

# Predicción de rugosidad en maquinado de aleación de Ti-6Al-4V usando redes neuronales

Indira Gary Escamilla Salazar<sup>A,B</sup>, Luis Martín Torres Treviño<sup>B</sup>, Patricia del Carmen Zambrano Robledo<sup>A</sup>, Pedro Pérez Villanueva<sup>B</sup>, Bernardo González Ortiz<sup>A,B</sup>

<sup>A</sup>FIME-UANL

<sup>B</sup>Corporación Mexicana de Investigación en Materiales. Saltillo, Coahuila  
{indirae, pzambran}@fime.uanl.mx  
{indiraescamilla, ltorres, pperez, bgonzalez}@comimsa.com

## RESUMEN

*En la actualidad es de gran importancia el papel que juega la rugosidad superficial en la calidad de los productos y la planeación de los procesos de manufactura. El objetivo de este trabajo es presentar una metodología para predecir la rugosidad (Ra) del Ti-6Al-4V obtenida en el maquinado, con un intervalo de confianza definido, y comparar los resultados con los obtenidos mediante Redes Neuronales Artificiales (RNA), considerando como variables de entrada la velocidad de corte, el avance y la penetración. Las pruebas de maquinado se llevaron a cabo usando un inserto de carburo cubierto por PVD (TiAlN).*

## PALABRAS CLAVE

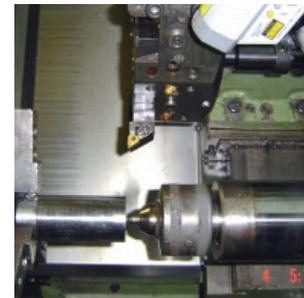
Red neuronal artificial, parámetros de maquinado, rugosidad, superaleaciones, titanio.

## ABSTRACT

*Currently the roughness is a variable of great importance on the quality of the products and on the manufacturing programming process. The aim of this work is to present a methodology for predicting the roughness (Ra) obtained from the machining of the Ti-6Al-4V, with a given confidence interval, and compare this results with an Artificial Neural Network (ANN), considering the cutting speed, feed and depth as input variables. Machining tests were carried out using and carbide insert covered with PVD (TiAlN).*

## KEYWORDS

Artificial Neural Network, machining parameters, roughness, super alloys, Titanium.



## INTRODUCCIÓN

Determinar y optimizar parámetros de maquinado es un proceso crítico y muy importante. Las aleaciones de titanio son materiales extremadamente difíciles de maquinar. La maquinabilidad del titanio y sus aleaciones generalmente se considera pobre debido a su baja conductividad térmica, lo que incrementa la temperatura en el filo de la herramienta de corte,<sup>1</sup> y a su alta reactividad química con otros materiales, lo cual produce una mala calidad de maquinado en la pieza de trabajo. Las compañías especializadas en el maquinado de materiales como el titanio generalmente buscan técnicas para maximizar la integridad superficial de las piezas, lo cual es uno de los requerimientos más comúnmente solicitados por los clientes,<sup>2</sup> por lo que la industria moderna dedica una gran atención al acabado superficial y dimensional de los productos.<sup>3</sup>

El proceso de maquinado es un sistema dinámico, en el cual interactúan muchas variables y el predecirlas y optimizarlas es importante en el proceso de manufactura. El hacer modelos de predicción de operaciones de maquinado requiere detallar todas las condiciones de trabajo y el predecir la rugosidad requiere validar el modelo lo cual se efectúa apoyándose en experimentos en laboratorio, porque es muy difícil en el campo mantener todos los factores bajo control como se necesita para obtener buenos resultados.<sup>4</sup>

En las últimas dos décadas, los sistemas inteligentes compuestos por redes neuronales artificiales, lógica difusa, computación evolutiva, algunas veces solos y otras combinados, han sido aplicados en la manufactura, siendo una importante herramienta de cómputo para resolver problemas ingenieriles.<sup>5, 6</sup> Esto ha permitido una gran variedad de aplicaciones en la industria, tales como control de manufactura de productos, la planeación de procesos, incluyendo el controlar y optimizar la rugosidad superficial en diferentes materiales.<sup>7</sup>

Las RNA son una de las más potentes técnicas de modelado computacional, basadas en un acercamiento estadístico, siendo utilizadas en procesos de ingeniería para simular relaciones complejas, las cuales son difíciles de describir con modelos determinísticos. Las RNA han sido utilizadas ampliamente en el modelado del corte en

muchas operaciones de maquinado, tales como el torneado, fresado y taladrado.<sup>8</sup>

Se propone un sistema neuro-estadístico para predecir la rugosidad producida durante el proceso de maquinado del Ti64, usando para ello una red neuronal de retropropagación y un proceso estadístico de regresión lineal

Los resultados obtenidos pueden servir como soporte en la toma de decisiones para el mejoramiento del proceso de maquinado, la productividad y los ahorros en el costo del producto.

## REVISIÓN DE LA LITERATURA

Ramesh<sup>2</sup> propuso un modelo de predicción en el cual incluyó parámetros tales como avance, velocidad de giro y profundidad de corte para ver sus efectos al torner el titanio y obtener los parámetros de calidad por medio de superficies de respuesta, por otro lado Che-Haron<sup>9</sup> trabajó en una investigación que determinaba el efecto que tiene el maquinado del Ti64 en el acabado superficial, checando las alteraciones metalográficas obtenidas en el maquinado tanto en el material como en los diversos tipos de herramienta utilizados en el estudio.

Rico<sup>8</sup> usó la metodología de superficies de respuesta y redes neuronales para predecir la rugosidad y temperatura de la herramienta de corte durante el maquinado de acero 1018. Pawadea<sup>5</sup> muestra que para Inconel 718 la alta velocidad de corte y el bajo avance, así como la moderada profundidad de corte, unido al uso de sutiles ángulos de corte, pueden asegurar la relevación de esfuerzos residuales.

A. Molinari, *et al*<sup>10</sup> se dedicaron a hacer estudios exhaustivos de la rebaba producida al fresar el Ti-6Al-4V, analizando el proceso de corte ortogonal producido en diversas velocidades y la transformación de bandas adiabáticas. Encontró que con velocidades inferiores la rebaba se vuelve más dentada debido a la debilidad termomecánica, lo que genera las bandas adiabáticas, a diferencia del comportamiento en velocidades altas.

Krain<sup>11</sup> evaluó los efectos de la variación del avance y el espesor de la rebaba, cambiando el radio de la herramienta de corte, así como el material y la geometría de la misma y sus efectos en la vida de la

herramienta, el desgaste en el fresado del Inconel 718. Kopac *et al.*<sup>12</sup> utilizó un diseño experimental Taguchi para determinar los parámetros óptimos de maquinado que logran el mejor acabado superficial en un torneado tradicional, encontrando que la rugosidad se incrementaba con el aumento de la velocidad de corte.

Ocktem<sup>13</sup> desarrolló un modelo para la determinación de los mejores parámetros para obtener la mejor rugosidad en el fresado de las caras de un molde uniendo redes neuronales y algoritmos genéticos.

Se aprecia de estos trabajos en conjunto que lo único que se tiene son recomendaciones para predecir la operación de maquinado, que no siempre se pueden extender a otros materiales por lo que se propone utilizar inteligencia artificial (AI) basada en modelado RNA para predecir operaciones de maquinado.<sup>4</sup>

### Redes Neuronales Artificiales

Las RNA son un paradigma computacional que simula el comportamiento del cerebro humano, con algunas capacidades racionales, como asociación, reconocimiento de formas e incluso seguimiento de patrones. La predicción es una de las propiedades más importantes de las redes neuronales.

Esta técnica utiliza un sistema de mapeo no lineal que se basa en procesadores simples llamados neuronas, las cuales están interconectadas por enlaces ponderados. Cada neurona tiene entradas y genera salidas que son resultado de la información que fue almacenada y procesada en las capas ocultas. La señal de salida de la neurona es usada por otras neuronas como señal de entrada dada la interconexión entre ellas. La capacidad de una neurona es limitada, se necesita una función compleja para conectar varias neuronas. Esto se muestra en la estructura de una red neuronal, figura 1, donde la representación de datos, normalización de las entradas y salidas, y la apropiada selección de la función de activación tiene gran influencia y valor en el entrenamiento de la red neuronal.<sup>7, 14</sup>

Algunos de los beneficios de aplicación de las redes neuronales son los siguientes:

- Gran exactitud y capacidad de adaptación.
- Manejo de datos históricos.
- La capacidad de filtrar ruidos.

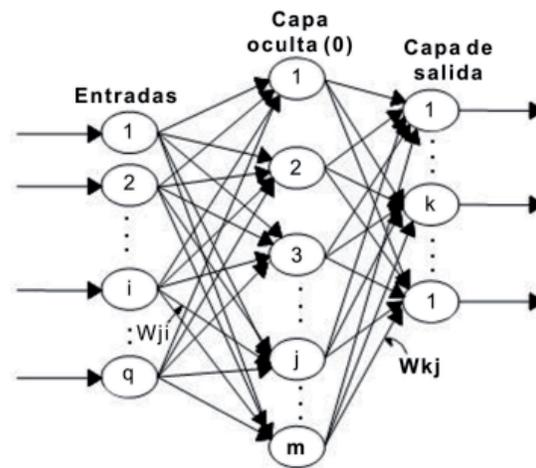


Fig. 1. Estructura típica de una red neuronal multicapa.

Aunque hay muchas redes neuronales,<sup>4, 5, 7, 11</sup> en este trabajo se utiliza un perceptrón con reglas de aprendizaje de retropropagación, ya que es la más común para la predicción de parámetros. En este estudio se utilizó una red multi-capa perceptrón con reglas de retropropagación

### Rugosidad

La rugosidad superficial es el conjunto de irregularidades de la superficie real, definidas convencionalmente en una sección donde los errores de forma y las ondulaciones han sido eliminados.<sup>16</sup> Para medir la rugosidad superficial de las piezas se utilizan instrumentos electrónicos de sensibilidad micrométrica llamados rugosímetros.

Existen varios parámetros que reflejan la medición de la rugosidad, tales como  $R_a$ ,  $R_y$ ,  $R_z$ . El más común es  $R_a$  que es la media aritmética<sup>16</sup> de los valores absolutos de la distancia del perfil de rugosidad de la línea intermedia de la longitud de medición, ver figura 2, y ecuación 6, que lo denota.

$$R = \frac{1}{N} \sum_{i=0}^N |Datos| \quad (6)$$

Cotidianamente el grado de rugosidad de una superficie es muy importante. Algunas veces es necesario tener valores de rugosidad muy altos, otras veces es indeseable, ya que la superficie del producto se requiere con una mejor apariencia, o porque se necesita el menor índice de fricción de la superficie al estar en contacto con otra, con ello minimizando el fenómeno de desgaste de los materiales.

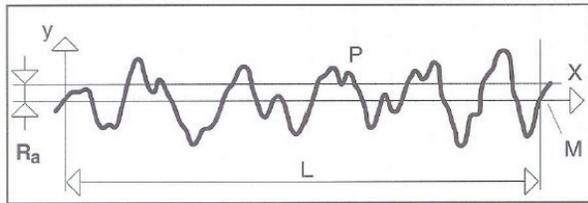


Fig. 2 Gráfica de Ra para la medición de la rugosidad.

## DESARROLLO EXPERIMENTAL

### Secuencia

Para el desarrollo de este trabajo se siguieron los siguientes pasos:

- Obtención de datos de base para entrenar un modelo neuronal.
- Ordenar de manera lógica los datos base con sus respectivos parámetros.
- Propuesta de modelo basado en redes neuronales.
- Entrenamiento de la red neuronal.
- Obtención de valores mediante modelo de Ramesh para validar a la red neuronal.
- Determinación de las diferencias entre las rugosidades calculadas mediante el modelo base y el RNA propuesto en este trabajo.
- Determinación de la normalidad del error.
- Cálculo de los intervalos de confianza.
- Determinación de los parámetros óptimos para el maquinado del material especificado.

La identificación y optimización de variables envueltas en el proceso de maquinado de un producto no es una tarea fácil. El uso de nuevas disciplinas, tales como los sistemas inteligentes, en la manufactura muestran que la integración del conocimiento de los expertos, genera excelentes resultados, para lograr esa difícil hazaña, la tendencia global ha sido adaptar sistemas inteligentes que sean capaces de desarrollar la habilidad de aprender de los expertos y mejorar lo aprendido a través de una secuencia del tipo que se muestra partiendo de datos experimentales.

### Descripción del problema

Como principio se determinaron los parámetros que se tomarán en cuenta para el corte, es decir los rangos de trabajo para la profundidad de corte, avance y velocidad de giro, que serían los datos de entrada en la red neuronal.

Para fines de comparación y validación del modelo, se tomaron las condiciones de maquinado utilizadas por Ramesh, en la referencia<sup>2</sup>, quien las programó y las realizó en un torno NAGMATI-175 (figura 3), con una herramienta de carburo cubierta de PVD-TiAlN.

Se maquinó una barra de 38 mm de diámetro y 125 mm de largo de una aleación de titanio (Ti-6Al-4V) recocida. El torneado se llevó a cabo en una longitud de 110 mm para cada experimento del diseño de 3 factores y 3 niveles, ver tabla I, que dan un total de 27 experimentos, sin réplica.

Ramesh midió la rugosidad con un rugosímetro Taylor Hobson Surtronic 3+, mostrado en la figura 4. Las mediciones fueron realizadas sobre una mesa de granito, y utilizando bloques patrón para nivelar las piezas.

La figura 5 muestra la rugosidad de las 27 combinaciones de parámetros probadas, las cuales se utilizaron para entrenar la red neuronal artificial que representa el modelo de maquinado estudiado.

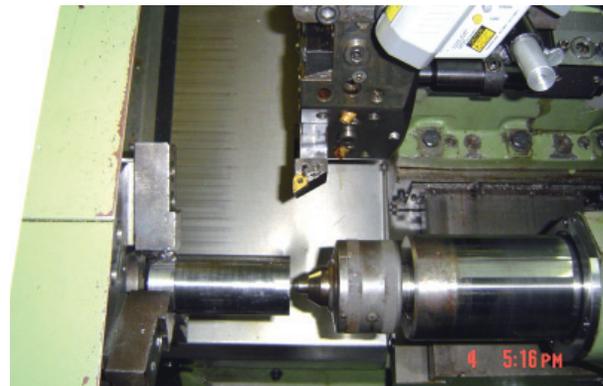


Fig. 3. Torno NAGMATI-175.



Fig. 4. Medidor de rugosidad Taylor Hobson Surtronic 3+.

Tabla I. Parámetros de maquinado usados para las pruebas.

Condiciones	Unidades	Nivel 1	Nivel 2	Nivel 3
Velocidad	m/min	40	60	80
Avance	mm/rev	0.130	0.179	0.220
Prof. de corte	mm	0.500	0.750	1.000

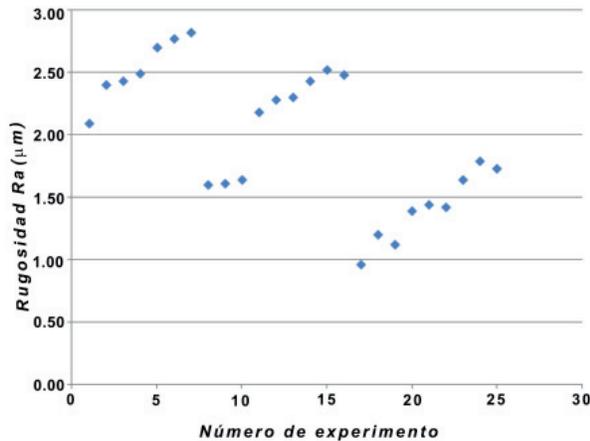


Fig. 5. Rugosidad reportada por Ramesh<sup>2</sup> para los 27 experimentos.

El propósito principal de este trabajo es determinar los mejores parámetros para el maquinado de la aleación de titanio 6Al-4V y con ello garantizar la rugosidad deseada al momento de hacer un maquinado de este material.

### Red Neuronal Artificial

Para poder predecir la rugosidad se propone un modelo basado en una Red Neuronal Artificial multicapas con aprendizaje mediante retropropagación.

En la construcción de la red neuronal es muy importante la identificación de los siguientes parámetros:

- El grupo de datos para el entrenamiento. Tanto de entrada como objetivo que se quiere alcanzar.
- Un valor para la tasa de aprendizaje.
- Un criterio de finalización del algoritmo.
- Una metodología para actualizar las ponderaciones.
- Valores iniciales para las ponderaciones.
- Momentos de aprendizaje.

Las variables usadas fueron:

T<sub>inp</sub> = Neuronas de la capa de entrada más polarización.

T<sub>mid</sub> = Neuronas de la capa media.

T<sub>out</sub> = Neuronas de la capa externa.

eta = Constante de aprendizaje.

alpha = Momento.

Ntepochs = Número de ciclos.

error4 = Error.

### RESULTADOS Y DISCUSIÓN

#### Entrenamiento de la red

Se utilizaron los datos de la figura 5 para realizar el entrenamiento de la RNA y se encuentra que las constantes que se muestran en la tabla II son las que minimizan la diferencia (figura 6) entre los valores de rugosidad reportados y los calculados con la red neuronal.

En la referencia<sup>2</sup> Ramesh propone un modelo el cual se utiliza para validar el desarrollado en este trabajo.

Tabla II. Mejores resultados obtenidos para las variables usadas en la red neuronal.

T <sub>inp</sub>	T <sub>mid</sub>	T <sub>out</sub>	eta	alpha	Ntepochs	error4
3+1	25	1	0.600	0.250	5000	0.0003
3+1	25	1	0.600	0.250	5000	0.0002
3+1	25	1	0.600	0.250	5000	0.0003

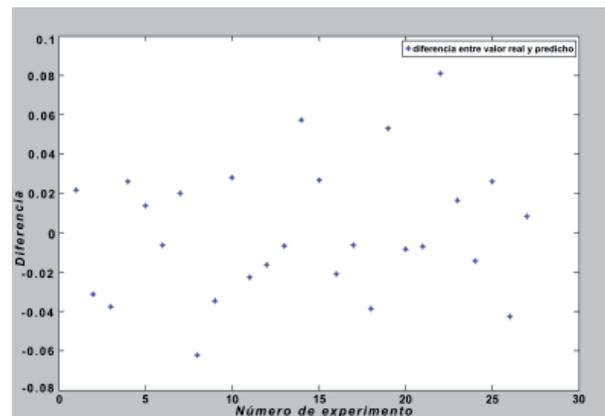


Fig. 6. Gráfica que muestra la diferencia entre los valores de rugosidad calculados con el modelo utilizado por Ramesh y por el modelo RNA propuesto.

Se decidió tomar como ejemplo los siguientes valores para los parámetros de maquinado, los cuales se encuentran dentro del intervalo utilizado por Ramesh, y son típicos en el maquinado de estas aleaciones:

- Avance 0.13 mm/rev.
- Velocidad 50 m/min.
- 3 diferentes profundidades 0.5, 0.75 y 1 mm.

### Optimización de parámetros

Encontrar los mejores parámetros de maquinado requiere de conocer los intervalos de confianza, no es suficiente observar la figura 7 en la que se muestra una comparación entre las rugosidades calculadas mediante los modelos de Ramesh y el de RNA propuesto en este trabajo, pues aunque los valores lucen similares, se requiere determinar la normalidad del error.

Con esta intención se utilizó una prueba de Kolmogorov-Smirnov, con la cual se evalúa la normalidad de los datos, esto con la ayuda del paquete de cómputo Minitab 14. Los resultados se presentan

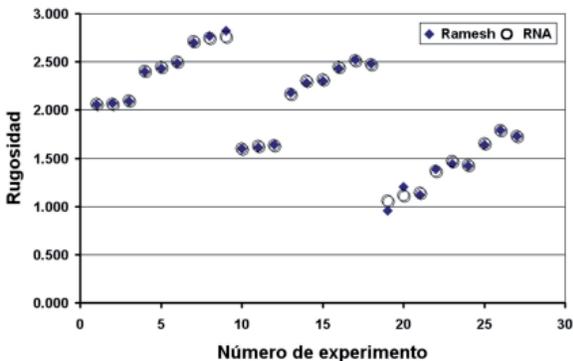


Fig. 7. Rugosidad según Ramesh contra la predicha por el modelo RNA propuesto.

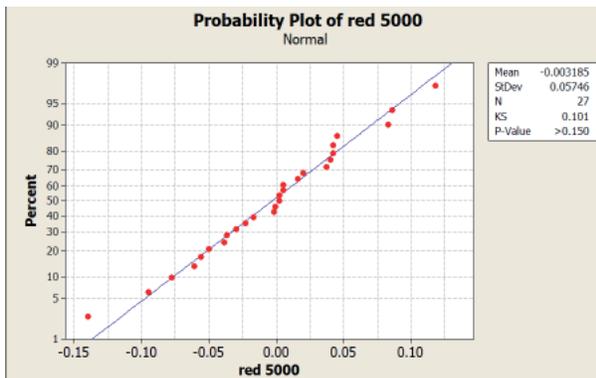


Fig. 8. Prueba de normalidad para los errores de la RNA.

en la figura 8, en la que se observa que en la red sí existe normalidad ya que el valor de  $p$  es mayor que 0.05.

Una vez que se demostró que los errores son normales, se pueden calcular los intervalos de confianza (IC), mediante:

$$\bar{x} \pm \left( t_{r-1, \alpha/2} \right) * \left( \frac{\sigma}{\sqrt{r}} \right)$$

los cuales se muestran en la tabla III.

Con estos intervalos de confianza se pueden predecir los parámetros de maquinado y obtener una rugosidad con una aproximación muy cercana a la realidad.

En la tabla IV se muestran los intervalos obtenidos de las predicciones de rugosidad mediante el uso de redes neuronales, con diferentes parámetros, seleccionándose como óptimo el que muestre la menor rugosidad. En la tabla se observa que las condiciones óptimas de maquinado, suponiendo que se busca rugosidad mínima, de acuerdo al modelo RNA propuesto para el material especificado son:

- Velocidad = 80 m/min
- Avance = 0.13 mm/rev
- Profundidad = 0.5 mm

Tabla III. Intervalos de confianza para la red.

IC max	0.01228947
IC min	-0.01232538

Tabla IV. Ejemplos de diferentes intervalos de confianza obtenidos con diferentes parámetros entre los que se encuentra el óptimo.

Vel	Ava	Prof	Ra	Ra min	Ra max
40	0.13	0.5	2.0655	2.5655	4.1310
40	0.13	0.6	2.0616	2.5616	4.1271
41	0.22	1.0	2.7619	3.2619	4.8274
41	0.13	0.5	2.0571	2.5571	4.1226
41	0.13	0.6	2.0537	2.5537	4.1192
41	0.13	0.7	2.0512	2.5512	4.1167
79	0.22	0.9	1.8067	2.3067	3.8722
79	0.22	1.0	1.7565	2.2565	3.8220
80	0.13	0.5	1.0584	1.5584	3.1239
80	0.13	0.6	1.0838	1.5838	3.1493

## CONCLUSIONES

En los resultados de la red neuronal para predicción se calcularon los intervalos de confinaza ya que se demostró que los errores son normales con una desviación estándar conocida. Esto muestra que la red neuronal puede ayudar a predecir la rugosidad necesaria en el diseño de partes.

Utilizando un sistema inteligente es posible encontrar las condiciones ideales de maquinado en este tipo de aleaciones que tienen un bajo grado de maquinabilidad.

## REFERENCIAS

1. C.H. Che-Haron, A. Jawaid (2005). The effect of machining on surface integrity of titanium alloy Ti-6% Al-4% V. *Journal of Materials Processing Technology* 166 pp. 188-192.
2. S. Ramesh, L. Karunamoorthy, R. Ramakrishnan (2007). Modeling for prediction of surface roughness in machining of Ti64 alloy using response surface methodology. *Journal of Materials Processing Technology*, doi:10.1016/j.jmatprotec.2007.11.031.
3. Meziane, F., Vadera, S. (2000). Intelligent systems in manufacturing: current developments and future *Integrated Manufacturing Systems*. Vol. 11, pp. 218-238.
4. Morales R., Vallejo A. Avellan J. (2007). AI approaches for cutting tool diagnosis in machining processes. *Proceedings of the 25 th IASTED* ISSN 978-0-88986-629-4, pp. 186-191.
5. Pawadea R.S., Suhas S., Brahmanekar P.K. (2007). Effect of machining parameters and cutting edge geometry on surface integrity of high-speed turned Inconel 718. *International Journal of Machine Tools and Manufacture* doi:10.1016/j.ijmachtools.2007.08.004.
6. Russell, Stuart J. Norvig, Peter (2003). *Artificial Intelligence: A Modern Approach* (2nd ed.). Upper Saddle River, NJ: Prentice Hall, pp. 111-114, ISBN 0-13-790395-2.
7. W. He, Y.F. Zhang, K.S. Lee T.I. Liu February (2001). Development of a fuzzy-neuro system for parameter resetting injection molding. *Transactions of the ASME*, Vol. 123, pp. 110-118.
8. Rico L. Díaz J. (2005) Surface roughness prediction at 1018 cold rolled steel using Response Surface Methodology and neural networks. *Culcyt Research*, Year 2, No.10, pp. -20
9. C.H. Che-Haron, A. Jawaid (2005). The effect of machining on surface integrity of titanium alloy Ti-6% Al-4% V. *Journal of Materials Processing Technology* 166, pp. 188-192.
10. A. Molinari, C. Musquar G. Sutter (2002). Adiabatic shear banding in high speed machining of Ti-6Al-4V: experiments and modeling". *International Journal of Plasticity*, Vol. 18. pp. 443-459.
11. Krain, H., Sharman, A. Ridgway, K (2007). Optimization of tool life and productivity when end milling Inconel 718 M. *Journal of materials processings technology*, Vol. 189, pp.153-161.
12. Kopac, J. Bahor, M. and Sokovic, M. (2002) Optimal machining parameters for achieving the desired surface roughness in fine turning of cold preformed steel workpieces. *International Journal of Machine Tools and Manufacture*, 42, pp.707-716.
13. Oktem H and Erzurumlu F (2006). Prediction of minimum surface roughness in end milling mold parts using neural network and genetic algorithm *Materials and Design Journal*, No. 27, pp. 735-744.
14. Hagan M. Demuth H., (1996). *Neural Network Design*. PWS publishing Company. ISBN 0-534-94332-2.
15. D. Montgomery, E. Peck, G. Vining . *Introduct to linear regression analysis*. Wiley Interscience. pp. 35-50.
16. Carlos González González y Ramon Zeleny, *Metrología Dimensional*, Mc Graw Hill. pp. 155-165.