

APLICACIÓN DE UNA RED NEURONAL PARA LA PREDICCIÓN DE DUREZA DE ACEROS GRADO HERRAMIENTA TRATADOS TÉRMICAMENTE

Cindy Estefanía Morales Bazaldúa¹, Rolando Javier Praga Alejo²,
David Salvador González González³, Massiel Cristina Cisneros Morales⁴, Nancy Verónica Pérez Aguilar⁵ y
Edgardo Hernández Chavero⁶

Resumen— En la actualidad el empleo de redes neuronales para la predicción de datos en el sector industrial ha generado amplio interés, ya que es una herramienta que proporciona mejores resultados que otros tipos de modelos al resolver problemas complejos. Con el empleo de este tipo de técnicas, el sector antes mencionado se beneficia en resolver sus problemáticas de toma de decisiones como consecuencia de los constantes cambios en producción sin recurrir a la tendencia de prueba y error. El presente estudio desarrolla un modelo de predicción de dureza de aceros grado herramienta tratados térmicamente en un horno al vacío, con el objetivo de observar el efecto que tiene la variación de los principales parámetros del proceso en dicha propiedad; de tal forma que la RNFBR (Red Neuronal de Función Base Radial) prediga adecuadamente los valores, promoviendo una mejor eficiencia en producción.

Palabras clave— RNFBR, dureza, modelado, sistemas inteligentes.

Introducción

La toma de decisiones en el sector de la manufactura es una problemática frecuente ya que sus procesos se encuentran en constante cambio en la búsqueda de eficiencia, vanguardia y disminución de costos de producción. Es precisamente la eficiencia uno de los principales objetivos a mejorar, sin embargo, es necesario apoyarse en tecnologías y herramientas que ayuden a solucionar esta problemática sin recurrir a la experimentación al azar (Bulsari and Hocksell 1997; Janciková Z., Roubicek V., and Juchelková D. 2008; Žmak and Filetin 2002).

Los aceros grado herramienta son materiales de elevada calidad aplicados en conformado, maquinado, extrusión, moldeo y forjado. Se componen por C y elementos aleantes como Cr, Mo y V, teniendo como principales propiedades durabilidad, resistencia, propiedades anticorrosivas y estabilidad a altas temperaturas (Steels 1961; Uddeholm 2012). Los tratamientos térmicos son métodos importantes para mejorar e incrementar las propiedades mecánicas de los productos empleados a nivel industrial, uno de los más empleados es el temple y el revenido, que incluye llevar al acero hasta su temperatura de austenización y un rápido enfriamiento en agua, aceite o gas, generando una microestructura endurecida pero frágil. Para mejorar estos aspectos se aplica el revenido, el cual recalienta el material por cierto tiempo y temperatura hasta mejorar la microestructura y endurecer al metal. (Dobrzański and Trzaska 2004; Hoffmann et al. 2013; Trzaska and Dobrzański 2005). Los sistemas inteligentes son ampliamente empleados a nivel industrial para analizar los procesos de manufactura, ya que a través del estudio de las variables de entrada del proceso pueden aplicarse diversas herramientas (como las redes neuronales) para facilitar el modelado, ajuste, predicción y optimización de la característica final del producto, trayendo consigo mejoras en calidad y producción. Las redes neuronales artificiales (RNA) son técnicas capaces de resolver problemas complejos, ya que pueden procesar información empleando modelos matemáticos, aproximando resultados a través de la relación entre las variables de entrada y salida (Gurney 2004; Haykin 2009). Se ha observado que el empleo de estas técnicas trae mejoras al sector industrial antes mencionado (Bulsari and Hocksell

¹ La M.T. Cindy Estefanía Morales Bazaldúa es Maestra y Especialista en Tecnología de la Soldadura Industrial por la Corporación Mexicana de Investigación en Materiales S.A. de C.V. cindy.morales@comimsa.com

² El Dr. Rolando Javier Praga Alejo es Profesor-Investigador en la Corporación Mexicana de Investigación en Materiales en Saltillo, Coahuila, México. rolandopraga@comimsa.com

³ El Dr. David Salvador González González es Profesor-Investigador en la Corporación Mexicana de Investigación en Materiales en Saltillo, Coahuila, México. davidgonzalez@comimsa.com

⁴ La Dra. Massiel Cristina Cisneros Morales encargada del área de Procesos en FEDSA HT Technologies en Ramos Arizpe, Coahuila, México (**autor correspondiente**) procesos@fedsa.com.mx

⁵ La Dra Nancy Verónica Pérez Aguilar es Profesora-Investigadora en la Facultad de Ciencias Químicas de la Universidad Autónoma de Coahuila en Saltillo, Coahuila, México. nancyperez@uadec.edu.mx

⁶ El Dr. Edgardo Hernández Chavero es Profesor-Investigador en la Facultad de Ciencias Químicas de la Universidad Autónoma de Coahuila en Saltillo, Coahuila, México. edherman@uadec.edu.mx

1997; Dobrzański and Honysz 2009; Dobrzański and Trzaska 2004; Sterjovski et al. 2005; Trzaska and Dobrzański 2005), (Žmak and Filetin 2002), (Podgornik et al. 2016). Motivo por el cual en el presente estudio se emplea una Red Neuronal de Función de Base Radial apoyada en un algoritmo genético para establecer un modelo de predicción de dureza de aceros grado herramienta tratados térmicamente, al variar los principales parámetros del proceso, con el objetivo de mejorar la eficiencia de la producción evitando la tendencia prueba y error.

Descripción del Método

Red neuronal de base radial

Una red neuronal artificial es un conjunto interconectado de unidades (neuronas) de procesamiento, el cual se basa en el comportamiento del cerebro humano, siendo una función de aproximación no lineal que modela las relaciones entre las variables de entrada y salida de un sistema a través de interconexiones obtenidas del aprendizaje de un conjunto de patrones de entrenamiento. Son capaces de procesar gran cantidad de información mediante modelos matemáticos y consisten de capas de neuronas, donde cada unidad está conectada con otras mediante pesos (Ganguli 2017; Gurney 2004; Haykin 2009; Otto 2016). La función de base radial (RNFBR) es un modelo híbrido que se caracteriza por la simetría radial entre el patrón de entrada y el centroide, la cual cuenta con tres capas representativas:

- Capa de entrada; formada por los nodos de entrada x_i
- Capa oculta: transforma el vector de entrada a un espacio oculto de gran dimensión, donde se produce la transformación siendo las neuronas presentes quienes forman las funciones base para los datos de entrada $\varphi_i(x_i)$
- Capa de salida; $y(x)$ las neuronas ejecutan la transformación lineal, ya que activan los patrones aplicados en la capa.

Las neuronas de las capas de salida son lineales, las de la capa oculta calculan la diferencia entre el vector de entrada y el vector central o centroides donde se le aplica una función de transferencia radial con forma gaussiana, la cual está dada por la ecuación (1).

$$G(\|x - z_i\|) = \exp(-\|x - z_i\|^2) \quad (1)$$

La cual al ser simplificada con $\varphi_i(x_i)$ se observa como (2).

$$\varphi_i(x) = G(\|x - z_i\|) \quad (2)$$

En donde x son las entradas y z_i son los centros, conformando la distancia Euclidiana de $\|x - z_i\|$, la cual se sumará por el vector de umbrales o bias, aplicándole al resultado la función radial y dejando a G en base a esa distancia (Homero, Haykin). La relación de las variables de entrada y salida de la red neuronal define la $y(x)$ como (3), donde esta representa la variable de salidas o respuesta por:

$$y(x) = \sum_{i=1}^m wG(\|x - z_i\|) + b + \varepsilon \quad (3)$$

El vector de los pesos W se determina con (4) obtenida de la pseudoinversa o por mínimos cuadrados.

$$w = (G'G)^{-1}G'y \quad (4)$$

Algoritmo genético

Los algoritmos genéticos (AG) están inspirados en el mecanismo de la evolución biológica, son ampliamente utilizados para resolver problemas de optimización de funciones no lineales y complejas, ya que son conocidos como un método de búsqueda heurística que ayudan a la red neuronal a aprender y entrenarse minimizando el error de la misma. Su funcionamiento se basa en una población de cromosomas (representando posibles soluciones) empleando la selección junto con los operadores genéticos de cruce, mutación e inversión, lo que permitirá la reproducción de los cromosomas que dicten la mejor respuesta o biológicamente hablando sobrevivan (Mitchell 1995; Shaheed and Tokhi 2017). Los algoritmos se desarrollan de la siguiente manera:

1. Generación de población aleatoria
2. Evaluación de la población
3. Seleccionar los mejores individuos
4. Realizar el operador cruce para encontrar nuevas soluciones

5. Determinar si algún individuo muta
6. Generar una nueva población
7. Regresar al punto dos hasta que se cumpla el criterio
8. Encontrar una solución óptima

Métricas estadísticas

Las soluciones presentadas por la red neuronal de base radial y algoritmo genético pueden expresarse con las siguientes métricas; R^2 del modelo, la cual sirve para observar el comportamiento del mismo y representa la variación de las variables de entrada, representándose por (5).

$$R^2 = 1 - \frac{y'y - w'G'y}{y'y - (\sum_{i=1}^n y_i)^2/n} \tag{5}$$

Entre más cercano a uno indica que la variabilidad de R^2 es explicada por el modelo.

La R^2_{Adj} es el coeficiente de la determinación del ajuste del modelo, dictando la cantidad de variabilidad en los datos que se explica por la modelo, expresada como (6).

$$R^2_{Ajuste} = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2 / (n-p)}{\sum_{i=1}^n (y_i - \bar{y})^2 / (n-1)} \tag{6}$$

Por último la $R^2_{Predicción}$ es el coeficiente de determinación de predicción del modelo, dada como (7) (Montgomery 2004).

$$R^2_{Predicción} = 1 - \frac{PRESS}{y'y - (\sum_{i=1}^n y_i)^2/2} \tag{7}$$

Desarrollo experimental

Tratamiento térmico

Placas de dos distintos aceros grado herramienta, provenientes de distinto proveedor con medida 0.5 x 2.5 x 3.5 in (Figura 1) se utilizaron para realizar la presente experimentación (Tabla 1). Se empleó un horno de vacío (Figura 2) para realizar los tratamientos térmicos de las placas, el cual constó de un calentamiento hasta la temperatura de austenización de los materiales (1040 °C), seguido de un temple en nitrógeno dentro de la cámara del horno y posteriormente un revenido al vacío a distintas temperaturas y tiempos de permanencia. Se construyó un diseño de experimentos para establecer las líneas de conjuntos de parámetros a emplear para tratar los diferentes aceros a introducir en el horno al vacío, tal como se observa en la Tabla 2, posteriormente a cada muestra se le midió dureza HRC.

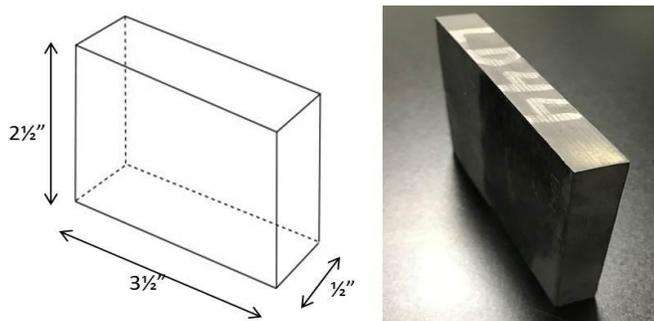


Figura 1. Dimensión de las muestras.

Acero	Proveedor	Dimensión (in)
D2	P1	0.5 x 2.5 x 3.5
	P2	
H13	P1	0.5 x 2.5 x 3.5
	P2	

Tabla 1. Dimensiones de los aceros empelados en la presente experimentación.



Figura 2. Horno al vacío empleado para el tratamiento térmico de los aceros grado herramienta.

Entradas (X's)					Respuesta (Y)
					Dureza HRC
Línea	Tiempo (h)	Proveedor	Acero	Temp. (°C)	0.5 x 2.5 X 3.5
1	2.0	P2	H13	510	52.7
2	3.5	P2	D2	515	57.0
3	3.5	P1	D2	515	58.7
4	3.5	P1	D2	515	60.7
5	3.5	P1	D2	515	60.2
6	2.0	P1	H13	520	56.3
7	5.0	P2	H13	520	52.8
8	5.0	P1	H13	510	55.3
9	3.5	P2	H13	515	53.5
10	3.5	P2	H13	515	52.5
11	3.5	P1	H13	515	56.2
12	5.0	P2	D2	510	58.7
13	3.5	P2	H13	515	53.3
14	2.0	P1	D2	510	61.0
15	3.5	P1	H13	515	56.7
16	5.0	P1	D2	520	59.7
17	3.5	P2	D2	515	58.5
18	3.5	P1	H13	515	56.5
19	3.5	P2	D2	515	57.0
20	2.0	P2	D2	520	57.8

Tabla 2. Tabla de diseño del tratamiento térmico de los aceros grado herramienta.

Aplicación de la RNFBR

Una vez obtenidos los datos de dureza, se construye la red neuronal de base radial introduciendo como variables de entrada el tiempo y temperatura de cada línea, buscando como respuesta la dureza posterior al revenido, con el fin de observarla con respecto de la variación de los parámetros de entrada y generar un modelo que prediga futuros resultados al variar los principales parámetros del proceso. La **Tabla 2** muestra los valores utilizados para construir la red.

El algoritmo genético empleado, sirve para calcular los centros de la matriz ayudando a solucionar la distancia Euclidiana, la cual se convierte en su función de evaluación, apoyando al aprendizaje de la red para predecir y optimizar los datos. En el presente caso, el AG tuvo 100 ciclos de generaciones, con 250 líneas de población inicial, donde cada individuo representa un conjunto de $(m \times m)$ soluciones. Se utilizó un punto de cruce (Pc) y de mutación (Pm) de 0.9 y 0.01, respectivamente.

Comentarios Finales

Resultados

La dureza mínima de los aceros H13 y D2 empleados en la presente experimentación son de aproximadamente 52 HRC y 59 HRC (ASTM International 2015) respectivamente, por lo que se puede mencionar que con el tratamiento térmico aplicado la dureza de los materiales fue satisfactoriamente alcanzada, sin embargo el objetivo del presente se basa en la construcción de un modelo para predecir la dureza de estos dos aceros al variar los parámetros de tiempo y temperatura, evitando la producción innecesaria de muestras.

Los resultados obtenidos de la RNFBR arrojan un modelo de predicción con un valor de R_2 de 93.17%, observando que la cantidad de variabilidad de los datos se encuentra por encima del 90%, lo que indica que la respuesta esta explicada adecuadamente por el modelo. Los resultados obtenidos de R^2_{Adj} 93.17% y $R^2_{predicción}$ 91.14%, indican que la red es buena para predecir ya que la variabilidad presente en el ajuste de los datos es explicada por el modelo, concluyendo que el modelo predicho es casi excelente para predecir nuevas observaciones en el futuro. En la **Figura 3** se puede observar el gráfico de predicción obtenido por la red, donde se observa la línea de las durezas medidas durante el proceso y la predicción hecha por el modelo de la red, observando que casi se traslapan, demostrando con esto la cercanía de los resultados reales y los predichos.

Conclusiones

Con el objetivo de predecir valores de dureza en campo al variar los principales parámetros de los tratamientos térmicos (tiempo y temperatura) se construyó una RNFBR apoyada en un AG para obtener un modelo de predicción a partir de valores de dureza obtenidos de un tratamiento térmico de temple + revenido en un horno al vacío de dos distintos grados de acero para herramientas. Como conclusiones se obtiene que el modelo obtenido presenta una $R^2_{predicción}$ de 91.14%, indicando que tiene un excelente comportamiento para predecir futuras observaciones, ya que la variabilidad del proceso es explicada en un valor mayor al 90% por el modelo matemático, puntualizando que este es adecuado para la optimización del proceso. Como trabajo a futuro es necesario validar las opciones de parámetros arrojados por la red para verificar que la dureza real se comporta como la predicha, además es pertinente emplear otro tipo de configuraciones en el modelo para abarcar más campo del sector, puesto que a nivel industrial piezas de distintas medidas y configuraciones son tratadas térmicamente y el emplear una red para predecir los valores de las propiedades mecánicas así como optimizar los tiempos de producción sería un gran aporte para generar eficiencia en el sector industrial.

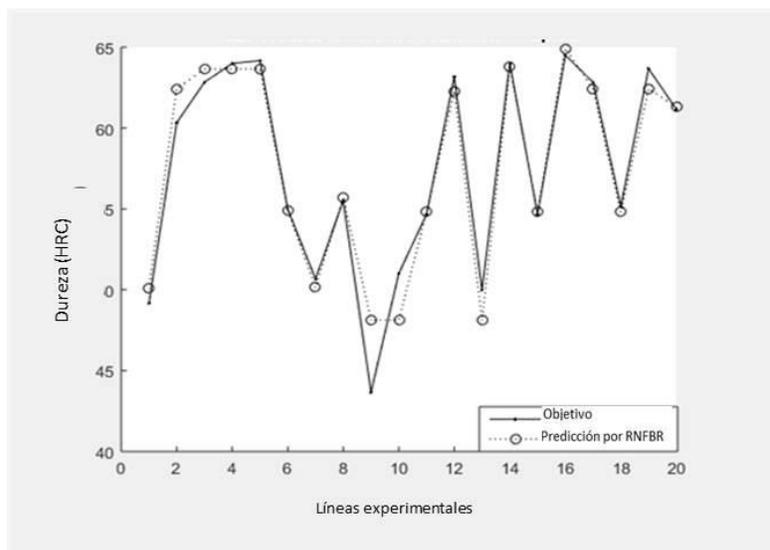


Figura 3. Predicción de comportamiento real de la dureza del TT contra la predicción del modelo.

Referencias

- ASTM International. *A681-08: Standard Specification for Tool Steels Alloy*. 2015.
- Bulsari, Abhay, and Erik Hocksell. "A Quality Control System for Direct Hardened Steel Components Based on Neural Networks." *IFAC Proceedings Volumes* 30(3): 379–83. 1997.
- Dobrzański, L. A., and J. Trzaska. "Application of Neural Networks to Forecasting the CCT Diagrams." *Journal of Materials Processing Technology* 157–158(SPEC. ISS.): 107–13. 2004.
- Dobrzański, L.A., and R. Honysz. "Application of Artificial Neural Networks in Modelling of Normalised Structural Steels Mechanical Properties." *Journal of Achievements in Materials and Manufacturing Engineering* 32(1): 50–57. 2009.
- Ganguli, Ranjan. Aerodynamic Derivative Calculation Using Radial Basis Function Neural Networks." In *Advanced UAV Aerodynamics, Flight Stability and Control: Novel Concepts, Theory and Applications*, eds. Pascual Márques and Da Ronch Andrea. John Wiley & Sons, 776. 2017.
- Gurney, Kevin. *An Introduction to Neural Networks*. London: Taylor & Francis e-Library. 2004.
- Haykin, Simon. *Neural Networks and Learning Machines*. 3rd ed. New Jersey: Pearson Prentice Hall. 2009.
- Hoffmann, Franz et al. "ASM Handbook." 4: 263–387. 2013.
- Janciková Z., Roubicek V., and Juchelková D. "Application of Artificial Intelligence Methods For Prediction of Steel Mechanical Properties." *Meturgia* 47(4): 339–42. 2008.
- Mitchell, Melanie. *Genetic Algorithms : An Overview 1*. Santa Fe. 1995.
- Montgomery, D.C. *Diseño y Análisis de Experimentos*. 2nd ed. México D.F.: LIMUSA WILEY. 2004.
- Otto, Matthias. "Knowledge Processing and Soft Computing." In *Chemometrics: Statistics and Computer Application in Analytical Chemistry*, Wiley, 400. 2016.
- Podgornik, Bojan, Igor Belič, Vojteh Leskovšek, and Matjaz. Godec. "Tool Steel Heat Treatment Optimization Using Neural Network Modeling." *Metallurgical and Materials Transactions A* 47(11): 5650–59. 2016.
- Shaheed, M H, and M O Tokhi. "Parametric and Non-Parametric Modelling of Flexible Manipulators." In *Flexible Robot Manipulators: Modelling, Simulation and Control*. The Institution of Engineering and Technology, 536. 2017.
- Steels, Tool. "Tool Steels." In *Steel Metallurgy for the Non-Metallurgist*, 419–20. 1961.
- Sterjovski, Z. et al. "Artificial Neural Networks for Modelling the Mechanical Properties of Steels in Various Applications." *Journal of Materials Processing Technology* 170(3): 536–44. 2005.
- Trzaska, J., and L. A. Dobrzański. "Application of Neural Networks for Designing the Chemical Composition of Steel with the Assumed Hardness after Cooling from the Austenitising Temperature." *Journal of Materials Processing Technology* 164–165(1): 1637–43. 2005.
- Uddeholm.. 8 Uddeholm Tool Steel for Die Casting *Heat Treatment of Tool Steel*. 2012.
- Žmak, I, and T. Filetin.. "Neural Network in Predicting Steel Properties: Artificial Neural Network as a Tool in Predicting Mechanical and Thermal Properties of Steels." In *International Conference on Materials and Tribology*, 1–9. 2002.