000.
- [31] Marc Stipo. *It's all in the chips...* Publicación en LinkedIn. Oct. de 2019. URL: <https://www.linkedin.com/pulse/its-all-chips-marc-stipo>.
- [32] M Machkova et al. «Effect of the anionic part of various Ce (III) salts on the corrosion inhibition efficiency of AA2024 aluminium alloy». En: *Corrosion Science* 69 (2013), págs. 396-405.
- [33] HA Kishawy et al. «Effect of coolant strategy on tool performance, chip morphology and surface quality during high-speed machining of A356 aluminum alloy». En: *International Journal of Machine Tools and Manufacture* 45.2 (2005), págs. 219-227.
- [34] G Castro et al. «Dry machining of silicon–aluminium alloys with CVD diamond brazed and directly coated Si₃N₄ ceramic tools». En: *Vacuum* 82.12 (2008), págs. 1407-1410.
- [35] GV Chakravarthy et al. «A comparative study on wear behavior of TiN and diamond coated WC–Co substrates against hypereutectic Al–Si alloys». En: *Applied surface science* 261 (2012), págs. 520-527.
- [36] Mikell P Groover. *Fundamentals of modern manufacturing: materials, processes, and systems*. John Wiley & Sons, 2020.
- [37] Johan Zander y Rolf Sandström. «Modelling technological properties of commercial wrought aluminium alloys». En: *Materials & design* 30.9 (2009), págs. 3752-3759.

- [38] RM Rashad y TM El-Hossainy. «Machinability of 7116 structural aluminum alloy». En: *Materials and Manufacturing Processes* 21.1 (2006), págs. 23-27.
- [39] Halil Demir y Süleyman Gündüz. «The effects of aging on machinability of 6061 aluminium alloy». En: *Materials & Design* 30.5 (2009), págs. 1480-1483.
- [40] G Rotella et al. «Finite element modeling of microstructural changes in turning of AA7075-T651 alloy». En: *Journal of Manufacturing Processes* 15.1 (2013), págs. 87-95.
- [41] Janez Grum y Marija Kisin. «The influence of the microstructure of three Al–Si alloys on the cutting-force amplitude during fine turning». En: *International Journal of Machine Tools and Manufacture* 46.7-8 (2006), págs. 769-781.
- [42] Moises Batista et al. «Image based analysis evaluation of the elements of secondary adhesion wear in dry turning of aluminum alloys». En: *Advanced Materials Research* 498 (2012), págs. 133-138.
- [43] P Eh Hovsepian et al. «TiAlN/VN superlattice structured PVD coatings: a new alternative in machining of aluminium alloys for aerospace and automotive components». En: *Surface and coatings technology* 201.1-2 (2006), págs. 265-272.
- [44] Humberto Gomez et al. «Adhesion analysis and dry machining performance of CVD diamond coatings deposited on surface modified WC–Co turning inserts». En: *Journal of Materials Processing Technology* 212.2 (2012), págs. 523-533.
- [45] GV Chakravarthy et al. «A comparative study on wear behavior of TiN and diamond coated WC–Co substrates against hypereutectic Al–Si alloys». En: *Applied surface science* 261 (2012), págs. 520-527.
- [46] F Itoigawa et al. «Effects and mechanisms in minimal quantity lubrication machining of an aluminum alloy». En: *Wear* 260.3 (2006), págs. 339-344.
- [47] Gobierno de España Jefatura del estado. *Ley 7/2022, de 8 de abril, de residuos y suelos contaminados para una economía circular*. BOE núm. 86, de 9 de abril de 2022.
- [48] Zhiqiang Liu et al. «Wear performance of (nc-AlTiN)/(a-Si₃N₄) coating and (nc-AlCrN)/(a-Si₃N₄) coating in high-speed machining of titanium alloys under dry and minimum quantity lubrication (MQL) conditions». En: *Wear* 305.1-2 (2013), págs. 249-259.
- [49] F Pusavec. «Porous tungsten machining under cryogenic conditions». En: *International Journal of Refractory Metals and Hard Materials* 35 (2012), págs. 84-89.

- [50] HL Coldwell et al. «The use of soft/lubricating coatings when dry drilling BS L168 aluminium alloy». En: *Surface and Coatings Technology* 177 (2004), págs. 716-726.
- [51] Alborz Shokrani, Vimal Dhokia y Stephen T Newman. «Environmentally conscious machining of difficult-to-machine materials with regard to cutting fluids». En: *International Journal of Machine Tools and Manufacture* 57 (2012), págs. 83-101.
- [52] Manuel S Carrilero y Mariano Marcos. *Relaciones paramétricas en el mecanizado*. Servicio Publicaciones UCA, 1994.
- [53] EG Ng et al. «High speed face milling of a aluminium silicon alloy casting». En: *CIRP Annals* 53.1 (2004), págs. 69-72.
- [54] Balkrishna Rao y Yung C Shin. «Analysis on high-speed face-milling of 7075-T6 aluminum using carbide and diamond cutters». En: *International Journal of Machine Tools and Manufacture* 41.12 (2001), págs. 1763-1781.
- [55] VD Calatoru et al. «Diffusion wear mechanism during high-speed machining of 7475-T7351 aluminum alloy with carbide end mills». En: *Wear* 265.11-12 (2008), págs. 1793-1800.
- [56] NA Abukhshim, PT Mativenga y Mohammed Aslam Sheikh. «Heat generation and temperature prediction in metal cutting: A review and implications for high speed machining». En: *International Journal of Machine Tools and Manufacture* 46.7-8 (2006), págs. 782-800.
- [57] Ali Basti, Toshiyuki Obikawa y Jun Shinozuka. «Tools with built-in thin film thermocouple sensors for monitoring cutting temperature». En: *International Journal of Machine Tools and Manufacture* 47.5 (2007), págs. 793-798.
- [58] Masafumi Kikuchi. «The use of cutting temperature to evaluate the machinability of titanium alloys». En: *Acta biomaterialia* 5.2 (2009), págs. 770-775.
- [59] R Venkata Rao y OP Gandhi. «Digraph and matrix methods for the machinability evaluation of work materials». En: *International Journal of Machine Tools and Manufacture* 42.3 (2002), págs. 321-330.
- [60] M Nouari et al. «Experimental analysis and optimisation of tool wear in dry machining of aluminium alloys». En: *Wear* 255.7-12 (2003), págs. 1359-1368.
- [61] Hiromichi Yoshikawa y Akio Nishiyama. «CVD diamond coated insert for machining high silicon aluminum alloys». En: *Diamond and Related Materials* 8.8-9 (1999), págs. 1527-1530.

- [62] G Fox-Rabinovich et al. «Cutting performance of different coatings during minimum quantity lubrication drilling of aluminum silicon B319 cast alloy». En: *Surface and Coatings Technology* 205.16 (2011), págs. 4107-4116.
- [63] H Hanyu et al. «Development of high performance diamond-coated drills for cutting high silicon aluminum alloy». En: *Thin Solid Films* 413.1-2 (2002), págs. 139-146.
- [64] Prabhu U Arumugam, Ajay P Malshe y Stephen A Batzer. «Dry machining of aluminum–silicon alloy using polished CVD diamond-coated cutting tools inserts». En: *Surface and Coatings Technology* 200.11 (2006), págs. 3399-3403.
- [65] JM Dasch et al. «The effect of free-machining elements on dry machining of B319 aluminum alloy». En: *Journal of Materials Processing Technology* 209.10 (2009), págs. 4638-4644.
- [66] G List et al. «Wear behaviour of cemented carbide tools in dry machining of aluminium alloy». En: *Wear* 259.7-12 (2005), págs. 1177-1189.
- [67] JM Sánchez-Sola y M Sebastian. «Characterization of the built-up edge and the built-up layer in the machining process of AA 7050 alloy». En: *Revista de Metalurgia* (2005), págs. 365-368.
- [68] Hasan Gökkaya. «The Effects of Machining Parameters on Cutting Forces, Surface Roughness, Built-Up Edge (BUE) and Built-Up Layer (BUL) During Machining AA2014 (T4) Alloy.» En: *Journal of Mechanical Engineering/Strojniški Vestnik* 56.9 (2010).
- [69] N Fang y P Dewhurst. «Slip-line modeling of built-up edge formation in machining». En: *International Journal of Mechanical Sciences* 47.7 (2005), págs. 1079-1098.
- [70] Chao Xue y Wuyi Chen. «Adhering layer formation and its effect on the wear of coated carbide tools during turning of a nickel-based alloy». En: *Wear* 270.11-12 (2011), págs. 895-902.
- [71] JC Hamann, F Le Maitre y D Guillot. «Selective transfer built-up layer displacement in high-speed machining—consequences on tool wear and cutting forces». En: *CIRP annals* 43.1 (1994), págs. 69-72.
- [72] HS Qi y B Mills. «On the formation mechanism of adherent layers on a cutting tool». En: *Wear* 198.1-2 (1996), págs. 192-196.
- [73] A Gómez-Parra et al. «Analysis of the evolution of the Built-Up Edge and Built-Up Layer formation mechanisms in the dry turning of aeronautical aluminium alloys». En: *Wear* 302.1-2 (2013), págs. 1209-1218.

- [74] MA Sebastian et al. «Turned aluminium alloys surface finish monitoring through cutting force measurements». En: *Journal for Manufacturing Science and Production* 4.4 (2002), págs. 211-220.
- [75] MS Carrilero, M Marcos y VM Sánchez. «Feed Cutting Speed and Cutting Forces as Machinability Parameters of Al-Cu Alloys». En: *Journal of the Mechanical Behavior of Materials* 7.3 (1996), págs. 167-178.
- [76] MS Carrilero et al. «Predicción dinamométrica del comportamiento de la aleación AA2024 en los procesos de mecanizado en un rango de velocidades moderadas». En: *Boletín de la Sociedad Española de Cerámica y Vidrio* 36.2-3 (1997), págs. 222-225.
- [77] M Sánchez-Carrillero et al. «Evaluación de la calidad superficial de piezas mecanizadas a partir del análisis de la fuerza de corte». En: *Revista de metalurgia* 34.Extra (1998), págs. 27-31.
- [78] J Salguero et al. «Roughness prediction models for tangential cutting forces in the dry turning of Al-Cu alloys». En: *Proc. of AMPT* (2011).
- [79] Tarek Mabrouki et al. «Numerical and experimental study of dry cutting for an aeronautic aluminium alloy (A2024-T351)». En: *International Journal of Machine Tools and Manufacture* 48.11 (2008), págs. 1187-1197.
- [80] Abeesh C Basheer et al. «Modeling of surface roughness in precision machining of metal matrix composites using ANN». En: *Journal of Materials Processing Technology* 197.1-3 (2008), págs. 439-444.
- [81] KA Risbood, US Dixit y AD Sahasrabudhe. «Prediction of surface roughness and dimensional deviation by measuring cutting forces and vibrations in turning process». En: *Journal of Materials Processing Technology* 132.1-3 (2003), págs. 203-214.
- [82] Ataollah Javidi, Ulfried Rieger y Wilfried Eichlseder. «The effect of machining on the surface integrity and fatigue life». En: *International Journal of fatigue* 30.10-11 (2008), págs. 2050-2055.
- [83] Brian Griffiths. *Manufacturing surface technology: surface integrity & functional performance*. CRC Press, 2001.
- [84] JC De Lacerda et al. «Evolution of the surface roughness of a low carbon steel subjected to fatigue». En: *International Journal of Fatigue* 102 (2017), págs. 143-148.
- [85] Y Matsumoto, F Hashimoto y G Lahoti. «Surface integrity generated by precision hard turning». En: *CIRP Annals* 48.1 (1999), págs. 59-62.

- [86] Dyna Benchergui y Charlie Svoboda. «Aircraft design». En: *AEROSPACE AMERICA* 50.11 (2012), págs. 28-28.
- [87] Guangming Zheng et al. «Effect of cutting parameters on wear behavior of coated tool and surface roughness in high-speed turning of 300M». En: *Measurement* 125 (2018), págs. 99-108.
- [88] K Aslantas y A Çiçek. «High speed turning of Ti6Al4V alloy in micro cutting conditions». En: *Procedia CIRP* 77 (2018), págs. 58-61.
- [89] Martina Gassner et al. «Influence of cutting speed and workpiece material on the wear mechanisms of CVD TiCN/ α -Al₂O₃ coated cutting inserts during turning». En: *Wear* 398 (2018), págs. 90-98.
- [90] Prashant Parhad et al. «The impact of cutting speed and depth of cut on cutting force during turning of austempered ductile iron». En: *Materials Today: Proceedings* 19 (2019), págs. 663-669.
- [91] UNEEN ISO. «4287: 1999, Especificación geométrica de productos (GPS)». En: *Calidad superficial: Método del perfil. Términos, definiciones y parámetros del estado superficial. (ISO 4287: 1997+ Technical Corrigendum 1)* (1999).
- [92] M Sánchez Carrilero et al. «Relaciones paramétricas asociadas a la maquinabilidad de aleaciones de aluminio-cobre». En: *Anales de Ingeniería Mecánica*. Vol. 11. 1997, págs. 59-66.
- [93] M. Á. Sebastián Pérez et al. «Estudio de los parámetros de acabado superficial en el mecanizado de la aleación de Al-Cu AA2024. Aplicación de UNE-EN ISO 4288 y UNE-EN ISO 1302». En: *Actas del XVII Congreso Internacional de Ingeniería Gráfica y XV ADM*. Sevilla, 2005.
- [94] EM Rubio et al. «Surface roughness of AA7050 alloy turned bars: Analysis of the influence of the length of machining». En: *Journal of Materials Processing Technology* 162 (2005), págs. 682-689.
- [95] M Marcos-Bárcena et al. «Study of roundness on cylindrical bars turned of aluminium-copper alloys UNS A92024». En: *Journal of materials processing technology* 162 (2005), págs. 644-648.
- [96] J. M. Sánchez Sola et al. «La precisión geométrica en el mecanizado de barras cilíndricas de aleación de Aluminio-Zinc, basado en mediciones de oscilación radial». En: *Actas del XVIII Congreso Internacional de Ingeniería Gráfica*. Sitges, 2006.
- [97] José Miguel Sánchez-Sola et al. «Cutting speed-feed based parametric model for macro-geometrical deviations in the dry turning of UNS A92024 Al-Cu alloys». En: *Key Engineering Materials* 504 (2012), págs. 1311-1316.

- [98] Michael Field, KAHLES JF y CAMMETT JT. «A review of measuring methods for surface integrity». En: (1972).
- [99] Bing Liu et al. «Machining introduced microstructure modification in aluminium alloys». En: *Journal of Alloys and Compounds* 757 (2018), págs. 233-238.
- [100] Yuchao Bai, Akshay Chaudhari y Hao Wang. «Investigation on the microstructure and machinability of ASTM A131 steel manufactured by directed energy deposition». En: *Journal of Materials Processing Technology* 276 (2020), pág. 116410.
- [101] Wit Grzesik. *Advanced machining processes of metallic materials: theory, modeling and applications*. Elsevier, 2008.
- [102] Mingshuai Huo et al. «Effects of micro flexible rolling and annealing on microstructure, microhardness and texture of aluminium alloy». En: *Materials Characterization* 148 (2019), págs. 142-155.
- [103] Ping Zhang et al. «Analysis of the microhardness, mechanical properties and electrical conductivity of 7055 aluminum alloy». En: *Vacuum* 171 (2020), pág. 109005.
- [104] A. Anon. «Surface integrity». En: *Manufacturing Engineering* 103.1 (1989).
- [105] Jue Lu et al. «Thermal deformation behavior and processing maps of 7075 aluminum alloy sheet based on isothermal uniaxial tensile tests». En: *Journal of Alloys and Compounds* 767 (2018), págs. 856-869.
- [106] Vijay Kurkute y Sandeep T Chavan. «Modeling and Optimization of surface roughness and microhardness for roller burnishing process using response surface methodology for Aluminum 63400 alloy». En: *Procedia Manufacturing* 20 (2018), págs. 542-547.
- [107] Adnan Akkurt. «The effect of cutting process on surface microstructure and hardness of pure and Al 6061 aluminium alloy». En: *Engineering Science and Technology, an International Journal* 18.3 (2015), págs. 303-308.
- [108] Korimilli Surya Sundara Rao y K Viswanath Allamraju. «Effect on microhardness and residual stress in CNC turning of aluminium 7075 alloy». En: *Materials Today: Proceedings* 4.2 (2017), págs. 975-981.
- [109] Carelyn E Campbell et al. «Microstructural characterization of Al-7075-T651 chips and work pieces produced by high-speed machining». En: *Materials Science and Engineering: A* 430.1-2 (2006), págs. 15-26.
- [110] JP Ajithkumar y M Anthony Xavier. «Cutting force and surface roughness analysis during turning of Al 7075 based hybrid composites». En: *Procedia Manufacturing* 30 (2019), págs. 180-187.

- [111] OB Abouelatta y J Madl. «Surface roughness prediction based on cutting parameters and tool vibrations in turning operations». En: *Journal of materials processing technology* 118.1-3 (2001), págs. 269-277.
- [112] M. Correa. «Estudio de técnicas de inteligencia artificial aplicadas al modelado del proceso de fresado». Tesis de mtría. Universidad Politécnica de Madrid, 2003.
- [113] PG Benardos y G-C Vosniakos. «Predicting surface roughness in machining: a review». En: *International journal of machine tools and manufacture* 43.8 (2003), págs. 833-844.
- [114] Stefan Pittner et al. «Correlation between acoustic emission statistics and surface roughness in finish turning». En: *Citeseerx* (2000).
- [115] Samson S Lee y Joseph C Chen. «On-line surface roughness recognition system using artificial neural networks system in turning operations». En: *The International Journal of Advanced Manufacturing Technology* 22 (2003), págs. 498-509.
- [116] John L Yang y Joseph C Chen. «A systematic approach for identifying optimum surface roughness performance in end-milling operations». En: *Journal of industrial technology* 17.2 (2001), págs. 1-8.
- [117] Lieh-Dai Yang et al. «Fuzzy-nets-based in-process surface roughness adaptive control system in end-milling operations». En: *The International Journal of Advanced Manufacturing Technology* 28 (2006), págs. 236-248.
- [118] Joseph C Chen. «An effective fuzzy-nets training scheme for monitoring tool breakage». En: *Journal of Intelligent Manufacturing* 11 (2000), págs. 85-101.
- [119] E Daniel Kirby, Zhe Zhang y Joseph C Chen. «Development of an accelerometer-based surface roughness prediction system in turning operations using multiple regression techniques». En: *Journal of Industrial Technology* 20.4 (2004).
- [120] OB Abouelatta y J Madl. «Surface roughness prediction based on cutting parameters and tool vibrations in turning operations». En: *Journal of materials processing technology* 118.1-3 (2001), págs. 269-277.
- [121] W. Chien y C. Chou. «The prediction model for machinability of 304 stainless steel». En: *Journal of Materials Processing Technology* 118 (2001), págs. 442-447.
- [122] WT Chien y CF Yao. «The development of the predictive model for metal machining parameters based on artificial neural network and genetic algorithm». En: *Proceedings of the 14th Mechanical Engineering, CSME, Taichung* (1997), págs. 468-475.
- [123] Chang-Xue Feng y Xian-Feng Wang. «Surface roughness predictive modeling: neural networks versus regression». En: *IIE Transactions* 35.1 (2003), págs. 11-27.

- [124] Guillem Quintana, Maria Luisa Garcia-Romeu y Joaquim Ciurana. «Surface roughness monitoring application based on artificial neural networks for ball-end milling operations». En: *Journal of Intelligent Manufacturing* 22 (2011), págs. 607-617.
- [125] Alex Baños Chetyrki. «Desarrollo de modelos predictivos de las desviaciones geométricas en piezas mecanizadas en seco de la aleación Ti6Al4V mediante la aplicación de Redes Neuronales Artificiales». Tesis de mtría. Málaga, España: Escuela de Ingenierías Industriales, Universidad de Málaga, Junio 2023.
- [126] Patricia Muñoz-Escalona y Paul G Maropoulos. «Artificial neural networks for surface roughness prediction when face milling Al 7075-T7351». En: *Journal of Materials Engineering and Performance* 19 (2010), págs. 185-193.
- [127] T Saric, G Simunovic y K Simunovic. «Use of neural networks in prediction and simulation of steel surface roughness». En: *International journal of simulation modelling* 12.4 (2013), págs. 225-236.
- [128] N Fang, P Srinivasa Pai y N Edwards. «Neural network modeling and prediction of surface roughness in machining aluminum alloys». En: *Journal of Computer and Communications* 4.5 (2016), págs. 1-9.
- [129] Azlan Mohd Zain, Habibollah Haron y Safian Sharif. «Prediction of surface roughness in the end milling machining using Artificial Neural Network». En: *Expert Systems with Applications* 37.2 (2010), págs. 1755-1768.
- [130] Maritza Correa Valencia. «Inteligencia artificial para la predicción y control del acabado superficial en procesos de fresado a alta velocidad». Tesis doct. Dpto. de Inteligencia Artificial, Facultad de Informatica, Universidad Politécnica de Madrid, 2010.
- [131] Guillermo Arias Veiga. «Aplicación de redes neuronales artificiales al análisis de desviaciones geométricas en el mecanizado en seco de la aleación UNS A97075 (Al-Zn)». Tesis de mtría. Málaga, España: Escuela de Ingenierías Industriales, Universidad de Málaga, Junio 2023.
- [132] M Vishnu Vardhan, G Sankaraiah y M Yohan. «Prediction of surface roughness & material removal rate for machining of P20 steel in CNC milling using artificial neural networks». En: *Materials Today: Proceedings* 5.9 (2018), págs. 18376-18382.
- [133] Venkatesh Mundada y Suresh Kumar Reddy Narala. «Optimization of milling operations using artificial neural networks (ANN) and simulated annealing algorithm (SAA)». En: *Materials Today: Proceedings* 5.2 (2018), págs. 4971-4985.

- [134] Erol Kilickap, Ahmet Yardimeden y Yahya Hışman Çelik. «Mathematical modelling and optimization of cutting force, tool wear and surface roughness by using artificial neural network and response surface methodology in milling of Ti-6242S». En: *Applied Sciences* 7.10 (2017), pág. 1064.
- [135] Guijian Xiao et al. «An intelligent parameters optimization method of titanium alloy belt grinding considering machining efficiency and surface quality». En: *The International Journal of Advanced Manufacturing Technology* 125.1-2 (2023), págs. 513-527.
- [136] Koshy Zacharia y P Krishnakumar. «Chatter prediction in high speed machining of titanium alloy (Ti-6Al-4V) using machine learning techniques». En: *Materials today: proceedings* 24 (2020), págs. 350-358.
- [137] B. Anuja Beatrice et al. «Surface Roughness Prediction using Artificial Neural Network in Hard Turning of AISI H13 Steel with Minimal Cutting Fluid Application». En: *Procedia Engineering* 97 (2014). "12th Global Congress on Manufacturing and Management" GCM - 2014, págs. 205-211. ISSN: 1877-7058. DOI: <https://doi.org/10.1016/j.proeng.2014.12.243>. URL: <https://www.sciencedirect.com/science/article/pii/S1877705814033025>.
- [138] Yusimit Zamora-Hernández et al. «Comparación entre redes neuronales artificiales y regresión múltiple para la predicción de la rugosidad superficial en el torneado en seco». En: *Ingenius. Revista de Ciencia y Tecnología* 19 (2018), págs. 79-88.
- [139] Şener Karabulut y Halil Karakoç. «Investigation of surface roughness in the milling of Al7075 and open-cell SiC foam composite and optimization of machining parameters». En: *Neural Computing and Applications* 28 (2017), págs. 313-327.
- [140] Patricia Muñoz-Escalona y Paul G Maropoulos. «Artificial neural networks for surface roughness prediction when face milling Al 7075-T7351». En: *Journal of Materials Engineering and Performance* 19 (2010), págs. 185-193.
- [141] Anh-Tu Nguyen et al. «Multiobjective Optimization of Surface Roughness and Tool Wear In High-Speed Milling of AA6061 by Machine Learning and NSGA-II». En: *Advances in Materials Science and Engineering* 2022 (2022).
- [142] Juan Carlos García Jiménez. *Aplicación de las redes neuronales a la optimización de fármacos*. Trabajo Fin de Grado, Grado en Ingeniería de Tecnologías Industriales. Dpto. de organización Industrial y Gestión de Empresas I, Escuela Técnica Superior de Ingeniería, Universidad de Sevilla. 2017.
- [143] Joaquín Amat. *Redes neuronales con Python*. Mayo, 2021. 2021. URL: <https://cienciadedatos.net/documentos/py35-redes-neuronales-python>.

- [144] MathWorks Matlab. *Choose a Multilayer Neural Network Training Function*. URL: <https://es.mathworks.com/help/deeplearning/ug/choose-a-multilayer-neural-network-training-function.html> (visitado 08-07-2023).
- [145] *Metallic Materials – Rotating Bar Bending Fatigue Testing*. International Organization for Standardization. ISO 1143:2010. 2010. URL: <https://www.iso.org/standard/51947.html>.
- [146] *Metallic Materials – Fatigue Testing – Statistical Planning and Analysis of Data*. International Organization for Standardization. ISO 12107:2012. 2012. URL: <https://www.iso.org/standard/51957.html>.
- [147] *Materiales Metálicos. Ensayo de Dureza Vickers. Parte 1: Métodos de Ensayo*. Asociación Española de Normalización. UNE-EN ISO 6507-1:2018. 2018. URL: <https://www.aenor.com/normas-y-libros/buscador-de-normas/une?c=N0065069>.
- [148] J. Salguero Gómez. «Análisis, evaluación y propuestas de mejora del rendimiento del mecanizado de alta velocidad de aleaciones de aluminio de interés en la industria aeronáutica». Tesis doct. Universidad de Cádiz, 2013.
- [149] *Especificación Geométrica de Producto (GPS). Calidad Superficial: Método del Perfil. Reglas y Procedimientos para la Evaluación del Estado Superficial*. Asociación Española de Normalización. UNE-EN ISO 4288:1998. 1998. URL: <https://www.aenor.com/normas-y-libros/buscador-de-normas/une?c=N0005623>.
- [150] Peng Dong et al. «Microstructure, microhardness and corrosion susceptibility of friction stir welded AlMgSiCu alloy». En: *Materials & Design (1980-2015)* 54 (2014), págs. 760-765.
- [151] I Alfonso et al. «Efecto de las variables experimentales sobre la microdureza en aleaciones Al-6Si-3Cu-xMg T6». En: *Matéria (Rio de Janeiro)* 13 (2008), págs. 110-118.
- [152] Lorenzo Viscanti. «Your Predictions Are Only As Good As Your Data: Testing Data Vs Training Data In Machine Learning». En: *Becoming Human: Artificial Intelligence Magazine* (2023). URL: <https://becominghuman.ai/your-predictions-are-only-as-good-as-your-data-2a975e53dc18>.
- [153] Pei Chin Sim et al. «Prediction of tool wear using Machine Vision Approach». En: *Academic Journal of Manufacturing Engineering* 20.1 (2022).
- [154] Hilde JP Weerts, Andreas C Mueller y Joaquin Vanschoren. «Importance of tuning hyperparameters of machine learning algorithms». En: *arXiv preprint arXiv:2007.07588* (2020).

- [155] Andrea Menapace, Ariele Zanfei y Maurizio Righetti. «Tuning ANN hyperparameters for forecasting drinking water demand». En: *Applied Sciences* 11.9 (2021), pág. 4290.
- [156] Frank Hutter, Jörg Lücke y Lars Schmidt-Thieme. «Beyond manual tuning of hyperparameters». En: *KI-Künstliche Intelligenz* 29 (2015), págs. 329-337.
- [157] GE Robbins et al. «Generation and adaptation of neural networks by evolutionary techniques (GANNET)». En: *Neural Computing & Applications* 1 (1993), págs. 23-31.
- [158] Aleksandar Kosarac et al. «Neural-Network-Based Approaches for Optimization of Machining Parameters Using Small Dataset». En: *Materials* 15.3 (2022). ISSN: 1996-1944. DOI: [10.3390/ma15030700](https://doi.org/10.3390/ma15030700). URL: <https://www.mdpi.com/1996-1944/15/3/700>.
- [159] B. Anuja Beatrice et al. «Surface Roughness Prediction using Artificial Neural Network in Hard Turning of AISI H13 Steel with Minimal Cutting Fluid Application». En: *Procedia Engineering* 97 (2014). "12th Global Congress on Manufacturing and Management" GCM - 2014, págs. 205-211. ISSN: 1877-7058. DOI: <https://doi.org/10.1016/j.proeng.2014.12.243>. URL: <https://www.sciencedirect.com/science/article/pii/S1877705814033025>.
- [160] C Sanjay y CJTIJOAMT Jyothi. «A study of surface roughness in drilling using mathematical analysis and neural networks». En: *The International Journal of Advanced Manufacturing Technology* 29 (2006), págs. 846-852.
- [161] EO Ezugwu et al. «Modelling the correlation between cutting and process parameters in high-speed machining of Inconel 718 alloy using an artificial neural network». En: *International Journal of Machine Tools and Manufacture* 45.12-13 (2005), págs. 1375-1385.
- [162] Muataz HF Al Hazza y Erry YT Adesta. «Investigation of the effect of cutting speed on the Surface Roughness parameters in CNC End Milling using Artificial Neural Network». En: *IOP conference series: materials science and engineering*. Vol. 53. 1. IOP Publishing. 2013, pág. 012089.
- [163] Mozammel Mia y Nikhil Ranjan Dhar. «Prediction of surface roughness in hard turning under high pressure coolant using Artificial Neural Network». En: *Measurement* 92 (2016), págs. 464-474. ISSN: 0263-2241. DOI: <https://doi.org/10.1016/j.measurement.2016.06.048>. URL: <https://www.sciencedirect.com/science/article/pii/S0263224116303402>.

- [164] Muammer Nalbant et al. «The experimental investigation of the effects of uncoated, PVD-and CVD-coated cemented carbide inserts and cutting parameters on surface roughness in CNC turning and its prediction using artificial neural networks». En: *Robotics and Computer-Integrated Manufacturing* 25.1 (2009), págs. 211-223.
- [165] Geoffrey E Hinton, Simon Osindero y Yee-Whye Teh. «A fast learning algorithm for deep belief nets». En: *Neural computation* 18.7 (2006), págs. 1527-1554.
- [166] Muhammad Uzair y Noreen Jamil. «Effects of hidden layers on the efficiency of neural networks». En: *2020 IEEE 23rd international multitopic conference (INMIC)*. IEEE. 2020, págs. 1-6.
- [167] Huayu Shen et al. «Determining the number of BP neural network hidden layer units». En: *Journal of tianjin University of Technology* 24.5 (2008), pág. 13.
- [168] Dimitris Stathakis. «How many hidden layers and nodes?» En: *International Journal of Remote Sensing* 30.8 (2009), págs. 2133-2147.
- [169] Saurabh Karsoliya. «Approximating number of hidden layer neurons in multiple hidden layer BPNN architecture». En: *International Journal of Engineering Trends and Technology* 3.6 (2012), págs. 714-717.
- [170] Nayer Wanas et al. «On the optimal number of hidden nodes in a neural network». En: *Conference proceedings. IEEE Canadian conference on electrical and computer engineering (Cat. No. 98TH8341)*. Vol. 2. IEEE. 1998, págs. 918-921.
- [171] Purva Raut y Apurva Dani. «Correlation between number of hidden layers and accuracy of artificial neural network». En: *Advanced Computing Technologies and Applications: Proceedings of 2nd International Conference on Advanced Computing Technologies and Applications—ICACTA 2020*. Springer. 2020, págs. 513-521.
- [172] Tong Yu y Hong Zhu. «Hyper-parameter optimization: A review of algorithms and applications». En: *arXiv preprint arXiv:2003.05689* (2020).
- [173] Jeff Heaton. *The number of hidden layers*. 2017. URL: <https://www.heatonresearch.com/2017/06/01/hidden-layers> (visitado 10-07-2023).
- [174] K Gnana Sheela, Subramaniam N Deepa et al. «Review on methods to fix number of hidden neurons in neural networks». En: *Mathematical problems in engineering* 2013 (2013).
- [175] Tijana Vujičić et al. «Comparative analysis of methods for determining number of hidden neurons in artificial neural network». En: *Central European conference on information and intelligent systems*. Vol. 219. 2016.

- [176] Alan J Thomas et al. «On predicting the optimal number of hidden nodes». En: *2015 International Conference on Computational Science and Computational Intelligence (CSCI)*. IEEE. 2015, págs. 565-570.
- [177] G David Garson. «Interpreting neural-network connection weights». En: *AI expert* 6.4 (1991), págs. 46-51.
- [178] Hamid Beigy y Mohammad R Meybodi. «Backpropagation algorithm adaptation parameters using learning automata». En: *International Journal of Neural Systems* 11.03 (2001), págs. 219-228.
- [179] Jianye Sun. «Learning algorithm and hidden node selection scheme for local coupled feedforward neural network classifier». En: *Neurocomputing* 79 (2012), págs. 158-163.
- [180] Ehecatl A del Rio-Chanona et al. «An efficient model construction strategy to simulate microalgal lutein photo-production dynamic process». En: *Biotechnology and Bioengineering* 114.11 (2017), págs. 2518-2527.
- [181] Muhammad Ibnu Choldun Rachmatullah, Judhi Santoso y Kridanto Surendro. «Determining the number of hidden layer and hidden neuron of neural network for wind speed prediction». En: *PeerJ Computer Science* 7 (2021), e724.
- [182] Fatai Anifowose, Jane Labadin y Abdulazeez Abdulraheem. «Towards an improved ensemble learning model of artificial neural networks: lessons learned on using randomized numbers of hidden neurons». En: *Artificial Intelligence: Concepts, Methodologies, Tools, and Applications*. IGI Global, 2017, págs. 325-356.
- [183] Bahareh Kalantar et al. «Assessment of the effects of training data selection on the landslide susceptibility mapping: a comparison between support vector machine (SVM), logistic regression (LR) and artificial neural networks (ANN)». En: *Geomatics, Natural Hazards and Risk* 9.1 (2018), págs. 49-69.
- [184] Thuy-Anh Nguyen et al. «Prediction of later-age concrete compressive strength using feedforward neural network». En: *Advances in Materials Science and Engineering* 2020 (2020), págs. 1-8.
- [185] Matt K Smith, Charles C Castello y Joshua R New. «Machine learning techniques applied to sensor data correction in building technologies». En: *2013 12th International Conference on Machine Learning and Applications*. Vol. 1. IEEE. 2013, págs. 305-308.
- [186] Claudio Guarnaccia et al. «Public transportation energy consumption prediction by means of neural network and time series analysis approaches». En: *Proceedings of Recent Researches in Mechanical and Transportation systems* (2015).

- [187] F. Trujillo et al. «Influence of Tool Wear on Form Deviations in Dry Machining of UNS A97075 Alloy». En: *Metals* 11 (jun. de 2021), pág. 958. DOI: [10.3390/met11060958](https://doi.org/10.3390/met11060958).
- [188] Sergio Martín Béjar et al. «Cutting parameters influence analysis on fatigue behaviour of dry turned UNS A97075 alloy after corrosion». En: *IOP Conference Series: Materials Science and Engineering* 1037 (feb. de 2021), pág. 012012. DOI: [10.1088/1757-899X/1037/1/012012](https://doi.org/10.1088/1757-899X/1037/1/012012).
- [189] Sergio Martín Béjar et al. «Fatigue Behavior Parametric Analysis of Dry Machined UNS A97075 Aluminum Alloy». En: *Metals* 10 (mayo de 2020), pág. 631. DOI: [10.3390/met10050631](https://doi.org/10.3390/met10050631).
- [190] Richárd Horváth y Agota Dregelyi-Kiss. «Analysis of surface roughness of aluminum alloys fine turned: United phenomenological models and multi-performance optimization». En: *Measurement* 65 (2015), págs. 181-192.
- [191] A Torres, I Puertas y CJ Luis. «Surface roughness analysis on the dry turning of an Al-Cu alloy». En: *Procedia engineering* 132 (2015), págs. 537-544.
- [192] P.G. Benardos y G.-C. Vosniakos. «Predicting surface roughness in machining: a review». En: *International Journal of Machine Tools and Manufacture* 43.8 (2003), págs. 833-844. ISSN: 0890-6955. DOI: [https://doi.org/10.1016/S0890-6955\(03\)00059-2](https://doi.org/10.1016/S0890-6955(03)00059-2). URL: <https://www.sciencedirect.com/science/article/pii/S0890695503000592>.
- [193] Kuldip Singh Sangwan, Sachin Saxena y Girish Kant. «Optimization of machining parameters to minimize surface roughness using integrated ANN-GA approach». En: *Procedia Cirp* 29 (2015), págs. 305-310.
- [194] J Paulo Davim, VN Gaitonde y SR Karnik. «Investigations into the effect of cutting conditions on surface roughness in turning of free machining steel by ANN models». En: *Journal of materials processing technology* 205.1-3 (2008), págs. 16-23.
- [195] K Venkata Rao y PBGSN Murthy. «Modeling and optimization of tool vibration and surface roughness in boring of steel using RSM, ANN and SVM». En: *Journal of intelligent manufacturing* 29.7 (2018), págs. 1533-1543.
- [196] Francisco Javier Trujillo Vilches, Mariano Marcos Bárcena y Lorenzo Sevilla. «Experimental prediction model for roughness in the turning of UNS A97075 alloys». En: *Materials Science Forum*. Vol. 797. Trans Tech Publ. 2014, págs. 59-64.
- [197] Rafael Marinho Bandeira et al. «Influence of the thickness and roughness of polyaniline coatings on corrosion protection of AA7075 aluminum alloy». En: *Electrochimica Acta* 240 (2017), págs. 215-224.

- [198] José Miguel Sánchez-Sola et al. «Cutting speed-feed based parametric model for macro-geometrical deviations in the dry turning of UNS A92024 Al-Cu alloys». En: *Key Engineering Materials* 504 (2012), págs. 1311-1316.
- [199] FJ Trujillo, L Sevilla y M Marcos. «Cutting speed-feed coupled experimental model for geometric deviations in the dry turning of UNS A97075 Al-Zn alloys». En: *Advances in Mechanical Engineering* 6 (2014), pág. 382435.
- [200] V.N. Gaitonde et al. «Machinability investigations in hard turning of AISI D2 cold work tool steel with conventional and wiper ceramic inserts». En: *International Journal of Refractory Metals and Hard Materials* 27.4 (2009), págs. 754-763. ISSN: 0263-4368. DOI: <https://doi.org/10.1016/j.ijrmhm.2008.12.007>. URL: <https://www.sciencedirect.com/science/article/pii/S0263436808001790>.
- [201] Hamid Tebassi et al. «On the modeling of surface roughness and cutting force when turning of Inconel 718 using artificial neural network and response surface methodology: accuracy and benefit». En: *Periodica Polytechnica Mechanical Engineering* 61.1 (2017), págs. 1-11.

Anexo A

Código en Matlab

A.1. Análisis del tipo de algoritmo de aprendizaje

```
% Learning algorithm influence analysis.
% @author: Ignacio Repiso Lopez.
% University of Malaga. September 2023.

clear all

% Import dataset

data = readmatrix('Dataset.xlsx');
x = data(:, 1:2); % vc and f (input = cutting parameters)
t = data(:, 3); % output

% Training algorithms to be tested

algorithms = {'trainbr', 'trainlm', 'trainscg', 'trainbfg',
             'traingdx'};

% Parameters

numRepetitions = 200; % Number of repetitions of the
    training process
hiddenLayerSize = 10;
```

```
% Initialize matrix for storing training results

averageErrors = zeros(numRepetitions, numel(algorithms));

% Generate random selection once

[trainInd, valInd, testInd] = divideblock(size(x, 1), 0.7,
    0.15, 0.15);
trainFcn = algorithms{1}; % Selecting an algorithm to
    initialize the neural network

% Repeat the training process

for repetition = 1:numRepetitions
    for i = 1:numel(algorithms)
        trainFcn = algorithms{i};
        net = fitnet(hiddenLayerSize, trainFcn);
        net.trainParam.showWindow = 0;
        net.divideFcn = 'divideind';
        net.divideParam.trainInd = trainInd;
        net.divideParam.valInd = valInd;
        net.divideParam.testInd = testInd;
        net.trainParam.max_fail = 1000000;

        [net, tr] = train(net, x', t');
        averageErrors(repetition, i) = sqrt(tr.best_perf);
    end
end

% Calculate the maximum and minimum RMSE for each algorithm

rmseMax = max(averageErrors, [], 1);
rmseMin = min(averageErrors, [], 1);

% Plotting average results using a bar chart

bar(mean(averageErrors, 1));
```

```
hold on;
errorbar(1:numel(algorithms), mean(averageErrors, 1),
        rmseMin, rmseMax, 'k. ');
xticks(1:numel(algorithms));
xticklabels(algorithms);
ylabel('RMSE', 'Interpreter', 'LaTeX', 'FontSize', 16);
xlabel('Training algorithms', 'Interpreter', 'LaTeX', '
        FontSize', 16);
set(gca, 'TickLabelInterpreter', 'latex', 'FontSize', 12);
```

A.2. Análisis del número de capas ocultas

```
% Analysis of the influence of neurons number in the hidden
    layer
% @uthor: Ignacio Repiso Lopez.
% University of Malaga. September 2023.

clear all

% Import dataset

data = readmatrix('Dataset.xlsx');
x = data(:, 1:2); % vc and f (input = cutting parameters)
t = data(:, 3); % output

% Number of hidden layers to be tested

numHiddenLayers = 1:10;

% Parameters

numRepetitions = 200; % N mero de repeticiones del proceso
    de entrenamiento
hiddenLayerSize = 10;

% Initialize matrix for storing training results

averageErrors = zeros(numRepetitions, numel(numHiddenLayers
    ));

% Generate random selection once

[trainInd, valInd, testInd] = divideblock(size(x, 1), 0.7,
    0.15, 0.15);
trainFcn = 'trainbr'; % Fixed training algorithm (trainbr)
```

```
% Repeat the training process

for repetition = 1:numRepetitions
    for i = 1:numel(numHiddenLayers)
        numLayers = numHiddenLayers(i);
        layers = repmat(hiddenLayerSize, 1, numLayers);
        net = feedforwardnet(layers, trainFcn);
        net.trainParam.showWindow = 0;
        net.divideFcn = 'divideind';
        net.divideParam.trainInd = trainInd;
        net.divideParam.valInd = valInd;
        net.divideParam.testInd = testInd;
        net.trainParam.max_fail = 1000000;

        [net, tr] = train(net, x', t');
        averageErrors(repetition, i) = sqrt(tr.best_perf);
    end
end

% Calculate the average and standard deviation of the RMSE
for each number of hidden layers

meanErrors = mean(averageErrors, 1);
stdErrors = std(averageErrors, 0, 1);

% Plot the average results using a curve with error bars

errorbar(numHiddenLayers, meanErrors, stdErrors, 'o-');
ylabel('RMSE', 'Interpreter', 'LaTeX', 'FontSize', 16);
xlabel('Number of Hidden Layers', 'Interpreter', 'LaTeX', 'FontSize', 16);
set(gca, 'TickLabelInterpreter', 'latex', 'FontSize', 12);
```

A.3. Selección óptima de lotes para entrenamiento, validación y prueba y análisis del número de neuronas en la capa oculta

```
% Optimal selection of data batches for training,  
    validation and test and analysis of the influence of the  
    number of neurons in the hidden layer.  
% @uthor: Ignacio Repiso Lopez.  
% University of Malaga. September 2023.  
  
clear all  
  
% Inputs: cutting speed and feed rate.  
% Output: maximum height of roughness profile.  
  
% Import dataset  
  
data = readmatrix('Dataset.xlsx');  
x = data(:, 1:2); % vc and f (input = cutting parameters)  
y = data(:, 3); % output  
m = length(y);  
  
% Parameters  
  
% N = number of iterations.  
% Nmax = maximum number of neurons in the hidden layer.  
% N_divisiones = number of divisions in the RMSE histogram.  
  
Nmax = 20; N = 200; N_divisiones = 10;  
minim = 10; menor = 100; maxim = 0;  
trainRatio = 0.7;  
  
% Inicialization  
  
RMSE_t_suma = zeros(1, Nmax+1);  
RMSE_v_suma = zeros(1, Nmax+1);
```

```
RMSE_test_suma = zeros(1,Nmax+1);
frecuencia_t_suma = zeros(1,N_divisiones+2);
frecuencia_v_suma = zeros(1,N_divisiones+2);
frecuencia_test_suma = zeros(1,N_divisiones+2);
frecuencia_total_suma = zeros(1,N_divisiones+2);

for j=1:N
    for i=1:(Nmax+1)
        hiddenLayerSize = i;
        net = fitnet(hiddenLayerSize,'trainbr');
        net.trainParam.showWindow = 0;
        net.divideFcn = 'divideind';
        [net.divideParam.trainInd, net.divideParam.valInd,
         net.divideParam.testInd] = BatchIndexRandomArray
            (m,trainRatio);
        net.trainParam.max_fail = 1000000;
        [net,tr] = train(net, x', y');
        net.trainParam.showWindow = 0;
        yTrain = net(x(net.divideParam.trainInd,:));
        yTrainTrue = y(net.divideParam.trainInd);
        yVal = net(x(net.divideParam.valInd,:));
        yValTrue = y(net.divideParam.valInd);
        yTest = net(x(net.divideParam.testInd,:));
        yTestTrue = y(net.divideParam.testInd);
        RMSE_t(i) = sqrt(mean((yTrain-yTrainTrue).^2));
        RMSE_v(i) = sqrt(mean((yVal-yValTrue).^2));
        RMSE_test(i) = sqrt(mean((yTest-yTestTrue).^2));

        if ((trainRatio*RMSE_t(i) + 0.5*(1-trainRatio)*
            RMSE_v(i) + 0.5*(1-trainRatio)*RMSE_test(i)) <
            minim)
            minim = trainRatio*RMSE_t(i) + 0.5*(1-
                trainRatio)*RMSE_v(i) + 0.5*(1-trainRatio)*
                RMSE_test(i);
            armin(j) = i;
            RMSE_tmin = RMSE_t(i);
            RMSE_vmin = RMSE_v(i);
            RMSE_testmin = RMSE_test(i);
```

```

end

if ((trainRatio*RMSE_t(i) + 0.5*(1-trainRatio)*
    RMSE_v(i) + 0.5*(1-trainRatio)*RMSE_test(i)) >
    maxim)
    maxim = trainRatio*RMSE_t(i) + 0.5*(1-
        trainRatio)*RMSE_v(i) + 0.5*(1-trainRatio)*
        RMSE_test(i);
    N_RMSE_max = i;
    RMSE_tmax = RMSE_t(i);
    RMSE_vmax = RMSE_v(i);
    RMSE_testmax = RMSE_test(i);
end
end

if (menor > minim)
    menor = minim;
    N_RMSE_min = armin(j);
    RMSE_tmenor = RMSE_tmin;
    RMSE_vmenor = RMSE_vmin;
    RMSE_testmenor = RMSE_testmin;
    optimal_train_index = net.divideParam.trainInd;
    optimal_val_index = net.divideParam.valInd;
    optimal_test_index = net.divideParam.testInd;
    input_w = net.IW{1,1};
    hidden_w = net.LW{2,1};
    bias_input = net.b{1};
    bias_hidden = net.b{2};
end

% Weighted sum

RMSE_suma = trainRatio*RMSE_t + 0.5*(1-trainRatio)*
    RMSE_v + 0.5*(1-trainRatio)*RMSE_test;

if j==1
    rmse_array_t = min(RMSE_t):((max(RMSE_t)-min(RMSE_t))
        )/N_divisones):max(RMSE_t);

```

```

    rmse_array_v = min(RMSE_v):((max(RMSE_v)-min(RMSE_v)
        )/N_divisiones):max(RMSE_v);
    rmse_array_test = min(RMSE_test):((max(RMSE_test)-
        min(RMSE_test))/N_divisiones):max(RMSE_test);
    rmse_array_suma = min(RMSE_suma):((max(RMSE_suma)-
        min(RMSE_suma))/N_divisiones):max(RMSE_suma);
end

frecuencia_t = Frecuence(RMSE_t, Nmax, rmse_array_t);
frecuencia_v = Frecuence(RMSE_v, Nmax, rmse_array_v);
frecuencia_test = Frecuence(RMSE_test, Nmax,
    rmse_array_test);
frecuencia_total = Frecuence(RMSE_suma, Nmax,
    rmse_array_suma);
frecuencia_t_suma = frecuencia_t_suma + frecuencia_t;
frecuencia_v_suma = frecuencia_v_suma + frecuencia_v;
frecuencia_test_suma = frecuencia_test_suma +
    frecuencia_test;
frecuencia_total_suma = frecuencia_total_suma +
    frecuencia_total;
RMSE_t_suma = (RMSE_t_suma + RMSE_t);
RMSE_v_suma = (RMSE_v_suma + RMSE_v);
RMSE_test_suma = (RMSE_test_suma + RMSE_test);
minim = 10;

end
RMSE_t = RMSE_t_suma/N;
RMSE_v = RMSE_v_suma/N;
RMSE_test = RMSE_test_suma/N;
[M,I] = min(trainRatio*RMSE_t + 0.5*(1-trainRatio)*RMSE_v +
    0.5*(1-trainRatio)*RMSE_test);

% Hidden-layer-neurons-with-minim-RMSE array

figure
histogram(armin, 'FaceColor', [167/255,170/255,164/255])
xlabel('$N_{opt}$', 'Interpreter', 'LaTeX', 'FontSize', 17);
set(gca, 'TickLabelInterpreter', 'latex', "YGrid", "on", '

```

```

    'FontSize',15);
xlim([0 50]);

% Frecuency of RMSE

xt = min(rmse_array_t):((max(rmse_array_t)-min(rmse_array_t)
))/N_divisones):max(rmse_array_t)+((max(rmse_array_t)-
min(rmse_array_t))/N_divisones);
xv = min(rmse_array_v):((max(rmse_array_v)-min(rmse_array_v)
))/N_divisones):max(rmse_array_v)+((max(rmse_array_v)-
min(rmse_array_v))/N_divisones);
xtest = min(rmse_array_test):((max(rmse_array_test)-min(
rmse_array_test))/N_divisones):max(rmse_array_test)+((
max(rmse_array_test)-min(rmse_array_test))/N_divisones);
xsuma = min(rmse_array_suma):((max(rmse_array_suma)-min(
rmse_array_suma))/N_divisones):max(rmse_array_suma)+((
max(rmse_array_suma)-min(rmse_array_suma))/N_divisones);

figure
bar(xt, frecuencia_t_suma, 'FaceColor',
    [62/255,81/255,122/255])
xlabel('$RMSE_{tr}$ $\mathrm{\mu m}$', 'Interpreter', '
    LaTeX', 'FontSize',17);
set(gca, 'TickLabelInterpreter', 'latex', 'YGrid', 'on', '
    FontSize',15);

figure
bar(xv, frecuencia_v_suma, 'FaceColor',
    [62/255,81/255,122/255])
xlabel('$RMSE_{v}$ $\mathrm{\mu m}$', 'Interpreter', 'LaTeX
    ', 'FontSize',17);
set(gca, 'TickLabelInterpreter', 'latex', 'YGrid', 'on', '
    FontSize',15);

figure
bar(xtest, frecuencia_test_suma, 'FaceColor',
    [62/255,81/255,122/255])
xlabel('$RMSE_{t}$ $\mathrm{\mu m}$', 'Interpreter', 'LaTeX

```

```

    'FontSize',17);
set(gca,'TickLabelInterpreter','latex','YGrid','on','
    FontSize',15);

figure
bar(xsuma, frecuencia_total_suma,'FaceColor',
    [62/255,81/255,122/255])
xlabel('$RMSE_{tot}$ $\mathrm{\mu m}$','Interpreter','
    LaTeX','FontSize',17);
set(gca,'TickLabelInterpreter','latex','YGrid','on','
    FontSize',15);

% Mean RMSE evolution plot

figure
plot(1:Nmax+1, RMSE_t,'LineWidth',1.5, 'Color'
    ,[40/255,54/255,24/255]); hold on;
plot(1:Nmax+1, RMSE_v,'LineWidth',1.5, 'Color'
    ,[188/255,108/255,37/255]); hold on;
plot(1:Nmax+1, RMSE_test,'LineWidth',1.5, 'Color'
    ,[230/255,200/255,100/255]); hold on;
xlim([1 50]);
R = ['$R_a$, $\overline{RMSE}_{\min}= $ ' num2str(M) ' for
    ' num2str(N) ' iterations'];
title(R, 'Interpreter','LaTeX','FontSize',15);
Lgd = legend('Training','Validation','Test','Interpreter','
    LaTeX','FontSize',12,'Location','northwest');
xlabel('$N$', 'Interpreter','LaTeX','FontSize',15);
ylabel('$\overline{RMSE}$ $\mathrm{\mu m}$','Interpreter'
    ,'LaTeX','FontSize',15);
set(gca,'TickLabelInterpreter','latex','FontSize',15);
set(Lgd,'EdgeColor','none');

% Export to .xlsx and generation of complete ANN

T = table(optimal_train_index, optimal_val_index,
    optimal_test_index);
writetable(T,'Neurons_Optimal.xlsx');
```

A.4. Comparación entre modelos

```
% Comparison between analytical models (potential and RSM)
% vs. results obtained by the ANN. Specific case for Ra
% but extrapolable to the rest of the variables.
% @uthor: Ignacio Repiso Lopez.
% University of Malaga. September 2023.

clear all

% Inputs: cutting speed and feed rate.
% Output: maximum height of roughness profile.

data = readmatrix('Dataset.xlsx');
x = data(:,1:2);
t = data(:,3);
m = length(t);

% ANN architecture definition

% Parameters

trainRatio = 0.7;
hiddenLayerSize = 20;

net = fitnet(hiddenLayerSize, 'trainbr');
net.divideFcn = 'divideind';
i_training = ceil(trainRatio*m);
i_val = ceil(0.5*(1-trainRatio)*m);

optimo = readmatrix('Neurons_Optimal.xlsx');
net.divideParam.trainInd = optimo(1:i_training);
net.divideParam.valInd = optimo(i_training+1:i_val);
net.divideParam.testInd = optimo(i_val+1+1:m);

net.trainParam.max_fail = 1000000;
```

```

% Figure 2D

[net,tr] = train(net,x',t');
[R40, f40] = prediccionRa(net, 40, 0.05, 0.2, 0.01);
[R60, f60] = prediccionRa(net, 60, 0.05, 0.2, 0.01);
[R80, f80] = prediccionRa(net, 80, 0.05, 0.2, 0.01);

% ANN Results

plot(f40',R40', 'LineWidth',2, 'Color',[0 0 1]); hold on;
plot(f60',R60', 'LineWidth',2, 'Color',[1 0 0], 'LineStyle', '
    --'); hold on;
plot(f80',R80', 'LineWidth',2, 'Color',[0.4660 0.6740
    0.1880], 'LineStyle','-.'); hold on;

f = linspace(0.05, 0.2, 15);

Ra_potencial_40 = zeros(1, 15);
Ra_potencial_60 = zeros(1, 15);
Ra_potencial_80 = zeros(1, 15);
Ra_RSM_40 = zeros(1, 15);
Ra_RSM_60 = zeros(1, 15);
Ra_RSM_80 = zeros(1, 15);

for i = 1:15
    Ra_potencial_40(i) = 5.305*(40^0.087)*f(i)^0.9997;
    Ra_potencial_60(i) = 5.305*(60^0.087)*f(i)^0.9997;
    Ra_potencial_80(i) = 5.305*(80^0.087)*f(i)^0.9997;
    Ra_RSM_40(i) = 0.407 - 0.01334*40 + (5.51*f(i)) +
        0.000132*40^2 + (13.81*f(i)^2) - 0.0141*40*f(i);
    Ra_RSM_60(i) = 0.407 - 0.01334*60 + (5.51*f(i)) +
        0.000132*60^2 + (13.81*f(i)^2) - 0.0141*60*f(i);
    Ra_RSM_80(i) = 0.407 - 0.01334*80 + (5.51*f(i)) +
        0.000132*80^2 + (13.81*f(i)^2) - 0.0141*80*f(i);
end

```

```

% Potential model results

plot(f,Ra_potencial_40,'LineWidth',1,'Color',[0 0 1]); hold
    on;
plot(f,Ra_potencial_60,'LineWidth',1,'Color',[1 0 0],'
    LineStyle','--'); hold on;
plot(f,Ra_potencial_80,'LineWidth',1,'Color',[0.4660 0.6740
    0.1880],'LineStyle','-'); hold on;

% RSM model results

plot(f,Ra_RSM_40,'LineWidth',0.5,'Color',[0 0 1]); hold on;
plot(f,Ra_RSM_60,'LineWidth',0.5,'Color',[1 0 0],'LineStyle
    ','--'); hold on;
plot(f,Ra_RSM_80,'LineWidth',0.5,'Color',[0.4660 0.6740
    0.1880],'LineStyle','-'); hold off;

% Other results related to the figure

xlim([0.05 0.2])
set(gca,'TickLabelInterpreter','latex','FontSize',12);
xlabel('$f$ (mm$\backslash$backslash$rev)','Interpreter','LaTeX','
    FontSize',16)
ylabel('$R_a$ ($\mu$m)','Interpreter','LaTeX','FontSize'
    ,16)
legend('ANN, $v_{c}=40$ m/min', 'ANN, $v_{c}=60$ m/min', '
    ANN, $v_{c}=80$ m/min', ...
    'Potential model, $v_{c}=40$ m/min', 'Potential
    model, $v_{c}=60$ m/min', 'Potential model, $v_{c}
    =80$ m/min', ...
    'RSM, $v_{c}=40$ m/min', 'RSM, $v_{c}=60$ m/min', '
    RSM, $v_{c}=80$ m/min', ...
    'Interpreter', 'LaTeX', 'FontSize', 9, 'Location', '
    northwest', 'EdgeColor', 'none');

ax_small = axes;
set(ax_small, 'units', 'normalized', 'position', [0.67,

```

```
    0.2, 0.2, 0.2]);  
box(ax_small, 'on');  
plot(f40',R40','LineWidth',2,'Color',[0 0 1], 'parent',  
    ax_small); hold on;  
plot(f60',R60','LineWidth',2,'Color',[1 0 0],'LineStyle','  
    --', 'parent', ax_small); hold on;  
plot(f80',R80','LineWidth',2,'Color',[0.4660 0.6740  
    0.1880], 'LineStyle','-.', 'parent', ax_small); hold on;  
plot(f,Ra_potencial_40,'LineWidth',1,'Color',[0 0 1], '  
    parent', ax_small); hold on;  
plot(f,Ra_potencial_60,'LineWidth',1,'Color',[1 0 0], '  
    LineStyle','--', 'parent', ax_small); hold on;  
plot(f,Ra_potencial_80,'LineWidth',1,'Color',[0.4660 0.6740  
    0.1880], 'LineStyle','-.', 'parent', ax_small); hold on;  
plot(f,Ra_RSM_40,'LineWidth',0.5,'Color',[0 0 1], 'parent',  
    ax_small); hold on;  
plot(f,Ra_RSM_60,'LineWidth',0.5,'Color',[1 0 0], 'LineStyle'  
    , '--', 'parent', ax_small); hold on;  
plot(f,Ra_RSM_80,'LineWidth',0.5,'Color',[0.4660 0.6740  
    0.1880], 'LineStyle','-.', 'parent', ax_small); hold off;  
set(ax_small, 'xlim', [0.1,0.105], 'ylim', [0.7,0.75], '  
    TickLabelInterpreter','latex');
```