

Emisión Acústica y Redes Neuronales para Modelado y Caracterización del Proceso de Soldadura por Fricción Agitación

Emilio Jiménez Macías^a, Angel Sánchez Roca^{b,*}, Hipólito Carvajal Fals^b, Julio Blanco Fernández^c, Juan C. Sáenz-Diez Muro^a

^a Departamento de Ingeniería Eléctrica, Universidad de La Rioja, Edificio Departamental, C/Luis de Ulloa, 20, 26004, Logroño, España.

^b Facultad de Ingeniería Mecánica, Universidad de Oriente, Ave. Las Américas s/n, 90900, Santiago de Cuba, Cuba.

^c Departamento de Ingeniería Mecánica, Universidad de La Rioja, Edificio Departamental, C/Luis de Ulloa, 20, 26004, Logroño, España.

Resumen

En esta investigación se realiza un análisis para el modelado y la caracterización de los parámetros del proceso de soldadura por fricción agitación (FSW) a partir de las señales vibro-acústicas generadas por el proceso. El modelo se basa en una red neuronal empleada para predecir los parámetros del proceso de soldadura a partir de la medición *on-line* de las señales generadas durante su ejecución. En los ensayos se han soldado chapas de aluminio AA1050 H24 con 3mm de espesor, y las señales del proceso de soldadura han sido adquiridas empleando un sistema de adquisición NI USB-9234. Como entradas para el modelo basado en la Red Neuronal Artificial (RNA) se han empleado parámetros de caracterización de las señales a partir de la señal temporal y su descomposición a partir de la aplicación de Transformada Wavelet. Como salidas del modelo se han escogido los parámetros del proceso: velocidad de rotación, avance y diseño de la herramienta. Se ha empleado una red multicapas *feed-forward*, estudiándose diferentes topologías y algoritmos de entrenamiento. Los resultados obtenidos a partir de la comparación de los datos experimentales y los estimados por la RNA, demuestran la validez del modelo obtenido a partir de las investigaciones, el cual abre la puerta a avances en el control automático de los parámetros del proceso a partir de las señales vibro-acústicas, como línea natural de continuidad para futuras investigaciones. Copyright © 2013 CEA. Publicado por Elsevier España, S.L. Todos los derechos reservados.

Palabras Clave: Redes neuronales artificiales, análisis de señales, modelado, perceptrón multicapas, medición de vibraciones, soldadura por fricción agitación.

1. Introducción

La aplicación de técnicas de inteligencia artificial para la monitorización y el control de máquinas y procesos de manufactura es un campo relativamente novedoso, y sobre todo en constante desarrollo (Gajate and Haber, 2009) y (Flores *et al.*, 2011). Los procesos de soldadura desempeñan un papel cada vez más importante en la producción industrial, lo que ha dado lugar a la aparición de novedosas técnicas de unión. Un ejemplo de ello es la creación, hace sólo dos décadas, de las técnicas de soldadura por fricción agitación (*Friction Stir Welding*, FSW).

La novedad y las ventajas del proceso FSW abren una importante puerta para la investigación en el tema de su modelado, monitorización y control, dada su amplia aplicación para la unión de materiales empleados en las industrias aeroespacial, marítima, alimentaria, de tanques de combustibles, etc. Esas técnicas *on-line* sobre procesos de soldadura brindan la posibilidad de evaluar y controlar su calidad, haciendo más factible su automatización.

La utilización de técnicas de emisión acústica aplicadas a la

monitorización de procesos de soldadura por arco ha sido estudiada, y demostrada su capacidad de aplicación industrial. En trabajos publicados por Sánchez *et al.* (2007) y Jiménez *et al.* (2010), se obtienen expresiones matemáticas a partir de características de las señales de emisión acústica (EA) que permiten detectar la ocurrencia de inestabilidades en el proceso de soldadura.

Los primeros registros del empleo de técnicas de EA para monitorizar este tipo de procesos de FSW aparecen a principios de la década de 2000 (Chen *et al.*, 2003). Los autores procesan las señales de EA aplicando la transformada *Wavelet* para descomponer la señal en bandas de frecuencia diferentes con el fin extraer información de las mismas en lo referente a la aparición de cambios bruscos en el instante en que el hombro de la herramienta hace contacto, o deja de hacerlo, con el metal a unir. Finalmente los autores sugieren que es posible predecir la calidad de este proceso de soldadura y la formación de defectos en FSW mediante el control de las señales de AE.

Investigaciones realizadas por Okuyucu *et al.* (2007), dieron inicio a la aplicación de las Redes Neuronales Artificiales (RNA) para el modelado del proceso de FSW. En este caso, como entradas del modelo obtenido se emplearon la velocidad de soldadura y la velocidad de rotación de la herramienta, y como salidas las propiedades mecánicas de la unión (resistencia a la tracción, límite elástico, alargamiento, dureza de metal de soldadura y la dureza de la zona afectada por el calor (HAZ)).

* Autor en correspondencia.

Correos electrónicos: asroca@yahoo.com (A.S. Roca), emilio.jimenez@unirioja.es (E. Jiménez Macías), hcf151@yahoo.es (H. Carvajal Fals), julio.blanco@unirioja.es (J. Blanco Fernández), iuan-carlos.saenz-diez@unirioja.es (J.C. Sáenz-Diez Muro)

Un trabajo similar fue llevado a cabo por Yousif et al., (2008). En este caso el modelo obtenido permite predecir las propiedades mecánicas de la unión a partir de los parámetros del proceso. Sus resultados demostraron alta correlación entre los valores experimentales y los calculados por la RNA.

Fratini et al., (2009) demostraron la capacidad de aplicación de las RNA para predecir el tamaño del grano utilizando como entradas al modelo los valores numéricos de tensión, la velocidad de deformación, la temperatura y el parámetro de Zener-Hollomon.

Boldsai Khan et al., (2011), realizaron la monitorización en tiempo real de las señales de fuerza en la herramienta en los tres ejes (X,Y,Z). En este caso emplearon una RNA multicapas e información extraída de la transformada discreta de Fourier de las señales de fuerza, para predecir la aparición o no de defectos del tipo “agujero de gusano” en la unión soldada.

Paralelo a esto, Kulekci, et al. (2011) aplican las RNA en un proceso similar de soldadura denominado *Friction Stir Spot Welding*, con el objetivo de obtener la resistencia a la tracción de la unión soldada a partir de los parámetros del proceso: tiempo de soldadura, longitud del pin y velocidad de rotación de la herramienta. Los autores realizan una comparación del modelo obtenido basado en RNA con un análisis de regresión para demostrar la validez del mismo.

Existen otras investigaciones relacionadas con la temática, como los trabajos de Lakshminarayanan and Balasubramanian (2009) y Ebnonnasir et al. (2011), que modelan, para el periodo de post-soldadura, los valores de resistencia a la tracción a partir de los parámetros del proceso.

Del análisis anterior puede deducirse que son numerosos los trabajos que analizan el empleo de las RNA para el modelado del proceso de soldadura FSW, pero todos se basan en la predicción de las propiedades mecánicas y características micro-estructurales a partir de los parámetros predefinidos del proceso. La posibilidad de obtener un modelo que aplicando una técnica no invasiva, como la EA, sea capaz de predecir los valores de los parámetros del proceso, no ha sido realizada por otros investigadores. El presente artículo pretende ayudar a llenar ese “vacío”, analizando y ofreciendo una explicación detallada de la metodología y resultados obtenidos del procesamiento de las señales vibroacústicas y la obtención de un modelo empleando RNA.

La creación de un modelo de este tipo, permitirá un enfoque hacia futuras aplicaciones de monitorización y control automático de los parámetros del proceso FSW, a partir de la medición de las señales de EA emitidas por el mismo, que en definitiva constituye la línea natural de continuidad de esta investigación.

2. Materiales y Métodos

La metodología adoptada para la realización de los ensayos y el procesamiento de las señales de EA, es la misma empleada por el equipo de investigación en investigaciones previas, como por ejemplo la descrita en el trabajo precedente (Blanco et al., 2012), por lo que se remite a dicho artículo para profundizar en la misma. Esta metodología involucra la puesta a punto de la instalación experimental, elección de los niveles de los parámetros del proceso para la realización de los ensayos, la eliminación del ruido y la extracción de información útil de las señales de EA, para caracterizar el proceso.

2.1. Instalación Experimental

Para el desarrollo de la investigación fueron empleadas chapas de aluminio AA1050 H24 con 200mm de largo, 100mm de ancho y 3mm de espesor. El campo de aplicación de este tipo de aleación es muy diverso: industria automotriz, equipamiento de la industria química y alimentaria, reflectores de luz y en intercambiadores de calor, etc.

En la Fig. 1, se puede observar el esquema de la instalación experimental usada para la ejecución de los ensayos.



Figura 1: Instalación experimental.

El proceso FSW se realizó empleando una máquina CNC con control de desplazamiento. Las chapas fueron fijadas en su posición con el auxilio de bridas y la dirección de la soldadura fue normal a la dirección de laminado del metal base.

Se realizaron ensayos preliminares para definir los límites de operación prácticos de los parámetros del proceso FSW. Luego se llevó a cabo un diseño estadístico de experimentos, con la finalidad de realizar todas las mediciones necesarias para su posterior análisis por métodos estadísticos, lo que permitirá obtener conclusiones acertadas.

Se empleó un diseño de experimento factorial, por su utilidad en experimentos con varios factores con interacción entre ellos e incidencia de sus efectos conjuntos en la respuesta (señal de EA). Este tipo de diseño garantiza un número mínimo de experimentos que permita obtener resultados válidos.

Con el objetivo de reducir el error experimental, todos los experimentos fueron ejecutados tres veces bajo las mismas condiciones, empleando los niveles extremos y centrales de las variables, definidos en los ensayos previos y mostrados en la Tabla 1.

Tabla 1. Parámetros de soldadura por fricción – agitación

Parámetro	Nivel	Nivel	Nivel
	Inferior	Central	Superior
Velocidad de rotación, rpm	450	710	1120
Avance, mm/min	40	63	100

La geometría de las herramientas empleadas fue de un diámetro del pin y del hombro de 3mm y 10mm respectivamente. Se consideraron dos diseños de pin diferentes: un pin cilíndrico convencional con estrías (Herramienta 1) y un pin cilíndrico con ranuras horizontales (Herramienta 2). El perfil del hombro para ambas herramientas fue cóncavo y similar.

La adquisición de las señales de EA se realizó en las direcciones de los ejes Z e Y, tal como se aprecia en la Fig. 1. Para ello se emplearon como sensores acelerómetros piezoeléctricos acoplados al sistema de adquisición NI USB-9234 conectado al equipo informático. Todas las señales fueron muestreadas a 51.2 kHz. y procesadas empleando el software MATLAB®. Los sensores de EA fueron situados perpendicularmente en las superficies superior y lateral de la base de la chapa a soldar y se fijaron a la misma empleando un

acoplamiento roscado, con el objetivo de garantizar una buena transducción vibroacústica entre la base de la chapa y el sensor.

2.1. Procesamiento de la señal de emisión acústica

Una tarea crítica en el procesamiento de señales de EA es la selección de un apropiado rango de frecuencia que provea información acerca del comportamiento del proceso objeto de análisis. Teniendo esto en cuenta, fueron determinados los rangos de frecuencia inherentes al ruido provocado por los elementos de la máquina empleada y los ruidos externos, con el objetivo de excluirlos de los análisis.

Como técnica para el filtrado de las señales de EA se empleó la transformada Wavelet (*Discrete Wavelet Transform*, DWT), especialmente por su capacidad para obtener mayor precisión en la información de la señal en bajas frecuencias. En nuestro caso se emplearon en concreto las *Daubechies* wavelets de orden 8 con el objetivo de descomponer las señales a diferentes escalas, para obtener las bandas de frecuencias específicas que son inútiles para el análisis (ruido) y las que brindan información del estado del proceso para los diferentes niveles de los parámetros.

El algoritmo de descomposición se inicia con el paso de la señal de EA ($x(n)$) a través de un filtro digital paso-bajo con respuesta al impulso $h[n]$. La operación de filtrado de las señales de EA se corresponde con una operación matemática de convolución de las mismas con la respuesta a impulso del filtro. La operación de convolución en tiempo discreto se calcula empleando (1):

$$x[n] * h[n] = \sum_{k=-\infty}^{\infty} x[k] \cdot h[n-k] \quad (1)$$

En el caso de la DWT, se obtiene una representación tiempo-escala de la señal digital utilizando técnicas digitales de filtrado. La descomposición de la señal en diferentes bandas de frecuencia se obtiene mediante la aplicación de sucesivos filtrados, paso-alto y paso-bajo, de la señal de dominio de tiempo. La señal original $x[n]$ se pasa inicialmente a través de un filtro de paso alto $[n]$ y un filtro paso-bajo $h[n]$. Después del filtrado, de acuerdo con la regla de Nyquist, la señal puede ser sub-muestreada por un factor 2. Esto constituye un nivel de descomposición y puede expresarse matemáticamente como se muestra en (2) y (3):

$$y_{high}[k] = \sum_n x[n] \cdot g[2k-n] \quad (2)$$

$$y_{low}[k] = \sum_n x[n] \cdot h[2k-n] \quad (3)$$

Donde: $y_{high}[k]$ and $y_{low}[k]$ son las entradas de los filtros paso-alto y paso-bajo, respectivamente, tras el sub-muestreo por un factor 2.

En este caso, la aplicación de la DWT es equivalente al resultado de pasar las señales de EA para cada condición experimental. Se obtendrían las señales A8 y D1-D8 correspondientes al resultado de pasar las señales de EA a través de un filtro paso-bajo con ancho de banda resultante de [0-100 Hz]. Las señales D1–D8 se corresponden con las bandas de frecuencia [12.8, 25.6 kHz], [6.4, 12.8 kHz], [3.2, 6.4 kHz], [1.6, 3.2 kHz], [800 Hz, 1.6 kHz], [400, 800 Hz], [200, 400 Hz] y [100, 200 Hz], respectivamente.

Con la ayuda de la técnica explicada anteriormente se caracterizaron las señales temporales para los diferentes rangos de frecuencia, con el objetivo de extraer información útil de los rangos escogidos para el análisis. Se emplearon descriptores

estadísticos como la media, la mediana, la desviación estándar, etc.

Por último se realizó un análisis de varianza (ANOVA) con la finalidad de conocer qué indicador estadístico de las señales descompuestas varió de manera significativa ante los cambios en los parámetros del proceso analizados. Los parámetros finalmente escogidos se seleccionaron para usarse como entrada al modelo basado en la RNA.

2.2. Modelo basado en red neuronal artificial.

A continuación se muestra la metodología empleada para la obtención de un modelo, que a partir de las señales de EA pueda predecir los valores de los parámetros controlables del proceso de FSW, para responder a las aplicaciones futuras esperadas.

Para el desarrollo de la investigación se seleccionó una RNA perceptrón multicapas (MLP), una de las más empleadas en aplicaciones de ingeniería de este tipo, con demostrada eficacia para este proceso en investigaciones previas (Sánchez et al., 2009).

El modelo puede tener varias capas: la de entrada, la(s) oculta(s) y la de salida. La capa de entrada está compuesta por un número de nodos de entrada llamados neuronas, que reúnen todos los factores extraídos de la señal de EA y se representan por x . La topología de la red dependerá del número de capas y del número de nodos existentes en cada capa. En el presente trabajo se experimentaron varias topologías, variando el número de capas ocultas de la red, así como el número de nodos en cada capa oculta, con el objetivo de escoger la que aportara un menor error en los cálculos de los parámetros del proceso FSW.

La información de entrada a la red, es enviada a las neuronas de la(s) capa(s) oculta(s) durante el paso por el interior de la misma hasta las neuronas de salida. En este caso cada neurona de la RNA está conectada con las de la capa anterior por medio de conexiones con diferentes pesos (W). La suma ponderada de las entradas de la neurona, pasa a través de una función de activación no lineal para producir el vector de salida (y). La salida de la red puede ser calculada empleando (4).

$$y = f(W_2(f(W_1x + b_1) + b_2)) \quad (4)$$

Donde: W_1 y W_2 representan las matrices de ponderación de las neuronas de entrada-ocultas y las neuronas de salida-ocultas, respectivamente; s_1 y s_2 representan los sesgos de cada una de las neuronas de la capa oculta y de la capa de salida, y x representa el vector de entrada de la red.

Las funciones de transferencia de todas las neuronas ocultas son funciones *tangent sigmoid*, como se muestra en (5).

$$f(x) = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)} \quad (5)$$

En el caso de las neuronas de salida sus funciones de transferencias son lineales, como se muestra en (6).

$$f(x) = x \quad (6)$$

Los parámetros del proceso FSW son computados en la capa de salida, la cual contiene una neurona por cada parámetro que debe ser modelado.

Con el objetivo de introducir los patrones a la RNA fue necesaria su estandarización por medio de una etapa de pre-procesamiento. Un total de 113 patrones de entrada-salida fueron

empleados en el entrenamiento y 49 fueron empleados para comprobar el funcionamiento de la red.

La RNA fue entrenada empleando dos algoritmos de entrenamiento diferentes: el algoritmo del gradiente descendente con momento y el algoritmo de *Levenberg–Marquardt* (LM), realizándose una comparación entre ambos.

Después de examinar el comportamiento de diferentes arquitecturas de redes, los datos de prueba fueron introducidos a la RNA escogida para evaluar la capacidad del modelo de predecir las variables del proceso ante variaciones de la señal de EA.

3. Resultados y Análisis

En esta sección se muestran los principales resultados que justifican la factibilidad de empleo de las RNA para predecir los parámetros del proceso de soldadura FSW a partir de las señales de EA.

3.1. Caracterización de las señales de EA y extracción de parámetros de entrada a la RNA

La extracción de parámetros de las señales de EA desempeña un papel determinante en la obtención del modelo basado en RNA.

La Fig. 2a muestra los gráficos de la señal de EA, ya filtrada, correspondiente a la condición con velocidad de rotación de la herramienta de 450 rpm, velocidad de avance de 40 mm/min y la herramienta con pin cilíndrico con estrías.

La eliminación del ruido constituyó la etapa inicial de la caracterización de las señales de EA y se realizó como se indicó en la sección anterior, con resultados accesibles en detalle en el trabajo (Blanco *et al.*, 2012). En la Fig. 2b se observa la unión soldada empleando los parámetros antes mencionados, que dio lugar a la señal de EA mostrada en la Fig. 2a.

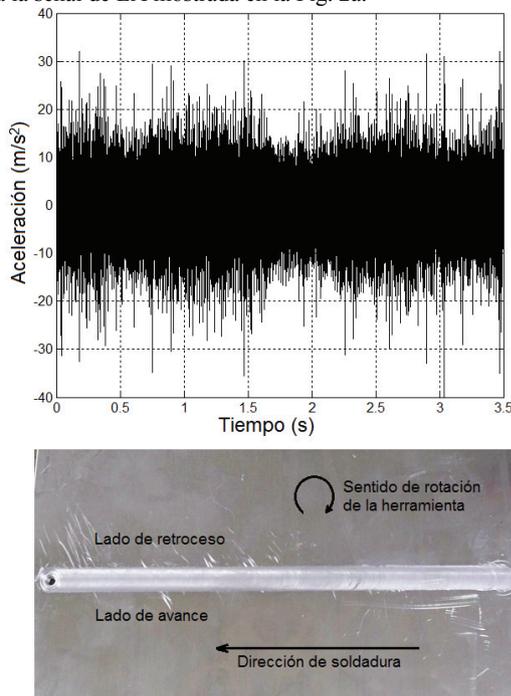


Figura 2: a) Señal temporal de EA; b) unión soldada

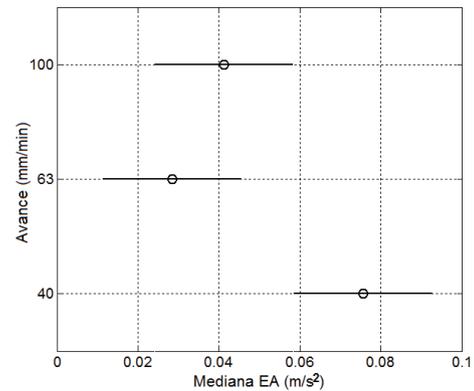


Figura 3: Influencia del avance en la mediana Med_{EA} de la señal de EA

Como resultado de la aplicación del análisis de varianza (ANOVA) a los parámetros estadísticos extraídos de las señales de EA captadas (RMS, media, mediana, varianza, coeficiente de variación, moda), sólo la mediana de las señales globales (Med_{EA}) fue influenciada por cambios en los niveles de los parámetros del proceso FSW. La Fig. 3 muestra la gráfica de ANOVA para el caso de las medianas ante cambios en el avance de la herramienta.

Como puede observarse en la Fig. 3, los cambios en el avance de la herramienta producen variaciones significativas en los valores de las medianas de la señal global adquirida. Teniendo esto en cuenta, la mediana de la señal adquirida fue elegida como entrada (x_1) a la RNA.

Debido a la complejidad de los fenómenos de deformación plástica que ocurren durante el proceso de soldadura FSW, y la elevada interacción entre sus variables, se hace necesaria la elección de otros parámetros que permitan brindar una estimación más certera de los parámetros y sirvan de entrada a la RNA.

Para la obtención de los parámetros estadísticos adicionales se empleó la DWT aplicada a cada una de las señales adquiridas, en concreto la DWT de 8 niveles y una wavelet madre *Daubechies* (Db5), tal como se indicaba en la sección 2.1.

Como resultado de su aplicación se obtuvieron series de señales temporales para cada una de las bandas de frecuencia definidas. En la Fig. 4 se muestran los gráficos obtenidos como resultado de la aplicación de la DWT a la señal de EA mostrada en la Fig. 2.

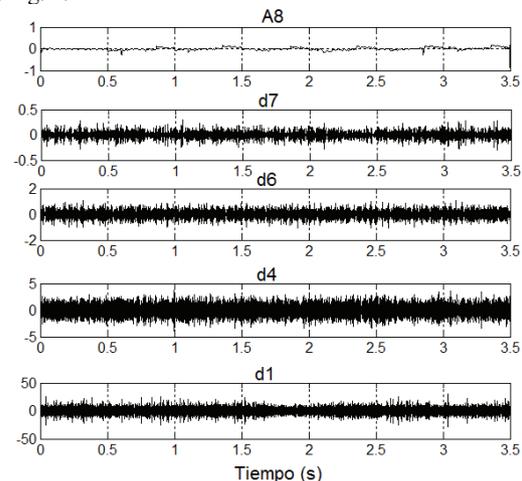


Figura 4: Transformada *wavelet* de las bandas de frecuencia seleccionadas.

Tabla 2. Entradas de la RNA.

Entrada	Parámetro de la señal de EA	Símbolo
x_1	Mediana de la señal de EA	Med_{EA}
x_2	Media de A8 DWT	M_{A8}
x_3	Mediana de A8 DWT	Med_{A8}
x_4	Media de D7 DWT	M_{D7}
x_5	Media de D6 DWT	M_{D6}
x_6	Media de D4 DWT	M_{D4}
x_7	Media de D1 DWT	M_{D1}
x_8	Mediana de D1 DWT	Med_{D1}

Cada una de las señales obtenidas fue caracterizada estadísticamente. Se excluyeron de los análisis los rangos de frecuencia asociados al ruido. Como resultado del análisis estadístico ANOVA de cada una de las señales descompuestas mediante la aplicación de la DWT, fueron seleccionados 7 nuevos descriptores estadísticos como entradas de la RNA.

En la Tabla 2 se muestran las siete nuevas entradas escogidas ($x_2 \dots x_8$) y la previamente seleccionada (x_1) de la señal de EA adquirida durante la realización del proceso FSW.

Las nuevas entradas definidas mostraron grupos significativamente diferentes ante los cambios en los niveles de los parámetros del proceso FSW y no fueron influenciadas por el ruido.

3.2. Selección de patrones para el entrenamiento y validación del modelo.

Las RNA, como la empleada en esta investigación, requieren un entrenamiento antes de ser empleadas para los fines definidos. El entrenamiento le permitirá calcular los pesos y sesgos de la RNA, con la finalidad de lograr la relación deseada entre entradas y salidas.

Los diagramas tiempo–frecuencia (espectrogramas) constituyen un método eficaz para estudiar muchas señales en ingeniería, incluyendo señales de EA. El espectrograma se calcula como una secuencia de transformada rápida de Fourier de segmentos de datos (ventana). En el espectrograma, el eje de tiempo es el eje horizontal (abscisas), y la frecuencia se observa en el eje vertical (ordenadas).

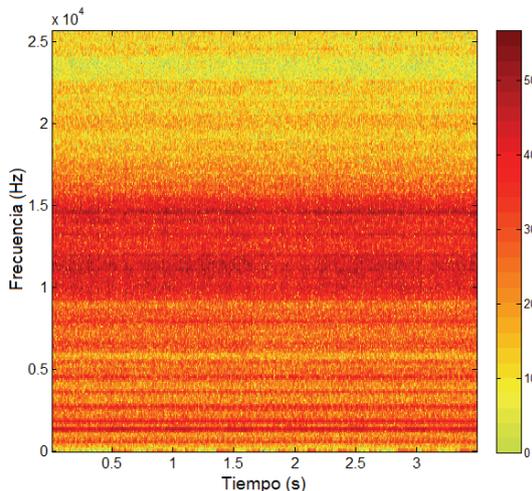


Figura 5: Diagrama tiempo–frecuencia de la señal de EA

En la Fig. 5 se muestra el diagrama de tiempo-frecuencia de la señal de EA para la condición de velocidad de rotación de la herramienta de 710 rpm, velocidad de avance de 40 mm/min y la herramienta con pin cilíndrico con estrías.

Como puede apreciarse en la Fig. 5, el proceso de soldadura FSW no presentó anomalías en su funcionamiento, lo que puede observarse en la continuidad de los espectros de la señal de EA a lo largo del tiempo. Teniendo esto en cuenta, así como el diseño experimental realizado (54 ensayos en total, consistentes en una serie de 18 ensayos y 2 réplicas de esa serie), se decidió seccionar las señales adquiridas durante la realización de la soldadura en intervalos de 3 segundos para aumentar así el número de patrones.

Con todo ello, de los ensayos realizados se extrajeron un total de 162 patrones. De ellos el 70% (113) se emplearon durante el entrenamiento de la RNA y el restante 30% (49), se emplearon durante la etapa de validación del modelo basado en RNA.

3.3. Entrenamiento y topología de la RNA

El entrenamiento de la red perceptrón multicapas se llevó a cabo de manera supervisada y empleando el método de retro-propagación del error. Se emplearon los algoritmos de entrenamiento de gradiente descendente con momento y el algoritmo de LM.

En el caso de la topología, el número de entradas y salidas de la RNA estará en correspondencia con las necesidades de la aplicación, es decir, con los requerimientos del proceso objeto de estudio. El número de nodos en la(s) capa(s) oculta(s), por experiencia y uso habitual, se elige mayor y se ajusta según el error deseado, y considerando el menor tamaño posible de la RNA para disminuir los problemas computacionales y disminuir los tiempos de procesamiento.

En la Fig. 6 se observan las curvas del error obtenidas durante el proceso de entrenamiento para cada uno de los algoritmos evaluados, empleando una topología de ocho entradas, una capa oculta con 14 nodos y tres neuronas de salida, es decir, una topología [8-14-3].

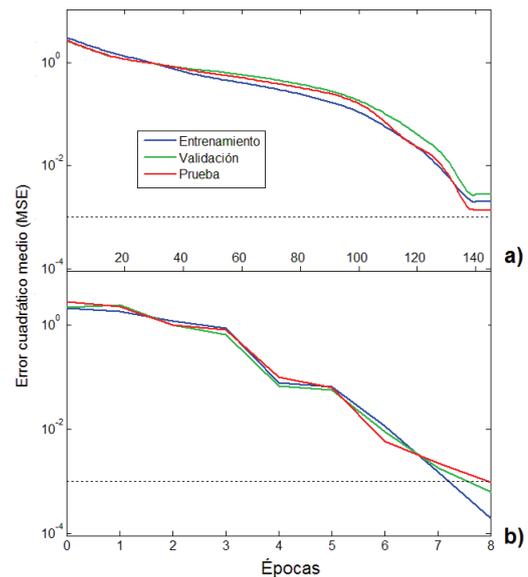


Figura 6: Curvas de error durante el entrenamiento. a) Método de gradiente descendente con momento, b) algoritmo de Levenberg-Marquardt

Puede apreciarse en la Fig. 6, que en el entrenamiento empleando el algoritmo de optimización numérica LM, se convergió al error final establecido para las salidas de la RNA (0.001), con una mayor rapidez, y en sólo 8 épocas. En este caso los resultados obtenidos fueron superiores para la RNA entrenada con el algoritmo de LM.

La Tabla 3 muestra un análisis comparativo de los resultados obtenidos para cada uno de los algoritmos comparados. Tal como se aprecia en esa tabla, se probaron 3 topologías de RNA. La evaluación de las diferentes arquitecturas con los dos algoritmos de entrenamiento demostró que la red con una capa oculta (14 neuronas en la capa oculta) entrenada por el algoritmo de LM mostró un menor error final. Teniendo esto en cuenta, se seleccionó dicha topología para la realización y validación del modelo.

La arquitectura de red seleccionada cuenta de 8 entradas, 14 neuronas ocultas con función de activación no lineal (*tangent sigmoid*) y tres neuronas de salida (velocidad de rotación, avance y geometría de la herramienta), con función de activación lineal. La topología del modelo de RNA seleccionada [8-14-3] es presentada en la Fig. 7.

El funcionamiento del modelo basado en RNA se rige por (7), (8) y (9) tal como se muestra a continuación:

$$Geometria = N_1W_{1,1}^2 + N_2W_{1,2}^2 + N_3W_{1,3}^2 + N_4W_{1,4}^2 + \dots + N_{14}W_{1,14}^2 + b_{2,1}^2 \quad (7)$$

$$Veloc = N_1W_{2,1}^2 + N_2W_{2,2}^2 + N_3W_{2,3}^2 + N_4W_{2,4}^2 + \dots + N_{14}W_{2,14}^2 + b_{2,1}^2 \quad (8)$$

$$Avance = N_1W_{3,1}^2 + N_2W_{3,2}^2 + N_3W_{3,3}^2 + N_4W_{3,4}^2 + \dots + N_{14}W_{3,14}^2 + b_{3,1}^2 \quad (9)$$

donde: $N_i = f(W^i \cdot x + b_i)$ $i = 1, 2, 3, 4, \dots, 14$

Una vez obtenidas las ecuaciones de la RNA, se procedió a validar los resultados obtenidos. Para ello se empleó el 30% de los patrones no usados durante la etapa de entrenamiento de la red.

En la Tabla 4 se muestran los valores de las tres salidas de la RNA correspondientes a los parámetros del proceso FSW, para los patrones correspondientes a las uniones realizadas con la herramienta con pin con estrías.

Tabla 3. Comparación entre algoritmos empleados.

Topología (entrada-oculta-salida)	Número de épocas	Tiempo (min)
Gradiente descendente con momento		
8-10-3	198	0:33
8-14-3	145	0:18
8-20-3	153	0:28
Optimización numérica <i>Levenberg-Marquardt</i>		
8-10-3	12	0:01
8-14-3	8	0:00
8-20-3	8	0:01

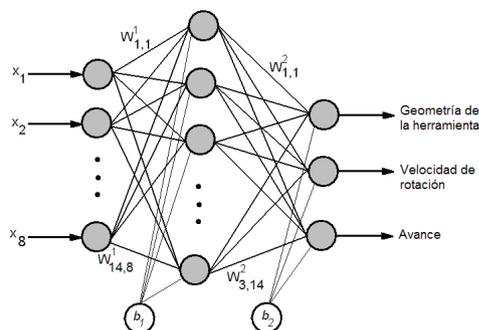


Figura 7: Topología de la RNA seleccionada.

Tabla 4. Parámetros Experimentales vs. Estimados por RNA

Velocidad de rotación (real/predicho)	Avance (real/predicho)	Geometría de la herramienta (real/predicho)
710/ 721,13	40/ 41,28	1/ 1,02
710/ 714,51	63/ 63,19	1/ 1,00
450/ 455,58	63/ 63,06	1/ 0,99
450/ 447,58	40/ 39,71	1/ 0,97
1120/ 1112,99	40/ 40,52	1/ 0,93
450/ 456,09	100/ 100,76	1/ 0,97
1120/ 1118,14	63/ 62,82	1/ 1,00
1120/ 1116,00	100/ 99,57	1/ 1,01

Los resultados mostrados en la Tabla 4, demuestran que para la topología seleccionada puede obtenerse más de un 95% de precisión en la predicción de los parámetros del proceso FSW a partir de características de las señales de EA monitorizadas *on-line*. El empleo de una topología con un mayor número de neuronas y capas ocultas puede traer como consecuencia un mayor tiempo de cálculo del modelo y retrasos en la toma de decisiones, lo que podría causar problemas si se emplea el modelo para el control automático de los parámetros del proceso.

En la Fig. 8 se muestra una comparación entre los valores numéricos calculados por el modelo *versus* los valores reales de las variables del proceso FSW.

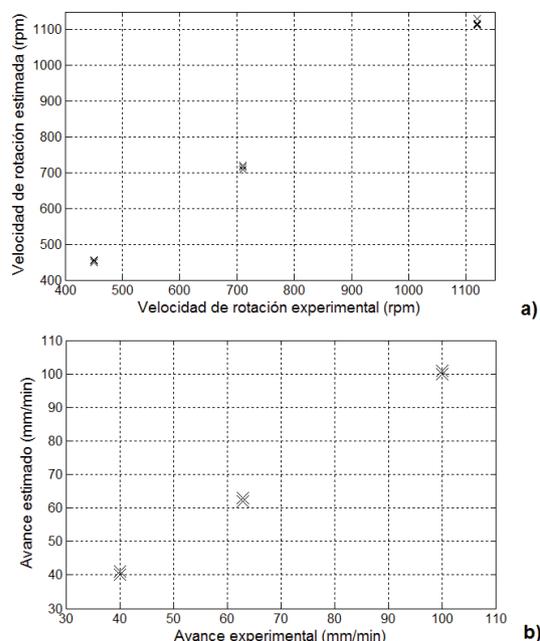


Figura 8: Validación del modelo. a) velocidad de rotación; b) avance

Como se observa en la Fig. 7, el error de estimación de los parámetros del proceso es muy pequeño, lo que corrobora que el modelo basado en la RNA representa el proceso de soldadura de manera adecuada y puede ser empleado en futuras investigaciones para el control de los parámetros de velocidad de rotación y avance de la herramienta, así como para la emisión de alarma ante cambios en la geometría de la herramienta, todo ello a partir de la medición de las señales de EA generadas durante la realización del proceso FSW.

4. Conclusiones

El estudio realizado evalúa la posibilidad del empleo de una RNA para predecir los parámetros del proceso FSW a partir del tratamiento de las señales de EA generadas durante su realización. Se puede concluir que:

- Los resultados muestran que el nuevo modelo obtenido, basado en RNA, es efectivo para predecir los parámetros del proceso FSW basado en la caracterización de las señales de EA provenientes del mismo. Los parámetros del proceso fueron identificados correctamente en un 99% de los casos.
- Las señales de EA en determinados rangos de frecuencia proveen de información útil, acerca de cambios en los parámetros del proceso FSW.
- El algoritmo LM muestra mejores prestaciones que el de gradiente decreciente para este proceso.
- El valor de la media de las señales de EA es uno de los parámetros estadísticos que presenta gran influencia por parte de los parámetros del proceso.
- Las técnicas de análisis basadas en *Wavelet* pueden ser empleadas como una herramienta para extraer características importantes de las señales de EA para la caracterización de procesos complejos, como lo es el FSW tratado en esta investigación.
- La investigación proporciona un nuevo método no destructivo de modelado para estimar los parámetros del proceso soldadura sin interferir en la operación durante los procesos de soldadura.

English Summary

Neural Networks and Acoustic Emission for Modelling and Characterization of the Friction Stir Welding Process.

Abstract

This paper presents an analysis of the correlation between acoustic emission (AE) signals and the main parameters of friction stir welding (FSW) process, based on artificial neural networks (ANN). The AE signals have been acquired by the data acquisition instrument NI USB-9234, applied during the welding process carried out on plates of 3mm thick of aluminium AA1050 alloy. Statistical and temporal parameters of decomposed EA signals using Wavelet Transform (WT) have been used as input of the ANN, while the outputs of model include the welding parameters: tool rotation speed and travel speed, as well as the tool profile. A multilayer feed-forward ANN has been selected and trained, using different algorithms and network architectures. The parameters provided by the ANN constitute the model and the characterization of the FSW process; finally an analysis of the comparison between the measured and the calculated data is presented, validating the results. The model obtained can be used to develop the automatic control of the parameters of the FSW process, based on vibro-acoustic signals, which constitutes the following step in this research line.

Keywords: Artificial neural networks, signal analysis, modelling, multilayer perceptron, vibration measurement, friction stir welding

Agradecimientos

Esta investigación ha sido sufragada parcialmente por el Proyecto Nacional del Gobierno español DPI2011-25007. “Soldadura por fricción-agitación de materiales disimilares. Caracterización por Técnicas de Emisión Acústica e Inteligencia Artificial”.

Referencias

- Boldsaikhana E., Corwin EM., Logarb AM., Arbagast WJ., 2011. The use of neural network and discrete Fourier transform for real-time evaluation of friction stir welding. *Applied Soft Computing*, 11, 4839–4846. DOI: 10.1016/j.asoc.2011.06.017
- Chen Ch., Kovacevic, K., Jandgric, D., 2003. Wavelet transform analysis of acoustic emission in monitoring friction stir welding of 6061 aluminum. *International Journal of Machine Tools & Manufacture*, 43, 1383–1390. DOI: 10.1016/S0890-6955(03)00130-5
- Fernandez JB., Roca, AS., Fals, HC., Macias, EJ., de la Parte, MP., 2012. Application of the vibro-acoustic signals to evaluate tools profile changes in the friction stir welding on AA1050 H24 alloy. *Science and Technology of Welding and Joining*. (no publicado). DOI: 10.1179/1362171812Y.0000000040
- Flores, VM., Corre, M., Alique JR., 2011. Modelo Pre-proceso de predicción de la calidad superficial en Fresado a Alta Velocidad basado en Softcomputing. *Revista Iberoamericana de Automática e Informática Industrial*, 8, 1, 38–43. DOI:10.4995/RIAI.2011.01.06
- Fratini, L., Buffa, G., Palmeri, D., 2009. Using a neural network for predicting the average grain size in friction stir welding processes. *Computers and Structures*, 87, 1166–1174. DOI: 10.1016/j.compstruc.2009.04.008
- Gajate A., Haber, RE., 2009. Control Neuroborroso en Red. Aplicación al Proceso de Taladrado de Alto Rendimiento. *Revista Iberoamericana de Automática e Informática Industrial*, 6, 1, 31–38.
- Kulecki MK., Esme U., Er O., Kazancoglu Y., 2011. Modeling and prediction of weld shear strength in friction stir spot welding using design of experiments and neural network. *Materialwissenschaft und Werkstofftechnik*, 42, 11, 990–995. DOI: 10.1002/mawe.201100781
- Lakshminarayanan, AK., Balasubramanian, V., 2009. Comparison of RSM with ANN in predicting tensile strength of friction stir welded AA7039 aluminium alloy joints. *Trans. Nonferrous Met. Soc. China*, 19, 9–18. DOI: 10.1016/S1003-6326(08)60221-6
- Macias, EJ., Roca, AS., Fals, HC., Fernandez JB., de la Parte, MP., 2010. Time–frequency diagram applied to stability analysis in gas metal arc welding based on acoustic emission. *Science and Technology of Welding and Joining*, 15, 3, 226–232. DOI: 10.1179/136217110X12665778348588
- Okuyucu, H., Kurt, A., Arcaklioglu, E., 2007. Artificial neural network application to the friction stir welding of aluminum plates. *Materials and Design*, 28, 78–84. DOI: 10.1016/j.matdes.2005.06.003
- Roca, AS., Fals, HC., Fernandez JB., Macias, EJ., Adan FS., 2007. New stability index for short circuit transfer mode in GMAW process using acoustic emission signals. *Science and Technology of Welding and Joining*, 12, 5, 460–466. DOI: 10.1179/174329307X213882
- Roca, AS., Fals, HC., Fernandez JB., Macias, EJ., de la Parte, MP., 2009. Artificial neural networks and acoustic emission applied to stability analysis in gas metal arc welding. *Science and Technology of Welding and Joining*, 14, 4, 117–124. DOI: 10.1179/136217108X382981
- Yousif, YK., Daws, KM., Kazem, BI., 2008. Prediction of Friction Stir Welding Characteristic Using Neural Network. *Jordan Journal of Mechanical and Industrial Engineering*, 2, 3, 151–155.