

Estimación cualitativa de la rugosidad mediante algoritmos de aprendizaje automático en una operación de taladrado

Qualitative estimation of roughness using automatic learning algorithms in a drilling operation

■■■■
Aitor Duo Zubiaurre, Erika Domínguez Romero, Larraitz Azpitarte-Aranzabal, Javier Aperribay-Zubia, Mikel Cuesta-Zabaljauregui, Ainhara Garay Araico, Rosa Basagoiti Astigarraga y Pedro-Jose Arrazola-Arriola
Universidad de Mondragón (España)

DOI: <http://dx.doi.org/10.6036/9388>

1. INTRODUCCIÓN

El aumento de la demanda de la precisión de los componentes fabricados, sujeta a una fabricación sostenible, es uno de los problemas al que se enfrenta el mecanizado. La toma de decisiones en cuanto a eventos críticos que pudieran ocurrir durante el proceso de corte se debe realizar lo antes posible, y hacerlo de manera automática supondría un gran ahorro. Para ello, es fundamental la monitorización de los procesos de corte. Con las herramientas de análisis de datos adecuadas, la virtualización y el control de los procesos se están dando pasos hacia la transformación de la máquina herramienta a un entorno más automático.

El proceso de taladrado es uno de los procesos más críticos en cuanto a procesos de mecanizado. Este proceso se desarrolla en las fases finales de la fabricación de un componente por lo que, podría ser defectivo en caso de no tomar medidas preventivas que indiquen el estado actual del proceso [1]. El taladrado es una operación de corte continuo donde dos o más filos de corte eliminan por arranque de viruta el volumen de material deseado.

El desgaste de herramienta es uno de los problemas más estudiados en cuanto a la monitorización de los procesos de corte [2]. Las señales más empleadas son las fuerzas de corte, vibraciones, emisiones acústicas o la presión sonora. Todas ellas son señales externas al proceso de corte, y por lo tanto más o menos invasivas. El

dinamómetro es utilizado orientado a fines de investigación ya que en entornos industriales el montaje y calibración puede ser un problema [3]. Como alternativa Corne y col. [4] proponen utilizar la potencia del cabezal ya que mantiene una gran relación con la fuerza de corte y es menos invasiva que un dinamómetro. Diniz y col. [5] proponen establecer una relación entre el desgaste de la herramienta y las emisiones acústicas comprobando con éxito que la desviación estándar de las emisiones acústicas está relacionada con el desgaste de herramienta. Duo y col. [6] muestran la relación entre el par del eje Z adquirido desde la máquina y la fuerza de avance. La medición del par de avance es una alternativa a la medición de la fuerza de avance ya que es menos costosa de adquirir y no requiere de sistemas invasivos para ser adquirida.

La señal más precisa es considerada la señal de emisiones acústicas; se define como la energía elástica liberada espontáneamente durante un cambio local, dinámico e irreversible en la microestructura del material [7]. Marinescu y col. [8] proponen un sistema para detectar anomalías en superficies generadas en fresado mos-

trando el potencial de las emisiones acústicas para la monitorización de defectos en la superficie del material de trabajo a diferencia de otras señales. La señal de vibraciones y presión sonora son caracterizadas por medir aquellos fenómenos que ocurren a una frecuencia menor a 10 kHz. Las emisiones acústicas son afectadas a altas frecuencias, desde los 50 a los 500 kHz, es por ello la capacidad de las emisiones acústicas de detectar fenómenos con mayor precisión. En la Figura 1 se puede apreciar el alcance de cada una de las señales comúnmente utilizadas en la monitorización de procesos de mecanizado.

Otros aspectos como la rugosidad o el daño generado en la superficie final pueden verse afectados por el desgaste de la herramienta de corte. En Pimenov y col. [10] donde se estudia la operación de fresado muestran que la rugosidad empeora junto al desgaste de herramienta. En procesos de taladrado en cambio, el rozamiento de la viruta y la periferia de la broca contra la superficie generada elimina el perfil generado, con lo que el desgaste no tiene que estar necesariamente relacionado con la rugosidad obtenida. Eckstein y col. [11] analizan el taladrado sobre Inconel 718 utilizando tanto el proceso de taladrado como el proceso de escariado. La rugosidad tiende a ser similar en ambos procesos pero se obtienen mejores resultados en el proceso de escariado. La rugosidad mejora en las primeras etapas de ambos procesos, se sugiere que esta tendencia se debe al efecto de redondeo de los filos de corte. Durante las diferentes operaciones el único parámetro modifica-




Fig. 1: Precisión de medida de los sensores (Modificado de Dornfeld y col.[9])

do es la geometría de la herramienta por lo que el desgaste no es solamente la eliminación del material de la herramienta en el flanco del filo de corte, sino una eliminación del material en todas las áreas expuestas al corte.

Los algoritmos de aprendizaje automático ofrecen la capacidad de aprender comportamientos de los procesos de mecanizado basándose en información extraída de datos recopilados durante los mismos procesos.

Suresh y col. [12] utilizan algoritmos genéticos para optimizar la rugosidad de la pieza mecanizada, concluyendo que es una herramienta útil para optimizar las condiciones de corte y lograr la superficie deseada. Venkata Rao y col. [13] crearon un sistema para optimizar las condiciones de corte en procesos de mandrinado mediante la señal de vibraciones con el objetivo de aumentar la vida útil de la herramienta y minimizar la rugosidad la superficie generada. En el estudio concluyen que utilizando una red neuronal es posible la creación de un sistema que permita realizar el cambio de herramienta antes del deterioro del proceso de corte. Kilickap y col. [14] crearon un modelo basado en la metodología de superficie de respuesta y minimizando el resultado con un algoritmo genético, obtienen las condiciones de corte necesarias para minimizar la rugosidad de la superficie mecanizada.

Los trabajos consultados están mayormente enfocados a la predicción del desgaste de herramienta, y a la predicción de la rugosidad en otras operaciones como el fresado o el torneado. Sin embargo, el taladrado es un proceso complejo donde afectan otros factores tales como la evacuación de la viruta. La periodicidad del perfil de la rugosidad desaparece en procesos de taladrado, por ello el desarrollo de un modelo que permita la predicción de la rugosidad es más difícil que en otras operaciones. Dados los pocos trabajos en torno a la predicción de la rugosidad obtenida en proceso de taladrado, en este trabajo se muestra una metodología que puede servir para la creación de modelos que describan la rugosidad de la parte mecanizada.

El principal objetivo es el desarrollo de un modelo de aprendizaje automático capaz de describir la rugosidad de la superficie mecanizada mediante el uso de emisiones acústicas. En las siguientes secciones se podrá encontrar la metodología llevada a cabo para la adquisición y extracción de las características que definirán el estado de la superficie del agujero. A continuación, se discutirán los resulta-




Fig. 2: Setup experimental utilizado para realizar los ensayos de taladrado

dos obtenidos y las conclusiones alcanzadas mediante el presente estudio.

2. METODOLOGÍA

En esta sección se presenta el setup experimental empleado y el análisis de la rugosidad de la pieza mecanizada en relación a las señales adquiridas durante el taladrado de acero con composición 35Cr-Mo4LowS. Basándonos en la energía de las emisiones acústicas generadas en cada una de las revoluciones de la máquina se predice el rango de rugosidad en el que se espera encontrar el agujero realizado.

2.1. SETUP EXPERIMENTAL

Para la ejecución de los ensayos experimentales se utilizó un centro de mecanizado vertical Lagun B1050. Durante el montaje del setup experimental se ha instalado un sensor de emisiones acústicas Kistler 5125B. Además de esta señal, se han adquirido señales internas de la máquina (Par del eje Z, potencia eléctrica y mecánica del cabezal y posición, velocidad, aceleración y *jerk* de la punta de la herramienta) para disponer de un mayor número de señales que puedan proporcionar información en torno a la integridad superficial.

Para la ejecución de los ensayos se utilizó una broca Kendu BH04.5D de 8 mm de diámetro. Cada una de las herramientas fue re-afilada para obtener una forma geométrica que representa un determinado desgaste de flanco. En total se emplearon 4 herramientas, (i) una herramienta nueva, (ii) una herramienta con desgaste de 0.1 mm, (iii) una herramienta con desgaste de 0.2 mm y (iv) otra herramienta con desgaste de 0.3 mm. Con cada una de las herramientas se realizaron 5 agujeros a una velocidad de corte $V_c = 40$ m/min y un avance por vuelta de $f = 0.07$ mm/rev, siendo de 5 mm la profundidad de los agujeros. En total son 20 los agujeros realizados. En la Figura 2 se puede apreciar un croquis del setup experimental utilizado durante el desarrollo de este trabajo.

Durante la ejecución de los ensayos se recogió la viruta para observar si existía un cambio durante el mecanizado en cuanto a la generación de la viruta. La Figura 3 muestra la geometría de cada una de las herramientas utilizadas y la viruta generada durante los ensayos de taladrado. Al principio (figura 3a), en el tiempo que la herramienta se mantiene nueva, la viruta tiende a tener una forma de fragmentos cónicos helicoidales [15]. A medida que el desgaste de la herramienta aumenta, la




Fig. 3: Herramientas y viruta extraídas por cada 5 agujeros realizados con cada una de ellas




Fig. 4: Mediciones de la rugosidad en base a ISO 4287-1997 del primer y último agujero realizado con cada una de las brocas empleadas durante los ensayos experimentales en sentido transversal

viruta tiende a ser más larga manteniendo su forma helicoidal ($V_b = 0.1$ y 0.2 mm). Con la herramienta más desgastada ($V_b = 0.3$ mm) la viruta tiende a tener la misma forma que en etapas anteriores, aunque a medida que se avanza en la perforación del agujero la viruta no se rompe con tanta facilidad y pierde su forma básica observándose problemas en la evacuación de la misma.

La rugosidad se midió en un perfilómetro Alicona IFG4 3D en base al ISO 4287-1997. Para ello, el primer y último agujero realizados con cada una de las brocas fue extraído mediante electroerosión para posteriormente ser cortado en dos partes en la cortadora de precisión y poder medir la superficie deseada. Los resultados de las mediciones de los agujeros pueden verse en la Figura 4.

La Figura 5 muestra la media aritmética (R_a), el error medio cuadrático de la rugosidad (R_q) y la altura máxima de pico a valle (R_t) para el primer y último agujero realizados con cada una de las bro-

cas. En la figura se puede apreciar que no necesariamente un desgaste más alto de la broca conlleva a un empeoramiento de la rugosidad de la superficie generada. La herramienta nueva es la que mejor perfil de rugosidad genera, en cambio, con la herramienta con desgaste $V_b = 0.1$ mm se obtiene la peor rugosidad.

Basándose en el ISO 1302:1992 se han asignado diferentes etiquetas según la medición de la rugosidad realizada. R_1 corresponde a una rugosidad entre $[0.4; 0.9] \mu m$, R_2 entre $[0.9; 1.2] \mu m$ y R_3 entre $[1.2; 3] \mu m$. A la rugosidad generada con la primera herramienta en el primer y último agujero se le dio la etiqueta 'R1' que en la norma corresponde a un grado de rugosidad N7. A las mediciones de rugosidad correspondientes a la herramienta con desgaste de $V_b = 0.1$ mm se les asignó la etiqueta 'R3' ya que corresponde a la peor rugosidad obtenida de entre todas las mediciones de rugosidad realizadas. A los agujeros realizados con herramienta $V_b = 0.2$ mm se les dio la etiqueta 'R2'. En




Fig. 5: R_a , R_q , R_t del primer y último agujero realizado con cada broca. (Identificador BH04.5D_2_(Vb)_HN, donde Vb es el desgaste de la herramienta y N es el número de agujero)

el caso de las herramientas con desgaste $V_b = 0.3$ mm el primer agujero corresponde a una etiqueta 'R3' mientras el quinto agujero a una etiqueta 'R2'. No se disponen de una gran cantidad de agujeros medidos de manera directa en el perfilómetro, ya que supone una tarea tediosa.

2.2. APRENDIZAJE AUTOMATICO

Para realizar el aprendizaje automático de entre las señales recogidas se ha escogido la señal de emisiones acústicas. Como se ha visto en la literatura, esta señal es más sensible a fenómenos que pudieran aparecer durante el proceso de mecanizado y su uso es más extendido hacia la detección y predicción de micro defectos.

Los experimentos para evaluar los algoritmos de aprendizaje automático se han realizado en la plataforma Weka [16]. Se han utilizado varios algoritmos de aprendizaje para poder evaluar el comportamiento de los modelos basándose en diferentes principios. Las descripciones de cada uno de los algoritmos se pueden encontrar en [16]. En concreto se ha utilizado una regresión lineal (función logística), el algoritmo de Naive Bayes que se basa en fundamentos probabilísticos, árboles de decisión J48 y LMT (Árbol de modelo logístico) y un algoritmo basado en aprendizaje vago, IBk.

Para valorar la precisión de los algoritmos de aprendizaje automático se han utilizado las siguientes métricas de evaluación:

Precisión: es la proporción entre las instancias correctamente predichas y el total de instancias.

Coefficiente de Kappa: mide el grado de concordancia de la predicción con la clase verdadera; 1.0 significa una concordancia completa.

MAE (Error medio absoluto): mide la magnitud media de los errores en un conjunto de previsiones.

La Figura 6 muestra los pasos realizados para la extracción de los atributos necesarios para la predicción de la rugosidad:

- I. La señal ha sido filtrada con un filtro pasa banda entre $(50; 450)$ kHz, esto permite eliminar ruido de bajas y altas frecuencias.
- II. La precisión de medida de los datos en el caso de la señal de emisiones acústicas cambia en cuanto a la posición en la que este colocado el sensor. Por ello, los datos han sido normalizados de tal manera que todos tengan una media de 0 y una desviación estándar de 1.

- III. En caso de cambio en las condiciones de corte, la relación entre la frecuencia de muestreo y las revoluciones de la máquina son parámetros a tener en cuenta. La frecuencia de muestreo varía en base a las condiciones de corte estando la adquisición de los datos condicionado por este factor. La energía se puede considerar como la amplitud relativa de la señal y es útil porque la energía de la emisión se puede determinar.
- IV. En el presente estudio se calcula la energía emitida en cada revolución del cabezal de la máquina (MARSE).
- V. De la señal resultante, se obtienen diferentes características estadísticas que permiten
- VI. La creación de una instancia, que supone un registro del agujero realizado.

Para la estimación de la rugosidad se ha obtenido un registro (instancia) por cada uno de los agujeros realizados. Cada uno de los registros está compuesto por los atributos mencionados en la Figura 6 y su correspondiente clase o valor objetivo a predecir, el cual corresponde a la etiqueta de rugosidad descrita en la sección anterior.

En total se ha medido la rugosidad de 8 agujeros. Al ser pocas las instancias que forman el dataset completo se han utilizado 10 instancias para entrenar el modelo. A los 8 agujeros medidos se les ha sumado el segundo y tercer agujero realizados con la herramienta de desgaste $V_b = 0$ mm asumiendo que la rugosidad en estos agujeros pertenece a la misma categoría que el primer y último agujero ('R1').

Para la comprobación del modelo se han utilizado además de las instancias utilizadas para entrenar el modelo, el resto de los agujeros correspondientes a las herramientas con desgaste 0, 0.1 y 0.2 mm. De este modo se suman otros 7 agujeros, teniendo un total de 17 registros para la validación del modelo. En los registros utilizados para la comprobación del modelo se ha asumido que tienen una rugosidad igual a la categoría del primer y último agujeros realizados con esa herramienta.

3. RESULTADOS Y DISCUSIÓN

Los algoritmos propuestos en este estudio nos permiten observar que es posible la creación de un sistema de estimación de la rugosidad de la superficie mecanizada. Estos sistemas automáticos se entrenan para emitir una estimación que luego




Fig. 6: Proceso de generación de los atributos para aprendizaje automático

debemos comparar con la realidad. Esta comparación se realiza mostrando una tabla de doble entrada donde constan, para cada instancia de test (correspondiente a un agujero), la etiqueta correspondiente a la rugosidad real medida en laboratorio y que denominaremos objetivo y la rugosidad estimada, a la cual denominaremos predicho.

La Tabla 1 muestra las matrices de confusión de cada uno de los modelos creados a partir de los algoritmos entrenados junto a las métricas de evaluación (previamente mencionadas) de los resultados. Las posiciones en verde, correspondientes a las diagonales de las tablas de doble entrada, recuentan las instancias cuya predicción de rugosidad es correcta con respecto a las mediciones de laboratorio. Los valores en las celdas rojas corresponden a errores

en la predicción, instancias que correspondiendo a una cierta rugosidad, acaban siendo estimadas de otra.

En general, observando los resultados obtenidos se puede decir que existe la presencia de una relación entre las emisiones acústicas y la rugosidad obtenida. Guo et al. [17], analizan la relación de las emisiones acústicas con diferentes parámetros de salida en procesos de torneado mostrando la relación entre las emisiones acústicas y la rugosidad obtenida. Kishawy y col. [18] mencionan varios trabajos en los que persiguen la relación entre las emisiones acústicas y el acabado superficial dejando claro que es una señal con gran potencial para una monitorización on-line de la superficie generada. Por lo que este estudio refuerza esta relación en lo que a procesos de taladrado respecta.

Función logística			Naïve Bayes			J48		
Objetivo		R1 R2 R3		R1 R2 R3		R1 R2 R3		
	R1	5 0 0	R1	5 0 0	R1	5 0 0		
	R2	0 6 0	R2	0 3 3	R2	3 3 0		
	R3	0 0 6	R3	1 1 4	R3	0 1 5		
Predicho			Predicho			Predicho		
Precisión		100%	Precisión		70.5%	Precisión		76.47%
Coef. de Kappa		1	Coef. de Kappa		0.55	Coef. de Kappa		0.65
MAE		0	MAE		0.18	MAE		0.17
Objetivo		R1 R2 R3	Objetivo		R1 R2 R3	Objetivo		R1 R2 R3
	R1	5 0 0		R1	5 0 0		R1	5 0 0
	R2	1 5 0		R2	2 3 1		R2	3 3 0
	R3	0 1 5		R3	0 0 6		R3	0 1 5
Predicho			Predicho			Predicho		
Precisión		88.2 %	Precisión		82.3%	Precisión		76.47%
Coef. de Kappa		0.82	Coef. de Kappa		0.73	Coef. de Kappa		0.65
MAE		0.16	MAE		0.31	MAE		0.17

Tabla 1: Matrices de confusión y métricas de evaluación de los modelos obtenidos

Como se puede observar, la función logística es la que mejores resultados presenta. En este tipo de función se crea un clasificador para cada par de clases, usando sólo las instancias de estas dos clases. El resultado de un registro desconocido se basa en qué clase recibe más votos.

El algoritmo probabilístico Naive Bayes no se comporta como lo esperado por la baja cantidad de instancias existentes para el entrenamiento del algoritmo. Una cosa que puede distorsionar los resultados usando Naive Bayes es que, si en la fase de comprobación del modelo generado hay una observación perteneciente a un grupo no contemplada en la fase de entrenamiento, el algoritmo le dará una probabilidad de 0 a dicha observación obteniendo así peores resultados.

El árbol de decisión J48 mejora tanto la precisión como el coeficiente de kappa respecto al algoritmo de Naive Bayes aunque mantiene un error absoluto medio semejante. Los árboles de decisión son contruidos por el algoritmo de dividir y conquistar, tienen un buen rendimiento en el conjunto de datos de entrenamiento. Por lo general están sobre ajustados a los datos de entrenamiento y no se generalizan bien a otros datos. Dadas las pocas instancias que se tienen se espera que el modelo este muy ajustado a los pocos datos proporcionados al algoritmo.

Por último, el árbol de modelo logístico (LMT), aunque tiene una buena precisión es el algoritmo que mayor error medio absoluto obtiene. Este modelo tiene dificultades a la hora de clasificar la etiqueta 'R2', en cuanto a las demás observaciones se clasifican de manera correcta.

La matriz de confusión del algoritmo IBk presenta resultados aceptables, confundiendo en dos de las instancias de la fase de testeo en concreto una observación con etiqueta R2 y una observación con etiqueta R3.

Por lo general, la clase que mayor error genera es 'R2', esta clase corresponde a las herramientas desgastadas a $V_b=0.2$ mm, al generar una viruta más larga la evacuación se dificulta pudiendo generar mayor incertidumbre sobre la superficie generada. Por otro lado, la clase que mejor se ajusta a los datos es 'R1' ya que obtiene el 100% de los aciertos en todos los algoritmos.

Aunque se dispongan de pocas instancias para el entrenamiento de los algoritmos, los algoritmos tienen un buen comportamiento y un sistema de estas características podría ayudar a determinar la evolución de la rugosidad que genera una cierta geometría de herramienta en

procesos de taladrado a partir de los datos adquiridos durante el proceso.

4. CONCLUSIONES

En este estudio se utiliza la señal de emisiones acústicas para la predicción de la rugosidad obtenida. Para ello se han medido diferentes parámetros durante todo el proceso dando especial importancia a la relación entre la rugosidad obtenida y el desgaste de herramienta empleado. No se encuentra relación entre la rugosidad y el desgaste de herramienta, pero un mayor desgaste de herramienta dificulta la evacuación de la viruta. Esto hace que se elimine el perfil creado por los filos de corte.

Se disponen de pocos datos pero los resultados parecen indicar que es posible usar modelos que permitan la estimación de la rugosidad en procesos de taladrado usando la energía registrada por las emisiones acústicas. Teniendo en cuenta tanto la energía producida por el corte de los filos como el roce de las paredes de la periferia.

Con una precisión del 100% el modelo con mejor comportamiento es el modelo logístico. En el futuro se pretende realizar un mayor número de ensayos y medición de un mayor número de muestras, favoreciendo la robustez de los modelos.

Es de destacar, en cualquier caso, que la medición de la rugosidad supone una tarea costosa pero asumible en caso de piezas de sectores críticos.

REFERENCIAS

- [1] V.P. Astakhov, Drills: Science and Technology of Advanced Materials, 2014. <https://doi.org/10.1088/1468-6996/12/6/063001>.
- [2] A.G. Rehorn, J. Jiang, P.E. Orban, E.V. Bordatchev, State-of-the-art methods and results in tool condition monitoring: a review, *Int. J. Adv. Manuf. Technol.* 26 (2005) 942–942. <https://doi.org/10.1007/s00170-004-2443-6>.
- [3] P.J. Arrazola, A. Garay, E. Fernandez, K. Ostolaza, Correlation between tool flank wear, force signals and surface integrity when turning bars of Inconel 718 in finishing conditions, *Int. J. Mach. Mach. Mater.* 15 (2014) 84. <https://doi.org/10.1504/IJMMM.2014.059193>.
- [4] R. Corne, C. Nath, M. El Mansori, T. Kurfess, Study of spindle power data with neural network for predicting real-time tool wear/breakage during inconel drilling, *J. Manuf. Syst.* 43 (2017) 287–295. <https://doi.org/10.1016/j.jmsy.2017.01.004>.
- [5] A.E. Diniz, J.J. Liu, D. Dornfeld, Correlating tool life, tool wear and surface roughness by monitoring acoustic emission in finish turning, *Wear* 27 (1992).
- [6] A. Duo, R. Basagoiti, P.J. Arrazola, J. Aperribay, M. Cuesta, The capacity of statistical features extracted from multiple signals to predict tool wear in the drilling process, *Int. J. Adv. Manuf. Technol.* (2019). <https://doi.org/10.1007/s00170-019-03300-5>.

- [7] L.H.A. Maia, A.M. Abrao, W.L. Vasconcelos, W.F. Sales, A.R. Machado, A new approach for detection of wear mechanisms and determination of tool life in turning using acoustic emission, *Tribol. Int.* 92 (2015) 519–532. <https://doi.org/10.1016/j.triboint.2015.07.024>.
- [8] I. Marinescu, D.A. Axinte, A critical analysis of effectiveness of acoustic emission signals to detect tool and workpiece malfunctions in milling operations, *Int. J. Mach. Tools Manuf.* 48 (2008) 1148–1160. <https://doi.org/10.1016/j.ijmachtools.2008.01.011>.
- [9] D.A. Dornfeld, Process Monitoring and Control for Precision Manufacturing, *VDI. Ber.* 33 (1998). [https://doi.org/10.1016/s1474-6670\(17\)36746-0](https://doi.org/10.1016/s1474-6670(17)36746-0).
- [10] D.Y. Pimenov, A. Bustillo, T. Mikolajczyk, Artificial intelligence for automatic prediction of required surface roughness by monitoring wear on face mill teeth, *J. Intell. Manuf.* 29 (2018) 1045–1061. <https://doi.org/10.1007/s10845-017-1381-8>.
- [11] M. Eckstein, M. Vrabel, I. Manková, Tool Wear and Surface Roughness Evolution in Hole Making Process of Inconel 718, *Mater. Sci. Forum.* 862 (2016) 11–17. <https://doi.org/10.4028/www.scientific.net/MSF.862.11>.
- [12] P.V.S. Suresh, P. Venkateswara Rao, S.G. Deshmukh, A genetic algorithmic approach for optimization of surface roughness prediction model, *Int. J. Mach. Tools Manuf.* 42 (2002) 675–680. [https://doi.org/10.1016/S0890-6955\(02\)00005-6](https://doi.org/10.1016/S0890-6955(02)00005-6).
- [13] K. Venkata Rao, B.S.N. Murthy, N. Mohan Rao, Prediction of cutting tool wear, surface roughness and vibration of work piece in boring of AISI 316 steel with artificial neural network, *Meas. J. Int. Meas. Confed.* 51 (2014) 63–70. <https://doi.org/10.1016/j.measurement.2014.01.024>.
- [14] E. Kilickap, M. Huseyinoglu, A. Yardimeden, Optimization of drilling parameters on surface roughness in drilling of AISI 1045 using response surface methodology and genetic algorithm, *Int. J. Adv. Manuf. Technol.* 52 (2011) 79–88. <https://doi.org/10.1007/s00170-010-2710-7>.
- [15] Sandvik-Coromant, Drilling tips, (n.d.). <https://www.sandvik.coromant.com/en-gb/knowledge/drilling/pages/drilling-tips.aspx> (accessed 18 November 2019).
- [16] I.H. Witten, E. Frank, M. a Hall, Data Mining: Practical Machine Learning Tools and Techniques second edition, 2011. <https://doi.org/10.1007/978-1-4939-9792-4>.
- [17] Y.B. Guo, S.C. Ammula, Real-time acoustic emission monitoring for surface damage in hard machining, *Int. J. Mach. Tools Manuf.* 45 (2005) 1622–1627. <https://doi.org/10.1016/j.ijmachtools.2005.02.007>.
- [18] H.A. Kishawy, H. Hegab, U. Umer, A. Mohany, Application of acoustic emissions in machining processes: analysis and critical review, *Int. J. Adv. Manuf. Technol.* 98 (2018) 1391–1407. <https://doi.org/10.1007/s00170-018-2341-y>.

AGRADECIMIENTOS

Este trabajo ha sido desarrollado por el grupo de Sistemas Inteligentes para Sistemas Industriales (IT-1357-19) y el grupo de Mecanizado de Alto Rendimiento (IT-1315-19) de Mondragon Unibertsitatea apoyado por el Departamento de Educación, Política Lingüística y Cultura del Gobierno Vasco. El presente trabajo ha sido realizado con el apoyo del proyecto Proceda (KK-2019/00004) y ha sido parcialmente subvencionado por el proyecto PRODUCTIVE 4.0 subvencionado por ECSEL (737459) y MINECO (PCIN-2017-071).