

## Desarrollo de un modelo de redes neuronales artificiales para predecir la dureza de la superficie de un acero A-36, tomando como variables la deformación térmica y la temperatura, producidas a lo largo del proceso de soldadura

### Development of a model of Artificial Neural Networks to predict the surface hardness of a steel A-36, taking as variables the thermal deformation and temperature, produced along welding process

SERVIN-CASTAÑEDA, Rumualdo<sup>1\*</sup>†, LOPEZ-REYNA, Laura<sup>2</sup>, GARCIA-YREGOI, Manuel<sup>2</sup>, ROSALES-SOSA, Ma. Gloria<sup>2</sup> y BARRERA-MORENO, Mario Alberto<sup>1</sup>

<sup>1</sup> Universidad Autónoma de Coahuila. Barranquilla S/N, Col. Guadalupe, Monclova Coah. México

<sup>2</sup> Universidad Autónoma de Coahuila. Carretera 57 Km 5, 25720, Monclova Coah. México

ID 1<sup>er</sup> Autor: Rumualdo, Servin-Castañeda / ORC ID: 0000-0002-8655-2572, Researcher ID Thomson: S-4952-2018, CVU CONACYT ID: 45820

ID 1<sup>er</sup> Coautor: Laura, Lopez-Reyna / ORC ID: 0000-0003-1703-586X, Researcher ID Thomson: S-4741-2018, arXiv ID: IYRNVZ-L9R89S, CVU CONACYT ID: 818710

ID 2<sup>do</sup> Coautor: Manuel, Garcia-Yregoi / ORC ID: 0000-0002-8710-6750, Researcher ID Thomson: S-5632-2018, CVU CONACYT ID: 322570

ID 3<sup>er</sup> Coautor: Ma. Gloria, Rosales-Sosa

ID 4<sup>to</sup> Coautor: Mario Alberto, Barrera-Moreno / ORC ID: 0000-0003-4772-7795, Researcher ID Thomson: S-4745-2018, CVU CONACYT ID: 430729

Recibido 23 de Septiembre, 2018; Aceptado 12 de Noviembre, 2018

#### Resumen

El presente trabajo de investigación tiene como objetivo aplicar un modelo de Red Neuronal Artificial (RNA) para predecir la transformación de dureza y la deformación térmica que sufre una placa de acero A-36 durante el proceso de soldadura. El modelo matemático para el entrenamiento de la red neuronal fue realizado en el software MATLAB® R2010a, en la cual se utilizaron como variables de entrada los datos obtenidos de deformación (planicidad) antes y después de la soldadura, y temperatura; y como variable de salida la dureza. De acuerdo con los resultados obtenidos durante el entrenamiento, la mejor arquitectura de la red fue de [3,15,1], es decir, 3 capas de entrada, 15 nodos en la capa oculta y 1 salida; durante la primera corrida se obtuvo un valor de regresión de  $R=0.96353$ , es decir, una eficiencia del 96%. Lo que indica que las durezas obtenidas por el modelo son muy cercanas a las durezas reales obtenidas durante la recopilación de datos.

**Redes Neuronales Artificiales (RNA), Dureza, Deformación, Acero A-36**

#### Abstract

The objective of this research work is to apply a model of Artificial Neural Network (ANN) to predict the transformation of hardness and thermal deformation suffered by a steel plate A-36 during the welding process. The mathematical model for the training of the neural network was carried out in the MATLAB® R2010a software, in which were used as input variables in which the data obtained from deformation (flatness) before and after the welding, and temperature; and as output variable the hardness. According to the results obtained during the training, the best architecture of the network was [3,15,1], that is, 3 input layers, 15 nodes in the hidden layer and 1 output; During the first run a regression value of  $R = 0.96353$  was obtained, that is, an efficiency of 96%. This indicates that the hardness obtained by the model is very close to the real hardness obtained during the data collection.

**Artificial Neural Networks (RNA), Hardness, Deformation, Steel A-36**

**Citación:** SERVIN-CASTAÑEDA, Rumualdo, LOPEZ-REYNA, Laura, GARCIA-YREGOI, Manuel, ROSALES-SOSA, Ma. Gloria y BARRERA-MORENO, Mario Alberto. Desarrollo de un modelo de redes neuronales artificiales para predecir la dureza de la superficie de un acero A-36, tomando como variables la deformación térmica y la temperatura, producidas a lo largo del proceso de soldadura. Revista del Diseño Innovativo. 2018, 2-5: 1-7

\*Correspondencia al Autor (Correo Electrónico: romualdoservinc@prodigy.net.mx)

† Investigador contribuyendo como primer autor.

## Introducción

(A. Amer et Al 2010, A.C Hunt 1994, et Al.) establecieron que para obtener componentes de acero o piezas finales algunas veces se necesita utilizar un proceso de soldadura, donde se genera una gran cantidad de calor. Este calor es conocido como calor de aporte, el cual es una medida relativa de la energía transferida a los componentes que van a ser soldados. El calor de aporte es importante porque afecta principalmente a la rapidez de enfriamiento, que a su vez afecta a la microestructura final de la soldadura y las propiedades mecánicas. Por lo tanto, los componentes ingenieriles unidos mediante este tipo de procesos, experimentan una serie de cambios microestructurales debido a los ciclos térmicos que se generan; esto lleva a que la zona de la soldadura presente, con respecto al material base tenga diferentes propiedades mecánicas, tales como tenacidad, y dureza, así como un campo de esfuerzos residuales y deformación térmica como lo mencionaron (Matsouka, Y.M 2010 y Boumerzoug, Z. 2010). En general la microestructura final es función de la composición química y ciclo térmico, y a su vez éste último, es función del calor aportado y del componente geométrico (cantidad de material a ser soldado). En la soldadura de aceros, los cambios en las propiedades físico-mecánicas que se presentan, dependiendo del ciclo térmico que se desarrolle (temperatura pico y rapidez de calentamiento y enfriamiento) son: deformación térmica y transformación de dureza.

Las propiedades mecánicas de los materiales juegan un papel muy importante en el desarrollo tecnológico, ahorrando tiempo y dinero cuando se aplican correctamente, tal es el caso de (Vandana Somkuwar), quien utilizó un modelo de Redes Neuronales para predecir la dureza de un acero de alta velocidad (HSS por sus siglas en inglés) en función de su composición química, o el caso de (P. Saravanakumar 2012) quien también utilizó este método para predecir las propiedades mecánicas de un acero al bajo carbón rolo en caliente.

En los últimos años, la modelación y simulación matemática son utilizadas ampliamente a escala industrial para predecir un proceso, o diagnosticar la respuesta esperada de un caso en particular.

La ayuda de la computadora en el proceso de la información ha sido favorecida con la aplicación de sofisticados software diseñados utilizando la aplicación de Redes Neuronales Artificiales (RNA), que han sido desarrolladas como herramientas de predicción. Estos son Modelos que intentan reducir el comportamiento del cerebro, del mismo modo que este realiza una simplificación, averiguando cuales son los elementos relevantes del sistema. Una elección adecuada de sus características, más un algoritmo de entrenamiento adecuado, es el procedimiento utilizado para construir modelos de redes capaces de realizar una buena predicción o clasificación como lo mencionó (Garza, V. 2009).

## Marco Teórico

El acero ASTM A-36 es utilizado en la fabricación de tubería para el transporte de crudo y sus derivados, debido a que es un acero estructural con buenas propiedades mecánicas (según la ASTM international 2014). (Calderón Concha. J. F. 2014) menciona que este acero ofrece una excelente resistencia y fuerza para un acero bajo en carbono y aleación. Una de las propiedades mecánicas utilizadas para este trabajo es la dureza que es una condición de la superficie del material, no representa ninguna propiedad de la materia y está relacionada con las propiedades elásticas y plásticas del material. Si bien, es un término que nos da idea de solidez o firmeza, no existe una definición única acerca la dureza y se la suele definir arbitrariamente en relación al método particular que se utiliza para la determinación de su valor como lo menciona (“Ensayo de dureza” Septiembre 2017).

Para este trabajo utilizaremos las Redes Neuronales Artificiales (RNA); según (Haykin, S. 1998) menciona que las RNA son un modelo matemático inspirado en el comportamiento biológico de las neuronas y en la estructura del cerebro. Esta también puede ser vista como un sistema inteligente que lleva a cabo tareas de manera distinta a como lo hacen las computadoras actuales. Si bien estas últimas son muy rápidas en el procesamiento de la información, existen tareas muy complejas, como el reconocimiento y clasificación de patrones, que demandan demasiado tiempo y esfuerzo aun en las computadoras más potentes de la actualidad, pero que el cerebro humano es más apto para resolverlas.

Muchas veces sin aparente esfuerzo (considere el lector como ejemplo el reconocimiento de un rostro familiar entre una multitud de otros rostros). El cerebro puede considerarse un sistema altamente complejo. Su unidad básica, la neurona, está masivamente distribuida con conexiones entre ellas (se calcula que hay aproximadamente 10 billones de neuronas en la corteza cerebral y 60 trillones de conexiones neuronales).

En la Figura 1 se muestra la estructura de una neurona biológica y una neurona artificial. Aunque sus estructuras sean similares, la RNA tiene un comportamiento más simplificado de acuerdo con (Fernandez, C. 2007).

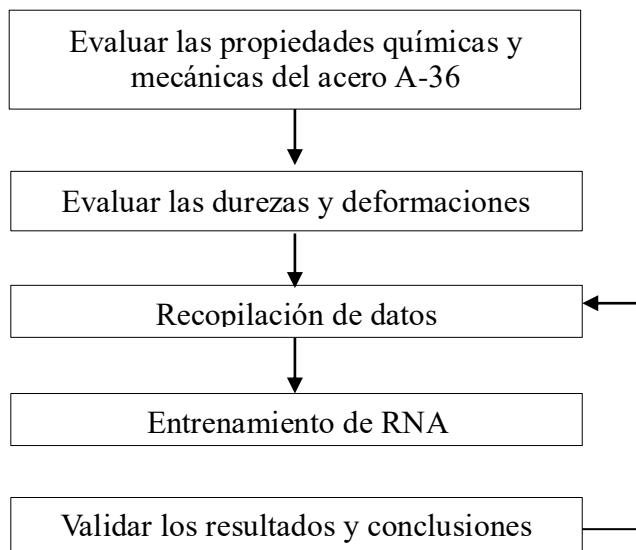


Figura 1 Capas de una red (Maticj, D. 2001)

(Maticj, D. 2001) estableció que la distribución de neuronas dentro de la red se realiza formando niveles o capas, con un número determinado de dichas neuronas en cada una de ellas. A partir de su situación dentro de la red, se pueden distinguir tres tipos de capas:

- De entrada: es la capa que recibe directamente la información proveniente de las fuentes externas de la red.
- Ocultas: son internas a la red y no tienen contacto directo con el entorno exterior. El número de niveles ocultos puede estar entre cero y un número elevado. Las neuronas de las capas ocultas pueden estar interconectadas de distintas maneras, lo que determina, junto con su número, las distintas topologías de redes neuronales.

- De salidas: transfieren información de la red hacia el exterior.

Metodología de Investigación

El desarrollo del estudio se lleva a cabo en cuatro etapas. Las actividades desarrolladas para este trabajo se muestran en el digrama de flujo representado en la Figura 3, y se describe detalladamente a continuación.





Figura 3 Diagrama de flujo de las actividades desarrolladas para el estudio

Estudiar las propiedades químicas y mecánicas del acero A-36.- Para este estudio se analizan las propiedades químicas y mecánicas del acero A-36, las cuales se muestran en la Tabla 1 y 2. Para el caso de estudio, se establecen como variables en la la capa de entrada la deformación antes y después de aplicar la soldadura, así como la temperatura, y como variable en la capa de salida la dureza superficial.

Elemento	Contenido
Hierro (Fe)	99
Carbono (C)	0.25 max.
Manganeso (Mn)	No existe requisito
Fosforo (P)	0.04 Max.
Azufre (S)	0.05 Max.
Silicio (Si)	0.40 Max.
Cobre (Cu)	0.20 Min.

Tabla 1 Composición química del acero ASTM A-36 mencionada en (Standard Specification for Carbon Structural Steel)

Evaluar las durezas y deformaciones.- De acuerdo a un estudio preliminar donde se aplicó soldadura a una placa de acero A-36 de ½ pulgada de espesor, la cual fue preparada con 100 taladros donde en cada uno de ellos se les aplicó soldadura. La placa se identificó en columnas y renglones, las columnas identificadas con letras y los renglones con números, y así formar 81 intersecciones, como se observa en la Figura 4, en ella muestra la intersección entre cada punto que se soldó (Por ejemplo I1 para el punto rojo). En cada intersección se midió planicidad con un indicador de caratula, antes y después del proceso de soldadura, también se midió la temperatura que sufrió y la transformación de dureza en escala Rockwell B (HRB) después del proceso.




**Figura 4** Diagrama de la placa a estudiar donde muestra los puntos soldados y la intersección donde se midió planicidad y temperatura (punto rojo)

Recopilación de datos.- Se tomaron un total de 81 datos por cada variable a considerar; es decir, 81 datos de planicidad antes de soldar, y después de soldar, además de la temperatura generada por el arco eléctrico al aplicar la soldadura, la cual es considerada en la RNA para la capa de entrada y salida. La otra variable de análisis en la red neuronal es la dureza superficial, la cual es la variable de salida.

Entrenamiento de la Red Neuronal Artificial.- Para el entrenamiento de la RNA se utiliza el software MATLAB® R2010a. En el que se ingresaron, como variables de entrada, los 81 datos correspondientes a la temperatura final del proceso, la planicidad antes y después del proceso.

Propiedades	Unidades métricas	Unidades imperiales
Esfuerzo último a la tracción	400-500 Mpa	58-80 Ksi
Esfuerzo de fluencia	250 Mpa	36 Ksi
Módulo de elasticidad	200 Mpa	29 Ksi
Módulo de Poisson	0.26-0.29	0.26-0.29
Elongación mínima 20%	200 mm	8 in
Elongación Mínima 23%	50 mm	2 in
Dureza Brinell	119-159	119-159
Dureza Rockwell B	67-83	67-83

Y como variables de salida la dureza; para la capa oculta se comenzó con 10 nodos, es decir, con 10 neuronas ocultas. La Figura 5 muestra el esquema que representa el diseño de la red neuronal. En cada uno de los nodos se entrenó 7 veces, es decir, se realizaron 7 corridas por cada aumento de nodos hasta llegar a los 24 nodos.



**Figura 5** Diseño de la red neuronal propuesta

Validar los resultados y conclusiones.- Con el fin de tener una mejor apreciación de los resultados, los datos obtenidos de dureza obtenidos en el entrenamiento de la RNA fueron comparados con los datos reales medidos después de la soldadura.

## Resultados

De acuerdo con el entrenamiento realizado en el software mencionado anteriormente, se obtuvieron datos significativos; en la Tabla 3 se muestran los resultados de los datos obtenidos divididos en la cantidad de nodos adicionales y el número de corridas.

Es importante mencionar, que para este trabajo se consideraron valores de regresión arriba del 0.90, es decir, una eficiencia del 90%, sin embargo, en la tabla solo de agregaron los valores mas altos que resultaron durante cada corrida.

Nodos de la capa oculta	Número de corridas	Valor de R (regresión)
10 nodos	1	0.82643
11 nodos	1	0.75837
12 nodos	3	0.71429
13 nodos	3	0.75241
14 nodos	2	0.85599
15 nodos	1	0.96353
16 nodos	3	0.80668
17 nodos	6	0.7434
18 nodos	5	0.86978


**Tabla 3** Valores de R durante el entrenamiento de la red neuronal, con la cantidad de nodos adicionados durante cada corrida.

De acuerdo con la Tabla 3, considerando una eficiencia arriba del 90%, se encontro que la mejor arquitectura de red fue de [3,15,1], es decir, con 3 capas de entrada, 15 nodos en la capa oculta y 1 salida; duranten la primera corrida la cual se obtuvo un valor de R=0.96353.

La Figura 6 muestra la gráfica de Regresión (plotregression) en ella se muestran los valores de dureza del objetivo vs salida, es decir, la dureza a la que se quiere llegar, y la salida obtenida del modelo de la RNA. Tambien nos muestra el valor de R=0.96353.

En esta grafica se tiene el objetivo (linea azul) vs la salida (linea punteada), esto nos quiere decir que cada dato que se tiene (circulos) deben de ir por encima de la linea azul, sin embargo, debido al valor de R, estos puntos solo se acercan un 96%, como se muestran en la linea punteada.


Mejor rendimiento de validación (Best Validation Performance) es 0.44625 a 14 épocas



**Figura 6** Gráfica de Regresión (Plotregression)

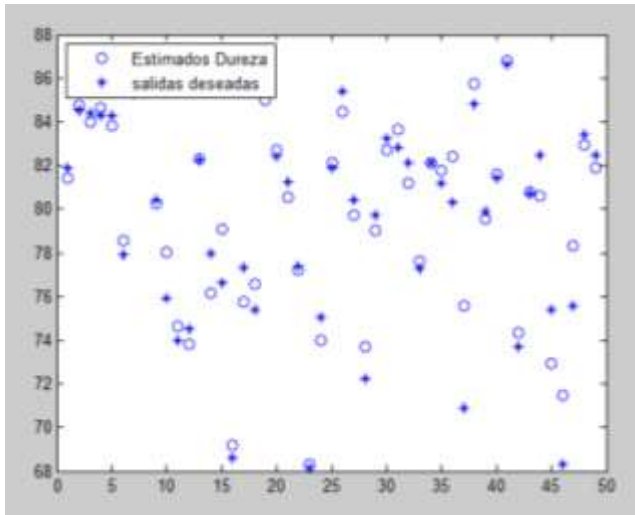
La Figura 7, muestra la gráfica de Performance (plotperform), en ella se muestran el mejor rendimiento de validación: épocas vs error medio cuadrado. En ella se observa la línea de entrenamiento (azul) que indica como va evolucionando el entrenamiento de la red, lo cual solo se ocupa un 60% de todos los datos, hasta que llega a estabilizarse despues de 20 épocas, y la línea de validación (verde) la cual valida los datos que se entrenaron, los cuales son un 20% de todos los datos.

Si la línea de validación esta muy aproximada a la línea punteada significa que los datos que se validaron son correctos, como lo muestra la gráfica de la Figura 7.



**Figura 7** Gráfica de Performance (plotperform)

La Figura 8 muestra la gráfica de los valores estimados de dureza vs salidas deseadas. Como se puede observar, los valores estimados y los valores deseados están muy juntos, lo cual muestra que se tiene una buena eficiencia, ya que los valores son muy similares.



**Figura 8** Gráfica de valores estimados de dureza vs salidas deseadas

En la Tabla 4 se muestran algunos resultados de los valores de dureza reales vs los del modelo.

Datos	Dureza real	Dureza estimada
1	81.9000	81.4344
2	84.5000	84.7566
3	84.4000	83.9870
4	84.3000	84.6202
5	84.3000	83.8086
6	77.9000	78.5503
7	85.3000	85.9438
8	86.1000	86.0442
9	80.4500	80.2577
10	75.9000	78.0502

**Tabla 4** Valores reales de dureza vs valores deseados del modelo

Como se muestra en la Tabla 4 los valores del modelo son muy similares a los valores reales lo que confirma en 96% de la eficiencia en el valor de la regresión.

## Conclusiones

Para este caso con el entrenamiento de la red neuronal, se obtuvo una eficiencia del 96%, lo cual nos indica que las durezas obtenidas por el modelo son muy cercanas a las durezas reales.

Validando la eficiencia del modelo, con lo cual podemos tener la certeza de que los datos que se esperan para casos similares las durezas calculadas serán muy cercanas a las reales.

Finalmente se puede concluir que con el modelo de Redes Neuronales Artificiales desarrollado nos ayudan a predecir la dureza que podría tener un acero A-36 que es sometido a un proceso de soldadura, si se ingresan datos de entrada como planicidad y temperatura.

## Referencias

A. Amer, M.K., K. Lee, S. Kim and S. Hong, *Journal of Materials Science* 45, 1248. 2010.

A.C. Hunt, A.O.K.R.E., *Welding Journal* 73, 9, 1994.

S. Zheng, Q.W., Q. Huang, S. Liu and Y. Han, *Fusion Engineering and Design* 86, 2616. 2011.

W.W. Xu, Q.F.W., T. Pan, H. Su and C.F. Yang, *Journal of Iron and Steel Research, International* 14, 234, 2007.

Y.-q. Zhang, H.-q.Z., J.-f. Li and W.-m. Liu, *Journal of Iron and Steel Research, International* 16, 73. 2009.

Matsuoka, Y.M., *Engineering Fracture Mechanics* 77, 1926. 2010.

Z. Boumerzoug, C.D.B., *Engineering Failure Analysis* 2, 502 2010.

Somkuwar, V., *Prediction of Hardness of High Speed Steel Using Artificial Neural Network*; *International Journal of Engineering Science and Innovative Technology*

P. Saravanakumar, V.J., L. Sureshbabu, S. Ayyappan, D. Noorullah and P.G. Venkatakrishnan, *Prediction of Mechanical Properties of Low Carbon Steel in Hot Rolling Process Using Neural Network Model, International Conference on Modeling Optimisation and Computing, Procedia Engineering* 38 3418-3425. Elsevier, 2012.

Garza, V.E.M., *Tesis "Predicción de propiedades mecánicas a partir de la composición química de un acero medio carbón empleando redes neuronales artificiales"*. 2009, UAdeC.

A36/A36M-00a., A., Standard Specification for Carbon structural steel. 2014(ASTM International, West Conshohocken, PA).

Calderón Concha, J.F., "Estudio comparativo de la soldabilidad en aceros (astm a36, a588 y a572) mediante el proceso fcaw", in *Tesis mecánica*. 2014, Escuela politécnica nacional.

"Ensayo de dureza". Septiembre 2017]; Available from:  
<http://190.105.160.51/~material/materiales/presentaciones/ApunteDureza.pdf>.

Haykin, S., "Neural Networks: A comprehensive foundation". 1998. Prentice-Hall.

Materials, A.S.f.T.a., ASTM A36/A36M- 12 Standard Specification for Carbon Structural Steel. ASTM.

Fernández, C.J.G., *TESIS "Diseño de modelos empiricos para procesos industriales: Refinamiento de acero inoxidable"*. 2007, Universidad de Málaga.

Matich, D.J., "*Redes neuronales: Conceptos básicos y aplicaciones*". 2001, Universidad Tecnológica Nacional.