

Predicción de la Rugosidad Superficial del Acero *cold rolled 1018* a través de la Metodología de Superficie de Respuesta y Redes Neuronales

M.C Lázaro Rico Pérez¹, Dr. Juan J. Díaz N.²,
Dr. Francisco J. Estrada O³, M.C. Javier Molina
Salazar³

RESUMEN

Se propone la predicción de la rugosidad superficial sobre un acero cold rolled 1018 empleando una herramienta de corte de alta velocidad. Como objetivo secundario, predecir la temperatura de la herramienta de corte y del material de trabajo. Como variables independientes se incluyen tres parámetros de maquinado: la velocidad de corte, tasa de alimentación y profundidad de corte. Los modelos predictivos son obtenidos con el apoyo de la metodología de superficie de respuesta (RSM) y la teoría de redes neuronales (NN).

Palabras claves: Parámetros de corte, Rugosidad superficial, Metodología de superficie de respuesta, Redes neuronales.

INTRODUCCIÓN

En la industria actual debido al alto grado de competitividad que existe a nivel mundial, los procesos de manufactura en las empresas, y en especial, los procesos de corte de metal (PDCM) requieren de confiables indicadores de desempeño que garanticen la obtención de buenos resultados operativos conduciendo a las empresas, a la obtención de ahorros significativos.

El acabado superficial es uno de los indicadores de desempeño que tiene efecto sobre la aceptación o rechazo de un producto terminado. Un producto terminado que no cumpla con el acabado superficial requerido por el cliente es garantía de la generación de costos en el PDCM manifestándose a través de grandes cantidades de desperdicio de material, re-trabajo de piezas, tiempos extras etc.

La uniformidad y calidad superficial de la pieza de trabajo se mide a través de su rugosidad superficial. La rugosidad superficial en el PDCM es el efecto de la combinación de materiales de trabajo,

¹ Estudiante del doctorado en Ingeniería Industrial. Instituto Tecnológico de Ciudad Juárez.

² Profesor investigador. Instituto Tecnológico de Ciudad Juárez.

³ Profesor investigador. Depto. Ing. Industrial y Manufactura. Universidad Autónoma de Ciudad Juárez.

herramientas y parámetros de corte. El acabado superficial es un fenómeno complejo, y en la actualidad la experiencia del operador es un factor determinante en la obtención de una rugosidad superficial adecuada.

Sin embargo, los académicos han usado diferentes herramientas de análisis para el modelado de la rugosidad superficial en diferentes materiales de trabajo en diferentes PDCM. Dos de las herramientas de análisis más utilizadas por los académicos son la metodología de superficie de respuesta (RSM) y las redes neuronales (NN).

En la literatura existe un amplio uso de la RSM y NN para la predicción de la rugosidad superficial, tal es el caso de Spedding T.A y Wang Z.Q.(1997) quienes utilizan la metodología de superficie de respuesta y redes neuronales para desarrollar un modelo predictor de la velocidad de corte, la rugosidad superficial y el segmento de más baja frecuencia en el proceso de una máquina EDM. Sus resultados muestran que ambas metodologías son capaces de predecir adecuadamente el desempeño del PDCM. Pero, puntualizan, que el modelo establecido por la metodología de redes neuronales se

ajusta mejor a los datos para predecir la velocidad de corte y la rugosidad superficial.

Suresh et.al.(2002) desarrollan un modelo para predecir la rugosidad superficial en un material de acero templado mediante la metodología de superficie de respuesta y con el apoyo de algoritmos genéticos. Ellos sostienen que, el radio de la nariz de la herramienta para corte, la velocidad de corte, la tasa de alimentación, la dureza del material, el uso de fluidos para corte, la vibración de la máquina herramienta y la profundidad de corte; son los factores que más afectan la rugosidad superficial de la pieza de trabajo.

Bernardos P.G. y Vosniakos G.C.(2002) estructuran un modelo para la predicción de la rugosidad superficial en operaciones de fresado empleando redes neuronales y el método Taguchi. Los resultados muestran que la tasa de alimentación por diente del cortador, el fluido para corte, la profundidad y la herramienta de corte son los factores que más afecta la rugosidad superficial de la pieza de trabajo.

Por otro lado, Zurperl Uros y Cus Franci (2003), establecen un modelo fundamentado en la teoría de redes neuronales, el cual

optimiza una función multiobjetivo para mejorar las condiciones de corte de metal en las operaciones de torneado. La función multiobjetivo está compuesta por los siguientes objetivos en conflicto: la tasa de producción, los costos de operación y la calidad del acabado superficial. Este modelo tiene como variables de entrada la tasa de alimentación, la velocidad y profundidad de corte, y como variables de salida la función multiobjetivo anteriormente mencionada. El modelo obtenido tiene la capacidad de predecir valores cercanos a los datos experimentales.

Choudhury S.K. y Bartarya G.(2003) utilizan la metodología de superficie de respuesta y redes neuronales para la predicción del acabado superficial, desgaste en el flanco de la herramienta y el incremento de la temperatura en la zona de corte. Ellos sostienen, que la red neuronal tiende a predecir valores más cercanos del desgaste en el flanco de la herramienta de corte. Y con respecto a la predicción de acabado superficial y el incremento de la temperatura en la zona de corte ambas metodologías son aceptadas.

Sahin Y. y Motorcu A.R.(2005), establecen un modelo para predecir la rugosidad superficial sobre un material de acero suave en piezas maquinadas a través un torno CNC y empleando herramientas de corte con recubrimiento de carburo. En sus resultados se observa, que la rugosidad superficial incrementa con el incremento de la tasa de alimentación pero decrementa con la velocidad y profundidad de corte.

A pesar de que existe una gran cantidad de literatura relacionada con la modelación de la rugosidad superficial, falta aún determinar algunos modelos para una gran cantidad de materiales que son de uso común en la industria. Por lo que, en este estudio, se propone como primera meta; establecer un modelo predictor de la rugosidad superficial para el acero cold rolled 1018. Siendo este un material muy requerido por las empresas de maquinado por sus propiedades mecánicas intrínsecas que posee. Y como segunda meta, la obtención de modelos para predecir la temperatura en la herramienta de corte y en el material de trabajo. Este estudio se lleva a cabo con el apoyo de la metodología de superficie de respuesta y redes neuronales. Los modelos obtenidos a través de ambas

metodologías son comparados para obtener el modelo que mejor se ajuste a los datos reales experimentales. Esta investigación es importante debido a que la estructuración de modelos matemáticos apoya significativamente a los operadores en la obtención de un acabado superficial satisfactorio antes de que la pieza de trabajo entre a producción reduciéndose los costos de maquinado.

Metodología de superficie de respuesta

La metodología de superficie de respuesta, es una colección de técnicas matemáticas y estadísticas para el modelado y análisis de problemas, en la cual, una respuesta de interés es afectada por varias variables (Montgomery2004).

Si la respuesta se modela mediante una función lineal, la función de aproximación es de primer orden. Siendo esta:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon$$

Cuando el sistema presenta una curvatura, entonces se debe emplear un polinomio de orden superior, así se tiene el modelo de segundo orden:

$$y = \beta_0 + \sum \beta_i x_i + \sum \beta_{ij} x_j^2 + K + \sum \beta_{ij} x_i x_j + \varepsilon$$

Para una explicación más detallada de la metodología de superficie de respuesta, se recomienda consultar Montgomery(2004).

Redes neuronales

NN es una herramienta útil en donde los métodos tradicionales no pueden dar una solución satisfactoria para resolver problemas complejos (J.F.Hair et.al.1999). NN son estructuras computacionales inspiradas en el comportamiento biológico neuronal del cerebro y tienen como finalidad resolver problemas de una manera similar a como lo resuelve el cerebro humano.

La estructura de una red neuronal se conforma por nodos, capas y pesos. Los nodos representan las neuronas. Estas, se interconectan entre sí y se agrupan por capas, el número de capas aumenta conforme crece la complejidad del problema. Por último, están los pesos, los cuales, se asignan entre las conexiones neuronales a través de las diferentes capas de la red. Estos pesos desempeñan un importante papel dentro de la estructura de NN ya que tienen la tediosa tarea de entrenarla. Además, el éxito del entrenamiento de una red depende en gran parte de la correcta selección de los pesos

iniciales así como de sus parámetros de funcionamiento. En la figura número uno se muestra la estructura de una red neuronal.

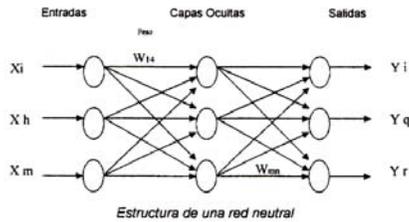


Fig. No. 1

Debido a los múltiples usos que se les ha dado tales como procesamiento de imágenes y de voz, reconocimiento de patrones, planeamiento, interfase adaptativa para estructuras hombre-máquina, predicción, control y optimización y filtrado de señales, en la actualidad, las redes neuronales son utilizadas en diferentes campos de la ciencia. Para mayor información sobre NN se recomienda consultar Hagan (2004).

MATERIALES Y MÉTODOS

La presente investigación se lleva a cabo con el apoyo de la metodología de superficie de respuesta y redes neuronales. Para ello se emplean 60 probetas de material Cold Rolled 1018 con diámetro y largo de 0.75" y 2" respectivamente. Las propiedades químicas como mecánicas del cold Rolled se

muestran en la tabla 1 y 2. El proceso de corte se realiza en un torno convencional horizontal con un rango de velocidades de 340 a 1150 rpm. La herramienta de corte utilizada es de acero de alta velocidad de 1/2" de espesor con un afilado de 60 grados.

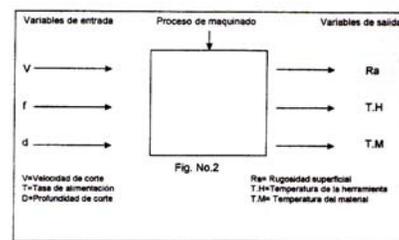
Tabla 1 Propiedades Químicas (AISI 1018)

C	Mn	P	S
0.15/0.2	0.6/0.9	0.04 Max	0.050 Max

Tabla 2 Propiedades Mecánicas (AISI 1018)

Resistencia a la tensión Psi	Límite elástico psi	Elongación en 2%	Reducción de área %	Dureza Brinell
64000	54000	15	40	125

La rugosidad superficial, la temperatura de la herramienta y del material de trabajo son variables dependientes de los principales parámetros de corte tales como: la velocidad de corte, tasa de alimentación y profundidad de corte (figura dos).



La figura número tres esquematiza la preparación del trabajo experimental para cada una de las probetas del estudio.

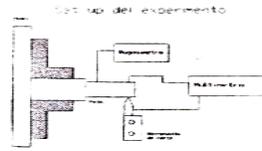


Figura No. 3

A través de la metodología de superficie de respuesta, y apoyado con el software Minitab se diseña un experimento 2^3 con seis puntos centrales y tres réplicas para cada una de las combinaciones. Con este arreglo experimental se generan sesenta corridas experimentales. En la tabla No. tres se muestran los parámetros de maquinado a través de los cuatro niveles codificados.

Tabla No. 3

Niveles codificados	-2	-1	0	1	2
Velocidad de corte v_m (m/min)	20.2949	25.3687	37.3064	56.7057	68.6438
Tasa de alimentación f_m (mm)	.0381	.04572	.05588	.05842	.07874
Profundidad de corte a_p (mm)	.508	.762	1.651	2.032	2.286

La rugosidad superficial de cada una de las réplicas se obtiene mediante el método R_a a través un rugosímetro mitutoyo modelo Surfesf.301. Además, un multímetro digital Steren modelo MUL-100 con adaptador para termopar es utilizado para medir la temperatura en la herramienta de corte y en la pieza de trabajo en grados centígrados. Los

resultados obtenidos a través de la metodología de superficie de respuesta son mostrados en la siguiente sección.

Por otro lado, para la obtención del modelo a través de las redes neuronales, se cuenta con el apoyo del software Matlab. El diseño de la red multicapas queda conformado por un tipo de red de aplicación en problemas complejos llamada back-propagation. La red queda estructurada con dos capas de 15 y 3 neuronas respectivamente. En la primera capa se emplea una función de transferencia hiperbólica tangente. Matemáticamente se representa a través de la ecuación número tres.

$$a = \frac{e^n - e^{-n}}{e^n + e^{-n}} \quad (3)$$

donde:

a = Valor de salida de una capa

n = es la sumatoria de salida es decir

$$n = \mathbf{Wp} + \mathbf{b}$$

\mathbf{W} = matriz de pesos

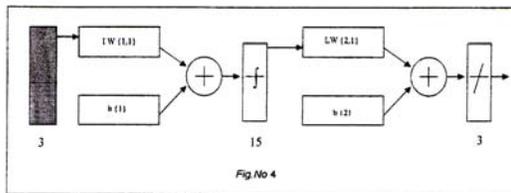
\mathbf{p} = Vector de entrada a la red

\mathbf{b} = bias

Para la segunda capa se utiliza una función de transferencia purelin representada por la ecuación número cuatro.

$$a = n \quad (4)$$

En forma esquemática el diagrama multicapas es mostrada en la figura número cuatro.



Para el entrenamiento de la red neuronal se opta por seleccionar el algoritmo de Levenberg –Marquardt. El algoritmo de Levenberg –Marquardt es de los más usados para el entrenamiento rápido de una red, y frecuentemente es utilizado para entrenar redes que estructuran problemas no lineales complejos.

El algoritmo de Levenberg –Marquardt se representa a través de la siguiente ecuación matemática.

$$\mathbf{x}_{k+1} = \mathbf{x}_k - [\mathbf{J}^T(\mathbf{x}_k) \cdot \mathbf{J}(\mathbf{x}_k) + \mu_k \mathbf{I}]^{-1} \mathbf{J}(\mathbf{x}_k) \cdot \mathbf{v}(\mathbf{x}_k) \quad (5)$$

Para obtener mayor información con respecto al desarrollo del algoritmo de Levenberg –Marquardt consultar Hagan (1996). El modelo obtenido a través de las redes neuronales es discutido más adelante.

Los modelos obtenidos a través de las dos metodologías son comparados mediante el error cuadrático medio tomando como mejor modelo el que alcance el error cuadrático medio mínimo (MSE). Matemáticamente se expresa de la siguiente manera.

$$\varepsilon = (y_R - y_T)^2 \quad (6)$$

ε = error cuadrático

$$MSE = \frac{\sum (y_R - y_T)^2}{N} \quad (7)$$

y_T = valor teórico obtenido del modelo

y_R = valor real

MSE = error cuadrático medio

N = No. de corridas

RESULTADOS

Modelos obtenidos a través de RSM

De la aplicación de la metodología de superficie de respuesta (tabla 4, 5 y 6) se obtienen las ecuaciones de regresión de segundo orden (8), (9) y (10) para modelar la rugosidad superficial, temperatura en la herramienta de corte y en el material de la pieza de trabajo.

Tabla No.4 Coeficientes estimados de regresión para la rugosidad superficial

Term	Coef	SE Coef	T	P
Constant	5.69307	0.2404	21.862	0.000
Vel	-2.23979	0.1632	-13.725	0.000
T.Alim	1.21896	0.1632	7.469	0.000
Prof.corte	0.24133	0.1673	1.443	0.155
Vel*Vel	-0.06013	0.1302	-0.462	0.646
T.Alim*T.Alim	-0.27097	0.1302	-2.081	0.043
Prof.corte*Prof.corte	0.10009	0.1326	0.755	0.454
Vel*T.Alim	-0.41292	0.2308	-1.789	0.080
Vel*Prof.corte	-0.75542	0.2308	-3.273	0.002
T.Alim*Prof.corte	-0.13792	0.2308	-0.598	0.553

S = 1.131 R-Sq = 84.2% R-Sq(Adj) = 81.3%

Tabla No. 5 Coeficientes estimados de regresión para la temperatura de la herramienta de corte

Term	Coef	SE Coef	T	P
Constant	35.2701	1.0895	32.374	0.000
Vel	3.4167	0.6827	5.004	0.000
T.Alim	-0.4583	0.6827	-0.671	0.505
Prof.corte	5.3362	0.6997	7.626	0.000
Vel*Vel	1.5924	0.5447	2.925	0.005
T.Alim*T.Alim	2.8851	0.5447	5.296	0.000
Prof.corte*Prof.corte	0.9411	0.5549	1.696	0.096
Vel*T.Alim	0.5000	0.9655	0.518	0.607
Vel*Prof.corte	5.9267	0.9655	6.142	0.004
T.Alim*Prof.corte	-0.2500	0.9655	-0.259	0.797

S = 4.730 R-Sq = 72.0% R-Sq(Adj) = 66.9%

Tabla No. 6 Coeficientes estimados de regresión para la temperatura del material

Term	Coef	SE Coef	T	P
Constant	43.8674	2.202	19.923	0.000
Vel	7.2500	1.380	5.254	0.000
T.Alim	-1.6250	1.380	-1.178	0.245
Prof.corte	11.6267	1.414	8.221	0.000
Vel*Vel	1.7254	1.101	1.567	0.123
T.Alim*T.Alim	9.3087	1.101	8.455	0.000
Prof.corte*Prof.corte	2.1631	1.121	1.929	0.059
Vel*T.Alim	1.0833	1.951	0.555	0.581
Vel*Prof.corte	7.3333	1.951	3.758	0.000
T.Alim*Prof.corte	0.0933	1.951	0.043	0.966

S = 9.560 R-Sq = 79.0% R-Sq(Adj) = 75.2%

$$Ra = -2.23979x_1 + 1.21896x_2 + 0.24133x_3 - 0.06013x_1^2 - 0.27097x_2^2 + 0.10009x_3^2 - 0.41292x_1x_2 - 0.75542x_1x_3 - 0.13792x_2x_3 + 5.69307 \quad (8)$$

$$T.H. = 3.41667 x_1 - 0.45833 x_2 + 5.33621 x_3 + 1.59339 x_1^2 + 2.88506 x_2^2 + 0.94109 x_3^2 + 0.50000 x_1x_2 + 2.91667 x_1x_3 - 0.25000 x_2x_3 + 35.27010 \quad (9)$$

$$T.M. = 7.25000x_1 - 1.62500x_2 + 11.62670x_3 + 1.72535x_1^2 + 9.30869x_2^2 + 2.16313x_3^2 + 1.08333x_1x_2 + 7.33333x_1x_3 + 0.08333x_2x_3 + 43.86740 \quad (10)$$

En donde las variables x_1 , x_2 , x_3 representan la velocidad de corte, tasa de alimentación y profundidad de corte respectivamente. Para que las ecuaciones proporcionen resultados correctos, las variables son codificadas aplicando las siguientes ecuaciones de transformación:

$$X_1 = \frac{(V) - (37.3064)}{(56.7057) - (37.3064)} \quad (11)$$

$$X_2 = \frac{(f) - (0.05588)}{(0.05842) - (0.05588)} \quad (12)$$

$$X_3 = \frac{(d) - (1.651)}{(2.032) - (1.651)} \quad (13)$$

Modelos obtenidos a través de NN

El modelo que representa la rugosidad superficial, temperatura de la herramienta y de la pieza de trabajo obtenido mediante redes neuronales se define por la ecuación No. 14.

$$\mathbf{X}^2 = \mathbf{f}^2 \cdot (\mathbf{W}^2 \cdot \mathbf{a}^1 + \mathbf{b}^2) \quad (14)$$

Donde:

- X es el vector de salida, siendo sus componentes la rugosidad superficial, temperatura del material y de la herramienta de corte.
- p es el vector de entrada a la red, siendo sus componentes : la velocidad de corte, tasa de alimentación y la profundidad de corte.
- W¹ y W² representan la matriz de pesos de la capa 1 y 2 respectivamente.
- b¹ y b² representan los biases de la capa 1 y 2 respectivamente.
- a¹ representa el vector de salida de la capa No. 1

$$\mathbf{a}^1 = \mathbf{f}^1 \cdot (\mathbf{W}^1 \cdot \mathbf{p} + \mathbf{b}^1)$$

Las matrices de los pesos W¹ y W² así como los biases b¹ y b² quedan de la siguiente forma:

$$\mathbf{W}^1 = \begin{bmatrix} 0.42397 & -0.34345 & -2.4413 \\ 0.29461 & -0.323825 & 0.78114 \\ 0.53151 & 61.1775 & 8.172 \\ 0.069717 & 175.4217 & -4.3966 \\ -0.89322 & -22.1225 & -17.1254 \\ 1.6315 & 152.0635 & -5.2901 \\ 0.68064 & -137.5312 & 3.9876 \\ 0.1513 & -107.5331 & 4.5466 \\ 0.083997 & 44.067 & -3.6508 \\ 0.040439 & 93.9309 & -1.9909 \\ 0.18801 & 113.6498 & 14.9361 \\ 1.2194 & 140.1334 & -20.999 \\ -0.21267 & -99.4362 & 8.5039 \\ 0.44143 & 75.27 & -4.7164 \\ 4.9687 & -123.1544 & 9.9516 \end{bmatrix}$$

$$\mathbf{W}^2 = \begin{bmatrix} 1.682 & -4.893 & 0.884 & -3.891 & 2.027 & 1.274 & 0.958 & -0.840 & -1.584 & 1.294 & 2.445 & -0.872 & 2.581 & 4.328 & 1.589 \\ -0.598 & 1.571 & 2.047 & -0.887 & 4.880 & -0.882 & -1.858 & 0.808 & -11.042 & 1.639 & 0.988 & 1.888 & -2.987 & 4.722 & 12.708 \\ -3.929 & -0.889 & -2.649 & -4.038 & -1.873 & -0.268 & -3.014 & 2.283 & 20.888 & 0.673 & 0.898 & 2.563 & -3.222 & 1.881 & 0.481 \end{bmatrix}$$

$$\mathbf{b}^1 = \begin{bmatrix} -0.8346 \\ 19.2343 \\ 9.4223 \\ -6.6315 \\ 6.2185 \\ -35.9475 \\ 14.3274 \\ -4.9841 \\ 7.8849 \\ -3.3744 \\ -9.6419 \\ -5.7869 \\ 20.4234 \\ -15.5310 \\ 4.8841 \end{bmatrix}$$

$$\mathbf{b}^2 = \begin{bmatrix} 3.4623 \\ 15.3258 \\ 17.7973 \end{bmatrix}$$

En las tablas 7,8 y 9 se muestra un resumen de las diferentes combinaciones de los datos experimentales, así como un comparativo entre el error cuadrático medio presentado por las dos metodologías propuestas para cada una de las variables de salida en el experimento.

Tabla No. 7 Comparativo entre la metodología de Superficie de Respuesta y redes neuronales para predecir la rugosidad superficial.

V. salida	f en mm	d mm	Pres. T. H. %	Modelo predictor de Rugosidad Superficial de Respuesta V _r (µm)	Error de predicción de Rugosidad Superficial de Respuesta (σ _r) ²	Modelo predictor de Rugosidad Superficial de Redes neuronales T (µm)	Error de predicción de Rugosidad Superficial de Redes neuronales (σ _r) ²
48.6438	0.05588	1.651	1.67	0.97	0.48	1.67	1e ⁻⁶
17.3064	0.05588	0.998	5.30	4.41	0.1	5.30	9.4e ⁻⁶
56.7077	0.04872	0.762	2.92	2.79	0.1	2.92	2.79e ⁻⁶
56.7077	0.04872	2.032	1.69	2.02	0.1233	1.69	1e ⁻⁶
17.3064	0.05588	1.651	5.72	5.69	0.0016	5.72	6.4e ⁻⁶
17.3064	0.07874	1.651	8.17	7.09	1.21	8.17	1.08e ⁻⁵
23.3687	0.04872	2.032	7.56	7.20	0.13	7.57	4.9e ⁻⁶
56.7077	0.05842	0.762	3.68	4.68	1	3.68	0
17.3064	0.05842	1.651	1.69	2.17	0.22	1.69	0
23.3687	0.05842	2.032	2.42	10.19	0.59	2.42	0
23.3687	0.04872	0.762	5.11	4.94	0.03	5.11	0
17.3064	0.05588	2.286	0.81	0.78	0.03	0.81	0
56.7077	0.05842	2.032	2.54	1.38	0.67	2.54	0
20.2949	0.05588	1.651	0.88	0.93	0.6	0.88	0
23.3687	0.05842	0.762	8.18	8.47	0.09	8.18	0
MSE					0.3114		1.12e ⁻⁶

Tabla No. 8 Comparativo entre la metodología de Superficie de Respuesta y Redes neuronales para predecir la Temperatura en la herramienta de corte.

V. salida	f en mm	d mm	Pres. T. H. %	Modelo predictor de Temperatura Superficial de Respuesta T (°C)	Error de predicción de Temperatura Superficial de Respuesta (σ _r) ²	Modelo predictor de Temperatura Superficial de Redes neuronales T (°C)	Error de predicción de Temperatura Superficial de Redes neuronales (σ _r) ²
48.6438	0.05588	1.651	22.67	48.48	17.58	52.67	0
17.3064	0.05588	0.998	29.67	28.36	1.71	29.67	0
56.7077	0.04872	0.762	20.67	22.26	23.93	20.67	0
56.7077	0.04872	2.032	50.00	52.37	0.50	50.00	0
17.3064	0.05588	1.651	35.94	35.87	0.45	35.94	1.6e ⁻⁶
17.3064	0.07874	1.651	46.67	45.89	0.60	46.67	0
23.3687	0.04872	2.032	43.00	40.90	1.21	43.00	0
56.7077	0.05842	0.762	31.00	36.15	26.47	31.00	1e ⁻⁶
17.3064	0.05842	1.651	51.00	47.73	10.71	51.00	0
23.3687	0.05842	2.032	39.33	38.48	0.72	39.33	0
23.3687	0.04872	0.762	31.33	35.56	17.01	31.33	0
17.3064	0.05588	2.286	45.33	49.71	19.16	45.33	0
56.7077	0.05842	2.032	52.33	52.15	0.03	52.33	0
20.2949	0.05588	1.651	34.67	34.81	0.02	34.67	0
23.3687	0.05842	0.762	32.67	34.15	2.18	32.67	0
MSE					8.62		1.13e ⁻⁶

DISCUSIÓN

El tratamiento estadístico de los datos mostrado en las tablas 4, 5 y 6 revela que la velocidad de corte y la tasa de alimentación son los factores que afectan significativamente la rugosidad superficial de la pieza de trabajo. Por un lado, la rugosidad superficial decrece al incrementar la velocidad de corte, pero, incrementa con la tasa de alimentación tal y como también lo demuestran parcialmente Sahin Y. y Motorcu A.R.(2005). Por otro lado, la temperatura de la herramienta y del material de la pieza de trabajo son influenciados significativamente por la velocidad y la profundidad de corte.

También se demuestra que las NN son mejores para predecir las variables de respuestas. Este argumento es además sostenido por özel Tugrul y Karpaz Yigit(2004). No así Choudhury y Bartarya (2003) quienes afirman que ambas metodologías son adecuadas para predecir las variables de respuesta.

RECOMENDACIONES

Se recomienda para investigaciones futuras crear modelos que utilicen otros diferentes materiales y herramientas de corte. Además se recomienda utilizar otros factores de importancia tales como la vibración de la máquina, el desgaste de la herramienta de corte, su geometría entre otros.

REFERENCIAS

- Benardos PG y Vosniakos GC. 2002. *Prediction of surface roughness in CNC face milling using neural networks and Taguchi's desing of experiments*. Robotics and computer integrated manufacturing. 18: 343-354.
- Choudhury GB. 2003. *Role of temperature and surface finish in predicting tool wear using neural network and design of experiments* International journal of machine tools & Manufacture. 43: 675-680.
- Hagan MT, Demuth HB, Beale M. 1996. *Neural network Design*.
- Hair JF, et al. 1999. *Análisis multivariante*. España: Prentice Hall Iberia.
- Montgomery DC, 2004. *Diseño y análisis de experimentos*. México: Limusa Wiley. 427-510.
- Özel T, Yigit K. 2004. *Predictive modeling of surface roughness and tool wear in hard turning using regression and neural networks*.International Journal of Machine Tools & Manufacture Vol. XX: 1-13.

Suresh, PVS, Rao PV, Deshmukh SG. 2002. *A Genetic algorithmic approach for optimization of surface roughness prediction models*. International Journal of machine tools & Manufacture. 675-680.

Spedding TA, Wang ZQ. 1997 *Study on modeling of wire EDM process*. Journal of Materials Processing Technology. Vol 69: 18-28.

Sahin Y, Riza MA. 2005. *Surface roughness model for machining mild steel with coated carbide tool*. Materials and Design. 26: 321-326.

Zuperl U. 2003. *Optimization of cutting conditions during cutting by using neural networks*. Robotics and Computer Integrated Manufacturing. 19: 189-19



Antigua Presidencia Municipal de Ciudad Juárez, Chihuahua. FOTO: Betina.