

Predicción de la rugosidad superficial en texturizados por electroerosión usando redes bayesianas

Prediction of roughness surface in textured by electrical erosion using bayesian networks

Maritza Correa Valencia, Ph.D.

mcorrea@uao.edu.co

*Dpto de Operaciones y Sistemas
Universidad Autónoma de Occidente
Cali-Colombia*

Jorge Pamies-Teixeira, Ph.D.

jorge.pamies@fct.unl.pt

*Dpto de Ingeniería Industrial y Mecánica
Faculdade de Ciências e Tecnologia,
Universidade Nova de Lisboa, Portugal*

Fecha de recepción: Octubre 3 de 2013

Fecha de aceptación: Diciembre 13 de 2013

Palabras clave

Estimación; rugosidad superficial; redes bayesianas; electroerosión; EDT.

Keywords

Prediction, Surface roughness, Bayesian networks, EDM, EDT

Colociencias
tipo 1

Resumen

Se presenta un modelo para la estimación de los parámetros que definen la rugosidad superficial [Ra] cuando se produce con un proceso de texturizado por descarga eléctrica [EDT, *Electro Discharge Texturing*]. La no linealidad, la inestabilidad y los costos de la experimentación en EDT son las principales causas para el uso de técnicas de predicción usando algoritmos robustos y fiables, con el fin de estudiar factores que presentan dificultades en la caracterización. Se realizaron varios experimentos para producir texturas de superficies planas usando una máquina de electroerosión [EDM, *Electric Discharge Machining*] modificada ALIC-1. Los datos obtenidos en la fase experimental se usaron para entrenar modelos Bayesianos con los clasificadores Naïve Bayes y Naïve Bayes Aumentado a Árbol. Los resultados conseguidos mostraron un comportamiento aceptable dentro del rango operativo, consistente con los fenómenos físicos que rigen el proceso EDT. Se demuestra que es posible encontrar una rugosidad superficial con especificaciones particulares.

Abstract

A model for prediction of parameters that defined roughness surface [Ra] when this texture is produced by Electro Discharge Texturing [EDT] is presented. The non-linearity, instabilities and expensive experimentation in this process, are main causes for use predictive techniques by means of robust and reliable algorithms, for study factors that present characterization hard. Series of experiments were conducted to produce plane surface textures using a modified EDM machine ALIC-1. The data collected in experimental phase were used for trained Bayesian models with Naïve Bayes and Tree Augmented Naïve Bayes [TAN] classifiers. Results show acceptable behavior within the operating range, consistent with the physical phenomena governing EDT process. Find a surface roughness with particular specifications is demonstrated.

I. Introducción

La textura superficial es uno de los atributos más importantes en las láminas metálicas (acero o aluminio) usadas en la industria automotriz, ya que mejoran las propiedades tribológicas, la conformabilidad del material y las operaciones de acabado, como el revestimiento y la pintura (Pfestorf, Engel, & Geiger, 1998).

Esta es la razón por la cual la producción de láminas texturizadas requiere controlar los parámetros que definen la textura. Considerando esta, se advierte la importancia de la comprensión clara de los mecanismos físicos y la correlación entre las variables resultantes de la textura y los parámetros operativos del respectivo proceso (Pamies-Teixeira, 2002).

El texturizado por descarga eléctrica [*Electro Discharge Texturing* - EDT] es un proceso tecnológico caracterizado por la generación de un arco eléctrico entre una pieza metálica y un electrodo de grafito. Separando a ambos hay un medio dieléctrico, eléctricamente aislante. La intensidad del campo eléctrico es mayor que la resistencia del dieléctrico, al menos en algún punto, y la corriente rompe, permitiendo el flujo eléctrico entre los electrodos. La chispa calentará la superficie de la pieza hasta una temperatura en que volatiliza el metal, arrancará partículas de la pieza y logrará finalmente reproducir en la pieza las formas del electrodo.

EDT es uno de los métodos de texturización más populares, usado, por ejemplo, en el caso de fresado de cilindros para la producción de láminas metálicas. El menor costo, en comparación con otras tecnologías competitivas –aparte de los factores tecnológicos–, es la causa principal para que este método sea más interesante. Mientras que en tecnologías basadas en chorro de arena [*SBT, Sand Blasting*] es más difícil controlar el resultado final, el texturizado por haz de electrones [*EBT, Electron Beam Texturing*] y el texturizado laser [*LT, Laser Texturing*] producen una textura muy regular, que puede ser perjudicial, ya que la textura presenta una rugosidad direccional que produce comportamientos tribológicos diferentes y es transversal a la dirección de laminación; algunas veces este acabado puede ser detectado sólo en el producto final, incluso después de terminado (Terpák, Dorak, Revaj, 2010). El EDT brinda un alto grado de aleatoriedad dando como resultado una superficie con un acabado mate uniforme (Simão, Aspinwall, Wise & El-Menshawy, 1996) (ver Figura 1a).

La eficiencia del proceso EDT depende esencialmente de la energía descargada con los mismos umbrales en la corriente de descarga y la frecuencia. Bajos valores de la corriente, conducen a pequeños espacios entre la pieza de trabajo y el electrodo (ver Figura 1b); con una frecuencia de descarga por encima de ciertos límites, pueden producirse arcos (ver Figura 1c), destruyendo la superficie (Aspinwall, Zhao, & El-Menshawy, 1989). Por otro lado, si la frecuencia es muy baja pueden ocurrir inestabilidades debido a

insuficiente chispa de energía para producir descargas homogéneas y, por consiguiente, superficies dañadas. Sin embargo, no se conocen modelos que describan la relación entre las variables del proceso y la textura superficial.




Figura 1. a) Textura superficial típica producida por EDT. b) Textura superficial producida por baja descarga de energía. c) Textura superficial producida por la ocurrencia de arcos.

Debido a la no linealidad y las inestabilidades, también a la experimentación algo costosa del proceso, es necesario proporcionar técnicas de predicción apropiadas, encontrar algoritmos robustos y fiables para hacer frente a estos factores que son difíciles de caracterizar. Con este trabajo se introducen los clasificadores basados en redes Bayesianas para la predicción de los parámetros de acabado que definen la rugosidad superficial (R_a), en un proceso EDT.

El artículo está dividido en 5 apartados. La sección 2 contiene el estado de arte, la metodología sobre la fase experimental y las pruebas realizadas están resumidas en la sección 3, el análisis de los resultados obtenidos a partir de los modelos Bayesianos aplicados a la predicción de la rugosidad superficial en EDT se exponen en la sección 4 y finalmente se presentan las conclusiones del trabajo.

II. Estado del arte

Varios trabajos se han enfocado en el uso de redes neuronales artificiales [RNA] para la predicción de la calidad superficial y especialmente de la tasa de remoción de material en procesos EDT, habitualmente en aceros. Por ejemplo, Markopoulos, Vaxevanidis, Petropoulos, y Manolagos (2006) plantean un modelo usando RNA para determinar el acabado en EDM aplicado a aceros, asegurando que las RNA se han usado principalmente para determinar la tasa de remoción de material con resultados que muestran un porcentaje de error muy diferente según el tipo de material, y sugiriendo nueva experimentación para corregir la exactitud del modelo.

Pradhan, Das, y Biswas (2009), por su parte, comparan dos tipos de redes neuronales, *BackPropagation* (BP) y *Radial Basis*, para predecir la rugosidad superficial en procesos EDM en piezas de acero, indicando que las redes BP son más exactas –aunque toman más tiempo en el entrenamiento–, presentando un error medio absoluto de 30% en BP y 57% en el caso de *Radial Basis*.

En el estudio de parámetros de corte, Gao, Zhang, Su, y Zhang (2008) aseguran que las RNA son muy utilizadas en aplicaciones con EDM para medir la tasa de remoción de material, aunque en este caso presentan un modelo de optimización de parámetros en un proceso EDM usando algoritmos genéticos y RNA para aceros.

Pellicer, Ciurana y Ozel (2009) estudian la influencia de los parámetros de corte y la geometría del electrodo en EDM para la fabricación de moldes de acero, usando modelos de regresión y RNA con resultados aceptables.

A pesar de que se encuentran reportes del uso de RNA en procesos EDM, con relativo éxito, es de resaltar que el comportamiento de este tipo de redes es como una *caja negra*, es decir, sólo se conoce la entrada y salida de la red, sin dar detalle sobre la influencia de las variables de entrada sobre la salida, ventaja que si se aprecia con el uso de redes bayesianas [RB]. Aunque el uso de RB en este tipo de proceso no es conocido, esta herramienta ha demostrado ser efectiva en el estudio de procesos de mecanizado por arranque de viruta (Correa, Alique, & Bielza, 2008; Correa, Bielza, Ramirez, & Alique, 2008; Correa, Bielza, & Pamies-Teixeira, 2009), en los cuales se resalta el conocimiento adicional que ofrecen estas redes sobre el comportamiento de las variables y sus relaciones.

A) Calidad superficial

Un parámetro representativo de la textura superficial, que además es más fácil de medir, es la rugosidad superficial; esto lo hace ampliamente utilizado. Para medirla se usan los rugosímetros, aunque aún restringidos a inspecciones post-proceso apoyado en métodos de control estadístico.

El término de rugosidad superficial es cuantificado por parámetros relativos a características de la superficie (Correa, Ramirez, Alique, & Rodriguez, 2004). Es la variación vertical sobre una distancia de medida. La medida usada más comúnmente es R_a definida como el promedio de los valores absolutos de las variaciones altas de la superficie Z_i medida desde el nivel medio a lo largo de una línea de datos del perfil (Ecuación 1). La norma ISO4288:1996 indica que los valores de medición van de $0.006 \mu\text{m}$ a $80 \mu\text{m}$.

$$R_a = \frac{1}{N} \sum_{i=1}^N |Z_i| \quad (1)$$

Asegurar la calidad del producto diseñado, aun incorporando métodos preproceso como Taguchi (Ghoreishi & Atkinson, 2002), requieren de una etapa intermedia que garantice la calidad superficial durante el propio proceso EDT. Añadir sensores para ayudar a asegurar la calidad no es sencillo, dado que el propio proceso ofrece un ambiente hostil para la vida del sensor. De allí surge la necesidad de desarrollar sensores basados en modelos predictivos, fundamentados en la teoría del mecanizado (mecánicos) y los apoyados en datos observados (empíricos).

Se desarrolla un sensor virtual basado en clasificadores que usan redes bayesianas para predecir los parámetros de acabado que definen la rugosidad superficial (R_a), en un proceso EDT.

B) Redes bayesianas

Una red bayesiana consta de un grafo acíclico dirigido, cuyos nodos representan variables aleatorias y los arcos la dependencia probabilística con una distribución de probabilidad condicionada para cada nodo X_i , dados sus padres $P(x_i|pa(x_i))$ (Pearl, 1988). Puede partir del conocimiento del experto o estimar las probabilidades a partir de la información disponible en una muestra (Langley, Iba, & Thompson, 1992).

Método Naïve Bayes

Es el paradigma clasificatorio en el que se utiliza el teorema de Bayes en conjunción con la hipótesis de independencia condicional de las variables predictoras dada la clase. A pesar una larga tradición en la comunidad de reconocimiento de patrones el clasificador Naïve Bayes [NB] aparece por primera vez en la literatura del aprendizaje automático a finales de los ochenta, con el objetivo de comparar su capacidad predictiva con la de métodos más sofisticados como la clasificación supervisada.

El método NB debe su nombre a las hipótesis de independencia condicional de las variables predictoras dada la variable clase sobre las que se construye dicho clasificador (ver Figura 2a).

La probabilidad que un k -ésimo ejemplo pertenezca a la clase i -ésima de la variable x_i se calcula aplicando el teorema de Bayes (Ecuación 2). Con este teorema se puede actualizar la probabilidad *a posteriori* usando la probabilidad *a priori* y la verosimilitud.

$$\begin{aligned}
 p(x_i|x_1, \dots, x_k) &= \frac{p(x_i, x_1, \dots, x_k)}{\sum_{x_i} p(x_i, x_1, \dots, x_k)} = \frac{p(x_i) \prod_j p(x_j | e_i)}{p(x_1 \dots x_k)} \\
 &= \frac{p(x_i) p(x_1, \dots, x_k | x_i)}{\sum_{x_i} p(x_i) p(x_1, \dots, x_k | x_i)} = \frac{p(x_i) \prod_{j=1}^k p(x_j | x_i)}{p(x_i)}
 \end{aligned} \tag{2}$$

Cuando se aplica el teorema de Bayes sucesivamente, la probabilidad *a posteriori* calculada en una etapa dada es la misma que la probabilidad *a priori* en la etapa siguiente.

Método Naïve Bayes aumentado a Árbol

El algoritmo *Tree Augmented Network* [TAN] (Friedman, Geiger, & Goldszmit, 1997) consiste básicamente en una adaptación del algoritmo de Chow-Liu (Chow & Liu, 1968) (ver Figura 2b). Este algoritmo tiene en cuenta la cantidad de información mutua condicionada a la variable clase, en lugar de la cantidad de información mutua en la que se basa el algoritmo de Chow-Liu. La cantidad de información mutua entre las variables discretas X y Y condicionada a la variable C se define en la Ecuación 3 como:

$$I_p(X, Y | C) = \sum_{i=1} \sum_{j=1} \sum_{r=1} p(x_i, y_j, c_r) \log \frac{p(x_i, y_j, c_r)}{p(x_i | c_r) p(y_j | c_r)} \tag{3}$$




Figura 2. a) Estructura gráfica de un modelo Naïve-Bayes. b) Estructura Naïve Bayes aumentada a árbol

III. Metodología

Con una máquina de electroerosión modificada (EDM) ALIC-1 con movimientos transversales, se hizo una serie de experimentos, produciendo texturas superficiales planas. Aunque el equipo tiene algunas limitaciones, como el pequeño rango de velocidad de desplazamiento, se reprodujeron situaciones típicas del proceso industrial.

Se utilizó acero DIN Ck45 para mecanizar la superficie de las probetas hasta obtener una medida de $R_a = 0,1$ a $0,5 \mu\text{m}$. Se usaron electrodos de grafito de alta densidad (EC17) y cobre HDCH (HD7), el fluido dieléctrico fue Fluxelf 2. La banda texturizada fue el resultado de varias pasadas, utilizando en todos los casos una distancia de voltaje de 40V. La superficie se midió con un rugosímetro Mitutoyo SurfTest 301 con longitud de *cut-off* de 0.8 mm, longitud de evaluación de 2.4 mm y nivel de pico máximo de $0.5 \mu\text{m}$. Para asegurar la uniformidad de la superficie, se hicieron cinco mediciones en tres sitios diferentes de la superficie texturizada (ver Figura 2). Como no se detectó ninguna desviación de la uniformidad, todas las 15 mediciones se consideraron representativas del mismo conjunto de datos.

Para correlacionar R_a con los parámetros del proceso, se utilizó un diseño de experimentos [DOE] (Ivancos, Luis, Ortiz, & Gonzalez. 2005). El trabajo experimental

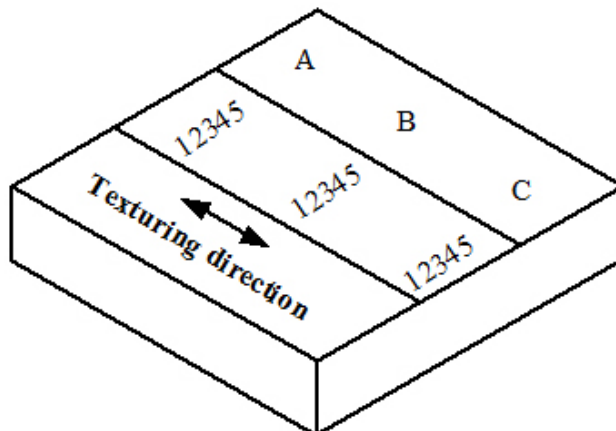


Figura 3. Ubicación de las mediciones en la probeta

se desarrolló a partir de un diseño factorial completo con dos niveles para cada variable, lo cual tiene por objeto permitir una selección conveniente de las variables que se utilizarán en la construcción del modelo.

A) Identificación de rangos y variables relevantes

Dadas las posibilidades de control de los parámetros en la máquina ALIC-1, se utilizaron las siguientes variables: corriente de descarga (I), *on-time* (t_d), *off-time* (t_q) y velocidad de desplazamiento (v). También se usó como variable el material del electrodo y la polaridad (m). El conjunto de variables utilizado y probado en la experimentación se muestra en la Tabla 1.

Tabla 1. Niveles asignados de las variables en los experimentos

Variable	Nivel	
	-1	1
Corriente de descarga (I) [A]	1	3
<i>On-time</i> (t_d) [s]	15	200
<i>Off-time</i> (t_q) [div]	2	5
Velocidad de desplazamiento (V) [m/min]	0.06	0.24
Material del electrodo y polaridad (m)	Cobre, negativo	Grafito, negativo

Los niveles 1 y -1 representan, respectivamente, los valores alto y bajo de las variables. En el caso de combinaciones de electrodo/polaridad, el valor bajo fue tomado como la combinación conocida de rugosidad más baja (cobre/negativo). En consecuencia, el valor alto es el que da la rugosidad alta (grafito/negativo). El valor de t_q fue dado en una escala de doce posiciones del sistema de control de la máquina; por lo tanto, el número de la división (div) se tomó como el valor de la variable. Los resultados experimentales se presentan en la Tabla 2. Se hizo un análisis de la varianza (Anova) para probar la importancia de las variables para un nivel de confianza de 95% (ver Tabla 3). Este análisis mostró que las variables relevantes para encontrar Ra son el material del electrodo y la polaridad de descarga, a tiempo actual y fuera de tiempo. Para el cálculo estadístico se usó el software comercial Statistics.

IV. Resultados

El objetivo principal de este trabajo es encontrar la combinación de parámetros que sean capaces de definir una calidad perteneciente a un rango dado; para la implementación del modelo de clasificación se usó el programa Elvira (Díez, 2005). Para la construcción de la arquitectura de la red se seleccionaron seis variables, medidas dentro y fuera del proceso (ver Tabla 1) y se midió la rugosidad superficial (Ra), fuera del proceso, como

Tabla 2. Resultados para la primera fase experimental

# Experimento	Variables					Resultados Ra (μm)
	I	t_d	t_q	m	v	
E1-01	-1	-1	-1	-1	-1	2.57
E1-02	-1	-1	-1	-1	1	1.98
E1-03	-1	-1	-1	1	-1	1.98
E1-04	-1	-1	-1	1	1	2.06
E1-05	-1	-1	1	-1	-1	1.54
E1-06	-1	-1	1	-1	1	2.32
E1-07	-1	-1	1	1	-1	3.25
E1-08	-1	-1	1	1	1	2.99
E1-09	-1	1	-1	-1	-1	2.07
E1-10	-1	1	-1	-1	1	2.07
E1-11	-1	1	-1	1	-1	3.30
E1-12	-1	1	-1	1	1	3.36
E1-13	-1	1	1	-1	-1	3.00
E1-14	-1	1	1	-1	1	3.30
E1-15	-1	1	1	1	-1	7.61
E1-16	-1	1	1	1	1	8.60
E1-17	1	-1	-1	-1	-1	2.31
E1-18	1	-1	-1	-1	1	2.65
E1-19	1	-1	-1	1	-1	3.60
E1-20	1	-1	-1	1	1	4.37
E1-21	1	-1	1	-1	-1	2.60
E1-22	1	-1	1	-1	1	2.12
E1-23	1	-1	1	1	-1	3.69
E1-24	1	-1	1	1	1	4.33
E1-25	1	1	-1	-1	-1	4.62
E1-26	1	1	-1	-1	1	3.45
E1-27	1	1	-1	1	-1	12.24
E1-28	1	1	-1	1	1	10.63
E1-29	1	1	1	-1	-1	5.44
E1-30	1	1	1	-1	1	3.32
E1-31	1	1	1	1	-1	11.90
E1-32	1	1	1	1	1	11.86

Tabla 3. Resultados del análisis de varianza en la primera fase experimental

Variables	Ra response				Ra response					
	Sum of squares	dof	Mean square	F-value	P-value	Sum of squares	dof	Mean square	F-value	P-value
v	0.1668	1	0.1668	0.1727	0.6832	1128.125	1	1128.1250	5.4394	0.0331
E _p	79.4115	1	79.4115	82.2482	1.05E-07	1624.500	1	1624.5000	7.8327	0.0129
t _q	6.6704	1	6.6704	6.9087	0.0183	1740.500	1	1740.5000	8.3921	0.0105
t _d	85.8378	1	85.8378	88.9040	6.19E-08	13041.125	1	13041.125	62.8796	6.22E-07
I	43.0824	1	43.0824	44.6214	5.29E-06	8128.125	1	8128.1250	39.1909	1.14E-05
v × E _p	0.3983	1	0.3983	0.4125	0.5298	406.125	1	406.1250	1.9582	0.1808
v × t _q	0.1164	1	0.1164	0.1206	0.7330	435.125	1	435.1250	2.0980	0.1668
v × t _d	0.7412	1	0.7412	0.7676	0.3939	264.500	1	264.5000	1.2753	0.2754
v × I	0.7907	1	0.7907	0.8189	0.3789	112.500	1	112.5000	0.5424	0.4721
E _p × t _q	3.6248	1	3.6248	3.7543	0.0705	24.500	1	24.5000	0.1181	0.7355
E _p × t _d	36.2313	1	36.2313	37.5255	1.46E-05	171.125	1	171.1250	0.8251	0.3772
E _p × I	14.8649	1	14.8649	15.3959	0.0012	378.125	1	378.1250	1.8232	0.1957
t _q × t _d	4.4775	1	4.4775	4.6375	0.0469	21.125	1	21.1250	0.1019	0.7537
t _q × I	4.3734	1	4.3734	4.5296	0.0492	1275.125	1	1275.1250	6.1482	0.0247
t _d × I	16.7765	1	16.7765	17.3758	0.0007	220.500	1	220.5000	1.0632	0.3178
Error	15.4482	16	0.9655			3318.375	16	207.3984		
Total SS	313.0119	31				32289.500	31			

$F_{(1,16;0.05)} = 4.49$; $R^2 = 0.951$

$F_{(1,16;0.05)} = 4.49$; $R^2 = 0.897$

la variable clase o salida. Dado que el programa requiere que todas las variables sean discretas, se usaron las etiquetas presentes en la Tabla 4.

Tabla 4. Etiquetas usadas en las variables del modelo

m		Ra	(rango)	I	V
Cobre +	1	Semifino	[1.6-4)	1.3	0.5
Cobre -	2	Medio	[4-8)	2	1
Grafito +	3	Semirugoso	[8-14)	3	2
Grafito -	4	Rugoso	[14-27]	4	4
				4.7	8
				5	

A) Caso 1. Clasificador NB

El clasificador NB es el más sencillo, por lo cual se usó para la primera estructura; se utilizó la corrección de Laplace para asignar una proporción de participación a todos los casos, aún en los que no estaban presentes en el momento del entrenamiento pero que sí pueden aparecer en el futuro. La red generada se muestra en la Figura 4.

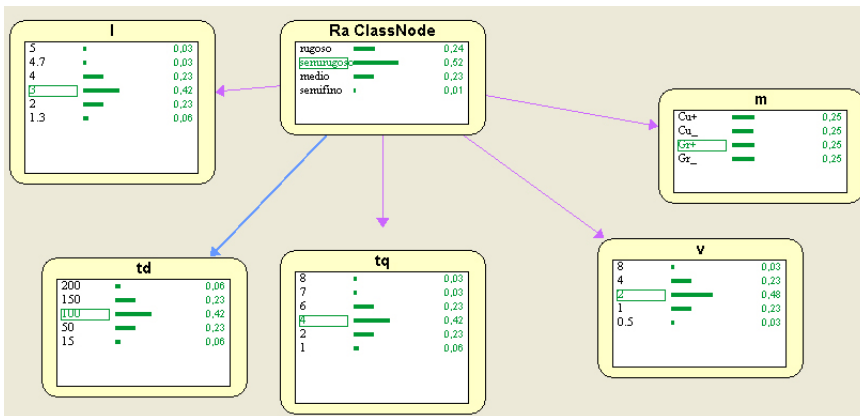


Figura 4. Estructura del clasificador NB

En un modelo de clasificación se busca catalogar correctamente casos nuevos, por lo tanto la validación debe hacerse con datos diferentes a los usados en el entrenamiento. El método de validación seleccionado fue K-Fold Cross-Validation, el cual consiste en dividir el conjunto total de casos en k subconjuntos disjuntos de aproximadamente el mismo tamaño; usando K-1 subconjuntos para entrenar el modelo, se valida con el subconjunto restante; este procedimiento se efectúa k veces. La estimación de la tasa de error se da como la media de las k tasas de error obtenidas; en este caso, la validación se efectuó con k=10, obteniendo una precisión de 76%.

Terminada la validación se genera una matriz de confusión media donde se cruza la variable derivada de la clasificación obtenida, con la variable que guarda la verdadera clasificación (los resultados del caso 1 se muestran en la Figura 5). Por estados la clasificación está distribuida en Rugoso 70.4%, Semirugoso 88.7%, Medio 53.4%, Semifino 70%, lo que significa que la mayoría de probetas tienen calidad Semirugoso.

Precisión: 0.7607142857142857

Matriz de confusión media

REAL \	"rugoso"	"semirugoso"	"medio"	"semifino"
ASSIGNED				
"rugoso"	143	17	6	0
"semirugoso"	60	387	78	1
"medio"	0	32	102	2
"semifino"	0	0	5	7

Figura 5. Matriz de confusión media usando NB

El clasificador NB toma las variables de forma independiente, como se muestra en la Figura 4. Del análisis del modelo se extractan algunas situaciones que, en opinión del experto, son consistentes con el proceso físico (Correa, Alique, & Bielza, 2008). Por ejemplo, cuando la variable *td* presenta valores menores, mejora la calidad *tq* con valores 1 y 2 mejora la probabilidad de conseguir *Ra* en los estados semifino y medio, si se valora la variable *V* de forma independiente esta no afecta el acabado o *Ra*. En cuando al material del electrodo y su polaridad se encontró que con *Gr-* se obtiene peor calidad y con *Cu-* se consigue la mejor. Con relación a la variable *tq* el experto considera que se presentarán regímenes operacionales (de *td*) en que la disminución de *tq* puede tener un efecto contrario al presentado en el modelo, aunque el efecto esperado es moderado.

B) Caso 2. Clasificador TAN

Las RBs tienen la virtud de mostrar la relación y el efecto entre variables, para la segunda red se usó un clasificador TAN (la red generada se muestra en la Figura 6). Con este algoritmo la precisión general aumenta a 79.5%.

La matriz de confusión con los resultados del caso 2 se ven en la Figura 7. Por estados la precisión en la clasificación está distribuida como: Rugoso 73.4%, Semirugoso 91.97%, Medio 59.68%, Semifino 0%, quedando clasificados como medio en 80%.

La diferencia entre los dos modelos radica en que usando el algoritmo TAN se obtiene información sobre la influencia de las variables, entre ellas y con el acabado (*Ra*), contrario a usar el algoritmo NB, donde se toman de forma independiente. En un modelo para predicción es útil definir escenarios donde se establezca cierta información, en este caso se aporta información sobre la calidad requerida para que el modelo asigne los mejores valores de los parámetros (necesarios para lograr la clase señalada). Para el análisis se parte del estado inicial (con la probabilidad *a priori*) y se hace una instancia de dos estados de *Ra*, obteniendo las combinaciones de los parámetros que producen

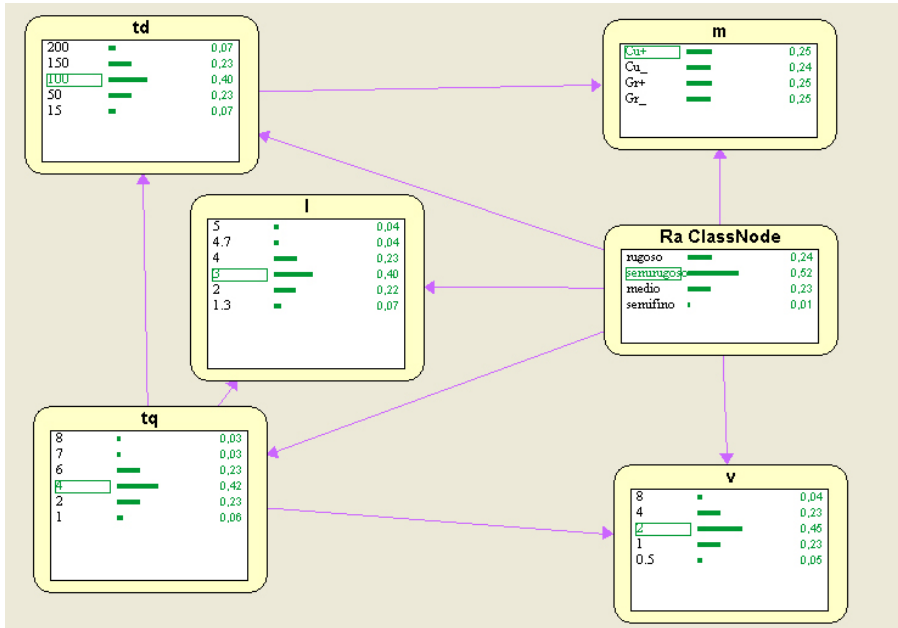


Figura 6. Estructura del clasificador TAN

Precisión: 0.7952380952380953

Matriz de confusión media

REAL \	"rugoso"	"semirugoso"	"medio"	"semifino"
ASSIGNED				
"rugoso"	151	13	0	0
"semirugoso"	49	407	81	3
"medio"	3	16	110	7
"semifino"	0	0	0	0

Figura 7. Matriz de confusión media usando TAN

Tabla 5. Probabilidades a priori calculadas con los datos de entrenamiento y los valores recalculados después de instanciar Ra como *medio* y *semirugoso*

Clasificación de parámetros	a Priori	CASO 1	CASO 2
	Vr. param / prob Ra= Semirugoso/0.52	Vr. param / prob Ra= medio / 1	Vr. param / prob Ra= Semirugoso / 1
t _d	100 / 0.40	50 / 0.39	100 / 0.42
t _q	4 / 0.42	2 / 0.43	4 / 0.44
V	2 / 0.45	2 / 0.39	2 / 0.46
m	Igual para todos / 0.25	Cu- / 0.52	Gr+ / 0.33
I	3 / 0.40	2 / 0.36	3 / 0.40

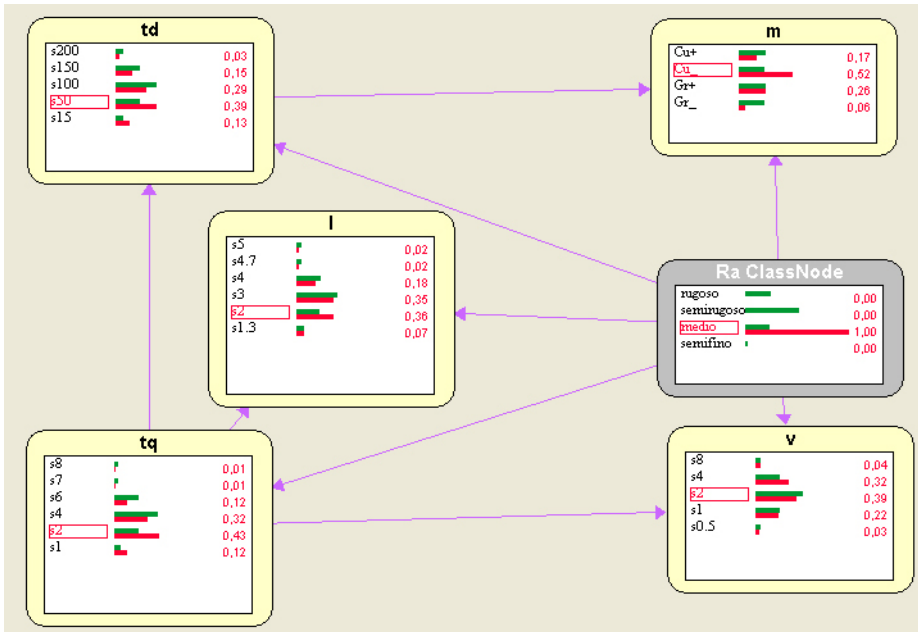


Figura 8. Estructura del clasificador TAN donde se instancia Ra=Medio (Caso 1)

la calidad deseada (los resultados se resumen en la Tabla 5). Los resultados del caso 1 se muestran en la Figura 8.

Adicionalmente se probaron algunos escenarios donde se especificaron valores a los parámetros, buscando la probabilidad de Ra, con resultados aceptables; hay que resaltar que el objetivo del modelo es lo contrario, encontrar los valores de los parámetros con una clase de acabado solicitada, como el ejemplo de la Tabla 5.

Conclusiones

En este artículo se propone el uso de redes Bayesianas con los algoritmos NB y TAN para el desarrollo de modelos empíricos que estimen el acabado superficial (Ra), en un proceso de texturizado por EDT.

Se demuestra que las RBs son una herramienta útil para aportar conocimiento en el desarrollo de un predictor de parámetros de mecanizado con tipos de Ra determinados. Los modelos de clasificación supervisada fueron validados con el conocimiento del experto, guardando una relación consistente entre el proceso físico y lo plasmado por el clasificador.

Los resultados de las dos estructuras usadas NB y TAN son comparadas usando los mismos datos experimentales, ambos modelos proveen una predicción estadísticamente satisfactoria.

El resultado de precisión, en el caso del clasificador NB es de 76%, es el indicador

de bondad del clasificador o probabilidad de que este clasifique correctamente nuevos casos. En el caso del clasificador TAN éste valor aumenta al 79.5%.

Haciendo el análisis de la matriz de confusión media con el clasificador NB se encontró que hay más exactitud en la clasificación de los tipos rugoso con 70% de bien clasificados, semirugoso con 89% de bien clasificados y semifino con 70% de bien clasificados; se presenta mayor confusión en el tipo medio –que tiene 53% de bien clasificados y 41% clasificados como tipo semirugoso–, por lo que es conveniente afinar proporcionando más ensayos pertenecientes a esta región.

Al analizar la matriz de confusión media con la estructura TAN se consigue mejorar de forma general los resultados anteriores. En el caso de rugoso se aumenta el porcentaje de bien clasificados a 73%; en semirugoso, a 92%; en medio, a 60%. El tipo semifino baja a 0%, quedando el 80% de veces clasificado erróneamente como medio. Aunque normalmente en el proceso EDT el acabado semifino no es tan probable, sería interesante producir resultados adicionales en esta región.

Para mejorar el desarrollo de los modelos se pueden adicionar otras características del proceso a la red, como el tipo de material a mecanizar y la corriente pico (p).SM

Referencias bibliográficas

- Aspinwall, D.K., Zhao, F.L., & El-Menshawly, F. (1989). Electrodischarge texturing (EDT) of steel rolls. *Surface Topography*, 2, 123-141
- Chow, C.K. & Liu, C.N. (1968). Approximating discrete probability distributions with dependence trees. *IEEE Transactions on Information Theory*, 14(3), 462-467
- Correa, M., Alique, J.R., & Bielza, C. (2008). Comparativa de modelos con aprendizaje supervisado: aplicación a un proceso industrial. En *IV Simposio de control inteligente, 11-13 June, Santander, España*, [CD]. Santander, España: Universidad de Cantabria
- Correa, M., Bielza, C., & Pamies-Teixeira, J.J. (2009). Comparison of Bayesian networks and artificial neural networks for quality detection in a machining process. *Expert Systems with Applications*, 36, 7270-7279
- Correa, M., Bielza, C., Ramirez, M.deJ., & Alique, J.R. (2008). A Bayesian network model for surface prediction in the machining process. *International Journal of Systems Science*, 39(12), 1181-1192
- Correa, M., Ramirez, M.deJ., Alique, J.R., & Rodriguez, C.A. (2004). Factores que afectan el acabado superficial en los procesos de mecanizado: técnicas de análisis y modelos. En *XXV Jornadas de automática, 8-10 Septiembre, Ciudad Real, España* [en línea]. Recuperado de <http://www.ceautomatica.es/old/actividades/jornadas/XXV/documentos/75-arlencicor.pdf>
- Díez, J. (2005, noviembre 10). *Elvira* [en línea]. Recuperado de www.ia.uned.es/~fjdíez/bayes/elvira/

- Friedman, N., Geiger, D., & Goldszmit, M. (1997). Bayesian network classifiers. *Machine Learning*, 29, 131-161
- Gao, Q., Zhang, Q., Su, S., & Zhang, J. (2008). Parameter optimization model in electrical discharge machining process. *Journal of Zhejiang University Science A*, 9(1), 104-108
- Ghoreishi, M. & Atkinson, J. (2002). A comparative experimental study of machining characteristics in vibratory, rotary and vibro-rotary electro-discharge machining. *Journal of Materials Processing Technology*, 120, 374-384
- International Organization for Standardization [ISO]. (2013). *ISO 4288:1996: Geometrical product specifications (GPS) -- Surface texture: Profile method -- Rules and procedures for the assessment of surface texture*. Ginebra, Suiza: ISO
- Ivancos, J., Luis, C.J., Ortiz, J.A., & González, H.A. (2005). Analysis of factors affecting the high speed side milling of hardened die steels. *Journal of Materials Processing Technology*, 162-163, 696-701
- Langley, P., Iba, W., & Thompson, K. An analysis of Bayesian classifiers. En *Proceedings of AAAI-92*, (pp. 223-228). Palo Alto, CA: AAAI
- Markopoulos, A., Vaxevanidis, N.M., Petropoulos, G., & Manolakas, D.E. (2006). Artificial neural networks modeling of surface finish in electro-discharge machining of tool steels, Proceedings of ESDA2006 8th Biennial ASME Conference on Engineering Systems Design and Analysis July 4-7, 2006, Torino, Italy. (V.4, pp.847-854). New York, NY: ASME. Disponible en <http://proceedings.asmedigitalcollection.asme.org/proceeding.aspx?articleid=1594550>
- Pamies-Teixeira, J.J. (2002). *Fundamentos físicos do corte de metais*. Lisboa, Portugal: Edinova
- Pearl, J. (1988). *Probabilistic reasoning in Intelligent Systems: networks of plausible inference*, San Francisco, CA: Morgan Kaufmann
- Pellicer, N., Ciurana, J., Ozel, T. (2009). Influence of process parameters and electrode geometry on feature micro-accuracy in electro discharge machining of tool steel. *Materials and Manufacturing Processes*, 24(12), 1282-1289
- Pfestorf, M., Engel, U., & Geiger, M. (1998). 3D-Surface parameters and their application on deterministic textured metal sheets. *International Journal of Machine Tools & Manufacture*, 38(5-6), 607-614
- Pradhan, M.K., Das, R., & Biswas, C.K. (2009). Comparisons of neural network models on surface roughness in electrical discharge machining. *Journal of Engineering Manufacture*, 223, 801-808 [Proceedings of the Institution of Mechanical Engineers, Part B:]
- Simão, J., Aspinwall, D.K., Wise, M.L.H., & El-Menshawey, F. (1996). Electrical discharge texturing of cold mill work rolls using different tool electrode materials. *Iron and Steel Engineer*, 73(3), 42-47
- Terpák, J., Dorak, L'. Revaj, J. (2010). Quality control of the electro-discharge texturing, *Metabk*, 49(1), 19-22

Curriculum vitae

Maritza Correa Valencia

Ingeniera Industrial de la Universidad Autónoma de Occidente [UAO], Recibió de la Universidad Politécnica de Madrid sus títulos como Especialista en Robótica Industrial, Magister en Tecnologías de la Información en Fabricación y Doctora en Ciencias de la Computación e Inteligencia Artificial. Es profesora de tiempo completo e investigadora de la UAO. Sus áreas de interés incluyen la aplicación de Inteligencia Artificial, especialmente redes Bayesianas y redes neuronales artificiales, en diferentes campos.

Jorge Joaquim Pamies Teixiera

Doctor en Ingeniería mecánica (Universidade Nova de Lisboa [Nova]) y Magister en Ingeniería Mecánica (Massachusetts Institute of Technology [MIT]). Es profesor de tiempo completo del Departamento de Ingeniería Mecánica y Electrónica en Nova y miembro de Unidemi, su unidad de investigación en Ingeniería Mecánica e Industrial.