

Redes neuronales artificiales para la predicción de la calidad en soldadura por resistencia por puntos*

O. Martín**, M. López** y F. Martín**

Resumen

Se propone una red neuronal artificial como herramienta para predecir, a partir de tres parámetros operativos (tiempo de soldadura, intensidad de corriente y tipo de electrodo), si la calidad de una unión soldada por resistencia por puntos alcanza o no un cierto nivel. El entrenamiento de la red neuronal conlleva que la calidad se determine previamente mediante ensayos de tracción en probetas en cruz. El hecho de alcanzar o no el citado nivel de calidad constituye la respuesta objetivo que acompaña a cada entrada de la red neuronal artificial durante su aprendizaje supervisado. El conjunto de datos disponible está formado por pares entrada/salida objetivo y se divide de forma aleatoria en un subconjunto de entrenamiento (para actualizar los valores de los pesos sinápticos) y en un subconjunto de validación (para combatir el fenómeno de *overfitting* mediante validación cruzada).

Palabras clave

Soldadura por resistencia por puntos. Calidad metalúrgica. Redes neuronales artificiales.

Artificial neural networks for prediction of quality in resistance spot welding

Abstract

An artificial neural network is proposed as a tool for predicting from three parameters (weld time, current intensity and electrode sort) if the quality of a resistance spot weld reaches a certain level or not. The quality is determined by cross tension testing. The fact of reaching this quality level or not is the desired output that goes with each input of the artificial neural network during its supervised learning. The available data set is made up of input/desired output pairs and is split randomly into a training subset (to update synaptic weight values) and a validation subset (to avoid overfitting phenomenon by means of cross validation).

Keywords

Resistance spot welding. Metallurgical quality. Artificial neural networks.

1. INTRODUCCIÓN

El proceso de soldadura por resistencia por puntos se utiliza ampliamente en la unión de chapas de acero dentro de la industria automovilística^[1 y 2]. El elevado número de puntos de soldadura (entre 3.000 y 4.000) requerido por cada vehículo^[3], justifica el desarrollo de una herramienta capaz de predecir de manera fiable la calidad de cada punto a partir de parámetros

controlados en el proceso de soldeo^[4]. De entre los diferentes parámetros operativos, son tres los elegidos: el tiempo de paso de corriente de soldadura, la intensidad de corriente RMS y el tipo de electrodo (que es función de la composición química de la aleación empleada y del tratamiento térmico y/o mecánico a que haya sido sometido).

Las redes neuronales artificiales (en adelante RNA) constituyen una eficaz herramienta para representar

* Trabajo recibido el día 1 de diciembre de 2005 y aceptado en su forma final el día 8 de marzo de 2006.

** Área de Ciencia de los Materiales e Ingeniería Metalúrgica. Universidad de Valladolid. Escuela Técnica Superior de Ingenieros Industriales. Paseo del Cauce s/n. Valladolid 47011 España. Tel: +34-983423389, Fax: +34-983185951, E-mail: oml@eis.uva.es.

sistemas no lineales y/o de gran complejidad^[5], ante los cuales, los métodos de regresión pueden presentar limitaciones^[6]. Puesto que las RNA han demostrado su aplicabilidad en modelos predictivos en metalurgia^[7-15], se propone una RNA que ante una entrada asociada a un punto de soldadura por resistencia y compuesta por los valores particulares que para ese punto toman los tres parámetros antes referidos, ofrece como salida experimental una estimación de la calidad del punto. Para que la RNA esté en disposición de efectuar esta tarea debe ser previamente entrenada, en este caso, mediante un aprendizaje supervisado, utilizando un conjunto de pares de datos entrada/salida objetivo, \hat{y}/t , de tal manera que se modifica iterativamente el valor de los pesos sinápticos (asociados a cada conexión entre cada par de neuronas), reduciéndose, así, en cada iteración, una función que depende de la diferencia entre las salidas experimentales que ofrece la RNA, o , y las correspondientes salidas objetivo, \hat{t} ^[16].

La RNA es eficaz si predice adecuadamente la calidad de puntos de soldadura no utilizados en su entrenamiento, es decir, si tiene capacidad de generalización. Para salvaguardar esta capacidad de generalización o, lo que es lo mismo, para evitar la aparición del fenómeno de *overfitting*, se recurre a la "validación cruzada".

2. PROCEDIMIENTO EXPERIMENTAL

2.1. Materiales y equipamiento

Los puntos de soldadura se ejecutaron sobre chapas de acero en negro previamente sometidas a un proceso de limpieza, de 1 mm de espesor y con dimensiones 100 mm × 300 mm. Las chapas se unieron por parejas y a solape. La composición química del acero se muestra en la tabla I.

El límite de elasticidad, la resistencia a la tracción y la elongación porcentual tras la fractura se obtuvieron según norma^[17], en una máquina universal de ensayos Shimadzu UH-F500 kN. La microdureza se determinó en un equipo Matsuzawa Seiki MXT70 aplicando una carga de 0,981 N y un tiempo de mantenimiento de 30 s. Las anteriores propiedades mecánicas del acero se recogen en la tabla II.

El tamaño de grano ASTM del acero es de 5-6 y se evaluó según norma^[18].

El acero posee una microestructura ferrítica con ligera presencia de perlita (figura 1).

Los puntos de soldadura se efectuaron en un equipo cuyas características técnicas se detallan en la tabla III. La fuerza entre electrodos se mantuvo constante e igual a 980,7 N.

Tabla I. Composición química del acero (% en peso)

Table I. Chemical composition of the steel (weight %)

C	Mn	Si	P	S	Al
0,05	0,26	0,02	0,012	0,011	0,033

Tabla II. Propiedades mecánicas del acero

Table II. Mechanical properties of the steel

Límite de elasticidad (MPa)	Resistencia a tracción (MPa)	Elongación (%)	Microdureza (HV)
192	301	40	104

Tabla III. Características técnicas del equipo de soldadura

Table III. Technical characteristics of welding equipment

Tensión de línea (V)	Frec. (Hz)	Tipo de Tensión	Potencia 50% FM (kVA)	Caudal refrig. (l/h)
380	50	Monofásica	18	250

En el análisis por ultrasonidos se empleó un palpador Krautkrämer de burbuja, con 4,5 mm de diámetro y 20 MHz de frecuencia.

2.2. Entradas a la RNA

Inicialmente, los parámetros operativos considerados fueron cinco:

- Tiempo de soldadura.
- Intensidad de corriente.
- Fuerza entre electrodos.
- Tipo de electrodo.
- Caudal de agua de refrigeración.

La elección de las entradas a la RNA es un aspecto de gran importancia ya que deben ser suficientemente representativas del proceso pero sin que supongan un aumento innecesario en la complejidad del modelo neuronal^[19 y 20]. Teniendo esto en cuenta, se decidió tratar a la fuerza entre electrodos y al caudal de agua de refrigeración, como trasunto de la temperatura que alcanza el electrodo, como constantes (con valores especificados anteriormente) y considerar como entradas a la red neuronal a los otros tres parámetros. De este modo, cada una de las entradas a




Figura 1. Micrografía del acero para chapas. Sección longitudinal.

Figure 1. Micrograph of sheet steel. Longitudinal section.

la RNA se puede considerar como un vector, \hat{i} , que consta de tres componentes:

1. Tiempo de soldadura.
2. Intensidad de corriente.
3. Tipo de electrodo.

2.2.1. Tiempo de soldadura

Tiempo durante el cual circula la corriente de soldadura. Varía entre 4 y 20 ciclos.

2.2.2. Intensidad de corriente

Se considera el valor RMS. Toma valores entre 4 y 8 kA^[21-23].

2.2.3. Tipo de electrodo

Se utilizaron electrodos de cobre, material que posee una excelente conductividad térmica y eléctrica, pero que es demasiado blando y debe ser aleado y sometido a algún proceso de endurecimiento^[24].

Se emplearon dos aleaciones base cobre^[21 y 25-27]:

- Cobre-cromo (0,386% Cr).
- Cobre-berilio (0,598% Be y 1,86% Co).

Los estados considerados para cada aleación son tres^[25-29]:

- Recepción. Corresponde en las dos aleaciones a un tratamiento consistente en tres etapas:
 1. Solubilización.
 2. Deformación plástica en frío.
 3. Envejecimiento propiamente dicho.
- Recocido.
 - Aleación Cu-Cr.
 1. Calentamiento y mantenimiento a 1.010°C durante tiempo suficiente.

Tabla IV. Tipos de electrodo

Table IV. Electrode sorts

	Cu-Cr	Cu-Be
Recepción	1	2
Recocido	3	4
Envejecimiento	5	6

- 2. Enfriamiento lento en horno.
 - Aleación Cu-Be.
 1. Calentamiento y mantenimiento a 925°C durante tiempo suficiente.
 2. Enfriamiento lento en horno.
- Envejecimiento.
- Aleación Cu-Cr.
 1. Calentamiento y mantenimiento a 1.010°C durante tiempo suficiente.
 2. Enfriamiento rápido en agua.
 3. Envejecimiento a 465°C durante 4,5 h.
- Aleación Cu-Be
 1. Calentamiento y mantenimiento a 925°C durante tiempo suficiente.
 2. Enfriamiento rápido en agua.
 3. Envejecimiento a 450°C durante 4 h.

De este modo, la tercera componente de cada vector de entrada a la RNA es un número natural, comprendido entre 1 y 6, que se corresponde con uno de los seis posibles tipos de electrodos (tabla IV).

2.3. Salidas objetivo

El aprendizaje supervisado requiere que cada entrada se acompañe de la salida que se considera que la RNA le debería asignar (salida objetivo)^[30]. La salida objetivo de cada entrada será un escalar, un 1, si el punto de soldadura correspondiente es considerado válido y, un 0, si es considerado no válido.

El criterio adoptado para clasificar un punto de soldadura como válido o no válido, se fundamenta en las dimensiones y en la microestructura de la “lenteja” del punto estudiadas mediante análisis metalográfico y ultrasonidos^[4, 31 y 32]:

- Punto válido. La secuencia de ecos del oscilograma de ultrasonidos es corta por la alta atenuación que presenta una “lenteja” con estructura granular basta de bruto de colada y de espesor suficiente. La distancia entre dos ecos consecutivos corresponde a la suma del espesor de las dos chapas debido a que el diámetro de la “lenteja” es mayor que la anchura de haz de ultrasonidos y las reflexiones de éste




Figura 2. Micrografía de la sección transversal de un punto válido.

Figure 2. Micrograph of a cross-sectioned good weld.




Figura 5. Micrografía de la sección transversal de un punto pequeño.

Figure 5. Micrograph of a cross-sectioned undersize weld.



Figura 3. Macrografía de la sección transversal de un punto válido.

Figure 3. Macrograph of a cross-sectioned good weld.




Figura 6. Macrografía de la sección transversal de un punto pequeño.

Figure 6. Macrograph of a cross-sectioned undersize weld.

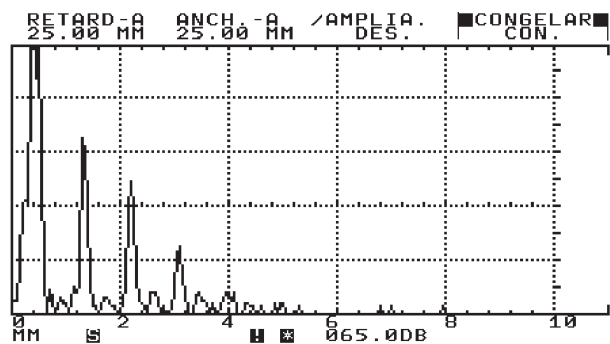


Figura 4. Oscilograma de ultrasonidos de un punto válido.

Figure 4. Ultrasonic oscillogram of a good weld.




Figura 7. Oscilograma de ultrasonidos de un punto pequeño.

Figure 7. Ultrasonic oscillogram of an undersize weld.

tienen lugar en las superficies exteriores de las dos chapas (figuras 2, 3 y 4).

— Punto no válido. Comprende tres tipos de puntos:

- Punto pequeño. La microestructura de la “lenteja” es de bruto de colada pero su diámetro es menor que el del haz ultrasónico, por lo que aparecen ecos intermedios entre

los ecos de fondo. Estos ecos intermedios corresponden a las reflexiones del haz de ultrasonidos que ocurren en la superficie de contacto de las dos chapas (figuras 5, 6 y 7).

- Soldadura fría. La “lenteja” posee una microestructura de bruto de colada pero tiene menor espesor que la de un punto válido




Figura 8. Micrografía de la sección transversal de una soldadura fría.

Figure 8. Micrograph of a cross-sectioned stick weld.




Figura 11. Micrografía de la sección transversal de una falta de soldadura.

Figure 11. Micrograph of a cross-sectioned no weld.



Figura 9. Macrografía de la sección transversal de una soldadura fría.

Figure 9. Macrograph of a cross-sectioned stick weld.




Figura 12. Macrografía de la sección transversal de una falta de soldadura.

Figure 12. Macrograph of a cross-sectioned no weld.




Figura 10. Oscilograma de ultrasonidos de una soldadura fría.

Figure 10. Ultrasonic oscillogram of a stick weld.

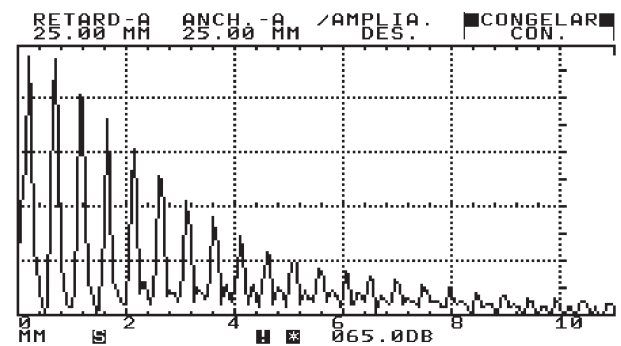


Figura 13. Oscilograma de ultrasonidos de una falta de soldadura.

Figure 13. Ultrasonic oscillogram of a no weld.

por lo que la atenuación es menor y la secuencia de ecos más larga. La distancia entre ecos equivale a la suma del espesor de las dos chapas puesto que el diámetro de la “lenteja” es mayor que la anchura de haz ultrasónico (figuras 8, 9 y 10).

- Falta de soldadura. No ha existido fusión por lo que el grano no es tan basto como el

correspondiente a una microestructura de bruto de colada. Existe poca atenuación y la secuencia de ecos es muy larga. La distancia entre ecos corresponde al espesor de una sola chapa debido a la falta de continuidad entre las dos chapas (figuras 11, 12 y 13).




Figura 14. Probeta en cruz de ensayo de tracción.

Figure 14. Specimen for cross tension testing.

Teniendo en cuenta lo anterior y aplicando el ensayo de tracción en probetas en cruz^[33] (figuras 14 y 15), el criterio establece que un punto de soldadura es:

- Válido, si la carga máxima que es capaz de soportar es igual o superior a 5 kN.
- No válido, si la carga máxima que es capaz de soportar es inferior a 5 kN.

2.4. Entrenamiento de la RNA

Para el presente trabajo se efectuaron 225 puntos de soldadura, luego para el entrenamiento de la RNA se dispone de un conjunto total de datos formado por 225 pares i/t .

Durante el entrenamiento de una RNA puede aparecer un fenómeno indeseable denominado *overfitting*, motivado porque la RNA memoriza los datos de entrenamiento en lugar de captar la estructura subyacente a los mismos. De este modo, la aparición de *overfitting* provoca una pérdida de la capacidad de generalización de la RNA^[34 y 35]. Para evitarlo, se divide el conjunto total de datos en dos:

- Un conjunto de 193 i/t pares destinado a entrenar la RNA mediante un procedimiento iterativo que actualiza el valor de los pesos sinápticos y minimiza una función error^[16 y 36].
- Un conjunto de 32 pares i/t utilizado en un procedimiento denominado “validación cruzada”, que sirve para evitar la aparición de *overfitting*. El entrenamiento se detiene si el error relativo




Figura 15. Probeta en cruz de ensayo de tracción montada sobre las mordazas.

Figure 15. Specimen for cross tension testing assembled on the clamps.

a este conjunto de validación comienza a aumentar (“parada temprana”). El procedimiento corre de forma simultánea al entrenamiento aunque no modifica el valor de los pesos sinápticos^[16 y 34-37].

El desarrollo de la RNA se ha llevado a cabo con el Neural Network Toolbox de MATLAB® 6.1. La RNA utilizada es del tipo retropropagación unidireccional multicapa. Para una RNA de M capas (incluyendo la capa de entrada), la salida de la neurona l en la capa $k + 1$ es^[38]:

$$a^{k+1}(l) = f^{k+1} \left(\sum_{j=1}^{S_k} w^{k+1}(l, j) a^k(j) + b^{k+1}(l) \right) \quad (1)$$

$$k = 1, \dots, M - 1$$

donde,

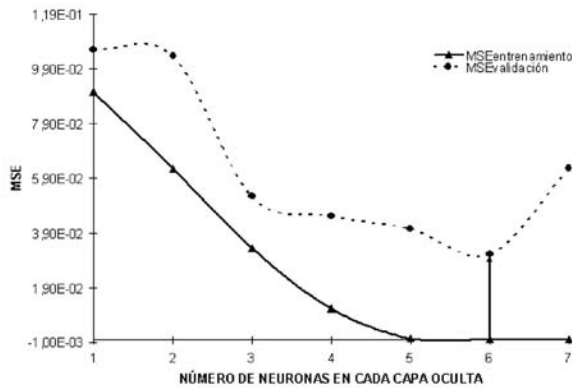


Figura 16. Curvas MSE de entrenamiento y MSE de validación-número de neuronas en las capas ocultas.

Figure 16. Training MSE and validation MSE-number of neurons in the hidden layers curves.

$$\begin{aligned} \mathbf{a}^1 &= \mathbf{i} \\ \mathbf{a}^M &= \mathbf{o} \end{aligned} \quad (2)$$

S_k es el número de neuronas en la capa k ; $w^{k+1}(l, j)$ es el peso sináptico que conecta la neurona l de la capa $k + 1$ con la neurona j de la capa k ; $b^{k+1}(l)$ es el umbral de la neurona l ; f^{k+1} es la función de transferencia de la capa $k + 1$.

La RNA dispone de cuatro capas ($M = 4$), una, de entrada con tres neuronas ($S_1 = 3$), una, de salida con una neurona ($S_4 = 1$) y dos, ocultas con el mismo número de neuronas en cada una ($S_2 = S_3$). Para determinar el número de neuronas de las capas ocultas se debe tener en cuenta que pocas neuronas no permiten a la RNA realizar un buen ajuste y que demasiadas neuronas pueden provocar *overfitting*^[37]. El error (MSE) de entrenamiento disminuye de forma monótona con el incremento del número de neuronas de las capas ocultas, pero el error (MSE) de validación, aunque también decrece inicialmente, comienza a aumentar debido al *overfitting*, al alcanzar el número de neuronas de las capas ocultas un cierto valor^[39]. Este valor es de 6 neuronas (tabla V) y es elegido porque supone un mínimo en el error de validación ($S_2 = S_3 = 6$). En la figura 16 se representan gráficamente los valores de la tabla V; para distintas RNA (diferenciadas entre sí por el número de neuronas en sus capas ocultas) se representan el error (MSE) de entrenamiento y el error (MSE) de validación correspondientes, la RNA seleccionada (3-6-6-1) es aquella que presenta un error de validación mínimo.

Se utiliza una función de transferencia sigmoidea para las capas ocultas ($f^2 = f^3 = \text{tansig}$) y una función de transferencia lineal para la capa de salida ($f^4 = \text{pulin}$)^[40].

Tabla V. Determinación del número de neuronas en las capas ocultas de la RNA

Table V. Determination of the number of neurons in the hidden layers of the ANN

RNA	MSE Entrenamiento	MSE Validación
3-1-1-1	9,055E-02	1,059E-01
3-2-2-1	6,242E-02	1,037E-01
3-3-3-1	3,346E-02	5,223E-02
3-4-4-1	1,136E-02	4,506E-02
3-5-5-1	4,502E-04	4,047E-02
3-6-6-1	2,319E-11	3,125E-02
3-7-7-1	8,709E-17	6,251E-02

El algoritmo de entrenamiento utilizado es el de Levenberg-Marquardt^[39-41].

El algoritmo de Levenberg-Marquardt actualiza los valores de los pesos sinápticos y de los umbrales (\underline{x}) del siguiente modo^[38, 42 y 43]:

$$\Delta \underline{x} = (\mathbf{J}^T(\underline{x})\mathbf{J}(\underline{x}) + \mu \mathbf{I})^{-1} \mathbf{J}^T(\underline{x})\underline{e}(\underline{x}) \quad (3)$$

Donde $\underline{e}(\underline{x})$ es el error asociado a cada par i/t de entrenamiento ($Q = 193$):

$$\begin{aligned} \underline{e}_q &= \underline{t}_q - \underline{o}_q \\ q &= 1, \dots, Q \end{aligned} \quad (4)$$

Así mismo, es la matriz Jacobiana:

$$\mathbf{J}(\underline{x}) = \begin{pmatrix} \frac{\partial e_1(\underline{x})}{\partial x_1} & \frac{\partial e_1(\underline{x})}{\partial x_2} & \dots & \frac{\partial e_1(\underline{x})}{\partial x_n} \\ \frac{\partial e_2(\underline{x})}{\partial x_1} & \frac{\partial e_2(\underline{x})}{\partial x_2} & \dots & \frac{\partial e_2(\underline{x})}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_N(\underline{x})}{\partial x_1} & \frac{\partial e_N(\underline{x})}{\partial x_2} & \dots & \frac{\partial e_N(\underline{x})}{\partial x_n} \end{pmatrix} \quad (5)$$

n es el número de pesos y umbrales en la RNA ($n = 73$ para una RNA 3 – 6 – 6 – 1) y N depende del número de pares i/t de entrenamiento, Q , y del número de neuronas de la capa de salida, S_4 :

$$N = Q \times S_4 = 193 \times 1 = 193 \quad (6)$$

El algoritmo de Levenberg-Marquardt^[38 y 42]:

— Evita el cálculo de la matriz Hessiana, $H(\underline{x})$, aproximándola a partir de la matriz Jacobiana, que se calcula de un modo menos complejo (a partir de una modificación del algoritmo de retropropagación):

$$H(\mathbf{x}) = \mathbf{J}^T(\mathbf{x}) \mathbf{J}(\mathbf{x}) \quad (7)$$

- Es una modificación de “región de confianza” del método de Gauss-Newton, donde el tamaño de dicha región depende del valor de μ .
- Se convierte en el método de descenso de máxima pendiente si μ es grande (con paso de μ^{-1}) y en el método de Gauss-Newton si μ es pequeño.

3. RESULTADOS

Para estimar la capacidad de generalización de la RNA se utilizan los mismos 32 vectores de entrada que se utilizaron en su “validación cruzada” pero no en su entrenamiento. Para cada entrada i la RNA ofrece una salida experimental \underline{q} que si es mayor que 0,75 es considerada un 1 y si es menor que 0,25 es considerada un 0 (valores entre 0,25 y 0,75 se consideran no válidos)^[44]. Se compara la salida experimental \underline{q} , obtenida para cada entrada i , con la correspondiente salida objetivo \underline{t} .

El resultado obtenido es satisfactorio ya que la RNA predice correctamente la calidad de 31 de los 32 puntos de soldadura considerados (96,8% de acierto).

4. CONCLUSIONES

Se pone de manifiesto la posibilidad de aplicar con éxito las RNA, en virtud de las características que poseen de adaptabilidad y robustez (“tolerancia a fallos”), para tareas predictivas y de clasificación en cualquier situación dentro del ámbito industrial, siempre que se cumplan unos requisitos mínimos:

- Poder disponer de un número suficiente de patrones de entrenamiento.
- Elección de una arquitectura de red y de un algoritmo de entrenamiento adecuados.
- Elección acertada de las variables de entrada a la RNA: deben ser representativas del problema pero sin incluir información redundante que complique innecesariamente el modelo neuronal.

De los variados parámetros operativos que intervienen, la elección de los tres seleccionados, se ha demostrado adecuada.

En conclusión, los resultados obtenidos ponen de manifiesto que las RNA son herramientas eficaces para predecir la calidad de puntos de soldadura por resistencia a partir de unos ciertos parámetros, adecuadamente seleccionados, controlados durante el proceso de soldeo.

REFERENCIAS

- [1] M. JOU, *J. Mater. Process. Technol.* 132 (2003) 102-113.
- [2] S. AGASHE y H. ZHANG, *Weld. J.* 82 (2003) 179s-183s.
- [3] E. BAYRAKTAR, D. KAPLAN y M. GRUMBACH, *J. Mater. Process. Technol.* 153-154 (2004) 80-86.
- [4] O. MARTÍN, Tesis Doctoral, Escuela Técnica Superior de Ingenieros Industriales, Universidad de Valladolid, 2004.
- [5] N.S. REDDY, A.K. PRASADA-RAO, M. CHAKRABORTY y B.S. MURTY, *Mater. Sci. Eng. A* 391 (2005) 131-140.
- [6] A. JIAHE, X. JIANG, G. HUIJU, H. YAOHE Y X. XISHAN, *Mater. Sci. Eng. A* 344 (2003) 318-322.
- [7] J.M. VITEK, Y.S. ISKANDER y E.M. OBLOW, *Weld. J.* 79 (2000) 33s-40s.
- [8] J.M. VITEK, Y.S. ISKANDER y E.M. OBLOW, *Weld. J.* 79 (2000) 41s-50s.
- [9] J.M. VITEK, S.A. DAVID y C.R. HINMAN, *Weld. J.* 82 (2003) 10s-17s.
- [10] J.M. VITEK, S.A. DAVID y C.R. HINMAN, *Weld. J.* 82 (2003) 43s-50s.
- [11] Y. CHO y S. RHEE, *Weld. J.* 81 (2002) 104s-111s.
- [12] M.J. KANG, Y. KIM, S. AHN y S. RHEE, *Weld. J.* 82 (2003) 238s-247s.
- [13] R. VALENTINI, V. COLLA y M. VANNUCCI, *Rev. Metal. Madrid* 40 (2004) 416-419.
- [14] S. CHO, Y. CHO y S. YOON, *IEEE Trans. Neural Netw.* 8 (1997) 874-882.
- [15] C. CANTERA, J. JIMÉNEZ, I. VARELA y A. FORMOSO, *Rev. Metal. Madrid* 38 (2002) 243-248.
- [16] J. MCBRIDE, S. MALINOV y W. SHA, *Mater. Sci. Eng. A* 384 (2004) 129-137.
- [17] UNE-EN 10002-1:2002.
- [18] ASTM, *Norma E 112-88*.
- [19] G. BARRERA, M.A. FABIÁN, M. VÉLEZ y L. VILLASEÑOR, *Rev. Metal. Madrid* 37 (2001) 403-411.
- [20] G. BARRERA, M.A. FABIÁN, y C.A. UGALDE, *Rev. Metal. Madrid* 38 (2002) 163-172.
- [21] P.T. HOULDCROFT, *Tecnología de los Procesos de Soldadura*, CEAC, Barcelona, España, 1990, pp. 166-191.
- [22] F. ABAD y J.M. BISBE, *Manual de Soldadura por Resistencia*, Consejería de Industria, Comercio y Turismo de la Junta de Castilla y León, España, 2002, pp. 11-18 (capítulo I).
- [23] R.B. McCAULEY, M.P. BENNETT, W.D. BODARY, G.C. FARRINGTON, R.J. GASSER, W.W. HURD, A.W. SCHUELER, T.W. SHEARER, J.B. SILVERBERG, *Resistance Spot Welding*, T. Lyman (Ed.), Metals Handbook Eighth Edition Volume 6 Welding and Brazing, American Society for Metals, Metals Park, Ohio, E.U.A., 1971, pp. 401-424.
- [24] J. VILLAFUERTE, *Weld. J.* 82, 11 (2003) 50-52.
- [25] J.M. RUIZ-PRIETO y A. VITORES, *Metales y Aleaciones No Férricas*, Fundación Gómez-Pardo Servicio de Publicaciones, Madrid, España, 1976, pp. 51-54.

- [26] J.M. RUIZ-PRIETO y A. VITORES, *Metales y Aleaciones No Férricas*, Fundación Gómez-Pardo Servicio de Publicaciones, Madrid, España, 1976, pp. 175-193.
- [27] O. MARTÍN y S. ALONSO, *Mantenimiento* 169 (2003) 38-43.
- [28] G. JOSEPH, *Copper: Its Trade, Manufacture, Use and Environmental Status*, K.J.A. Kundig (Ed.), ASM International, Materials Park, OH, E.U.A., 1999, pp. 277-280.
- [29] J.C. HARKNESS y A. GUHA, *Beryllium-Copper and Beryllium-Nickel Alloys*, K. Mills, J.R. Davis, J.D. Destefani, D.A. Dieterich, G.M. Crankovic y H.J. Frissell (Eds.), *Metals Handbook Ninth Edition Volume 9 Metallography and Microstructures*, American Society for Metals, Metals Park, Ohio, E.U.A., 1985, pp. 392-398.
- [30] B. MARTÍN DEL BRÍO y A. SANZ-MOLINA, *Redes Neuronales y Sistemas Borrosos*, RA-MA, Madrid, España, 1997, pp. 26-28.
- [31] J. KRAUTKRÄMER y H. KRAUTKRÄMER, *Ultrasonic Testing of Materials*, Springer-Verlag, Fourth Edition, Berlin, Alemania, 1990, pp. 462 y 463.
- [32] T. MANSOUR, *Ultrasonic testing of spot welds in thin gage steel*, P. McIntire (Ed.), *Nondestructive Testing Handbook Second Edition Volume 7 Ultrasonic Testing*, American Society for Non-destructive Testing, E.U.A., 1991, pp. 557-568.
- [33] UNE-EN ISO 14272:2002.
- [34] S. HAYKIN, *Neural Networks: A Comprehensive Foundation*, Prentice-Hall, Second Edition, Upper Saddle River, NJ, E.U.A., 1999, pp. 205-218.
- [35] C.M. BISHOP, *Neural Networks for Pattern Recognition*, Oxford University Press, New York, E.U.A., 1995, pp. 343-345.
- [36] S. GUESSASMA y C. CODDET, *Acta Mater.* 52 (2004) 5157-5164.
- [37] C.M. BISHOP, *Neural Networks for Pattern Recognition*, Oxford University Press, New York, E.U.A., 1995, pp. 9-15.
- [38] M.T. HAGAN y M.B. MENHAJ, *IEEE Trans. Neural Netw.* 5 (1994) 989-993.
- [39] K.K. THO, S. SWADDIWUDHIPONG, Z.S. LIU y J. HUA, *Model. Simul. Mater. Sci. Eng.* 12 (2004) 1055-1062.
- [40] N. SELVAKUMAR, P. RADHA, R. NARAYANASAMY y M.J. DAVIDSON, *Model. Simul. Mater. Sci. Eng.* 12 (2004) 611-620.
- [41] J. ZUECO y F. ALHAMA, *Rev. Metal. Madrid* 41 (2005) 227-232.
- [42] C.M. BISHOP, *Neural Networks for Pattern Recognition*, Oxford University Press, New York, E.U.A., 1995, pp. 290-292.
- [43] D.P. BERTSEKAS, *Nonlinear Programming*, Athena Scientific, Second Edition, Belmont, MA, E.U.A., 1999, pp. 107.
- [44] I.E. DROR, M. ZAGAESKI y C.F. MOSS, *Neural Netw.* 8 (1995) 149-160.