



## Resumen de Tesis: Inteligencia artificial para la predicción y control del acabado superficial en procesos de fresado a alta velocidad

**Resumen** En esta tesis se desarrolla una metodología para analizar y diseñar un sistema inteligente para la predicción y control del acabado superficial en un proceso de fresado a alta velocidad (FAV). Este sistema está compuesto por: 1) un modelo aprendido a partir de datos experimentales con redes bayesianas, que ayudará a comprender los procesos dinámicos involucrados en el mecanizado y las interacciones entre las variables relevantes; 2) dado que uno de los principales problemas de los clasificadores bayesianos es la comprensión de las tablas de probabilidad se plantea un método de explicación que genera un conjunto de reglas obtenidas de árboles de decisión. Estos árboles son inducidos a partir de un conjunto de datos simulados generados de las probabilidades a posteriori de la variable clase, calculadas con la red bayesiana aprendida en el paso anterior; 3) y, por último, se hace optimización multiobjetivo en el caso de que algunos de los objetivos no se puedan cuantificar como números reales sino como intervalos de valores. Esto ocurre a menudo en aplicaciones de aprendizaje automático, especialmente las basadas en clasificación supervisada, extendiendo las ideas de dominancia y frontera de Pareto a esta situación. Se aplica a la predicción de la rugosidad superficial en el caso de maximizar al mismo tiempo la sensibilidad y la especificidad del clasificador bayesiano inducido, en vez de maximizar sólo la tasa de clasificaciones correctas.

**Palabras clave:** clasificación supervisada, redes bayesianas, rugosidad superficial, optimización multiobjetivo en intervalos, Pareto.

## 1. Introducción

Las máquinas-herramienta son un elemento esencial base de las tecnologías de fabricación, en sectores industriales como la automoción, la ingeniería aeroespacial y general, despertando gran interés en cuanto a técnicas y prestaciones específicas de las máquinas-herramienta en los últimos años. El nuevo paradigma de mecanizado consistirá en maximizar la producción minimizando la tasa de desgaste de la herramienta y manteniendo la calidad de las piezas [4]. Ya no solo se exige productividad, hoy la calidad constituye un objetivo esencial. Ésta puede medirse por medio de la rugosidad, donde el parámetro  $Ra$  (valor medio de la rugosidad superficial) es el más usado en la industria. La medición normalmente se hace post-proceso provocando pérdida de tiempo en la línea de producción. Medir  $Ra$  en-proceso presenta algunas dificultades como: la poca luz en la mesa de mecanizado, el refrigerante y la viruta que salta mientras se hace el corte, los reflejos según el tipo de material, etc, por lo que el problema de medición en-proceso del acabado superficial para FAV aun no está resuelto.

El trabajo presentado en esta tesis está enmarcado en el área de modelización y reconocimiento de patrones. Se plantea como objetivo fundamental la supervisión inteligente de un proceso complejo basada en modelos, desarrollando una metodología para la predicción “en-proceso” del acabado superficial en

una operación de fresado a alta velocidad. Para conseguirlo se utilizan métodos basados en aprendizaje automático que involucran el conocimiento del experto con el conocimiento físico del proceso, en concreto redes bayesianas (RBs)[5], unido a una técnica de fusión de sensores para identificar y conocer señales propias del corte de metales.

## 2. Contribuciones

Las principales aportaciones de este trabajo son en tres áreas: clasificación, explicación y optimización. En clasificación se introducen los clasificadores bayesianos para la predicción de  $Ra$ , se incluyen variables novedosas (geometría de la pieza a mecanizar y la dureza del material) para el modelado, usando las estructuras naïve Bayes y TAN. Esta contribución fue publicada en [3]. Además se hace un análisis comparativo entre dos modelos para predicción de  $Ra$  desarrollados usando redes neuronales artificiales (RNAs) (*Multi Layer Perceptron*) y RBs (*Tree Augmented Network*). Esta contribución se encuentra publicada en [2]. Después de validar ambos modelos con los mismos datos y técnica (validación cruzada en K-rodajas), las RBs consiguen mejores resultados desde el punto de vista de la bondad del clasificador aplicado al problema de la predicción de la calidad superficial en procesos de FAV. Los resultados han sido confirmados por varios test de hipótesis. Un resumen de las medidas de mérito calculadas para ambos clasificadores se muestran en la tabla 1.

Tabla 1: Resumen de las medidas de mérito para cada clasificador

| Medida                                | RB  | RNA                         |
|---------------------------------------|---|-----------------------------|
| Ejemplos correctamente clasificados   | 1216 (96.35 %)                                    | 1197 (94.84 %)              |
| Ejemplos incorrectamente clasificados | 46 (3.64 %)                                       | 65 (5.15 %)                 |
| Estadístico Kappa                     | 0.94  | 0.92                        |
| Error absoluto medio (MAE)            | 0.03  | 0.04                        |
| Raíz error cuadrático medio (RMSE)    | 0.13  | 0.14                        |
| Error absoluto relativo(RAE)          | 10.41 %   | 13.05 %                     |
| Raíz error cuadrático relativo (RRSE) | 32.66 %   | 33.70 %                     |
| Interpretabilidad                     | Entendible, con inferencia en cualquier dirección | No se puede hacer preguntas |

En cuanto a la explicación, se presenta un método de explicación a nivel micro por medio de reglas tomadas de un árbol de decisión. Se consigue reducir y explicar la complejidad de las tablas de probabilidad a posteriori calculadas por una RB y un aspecto muy importante es que el significado de la explicación es generalmente aplicable a cualquier entorno, no restringido a un vocabulario específico. Esta contribución está publicada en [1]. La metodología se presenta resumida en la figura 1.

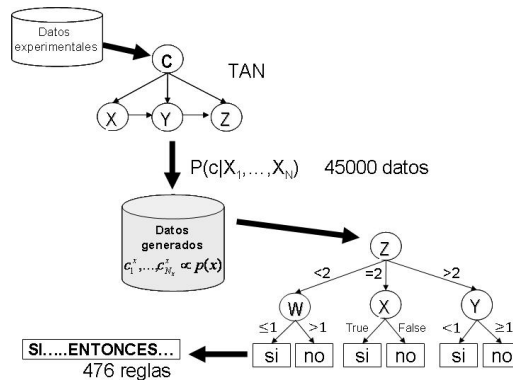


Figura 1: Método de explicación de un clasificador bayesiano mediante un árbol de decisión (aplicado a la predicción de  $Ra$ ).

En el área de optimización se hace una extensión de las ideas de dominancia de la optimización multiobjetivo al caso de objetivos con valores en intervalos, dado que la metodología desarrollada usa modelos de clasificación supervisada donde un modelo solución tiene al menos 2 objetivos (maximizar la sensibilidad y especificidad) y además estos objetivos (por la validación) no se pueden cuantificar como un único número real. Estos intervalos pueden ser el resultado de un intervalo de confianza estimado. Se examina el efecto del solapamiento y el nivel de confianza y se hace una extensión de los conceptos de la teoría de Pareto aplicados al campo de clasificación supervisada.

**Definición 1 (Dominancia de Pareto de grado  $\alpha$  para objetivos en intervalos de valores)**

1. *Dominancia de Pareto de grado  $\alpha$  ( $\alpha \in [0, 1]$ ). Una solución  $\mathbf{x}$  se dice que (Pareto)-domina con grado  $\alpha$  ( $\alpha \in [0, 1]$ ) a una solución  $\mathbf{y}$ , o  $\mathbf{x}$   $\alpha$ -domina  $\mathbf{y}$  para abreviar, denotado como  $\mathbf{x} \succ_{\alpha} \mathbf{y}$ , sii*

$$\forall i \in M_P : f_i(\mathbf{x}) \leq f_i(\mathbf{y}) \quad \text{y} \quad \forall i \in M_I : 1 - \frac{\sup f_i(\mathbf{x}) - \inf f_i(\mathbf{y})}{\sup f_i(\mathbf{x}) - \inf f_i(\mathbf{x})} \geq \alpha, \text{ y}$$

$$\exists j \in M_P : f_j(\mathbf{x}) < f_j(\mathbf{y}) \quad \text{o} \quad \exists j \in M_I : 1 - \frac{\sup f_j(\mathbf{x}) - \inf f_j(\mathbf{y})}{\sup f_j(\mathbf{x}) - \inf f_j(\mathbf{x})} > \alpha$$

2. *Solución óptima de Pareto de grado  $\alpha$ . Una solución  $\mathbf{x}$  se dice que es óptima de Pareto de grado  $\alpha$  sii  $\nexists \mathbf{y}$  con  $\mathbf{y} \succ_{\alpha} \mathbf{x}$ .*
3. *Conjunto óptimo de Pareto de grado  $\alpha$ . Es el conjunto  $\mathcal{P}_S^{\alpha}$  de todas las soluciones óptimas de Pareto de grado  $\alpha$ :  $\mathcal{P}_S^{\alpha} = \{\mathbf{x} | \nexists \mathbf{y} \text{ con } \mathbf{y} \succ_{\alpha} \mathbf{x}\}$ .*
4. *Frente óptimo de Pareto de grado  $\alpha$ . Es el conjunto  $\mathcal{P}_F^{\alpha}$  de todos los valores de la función objetivo correspondientes a las soluciones en  $\mathcal{P}_S^{\alpha}$ :*

$$\mathcal{P}_F^{\alpha} = \{(f_1(\mathbf{x}), \dots, f_r(\mathbf{x}), (\inf f_{r+1}(\mathbf{x}), \sup f_{r+1}(\mathbf{x})), \dots, (\inf f_m(\mathbf{x}), \sup f_m(\mathbf{x})) | \mathbf{x} \in \mathcal{P}_S^{\alpha}\}.$$

Nótese que si  $\sup f_i(\mathbf{x}) \leq \inf f_i(\mathbf{y})$ , entonces el cociente no es positivo y el resultado es mayor o igual a 1. En este caso, ponemos  $\alpha = 1$ . Por lo tanto, la definición de dominancia estricta de Pareto está incluida en la definición 1 más general cuando  $\alpha = 1$ . También, nótese que

$$1 - \frac{\sup f_i(\mathbf{x}) - \inf f_i(\mathbf{y})}{\sup f_i(\mathbf{x}) - \inf f_i(\mathbf{x})} \geq \alpha \Leftrightarrow \frac{\inf f_i(\mathbf{y}) - \inf f_i(\mathbf{x})}{\sup f_i(\mathbf{x}) - \inf f_i(\mathbf{x})} \geq \alpha$$

Una idea intuitiva del significado de los diferentes valores de  $\alpha$ , utilizando este último cociente, se muestra en la figura 2. Una definición más general sería permitir diferentes valores de  $\alpha$  para diferentes objetivos cuantificados en intervalos de valores.




Figura 2: Diferentes situaciones de  $\alpha$ -dominancia

### 3. Estructura

La tesis se organiza en 7 capítulos. En el capítulo 1 se hace una breve introducción al problema, se describen los objetivos, la metodología utilizada y la estructura de la memoria. El capítulo 2 estudia en profundidad algunas nociones básicas del mecanizado a alta velocidad, se muestran las dificultades inherentes dada la gran complejidad del proceso de mecanizado, los inconvenientes para medir la calidad superficial en-proceso y las soluciones planteadas hasta el momento.

El capítulo 3 analiza detalladamente la metodología propuesta para el modelado predictivo de la calidad superficial en el proceso de FAV. Se describe el sistema de adquisición de datos: sensores y procesamiento de las señales medidas. Se detalla la primera fase experimental, incluyendo la introducción teórica a las RBs y se expone la solución propuesta por medio de un modelo empírico para la predicción en-proceso de *Ra* basado en RBs.

En el capítulo 4 se describe la segunda y tercera fase de experimentación construida a partir de dos diseños de experimentos: fraccional y el método de superficie de respuesta, con cuyos datos se hizo el modelado. Se desarrollaron 2 modelos: los resultados de un modelo con RNAs se compararon con los de un modelo usando RBs. El capítulo 5 desarrolla un método para explicar la salida de los clasificadores bayesianos a partir de un conjunto de reglas obtenidas con árboles de decisión.

El capítulo 6 propone una solución novedosa a problemas de optimización multi-objetivo donde los objetivos son cuantificados como intervalos de valores en lugar de un número real. Concretamente, se extienden las ideas de dominancia y frontera de Pareto en este contexto y su aplicación al acabado superficial, en el caso de maximizar dos objetivos: la sensibilidad y la especificidad del clasificador, en lugar de únicamente el porcentaje de casos bien clasificados. Los intervalos de valores aparecen como resultado de una validación cruzada en 10 rodajas. Por último, en el capítulo 7, se presentan las conclusiones y algunas posibles líneas interesantes para continuar la investigación.

### 4. Conclusiones

Las principales herramientas usadas en los más recientes trabajos significativos para predecir la rugosidad superficial son la regresión lineal o múltiple y las RNAs. Los modelos con este tipo de herramientas no tienen presente frecuentemente el análisis mecánico del proceso de corte o la experiencia del experto en el proceso (operador, ingeniero de la producción o ingeniero mecánico). Éste era un punto fundamental al escoger la herramienta para desarrollar un predictor óptimo de *Ra*. Para suplir esta necesidad hemos introducido el uso de clasificadores bayesianos, este es un avance importante para alcanzar el mecanizado óptimo, ya que se encontraron relaciones interesantes entre los nodos. Según el conocimiento del experto, algunas de esas relaciones son evidentes en el proceso, aunque no tengan ninguna relación matemática en las fórmulas que definen el proceso de corte de metales. También se han conseguido mejores resultados, que con su más fuerte competidor las RNAs, desde el punto de vista de la bondad del clasificador aplicado a la predicción de *Ra*.

Uno de los principales problemas con el modelado es entender los resultados producidos y hacer generalizaciones. Extraer conclusiones de las tablas de probabilidades generadas (algunas veces enormes) no es trivial. La metodología es una forma útil de reducir y explicar la complejidad de las tablas de probabilidad a posteriori calculadas por una red bayesiana. La información se transmite con mayor claridad al experto quien encuentra más fácil entender los resultados en pocas reglas.

Basándose en conceptos de la teoría de Pareto, se plantea un nuevo concepto de optimización multiobjetivo. Se demuestran los resultados teóricos aplicados al campo de la clasificación supervisada, donde se tienen  $m$  métricas de evaluación de rendimiento con algunos valores reales y otros dados como intervalos. Se encuentra la posible clasificación de los modelos entre los que se elegirá uno óptimo, en el sentido de Pareto. Estos intervalos pueden ser el resultado de un intervalo de confianza para la métrica que se quiere estimar. En cuanto al control, actualmente los modelos desarrollados proveen un ciclo de control a lazo abierto, ya que las acciones de control están representadas como sugerencias que el operario decide si pone en práctica o no.

## Referencias

- [1] M. Correa and C. Bielza. Explanation of a bayesian network classifier by means of decision trees. Technical Report UPM-FI/DIA/2009-3, Universidad Politécnica de Madrid, 2009. *En revisión en International Journal of Pattern Recognition and Artificial Intelligence.*
- [2] M. Correa, C. Bielza, and J. Pamies-Teixeira. Comparison of Bayesian networks and artificial neural networks for quality detection in a machining process. *Expert Systems with Applications*, 36:7270–7279, 2009.
- [3] M. Correa, C. Bielza, M.J. Ramírez, and J.R. Alique. A Bayesian network model for surface roughness prediction in the machining process. *International Journal of Systems Science*, 39(12):1181–1192, 2008.
- [4] L.N. López de Lacalle, J.A. Sánchez, and A. Lamikiz. *Mecanizado de Alto Rendimiento*. Ediciones Técnicas Izaro S.A., 2004.
- [5] J. Pearl. *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*. Morgan Kaufmann, San Francisco, CA., 1988.