

## Modelo Pre-Proceso de predicción de la Calidad Superficial en Fresado a Alta Velocidad basado en Softcomputing

Víctor M. Flores, Maritza Correa, José R. Alique

Centro de Automática y Robótica (CAR) UPM-CSIC,  
Consejo Superior de Investigaciones Científicas.  
Carretera de Campo Real km 0,200, Arganda del Rey, 28500, Madrid-España.  
e-mail: {victor.flores, maritza.correa, jralique}@car.upm-csic.es

Resumen: La calidad superficial es uno de los aspectos más cuidados en la fabricación de piezas. Esta calidad se estima frecuentemente en función a la rugosidad superficial. Trabajos que incorporan técnicas de softcomputing al estudio de la rugosidad superficial en-proceso o pos-proceso son relativamente frecuentes en la literatura. Sin embargo, son casi inexistentes los dedicados al estudio de la rugosidad superficial en pre-proceso, pese a que esto puede ayudar a reducir costes asociados al aseguramiento de la calidad superficial en la producción industrial. En este trabajo se presenta una técnica softcomputing para generar un modelo pre-proceso predictivo de la rugosidad superficial basado en experimentación con características diversas del proceso de fresado a alta velocidad. El modelo de predicción es un clasificador Bayesiano, validado con el método k-fold cross-validation y varios valores de mérito, lo que ha permitido verificar la calidad del modelo predictivo respecto a otros modelos basados en técnicas similares. Copyright © CEA-IFAC 2011.

Palabras clave: Mecanizado a alta velocidad, proceso de fresado a alta velocidad, softcomputing, redes Bayesianas, modelos predictivos.

### 1. INTRODUCCIÓN

En procesos de mecanizado a alta velocidad (MAV), el arranque de material es uno de los que produce mayor impacto económico en la industria de fabricación con metales (Gajate, Haber, 2009), gracias entre otros aspectos al acabado superficial posible de obtener, de gran importancia en dominios como la aeronáutica (Altintas Y. and Weck M., 2004). En muchos casos, el acabado superficial influye en el comportamiento funcional de la pieza resultante, lo que le otorga particular atención en la fabricación. El acabado superficial depende en gran medida de la combinación de factores como las propiedades del material utilizado, las características de la máquina y de la herramienta usada (Zhou and Cheng, 2009).

En la fabricación es frecuente estimar la calidad de la pieza mecanizada en función a su textura superficial. Para estimar la calidad de una pieza es usual la integración de varias cantidades, de entre ellas la rugosidad superficial ( $R_a$ ) es el parámetro más utilizado debido a su influencia sobre la fricción, resistencia eléctrica y térmica, apariencia, etc. Además, la  $R_a$  puede calcularse de forma experimental con rugosímetros y puede aportar ideas de cómo se comporta una superficie en contacto con otras, elemento importante en dominios como la aeronáutica, industria automotriz, etc. (Lela et al., 2009).

En este contexto, son múltiples los trabajos que estudian las posibles combinaciones de factores que inciden para calcular o predecir la  $R_a$  en-proceso o pos-proceso (durante o después del mecanizado). Sin embargo, son casi inexistentes los trabajos de predicción de  $R_a$  en pre-proceso, (antes del corte mecánico). En este trabajo se describe la experimentación realizada para

construir un modelo predictivo pre-proceso de la  $R_a$ , en un proceso de MAV usando técnicas de softcomputing y basado en condiciones iniciales de corte y características de la herramienta.

Los datos experimentales usados en este trabajo se han utilizado anteriormente en (Correa et al., 2008) y (Redondo et al., 2009). En el primero se generó un modelo predictivo de  $R_a$  en-proceso, usando condiciones de corte, parámetros de la herramienta y señales de sensores de la fuerza de corte. En este trabajo se usaron clasificadores Bayesianos para predecir de forma probabilísticas la  $R_a$  al introducir evidencia en variables predictoras. En el segundo trabajo se desarrollaron modelos polinomiales de grado  $n$  para predecir la fuerza de corte tangencial en un proceso de fresado (*face milling*), dependiendo sólo de las condiciones de corte y de ciertos parámetros de la herramienta (número de dientes y diámetro), el algoritmo de Box-Jenkins generó los mejores resultados.

El trabajo presentado en este artículo describe el modelo predictivo de  $R_a$  pre-proceso que es independiente del mecanizado. El objetivo planteado con este proceso es estudiar las posibles dependencias entre variables predictoras y la clase  $R_a$ . Se busca además demostrar como usando solamente los parámetros de corte se puede lograr un modelo predictor fiable estadísticamente que puede ayudar, entre otras cosas, al operario a determinar las condiciones de corte iniciales para programar el CNC antes de la operación de corte.

#### 1.1 Calidad Superficial y sistemas CAD/CAM

La construcción de piezas con ciertas características de acabado es un proceso cotidiano en procesos como de arranque de

material. Para ello la integración de sistemas CAD/CAM facilita el generar programas pieza que usa el CNC (*control numérico computerizado*) para alcanzar valores deseados de  $R_a$  (Ko, et al. 2007). Los pasos principales de este proceso pueden describirse como: (1) la caracterización geométrica deseada de la pieza, mediante un sistema CAD (*computer aided design*), es decir, aportar las características o especificaciones geométricas como la forma, acabado, etc. (2) la representación geométrica de la pieza generada con una aplicación CAM (*Computer aided manufacturing*), este tipo de software genera las secuencias de instrucciones o programa pieza que usa el CNC, para completar el proceso de corte mecánico y (3) realizar el corte mecánico.

Los sistemas CAD/CAM más actuales (como por ejemplo Catia<sup>1</sup>) tienen entre otras capacidades, la posibilidad de admitir modificaciones del diseño geométrico en forma de entradas directamente sobre el CAM para cambiar los elementos del dispositivo de control numérico que controla el trabajo de la máquina para hacer coincidir más adecuadamente los resultados con el diseño original y actualizaciones. También el CAM puede simular comportamiento de la herramienta en contacto con el material a mecanizar en procesos como fresado, pero no cuentan con posibilidades de predecir o ajustar características del acabado superficial en los procesos de corte mecánico, según condiciones dadas.

### 1.2. Necesidad identificada

En procesos de MAV, es el operario quien modifica las condiciones de corte en el CNC (avance y giro) para adecuar el mecanizado al acabado deseado. Esto lo hace normalmente, basándose en su experiencia y en las observaciones in-situ del proceso de corte. En casos como producción en serie, la búsqueda por ensayo y error de la mejor calidad superficial puede resultar costosa. Se precisa entonces de mecanismos que faciliten la predicción de la calidad superficial deseada antes del proceso de corte mecánico, que permitan afinar el programa pieza.

En concreto, se identifican en este sector necesidades de contar con posibilidades como: (1) dada una  $R_a$  deseada, definir en el diseño las condiciones de corte adecuadas para lograrla o (2) según ciertas condiciones como geométricas y de corte, predecir la  $R_a$  futura (posible de obtener). Para lo expuesto en (1) es escasa la documentación, mientras que para dar respuesta a lo planteado en (2), existe en la literatura trabajos recientes que predicen la  $R_a$  según ciertas condiciones específicas. Buena parte de los trabajos consultados relacionan variables de una máquina, un tipo de herramienta particular y un material específico para proponer modelos predictores de la calidad superficial. Algunos de estos trabajos usan técnicas de softcomputing, como por ejemplo modelos predictivos que estiman valores futuros o desconocidos de variables de interés (variables objetivo o dependientes) usando otras variables independientes o predictoras.

En este documento se describe el trabajo realizado usando redes Bayesianas con una estructura TAN (*Tree Aumented naïve Bayes* (Friedman et al., 1997)) para generar un modelo predictivo de la  $R_a$  en pre-proceso para fresado, con condiciones específicas de mecanizado que se detallan en el apartado 3 del presente documento.

El resto de este documento está estructurado de la forma siguiente: en el apartado 2 se describen brevemente trabajos recientes que aplican técnicas de softcomputing, tanto para generar modelos predictivos de  $R_a$  como en aplicaciones software que se incorporan a las librerías software de un CNC para mejorar sus capacidades de estimación de valores de  $R_a$  pos-proceso, el apartado 3 describe el modelo propuesto para la predicción de la  $R_a$ , el 4 detalla los resultados obtenidos con el clasificador Bayesiano, en el apartado 5 se presentan las conclusiones y en el 6 las posibles líneas de trabajos futuros, seguido de la bibliografía.

## 2. TRABAJOS RELACIONADOS

Trabajos recientes en la industria de corte de metales reflejan la aplicación, cada vez mayor de técnicas de softcomputing en predicción de  $R_a$  en procesos de mecanizado. Por ejemplo en (Hao et al., 2006) y (Ezugwua et.al., 2005) se proponen técnicas basadas en redes neuronales artificiales para optimizar los valores de parámetros que participan en el proceso de corte, en (Zhou and Cheng, 2009) y (Zuperl and Cus, 2003) se aplican igualmente redes neuronales artificiales para calcular la incidencia de las fuerzas de corte en la  $R_a$ . En (Correa et al., 2009) se describe un trabajo con datos experimentales con diferentes aleaciones de aluminio sobre las que se mecanizaron diferentes geometrías básicas. Los parámetros de corte, características de herramienta y fuerzas medidas por sensores se usaron como variable predictora en los modelos de predicción de  $R_a$ . En este trabajo se presenta también una comparativa entre modelos desarrollados con redes neuronales artificiales y redes Bayesianas. Estos últimos reportaron mejores resultados, no solo en la precisión del modelo sino también en la interpretabilidad de los resultados.

En (Ozel et al., 2009) se describe un método que usa redes neuronales artificiales para estimar la influencia de los parámetros de la máquina (velocidad de corte, avance y fuerzas aplicadas) y de la herramienta (avance por diente y número de dientes) en la  $R_a$  con acero AISA1054. Se calcula la fuerza del proceso de mecanizado, y se usa junto al resto de parámetros mencionados anteriormente para alimentar la red. En la experimentación, la red se entrena con casos con diferentes condiciones de corte y considerando varias características de la herramienta para generar la  $R_a$  predicha. Los resultados de las pruebas usando herramienta entera fueron comparados con otros obtenidos en pruebas similares usando herramientas de plaquitas intercambiables, y se verificó la conveniencia de usar herramientas enterizas para obtener mejores resultados de  $R_a$ . Otro trabajo similar al antes descrito se presenta en (Soleimanimehr et al., 2009), pero pero trabajando con piezas de aluminio. Aquí aplican técnicas de softcomputing para generar un modelo predictivo de  $R_a$  en el que estudian la influencia del avance por diente, la profundidad de corte y la velocidad de corte en un proceso de mecanizado.

El trabajo descrito en (Correa et. al., 2008) detalla el experimento realizado en el presente trabajo, usando una máquina Kondia HS1000 equipada con un CNC Siemens 840D. El material usado para estas pruebas fue acero F114 sobre el que se realizaron cortes a diferentes profundidades. Las herramientas usadas para los cortes (Karnash modelo 30.6472) tienen diferentes diámetro y número de dientes. El entrenamiento para generar un modelo Bayesiano que relaciona la  $R_a$  con variables

<sup>1</sup> <http://www-01.ibm.com/software/applications/plm/catiav5/>

predictoras en-proceso se realiza con el software Elvira<sup>2</sup>, que por razones de funcionamiento requiere valores discretos en todas las variables. A tal efecto se seleccionó el algoritmo K-means (MacQueen, 2003) para la discretización, detallada en la tabla 2.

La Ra es uno de los parámetros más usados en la industria para caracterizar la rugosidad superficial, se representa La discretización de la variable Ra (la clase) se realizó en función a lo especificado en el estándar ISO 1302:2002. Particularmente las etiquetas de Ra se asignaron de acuerdo a los valores medios de rugosidad superficial establecidos en la norma ISO 1302:2002, la Ra se midió pos-proceso. Para calcular la Ra se usa la ecuación:

$$Ra = \frac{1}{L} \int_0^L |f(x)| dx \tag{1}$$

donde f(x) es la función usada para medir valores medios de rugosidad (por contacto) con intervalos de longitud L sobre la pieza mecanizada. Entre los resultados de este trabajo destaca el uso de una red Bayesiana para estimar valores de Ra dados ciertos valores de las variables predictoras, y el caso contrario: dado un valor de Ra deseada, calcula los valores (las probabilidades) de las variables predictoras para obtenerla.

También se encuentra en la literatura trabajos recientes que incorporan técnicas de softcomputing para modificar programas de CNC. Un ejemplos de estos es (Reddy et al., 2008) que usan un modelo de regresión múltiple y redes neuronales artificiales para generar un modelo de predicción de la Ra. El valor obtenido para ciertas condiciones se incorpora al CNC para mecanizar aleaciones de aluminio. Los resultados experimentales demuestran que se mejoran los resultados en el acabado.

### 3. DESCRIPCIÓN DEL MODELO

Dado que la experimentación en el dominio MAV suele ser costoso, en este trabajo se usa la colección de datos adquirida y descrita en (Correa et. al., 2008). En el mecanizado se crearon ranuras con diferentes condiciones (por ejemplo diferentes diámetros, avances por diente, etc.). A partir de la profundidad de corte inicial (2 mm) se realizaron variaciones en la profundidad de corte incrementando en 25, 50 y 75% en cada ranura (ensayo). La tabla 1 muestra ejemplos de configuración de estos ensayos, donde se ilustran algunas combinaciones de variables y parámetros de corte para ensayos con herramienta de dos dientes.

Los valores de Ra fueron medidos pos-proceso para cada ensayo (cada valor de Ra se calculó haciendo promedios de mínimo tres medidas por ensayo). Estas mediciones se realizaron con un rugosímetro Kart Zeiss Handysurf modelo E-35A. La experimentación generó un total de 625000 medidas, de donde se extrajeron 251 casos.

Para construir el modelo predictivo de Ra, se usa en este trabajo un modelo bayesiano con 6 variables (5 predictoras más la clase Ra) relacionadas con las condiciones de corte y con parámetros de corte, usuales en fresado a alta velocidad. Las variables relacionadas con las condiciones de corte son: profundidad de corte axial (ap), velocidad de avance (F) y velocidad de rotación

del husillo (n), las variables relacionadas con la herramienta son: número de dientes (flutes) y diámetro (diam).

La selección de estas variables predictoras se basa en estudios previos sobre la incidencia de factores del proceso de MAV en la calidad superficial, como por ejemplo (Benardos and Vosniacos, 2003) donde se presenta una revisión de los factores relacionados con el proceso de mecanizado, de la herramienta, y de la pieza, que afectan a la calidad superficial en fresado y torneado. Otros trabajos con objetivos similares pueden ser (Chien and Chou, 2001) o (Lee and Chen, 2003). Adicionalmente, en el presente trabajo se realizó un estudio de correlación entre variables relacionadas con el proceso de mecanizado y la Ra, para seleccionar las más significativas en el proceso, tomando como referente los resultados obtenidos en trabajos como los citados anteriormente.

Como se comentó, el clasificador usado en este trabajo es el clasificador TAN, un extendido del clasificador Bayesiano naïve Bayes con una estructura de árbol sobre las variables predictoras, este árbol se obtiene adaptando el algoritmo propuesto por (Chow and Liu, 1968) y calculando la información mutua condicional para cada par de variables dada la clase. Una ventaja significativa del uso del clasificador TAN para este trabajo, frente a otros clasificadores (como por ejemplo las redes neuronales artificiales), es la capacidad interpretativa de los resultados donde se pueden ver gráficamente las relaciones entre los nodos de la red y la clase.

#### 3.1. Resultados

La figura 1 ilustra la estructura TAN aprendida, en la que se aprecian los arcos causales entre las variables y la clase. La información proporcionada en la figura representa las influencias probabilísticas en las relaciones físicas existentes entre las variables predictoras, información difícilmente deducible a partir de ecuaciones físicas aplicables al proceso de corte mecánico. Se puede deducir de la información de la figura 1 varias relaciones como las siguientes: una dependencia lineal entre las variables ap, diam, F y n, lo que puede interpretarse como que: una profundidad radial de corte deseada, incidiría en la selección del diámetro de la herramienta, que a su vez incidiría en la selección de la velocidad de avance. También, según la profundidad de corte axial y el diámetro de la herramienta a usar en el mecanizado, se debe fijar el avance antes que la velocidad de rotación del husillo.

La tabla 3 muestra las probabilidades a priori de cada variable. Estos valores permiten interpretaciones como por ejemplo, inicialmente la probabilidad de que la herramienta tenga 2 filos es de 0.72 y 0.28 de que tenga 6 filos, o que la probabilidad de que la Ra tenga valor "Liso" es de 0.60.




Figura 1: Red TAN.

<sup>2</sup> <http://www.ia.uned.es/~elvira/index-en.html>

**Tabla 1: Ejemplos de condiciones de corte y mediciones de  $R_a$** 

<i>diam</i> (mm)	<i>Flutes</i>	<i>ap</i> (mm)	<i>F</i> (mm min <sup>-1</sup> )	<i>n</i> (rpm)	$R_a$ (μm)
6	2	2	1500	5000	1.775
6	2	2	1875	5000	1.631
6	2	2	2250	5000	1.758
6	2	2	1500	6250	2.245
6	2	2	1875	6250	1.049
6	2	2	2250	6250	1.509
6	2	2	1500	7500	1.781
6	2	2	1875	7500	0.999
6	2	2	2250	7500	1.195
6	2	4	1500	5000	1.378
6	2	4	1875	5000	1.224
6	2	4	2250	5000	1.531
6	2	4	1500	6250	1.467
6	2	4	1875	6250	1.141
6	2	4	1875	6250	1.141
6	2	4	2250	6250	1.372
6	2	4	1500	7500	0.807
6	2	4	2250	7500	1.282
8	2	2	1662	4375	2.195
8	2	2	2077	4375	0.535
8	2	2	2493	4375	2.121
8	2	2	1662	5468	1.972
8	2	2	2077	5468	1.123
8	2	2	2493	5468	1.667
8	2	2	1662	6562	1.741
8	2	2	2077	6562	0.961
8	2	2	2493	6562	1.287

**Tabla 2: Etiquetas y rangos para cada variable después de la discretización**

ESTADO	$R_a$ (μm) [inf,sup)	<i>flutes</i>	<i>diam</i> (mm)	<i>ap</i> (mm)	<i>F</i> (mm/min) [inf,sup)	<i>n</i> (rpm) [inf,sup)
0	Liso (L)=[0.7,1.1)	2	6	0.20	<1000=[300,1000)	Lento=[5250,7964)
1	Fino (F)=[1.1,2.1)	6	8	0.40	<2050=[1000,2050)	Medio=[7964,10758)
2	Semifino(S)[2.1,5.1)		10	0.60	<2775=[2050,2775)	Semi-rápido=[10758,14813)
3	Medio(M)=[5.1,8.5)		12	1.00	<3850=[2775,3850)	Rápido=[14813,19400)

**Tabla 3: Probabilidades a priori de cada variable**

ESTADO	<i>flutes</i>	<i>ap</i>	<i>F</i>	<i>n</i>	<i>diam</i>	$R_a$
0	0,72	0,26	0,39	0,30	0,42	0,60
1	0,28	0,19	0,39	0,37	0,40	0,20
2		0,23	0,20	0,32	0,19	0,21
3		0,32				

#### 4. VALIDACIÓN

Un objetivo en esta sección es reflejar la estimación de la probabilidad de acierto del modelo de clasificación ante casos nuevos. A tal efecto se tomó como método de validación el K-Fold Cross-Validation (Stone, 1974) que básicamente consiste en dividir el conjunto total de casos en  $K$  subconjuntos disjuntos. De estos  $K$  subconjuntos, uno se reserva como datos de validación para probar el modelo y los restantes ( $K-1$ ) se utilizan como datos de entrenamiento. El proceso se repite  $K$  veces (con cada uno de los subconjuntos usado sólo una vez como datos de validación). El resultado de esta validación se muestra en la tabla

3. Analizando los datos de la tabla 4 se observan valores con exactitud del 100% en la clasificación en los casos de  $R_a$ =“Liso”, también es importante que el resto de las clasificaciones supera siempre el umbral del 60% de correctamente clasificados.

Para validar la calidad (en general) del clasificador se usaron las fórmulas descritas en la tabla 5. Éstas permiten estimar las medidas de mérito del clasificador, que reflejan un nivel más que aceptable del clasificador pre-proceso. Por ejemplo, la precisión (valor relacionado con la capacidad de clasificar adecuadamente nuevos casos) es del 96%. El clasificador tiene una alta probabilidad de acierto en la clasificación (88%).

Otra técnica de validación usada en este trabajo consistió en contrastar la calidad de la clasificación y la calidad del clasificador, respecto a otros modelos descritos en la literatura. A tal efecto se seleccionaron 6 trabajos que usan técnicas de softcomputing y datos experimentales de procesos de corte mecánico a alta velocidad. En detalle, se seleccionaron cuatro trabajos que usan redes neuronales artificiales y dos que usan redes Bayesianas y se obtuvo la media de los errores medios absolutos (MAE) indicados en cada trabajo.

Este trabajo es una nueva propuesta respecto al trabajo descrito en (Correa et. al., 2008), dado que aunque se usaron los mismos datos experimentales y las mismas variables (sin incluir la fuerza de corte del mecanizado, se plantea un modelo pre-proceso. Por su similitud se contrastan los valores de mérito de ambos modelos para estimar qué tanto se degrada/mejora el modelo pre-proceso respecto al primero. Para esta comparación se consideró suficiente usar la desviación estándar del error MAE como línea base. Dicha comparación refleja que el modelo pre-proceso no se aleja considerablemente del modelo en-proceso.

El valor promedio de los errores MAE en los trabajos consultados es 13.5 (desviación estándar de 14.87), mientras que el valor del error MAE en este trabajo es de 13.0. Esto refleja que la calidad del modelo pre-proceso (respecto al error MAE) está dentro de lo usualmente obtenido en trabajos con técnicas de softcomputing.

**Tabla 4: Matriz de confusión.**

Real \ Asignado	Liso	Fino	Semi-fino	Medio
Liso	30 (100%)	0	0	0
Fino	17	82 (78,8%)	4	1
Semi-fino	2	16	38 (62,3%)	5
Medio	1	2	8	44 (80%)

**Tabla 5: Fórmulas para calcular los indicadores de mérito del clasificador y resultados (VP= verdaderos positivos, VN= verdaderos negativos, FP=falsos positivos y FN=falsos negativos).**

sensibilidad	$\frac{VP}{VP + FN}$	= 0.83
especificidad	$\frac{VN}{FP + VN}$	= 0.95
precisión	$\frac{VP}{VP + FP}$	= 0.96
exactitud	$\frac{VP + VN}{VP + FN + FP + VN}$	= 0.88

### 5. CONCLUSIONES

En este trabajo se han usado datos experimentales utilizados en trabajos previos para generar modelos de predicción de  $R_a$ . A diferencia de los trabajos anteriores mencionados, en este trabajo se ha descartado la fuerza del proceso de mecanizado del conjunto de variables predictoras, lo que ha permitido generar un modelo pre-proceso de predicción de  $R_a$ , dependiendo solamente de las condiciones de corte y de la herramienta.

El modelo de predicción de  $R_a$  relaciona las variables predictoras con la clase de modo gráfico, un modelo con estas características facilita la comprensión de las relaciones condicionales (Acebes et al., 2004). También se resaltan aportaciones en dos sentidos: respecto a lo novedoso y la validez del modelo pre-proceso de predicción de la calidad superficial, sin aportar conocimiento de sensores al modelo. En relación al primer punto, en este trabajo

se presenta una técnica softcomputing para generar un modelo predictivo de  $R_a$  en pre-proceso, basado en la experimentación descrita en el apartado 2. El modelo de predicción es un clasificador Bayesiano. La red obtenida con el clasificador TAN se basa, como se ha dicho, en parámetros de corte, características de herramienta y datos experimentales. Los resultados de esta experimentación son fiables estadísticamente hablando, según la validación.

Las redes Bayesianas con estructura naïve Bayes y TAN son estructuras usadas en trabajos previos, donde se ha validado su aplicabilidad a problemas de predicción de la  $R_a$ , en procesos de corte mecánico a alta velocidad, pero no se encuentra evidencia en la literatura de trabajos para generar modelos pre-proceso predictivos de la  $R_a$ , siendo precisamente esto, uno de los aportes principales de este trabajo, junto a la validación y estimación de la calidad del modelo generado. El valor del error MAE obtenido en la validación, refleja que el modelo Bayesiano está dentro de la media de estos valores.

Respecto a posibles incorporación de este tipo de modelos a la industria, este trabajo presenta un novedoso estudio, respecto a la mayoría de las experiencias encontradas en la literatura, dado que el modelo obtenido incorpora condiciones de corte específicas de un equipo de mecanizado, por lo que el trabajo presentado puede aportar en áreas de investigación como desarrollo de aplicaciones software para actuar sobre sistemas CAM, es decir: incorporar modelos de conocimiento de  $R_a$  en sistemas CAM para generar predicciones de acabado más precisas y ajustadas a la realidad del mecanizado.

También puede servir de soporte a mejorar las calidades obtenidas, pero también los costes de tiempo y material usado en estos procesos. Se puede incorporar a herramientas software de la posibilidad de introducir valores de  $R_a$  deseado para generar los parámetros de corte adecuados. Es decir, con una calidad superficial deseada poder definir avance, velocidad de giro, profundidad de corte, etc. y otros aspectos como características de la herramienta (por ejemplo diámetro, número de dientes, etc.), que resulten más adecuados para obtener la  $R_a$  deseada e incorporarlos directamente al diseño del programa pieza.

Un tercer aporte (potencial) es, dado que en el contexto de trabajo actual se puede planificar un mecanizado pero no verificar su acabado hasta el pos-proceso, modelos como el propuesto podrían incorporarse en herramientas software de control de procesos mecánico. Esto podría asegurar mejores resultados para unas condiciones dadas, puesto que el seguimiento del mecanizado se mejoraría sustancialmente.

### 6. LÍNEAS FUTURAS

El entrenamiento del clasificador resulta adecuado para los casos descritos, sin embargo, se considera conveniente entrenar el modelo con nuevos ensayos, realizados con el mismo diseño experimental para comprobar la validez del modelo. Es conveniente también realizar nuevos ensayos en otros centros de mecanizado con características distintas para comprobar la generalidad del modelo pre-proceso obtenido.

La experimentación descrita anteriormente representa un paso adelante en la predicción pre-proceso de  $R_a$ , pero la generalidad del modelo depende de realizar otros entrenamientos para disponer de nuevos casos, como por ejemplo condiciones de

corte diferentes, pero con los mismos parámetros de experimentación.

Respecto al modelo de entrenamiento usado, se estima conveniente estudiar la posibilidad de utilizar otros paradigmas como por ejemplo *support vector machines* o *logistic regresión* para contrastar los resultados del problema abordado. También, en relación a la discretización de variables en las redes Bayesianas, actualmente se dispone de técnicas que permiten el uso de variables continuas y discretas en un modelo, conocidas como redes Bayesianas mixtas. Éstas permiten utilizar tanto variables discretas (como es el caso de la clase  $R_a$  en este trabajo, dado que el interés es que  $R_a$  tome valores en un conjunto finito) como variables continuas. Este tipo de técnicas podrían incorporarse al modelo para lograr un estudio más exhaustivo de la propagación de la evidencia entre las variables del modelo.

Otro tópico importante de atender es la aplicación de los resultados del modelo predictivo de  $R_a$  pre-proceso a herramientas CAD/CAM, lo que puede comenzar por validar las conclusiones expresadas en este trabajo respecto a las relaciones de dependencia probabilística entre las variables predictoras que relacionan características de la herramienta de corte mecánico con características de la máquina usada. Otra aplicabilidad de lo obtenido sería la implementación de procesos de control al diseño CAM, basado en las relaciones entre variables del modelo Bayesiano. Por ejemplo, podrían implementarse (en forma de reglas) para formar parte de un conocimiento de control las relaciones entre profundidad de corte, avance, etc., que mejorara la selección más probable de las condiciones de corte o verificar el buen hacer del proceso de mecanizado.

#### REFERENCIAS

- Acebes L., Alves R., Merino A., de Prada C. (2004). Un entorno de modelado inteligente y simulación distribuida de plantas de proceso, *RIAI: Revista Iberoamericana de Automática e Informática Industrial*, **1**, 42-48.
- Altintas Y. and Weck M. (2004). Chatter stability of metal cutting and grinding, *CIRP Annals Manufacturing Technology*, **53**, 619-642.
- Benardos P.G. and Vosniakos G.C. (2003). Predicting surface roughness in machining: a review, *International Journal of Machine Tools & Manufacture*, **43**, 833-844.
- Correa, M. Ramírez, M. de J., Alique, J.R. and Rodríguez, C. (2004). Factores que afectan el acabado superficial en los procesos de mecanizado: técnicas de análisis y modelos, *XXV Jornadas de Automática*, Ciudad Real, España.
- Correa M., Bielza C., Ramírez M. and Alique J.R. (2008). A Bayesian network model for surface roughness prediction in the machining process, *International Journal of Systems Science*, **39**, 1181-1192.
- Correa M., Bielza C. and Pamies-Teixeira P. (2009). Comparison of Bayesian networks and artificial neural networks for quality detection in a machining process, *Expert Systems with Applications*, **36**, 7270-7279.
- Chow C.K. and Liu C. (1968). Approximating discrete probability distributions, *IEEE Transactions on Information Theory*, **14**, 462-467.
- Ezugwua E. O., Faderea D., Onney J., Bonney J., Da Silva R.B. and Sales W. F. (2005). Modelling the correlation between cutting and process parameters in high-speed machining of Inconel 718 alloy using artificial neural network, *International Journal of Machine Tools & Manufacture*, **45**, 1375-1385.
- Friedman N., Geiger D. and Goldszmit M. (1997). Bayesian network classifiers, *Machine Learning*, **29**, 131-161.
- Gajate A., Heber R. (2009). Control Neuroborroso en red. Aplicación al proceso de taladrado de alto rendimiento, *RIAI: Revista Iberoamericana de Automática e Informática Industrial*, **6**, 31-38.
- Hao W., Zhu X., Li X. and Turyayagyenda G. (2006). Prediction of cutting force for self-propelled rotary tool using artificial neural network, *Journal of Material processing Technology*, **180**, 23-29.
- Ko, T.J., Park, J.W., Kim, H.S. and Kim, S.H. (2007). On-machine measurement using a noncontact sensor based on a CAD model, *International Journal of Advanced Manufacturing Technology*, **32**, 739-746.
- Lee S. and Chen J.C. (2003). On-line surface roughness recognition system using artificial neural networks system in turning operations. *International journal of Advanced Manufacturing Technology*, **22**, 62-68.
- Lela B., Bajie D. and Jozié S. (2009). Regression analysis, support vector machines, and Bayesian neural Network approaches to modelling surface roughness in face milling, *Advanced Manufacturing Technology*, **42**, 1082-1088.
- MacQueen J. (2003). Some Methods for Classification Analysis of Multivariate Observations, *Proc. 5th Berkeley Symp. Math. Statistics and Probability*, **1**, 281-297.
- Ozel T., Esteves A. and Davim J. (2009). Neural network process modelling for turning of steel parts using conventional and wiper inserts, *International Journal of Materials and Product Technology*, **35**, 246 – 258.
- Ramírez-Cadena M., Correa M., Rodríguez-Gonzalez C. and Alique J.R. (2005). Surface Roughness Modelling Based on Surface Roughness Feature Concept for High Speed Machining, *American Society of Mechanical Engineers, Manufacturing Engineering Division*, **16**, 811-817.
- Redondo R., Santos P., Bustillo A., Sedano J., Villar J.R., Correa M., Alique J.R. and Corchado E. (2009). A soft Computing System to Persorm Face Milling Operations, *Proceedings of the 10th International Work-Conference on Artificial Neural Networks*, **5518**, 1282 – 1291.
- Reddy B., Padmanabhan G. and Reddy K. V. (2008). *Surface Roughness Prediction Techniques for CNC turning*, *Asian Journal of Scientific Research*, **1**, 256-264.
- Soleimanimehr H., Nategh M.J. and Amini S. (2009). Modelling of Surface Roughness in Vibration Cutting by Artificial Neural Network". *Proceedings of World Academy of Science, Engineering and Technology*, **40**, 386-390.
- Stone M. (1974). Cross-validators choice and assessment of statistical prediction, *Journal of the Royal Statistical Society B*, **36**, 111-147.
- Zhou L. and Cheng K. (2009). Dynamic cutting process modelling and its impact on the generation of surface topography and texture in nano/micro cutting, *In Proc. of IMechE-2009, Engineering Manufacture*, **223**, 247-266.
- Zuperl U. and Cus F. (2003) "Optimization of cutting conditions during cutting by using neural networks", *Robotics and Computer Integrated Manufacturing*, **19**, 189-199.