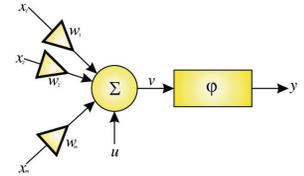


Clasificación del tratamiento térmico de aceros con ensayos no destructivos por corrientes inducidas mediante redes neuronales



HEAT-TREATMENT CLASSIFICATION OF STEELS WITH NONDESTRUCTIVE EDDY CURRENT TESTING USING NEURAL NETWORKS

DOI: <http://dx.doi.org/10.6036/7083> | Recibido: 23/01/2014 • Aceptado: 20/05/2014

Javier Garcia-Martin ^{1,2}, Víctor Martínez-Martínez ², Jaime Gomez-Gil ²

¹ INGENIERÍA Y SISTEMAS DE ENSAYOS NO DESTRUCTIVOS (ISEND). Parque Tecnológico de Boecillo. C/Luis Proust, 10 - 47151 Valladolid. Tfno. +34 983 132307.

² UNIVERSIDAD DE VALLADOLID. Departamento de Teoría de la Señal, Comunicaciones e Ingeniería Telemática. Campus Miguel Delibes - 47011 Valladolid. jgarmar@ribera.tel.uva.es

ABSTRACT

Eddy current-nondestructive techniques are increasingly present in industry because of the growing quality control demand. In addition to the classical crack detection, eddy currents permit physic and metallurgic properties detection in steels. The impedance values of one eddy-current-generating coil permit to differentiate steel pieces with different heat treatments. These impedance values can be processed with Artificial Neural Networks (ANNs) to implement automatic and efficient classifiers.

In this article two ANN classifiers that processed monofrequency impedances and one ANN classifiers that processed multifrequency impedances are compared. The impedances were extracted from two steel samples sets with different heat treatments. The predominant microstructure in the first set was martensite and bainite and in the second one was perlite. As experimental results, the monofrequency classification accuracy rate was 90% while the multifrequency classification reached 99.9%, the theoretical computing workload of the best multifrequency classifier was between 33% and 50% lower than the best monofrequency classifier, and the multifrequency classification execution time was 22% smaller than the measured time using the monofrequency methods.

Keywords: Classification algorithms, heat treatment, steel, artificial neural networks, nondestructive testing, eddy currents.

RESUMEN

Las técnicas de ensayos no destructivos basadas en corrientes inducidas están cada vez más presentes en la industria debido a la creciente demanda de los controles de calidad. Además de la detección clásica de defectos, con corrientes inducidas es también posible detectar propiedades físicas o metalúrgicas en piezas de acero. Las medidas de impedancia de un solenoide que genera corrientes inducidas en el acero permiten diferenciar piezas que han sido sometidas a tratamientos térmicos diferentes, las cuales, pueden procesarse después con Redes Neuronales Artificiales (RNAs) para implementar clasificadores automáticos y eficientes.

En este artículo se comparan dos clasificadores de piezas implementados con RNAs que procesaron impedancias monofrecuencia y un tercer clasificador RNA que procesó con impedancias multifrecuencia. Las impedancias fueron extraídas de dos grupos de piezas de acero con tratamientos térmicos diferentes, siendo la martensita y la bainita las microestructuras predominantes en el primer grupo y la perlita en el segundo.

Como resultados experimentales se obtuvo una tasa de acierto de clasificación monofrecuencia cercana al 90% y de un 99.9% en el caso multifrecuencia, una carga computacional teórica del clasificador multifrecuencia entre un 33% y un 50% inferior a la de los métodos monofrecuencia y un tiempo de ejecución de la clasificación multifrecuencia un 22% inferior al de los métodos monofrecuencia.

Palabras clave: Algoritmo de clasificación, tratamiento térmico, acero, redes neuronales artificiales, ensayos no destructivos, corrientes inducidas.

1. INTRODUCCIÓN

Las propiedades mecánicas del acero dependen tanto de su composición química como de su microestructura cristalina. Numerosas piezas de acero se someten en la industria a tratamientos térmicos para modificar esta microestructura sin cambiar la composición y conseguir unas propiedades mecánicas controladas de dureza, resistencia al desgaste y tenacidad. Las variables clave de los tratamientos térmicos son la composición química de partida y, atendiendo al ciclo térmico, la temperatura, la duración y la velocidad de enfriamiento [1]. Entre los diferentes tipos de tratamientos térmicos se encuentran los de templado, que realizan un calentamiento seguido de un enfriamiento rápido controlado del acero para incrementar la dureza y resistencia provocando transformaciones microestructurales martensíticas y/o bainíticas [2].

Los métodos más tradicionales para la medición de dureza en el acero se basan en los durómetros de indentación de tipo *Rockwell*, *Brinell* y *Vickers*. Como alternativa a estos test se encuentran los ensayos no destructivos con corrientes inducidas, que además de la aplicación tradicional de detección de defectos, permiten determinar propiedades físicas y metalúrgicas del acero [1]. Las técnicas de corrientes se caracterizan por su fiabilidad para la caracterización de los tratamientos térmicos en entornos industriales y ahorran costes de fabricación [3]. Estas técnicas aportan ventajas sobre los métodos tradicionales de indentación pues permiten ensayos sin contacto y sin retardos significativos permitiendo el análisis de la totalidad de la producción [4]. Además, proporcionan ensayos de alta sensibilidad, alta velocidad de detección y permiten ser automatizados [5].

La potencia de las técnicas basadas en corrientes para clasificar piezas de acero según el tratamiento térmico recibido se encuentra en el procesado de la información proporcionado por el equipo de instrumentación. Uno de los métodos que están adquiriendo una mayor importancia en la actualidad son las Redes Neuronales Artificiales (RNAs), que son paradigmas de aprendizaje y procesamiento cuya principal característica es la capacidad de inferir relaciones entre conjuntos de datos de entrada y de salida [6]. Las RNAs aportan las ventajas de poder trabajar con modelos con un número elevado de entradas o salidas sin incrementos en la complejidad y la posibilidad de clasificación de datos no lineales [7].

En este artículo se combinan las técnicas no destructivas de corrientes mono y multifrecuencia y redes neuronales, presentándose una comparativa entre tres RNAs diferentes que clasifican piezas de acero en función del tratamiento térmico recibido. En la bibliografía se pueden encontrar redes neuronales que procesan datos de ensayos con corrientes inducidas para la caracterización de defectos en piezas, como en los trabajos de Chady *et al.* [8] y Wrzuszczak *et al.* [9]. Sin embargo consideramos novedosa esta combinación de ensayos multifrecuencia y redes para determinar el tratamiento térmico en el acero, por lo que consideramos que el trabajo es una aportación que puede contribuir a mejorar los controles de calidad robotizados en las líneas de producción industriales.

2. CLASIFICACIÓN DE TRATAMIENTO TÉRMICO CON CORRIENTES INDUCIDAS

La aproximación de piezas de acero a una sonda inductiva alimentada por un oscilador provoca la generación de corrientes eléctricas inducidas en la superficie y en el interior de dichas piezas conforme al efecto pelicular [4]. Las corrientes $J(z)$ de la Ecuación (1) son más intensas en la superficie J_{max} y descienden exponencialmente con la profundidad dependiendo del acero aproximado según su conductividad σ , su permeabilidad μ_r, μ_o y la frecuencia f de la oscilación. La disminución de las corrientes se cuantifica con el parámetro “profundidad estándar de penetración” δ que se define en la Ecuación (1). Para una explicación más extensa sobre el comportamiento de las corrientes inducidas en los metales el lector puede consultar los libros de Mix [10] y de Davis [11].

$$J(z) = J_{max}e^{-z/\delta}, \text{ siendo } \delta = \sqrt{\frac{1}{\pi f \mu_o \mu_r \sigma}} \quad (1)$$

El flujo de corrientes inducidas en las piezas de acero provoca un cambio en la impedancia inicial del solenoide $Z_{aire} = R_a + j2\pi f L_a$. La detección de tratamiento térmico utilizando corrientes inducidas se basa en que su flujo depende de la conductividad eléctrica σ y de la permeabilidad magnética relativa μ_r del acero que se aproxima. A su vez, estas variables guardan relación con la microestructura metalúrgica de los diagramas de hierro-carbono. De esta manera un grupo de piezas de acero sometidas a un tratamiento térmico genera una impedancia del solenoide en aproximación $Z_1 = R_1 + j2\pi f L_1$ que es ligeramente diferente $Z_2 = R_2 + j2\pi f L_2$ en el caso de otro grupo de piezas sometidas a un tratamiento distinto.

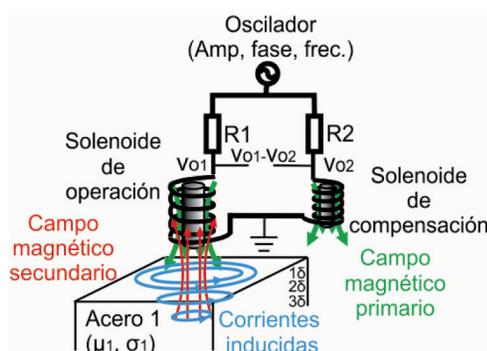


Figura 1: Generación de corrientes inducidas para la clasificación de piezas de acero por su tratamiento térmico

Los equipos de instrumentación de corrientes se comportan como extractores de impedancias y suelen mostrar un plano de impedancia bidimensional que representa en un eje la parte real $Re(Z)$ y en el otro la parte imaginaria $Im(Z)$. El final de las curvas de aproximación (o *lift-off*) de las m muestras tomadas de las piezas con tratamiento 1 forman una nube de puntos próximos $\{Z_{1,1}, Z_{1,2} \dots Z_{1,m}\}$, mientras que las n muestras tomadas de las piezas con tratamiento 2 generan otra nube de puntos cercanos $\{Z_{2,1}, Z_{2,2} \dots Z_{2,n}\}$ (Figura 2). El trabajo de clasificación consiste en calcular la mejor frontera de decisión bidimensional que maximice la tasa de acierto de clasificación de piezas, para lo que pueden emplearse métodos basados en RNAs como los presentados en este estudio.

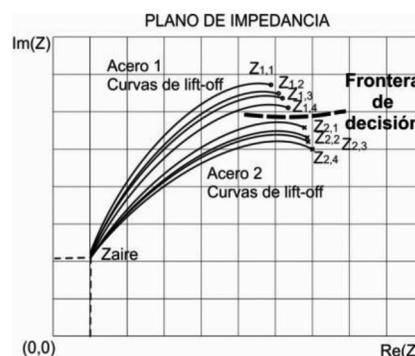


Figura 2: Plano de impedancia. Curvas de lift-off de aproximación de piezas con tratamientos térmicos 1 y 2 a un solenoide y frontera de decisión de clasificación

3. REDES NEURONALES

Esta sección muestra una breve introducción a las redes neuronales. Para una explicación más extensa y completa sobre su funcionamiento puede consultar los libros de Hayking [6] y Bishop [12].

3.1. LA NEURONA: UNIDAD ELEMENTAL DE PROCESADO

Las redes neuronales son herramientas complejas de procesamiento de datos inspiradas en el sistema nervioso de los animales. Las redes están compuestas por múltiples neuronas que constituyen unidades básicas de procesamiento capaces de generar un valor de salida en función de unos valores de entrada. En la Figura 3 se muestra la estructura de la neurona básica más común denominada *perceptrón*, la cual multiplica los valores de entrada (X_1, X_2, \dots, X_m) por los pesos (W_1, W_2, \dots, W_m), suma todos estos valores junto con umbral de activación (u) y aplica a su resultado v la función de activación ϕ . La tangente hiperbólica, la arcotangente o las funciones lineales son algunos ejemplos de ϕ .

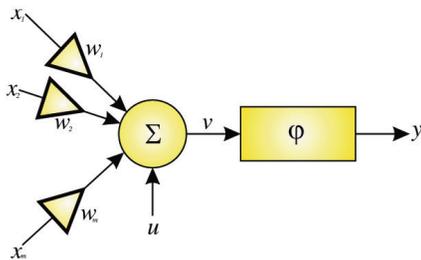


Figura 3: Estructura del perceptrón

3.2. ESTRUCTURA DE UNA RNA

El gran potencial de las RNAs se consigue con la formación de redes que interconectan perceptrones, de modo similar a las neuronas que se agrupan para constituir un cerebro. Sin embargo, existe una diferencia abismal entre el cerebro humano y las RNAs ya que éste consta de unas 10^{11} neuronas [13], mientras que el número de neuronas de las RNAs no suele exceder de las decenas.

3.2.1. Estructura de capas

Las neuronas de las RNAs se estructuran en capas, distinguiéndose la capa de entrada, cuyas neuronas únicamente introducen los datos en la red, las capas ocultas, que realizan el núcleo del procesamiento, y la capa de neuronas de salida, que muestra las variables de salida. Tanto el número de capas ocultas como el número de neuronas en cada capa oculta son parámetros de diseño de las redes.

3.2.2. Interconexión de neuronas

Las RNAs se pueden clasificar también en función de las conexiones entre neuronas: por un lado existen las RNAs *feedforward*, con conexiones exclusivamente hacia adelante entre las neuronas de una capa n -ésima con las neuronas de capas siguientes $\{n + 1, n + 2, \dots\}$; por el otro, están las RNAs *feedback*, con conexiones hacia atrás entre neuronas de una misma capa o con capas anteriores.

Además las RNAs se pueden clasificar en función del número de conexiones de cada neurona, distinguiéndose dos tipos. Por un lado, las “redes totalmente conectadas” tienen la salida de cada neurona de una capa conectada a las entradas de todas las neuronas de la capa siguiente. Por otro lado, las “redes localmente conectadas” no tienen todas las salidas de las neuronas de una capa conectadas a la entrada de las neuronas de la capa siguiente. A efectos aclaratorios en la Figura 4 se muestra una RNA multicapa *feedforward* totalmente conectada.

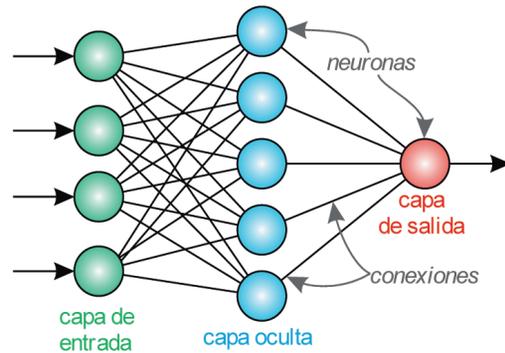


Figura 4: Estructura de una RNA feedforward totalmente conectada

3.3. ENTRENAMIENTO

El entrenamiento es la etapa posterior a la definición de la estructura de la RNA.

3.3.1. Tipos de aprendizaje

Los métodos empleados en el entrenamiento pueden ser supervisados o no supervisados en función de la información proporcionada a la red. En el aprendizaje supervisado se proporcionan a la red tanto los valores de entrada como los de salida asociados a dichas entradas. El aprendizaje en este caso consiste en ajustar los pesos y umbrales de activación de las neuronas, con el fin de minimizar el error al estimar esos valores de salida. Por otro lado, en el aprendizaje no supervisado únicamente se proporcionan a la red valores de entrada y ésta se ajusta infiriendo relaciones matemáticas entre las entradas.

En el caso del aprendizaje supervisado del perceptrón multicapa de tipo *feedforward*, el método más empleado es el *backpropagation* [14], y para su implementación el algoritmo más utilizado es el de *Levenberg-Marquardt*, el cual combina algoritmos de descenso en gradiente y de optimización *Gauss-Newton* [15, 16].

3.3.2. Criterio de parada

El entrenamiento de una RNA es un proceso iterativo que requiere un criterio de parada. Algunos criterios son la parada transcurrido un tiempo de iteración o alcanzado un número de iteraciones prefijado, la parada al alcanzar un error aceptable, la parada al alcanzar una tasa de acierto de un clasificador aceptable o la parada al detectar que los resultados no mejoran al aumentar el número de iteraciones.

3.3.3. Inicialización

El proceso de entrenamiento depende de la inicialización de la RNA, de modo que diferentes inicializaciones pueden conducir a RNAs con resultados distintos. Por ello, se suelen

variar los valores de inicialización de las RNAs en cada iteración para explorar el espacio vectorial de pesos y umbrales de activación de una manera completa y mejorar el resultado del entrenamiento. En la *Figura 5* se presenta un esquema del entrenamiento iterativo para mejorar posibles malos resultados debidos a una mala inicialización.



Figura 5: Esquema del proceso de entrenamiento de una RNA empleando un algoritmo iterativo.

4. OBJETIVOS

El objetivo general del artículo es la comparación de tres RNAs que implementan clasificadores automáticos de piezas de acero forjadas con enfriamiento rápido y correcto para una aplicación concreta, con microestructura predominante martensítica y bainítica y dureza aceptable, respecto de otras piezas no correctas, enfriadas más lentamente que las primeras, con microestructura predominante de perlita y algo de bainita y con dureza inferior al valor mínimo aceptable.

Los datos de entrada de las RNAs fueron medidas de impedancia de una sonda inductiva tomadas a diferentes frecuencias que proceden de la tecnología de ensayos no destructivos por corrientes inducidas. Se emplearon dos RNAs cuyas entradas fueron impedancias a las frecuencias de trabajo 50 y 100 kHz y una tercera RNA que utilizó simultáneamente las impedancias a las dos frecuencias.

Los objetivos específicos del artículo son comparar la tasa de acierto de clasificación de piezas de las tres RNAs, comparar la carga computacional calculada de las RNAs y comparar el tiempo de ejecución empleado por cada una de las RNAs para clasificar una pieza de acero.

5. MATERIALES

Para la realización de los experimentos se utilizó: un equipo de instrumentación de corrientes inducidas, una sonda inductiva, un juego de piezas de acero y un PC de procesado. Todos estos elementos se interconectaron según el diagrama de bloques del sistema de la *Figura 6*.

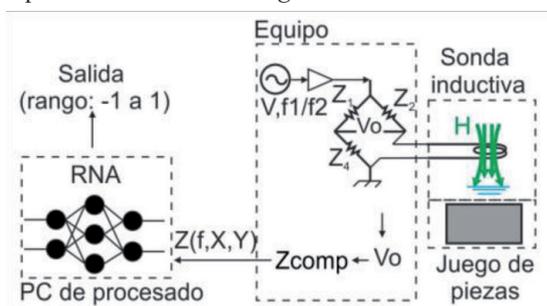


Figura 6: Diagrama de bloques del sistema (Equipo de corrientes, sonda inductiva, juego de piezas de acero y PC de procesado)

El equipo de instrumentación fabricado por ISEND se utilizó para la generación del flujo de corrientes en las piezas de inspección y la extracción de la impedancia resultante de la sonda inductiva.

La sonda inductiva también fabricada por ISEND, similar a la de la *Figura 1*, estaba formada por una bobina de operación y una bobina de compensación para aumentar su rango dinámico. Cada una de las bobinas, con núcleo de ferrita de diámetro 1.6 mm, estaba formada por 4 capas de hilo de cobre de 0.08 mm de diámetro hasta completar 100 vueltas.

El juego de piezas de acero se utilizó en las fases de entrenamiento, validación y test de cada una de las redes. El juego estaba formado por ocho levas forjadas fabricadas en acero 100Cr6 con denominación F1310 según UNE, divididas en dos grupos.

- El primer grupo de piezas había sido sometido a un enfriamiento rápido y habían adquirido una dureza deseada superior a 55HRC. En este grupo de piezas correctas predomina la microestructura metalúrgica de martensita y bainita.
- El segundo grupo de piezas, por el contrario, había recibido un enfriamiento más lento que las piezas del grupo anterior y su dureza resultante era inferior a 45HRC, predominando la microestructura de perlita y algo de bainita. Estas piezas no eran correctas para su posterior aplicación, por lo que había se separarlas de las del primer grupo con la tecnología presentada en el presente estudio.

El PC de procesado fue un ordenador portátil de propósito general con un procesador Intel Core i3 M350 @2.27GHz y una memoria RAM de 4 GB y se utilizó para implementar las tres RNAs de clasificación de piezas que se comparan en este estudio.

6. MÉTODOS

La metodología seguida estuvo formada por las siguientes cuatro etapas: inicialmente se realizó en ensayo no destructivo para la toma de medidas de impedancia, después se realizó un preprocesado de los datos adquiridos, a continuación se implementaron los clasificadores de piezas de acero mediante RNAs y finalmente se realizó un análisis de los clasificadores implementados.

6.1. TOMA DE DATOS

La toma de datos consistió en la aproximación de las piezas de acero al campo magnético primario creado por la sonda inductiva y la medida de la impedancia resultante a las frecuencias de trabajo 50 y 100 kHz. Se tomaron 40 medidas de impedancia manteniendo una distancia inferior a 0.1 mm entre sonda y pieza. Según la *Ecuación (1)* la profundidad estándar de penetración de las corrientes inducidas fue de 54.04 μm a 50 kHz y de 32.41 μm a 100 kHz, por lo que la exploración predominante fue superficial. Las duplas de impedancia compleja a cada frecuencia de trabajo f se expresa en puntos de conversión procedentes de la digitalización de un ADC.

6.2. PRE-PROCESADO

A continuación se normalizaron las componentes real (Z_x) e imaginaria (Z_y) de las impedancias adquiridas con el fin de

proporcionar un conjunto de variables de entrada a las RNAs con media nula y desviación estándar unitaria para mejorar los resultados de clasificación y reducir el tiempo de entrenamiento. Se aplicó la transformación de la Ecuación (2), siendo $Z_{x/y}$ la componente de la impedancia de entrada, $Z'_{x/y}$ la impedancia preprocesada, $\mu_{x/y}$ el valor medio y $\sigma_{x/y}$ la desviación típica de $Z_{x/y}$.

$$Z_{x/y} \rightarrow Z'_{x/y} = \frac{Z_{x/y} - \mu_{x/y}}{\sigma_{x/y}} \quad (2)$$

6.3. PROCESADO MEDIANTE RNAs

En tercer lugar, se procesaron las muestras normalizadas de impedancia para clasificar las piezas según el tratamiento térmico recibido. Para ello, se diseñaron dos primeras RNAs que procesaron en modo monofrecuencia las impedancias tomadas a las frecuencias de trabajo 50 y 100 kHz y una tercera RNA que realizó un procesamiento multifrecuencia de las impedancias extraídas a 50 y 100 kHz. A continuación se describen las características de las RNAs diseñadas:

Estructura:	Perceptrón multicapa <i>feedforward</i> . Red totalmente conectada. Una única capa oculta.
Capa de salida:	Una única neurona de salida.
Número de neuronas en la capa de entrada:	Procesado monofrecuencia: 2. Procesado multifrecuencia: 4.
Número de neuronas de la capa oculta:	Entre 2 y 10.
Función de activación:	Tangente hiperbólica.
División de muestras:	Entrenamiento: 60%. Validación 15%. Test: 25%.
Criterio de parada del entrenamiento:	Gradiente de error = 10^{-10} .
Criterio de finalización del entrenamiento:	Principal: Clasificación correcta de todas las muestras de entrenamiento y validación. Secundario: Tiempo máximo del proceso iterativo 60 s.

Tabla 1: Características de las RNAs diseñadas para la implementación de los clasificadores

6.4. ANÁLISIS DE LOS CLASIFICADORES

Por último, se evaluaron los clasificadores de piezas implementados mediante las RNAs.

El primer criterio de comparación fue la tasa de acierto de clasificación de las RNAs una vez entrenadas, definida como el ratio entre el número de muestras clasificadas correctamente y el número de muestras totales. El rango de los valores posibles de tasa de acierto se sitúa entre el 0% y el 100%.

El segundo criterio de comparación fue la carga computacional, calculada de manera teórica como el número de operaciones que necesita cada RNA para clasificar una pieza, y se desglosó en sumas, productos y cálculos de la función *tanh*.

El rango del número de operaciones de cada tipo se expresa en unidades naturales.

El tercer y último criterio de comparación de las RNAs entrenadas fue el tiempo de necesario para clasificar una pieza y se expresa en microsegundos.

7. RESULTADOS Y DISCUSIÓN

En esta sección se presentan los resultados obtenidos y un breve análisis de los mismos, así como las observaciones que surgen a partir de dichos resultados, las limitaciones del estudio y algunas líneas futuras que se podrían abordar a partir de este trabajo.

7.1. TASA DE ACIERTO

Los resultados de clasificación relativos a la tasa de acierto de las RNAs se muestran en la Figura 7. En el procesamiento monofrecuencia se distingue el tramo comprendido entre 2 y 5 neuronas ocultas, en el que la tasa de acierto aumentó a medida que se incrementó el número de neuronas, y entre 6 y 10 neuronas ocultas, en el que la tasa de acierto se mantuvo aproximadamente constante. Debido a este comportamiento, se eligió la RNA con 5 neuronas en la capa oculta como la estructura de referencia. La tasa de acierto de clasificación de piezas de la RNA con 5 neuronas fue del 88.5% con impedancias de entrada a 50 kHz y del 89.8% con impedancias a 100 kHz.

Por el contrario, los resultados de tasa de acierto de la clasificación multifrecuencia muestran una tendencia siempre decreciente al aumentar el número de neuronas ocultas. El valor máximo de tasa de acierto (99.9%) se alcanzó con 2 neuronas ocultas, aunque se mantuvo siempre por encima del 98% en el peor de los casos, por lo que se eligió la RNA de 2 neuronas ocultas como estructura de referencia.

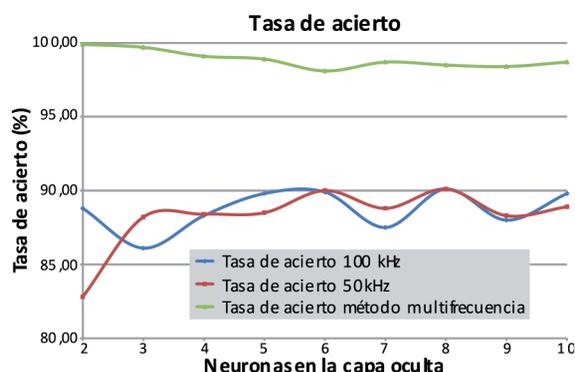


Figura 7: Tasa de acierto de la clasificación monofrecuencia a 50 kHz, a 100 kHz y de la clasificación multifrecuencia

Los resultados evidencian que la clasificación multifrecuencia consigue una tasa de acierto un 10.4% superior al procesamiento monofrecuencia. Estos resultados se deben a que las medidas de impedancia independientes a 50 y a 100 kHz no aportan por separado información suficiente para permitir la clasificación de los dos grupos de muestras, mientras que la complementariedad de las dos frecuencias de trabajo permite lograr una tasa de acierto muy cercana al 100%. También algunos autores que han realizado ensayos por corrientes como

Chady *et al.* [17] y Rao *et al.* [18] han obtenido buenos resultados con las técnicas multifrecuencia.

7.2. CARGA COMPUTACIONAL

Los resultados de carga computacional teórica de las RNAs se calcularon en función del número de neuronas ocultas de cada capa y se muestran en la *Tabla II*. El número de sumas y de productos es coincidente y depende tanto del número de entradas (N_{in}) como del número de neuronas de la capa oculta (N_{oc}), mientras que el número de cálculos de la función de activación *tanh* sólo depende del número de neuronas de la capa oculta.

En la *Figura 8* se representan el número de sumas/productos y el número de cálculos de la función de activación. Se comprobó que el número de operaciones del procesamiento multifrecuencia de 2 neuronas en la capa oculta fue inferior al del procesamiento monofrecuencia de 5 neuronas ocultas tanto en número de sumas/productos como en número de cálculos de la *tanh*.

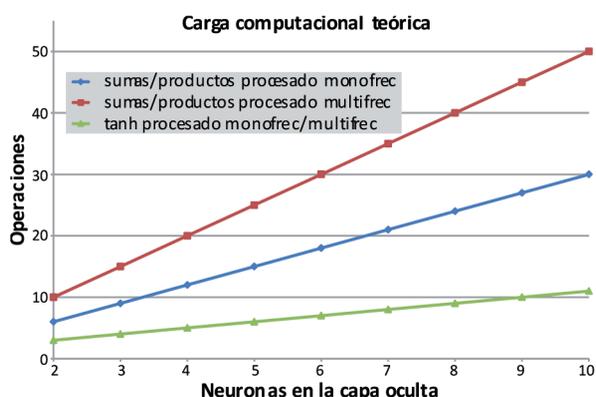


Figura 8: Carga computacional de las RNAs propuestas en función del número de neuronas de la capa oculta

Los resultados muestran que el incremento del número de variables de entrada de 2 a 4 no tiene por qué suponer un incremento en la carga computacional del clasificador de piezas, ya que el procesamiento multifrecuencia computa un número de sumas y productos un 33% inferior y un 50% inferior en términos de cálculos de la función *tanh* que en los casos monofrecuencia.

7.3. TIEMPO DE EJECUCIÓN

En la *Tabla III* se muestran los tiempos de ejecución medio y máximo que necesitaron las RNAs una vez entrenadas para clasificar una pieza de acero. Se incluyen los tiempos de las cuatro RNAs propuestas más representativas, que fueron en el caso del procesamiento monofrecuencia las RNAs con 5 y 6 neuronas en la capa oculta y en el caso multifrecuencia las RNAs con 2 y 3 neuronas ocultas. Los resultados muestran que la RNA más rápida fue la de procesamiento multifrecuencia con 2 neuronas ocultas con 0.2492 μ s de promedio. En segundo lugar se situó el procesamiento multifrecuencia de 3 neuronas, seguido del procesamiento monofrecuencia de 5 neuronas ocultas.

Tipo de operación	Operaciones en la capa oculta	Operaciones en la capa de salida	Total operaciones
Sumas/Productos	$N_{oc} * N_{in}$	N_{oc}	$N_{oc} * (N_{in} + 1)$
Operaciones de <i>tanh</i>	N_{oc}	1	$N_{oc} + 1$

Tabla II: Carga computacional teórica de las RNAs propuestas con N_{in} neuronas de entrada, N_{oc} neuronas en la capa oculta y una neurona de salida

Tipo de procesado	Neuronas en la capa oculta	Tiempo medio (μ s)	Tiempo máximo (μ s)
Monofrecuencia	5	0.3197	0.3613
Monofrecuencia	6	0.3864	0.4138
Multifrecuencia	2	0.2492	0.2787
Multifrecuencia	3	0.2896	0.3201

Tabla III: Tiempo de ejecución promedio y máximo requerido por cuatro configuraciones de RNAs propuestas para clasificar una pieza

En último lugar se situó el procesamiento monofrecuencia con 6 neuronas ocultas y 0.3864 μ s promedio, un 55.1% más que en el mejor caso. El tiempo de ejecución de la clasificación multifrecuencia de 2 neuronas ocultas fue un 22% inferior al necesario por la clasificación monofrecuencia de 5 neuronas ocultas.

7.4. ANÁLISIS DE RESULTADOS

Una primera observación sobre los resultados presentados es la estabilización o empeoramiento de la tasa de acierto de las RNAs diseñadas a partir de un cierto número de neuronas en la capa oculta: la tasa de acierto del procesamiento multifrecuencia fue siempre decreciente con el número de neuronas ocultas, mientras que las RNAs de clasificación monofrecuencia no mostraron mejoras significativas en su tasa de acierto a partir de cinco neuronas. Este hecho se justifica con sobre-entrenamiento de la red que se produce al aumentar el número de neuronas ocultas. Se produce una adaptación excesiva de las RNAs a los datos de entrenamiento cuando hay un exceso de parámetros de ajuste libres y, debido a esto, la capacidad de generalización de la RNA, y por tanto de clasificar, empeora. Para evitar el sobre-entrenamiento es adecuado seguir la estrategia de este estudio, que consistió en elegir el número de neuronas en la capa oculta mínimo a partir del cual se estabilizó o comenzó a disminuir la tasa de acierto.

Otra observación es la correlación entre la carga computacional teórica calculada y el tiempo de ejecución medido de manera experimental. Ordenando de menor a mayor los resultados de las cuatro RNAs analizadas en términos de carga computacional y en términos de tiempo de ejecución se obtuvo la misma clasificación: los dos mejores casos se obtuvieron en la clasificación multifrecuencia con dos y tres neuronas ocultas respectivamente, mientras que el tercer y el cuarto caso fueron para las RNAs relativas al procesamiento monofrecuencia con cinco y seis neuronas ocultas respectivamente. Esta observación verifica y valida los resultados de tiempo de ejecución obtenidos en base a los resultados teóricos de carga computacional.

La tercera observación es que la microestructura martensítica de las piezas correctas marca la pauta para la

desviación de las curvas de *lift-off* hacia la formación de una nube de puntos cercanos, mientras que la microestructura de perlita predominante de las piezas no correctas marca la pauta para la desviación de las colas de las curvas de *lift-off* hacia otra región del plano de impedancia. La microestructura común de bainita presente en los dos grupos de piezas tiende a desviar las nubes de puntos hacia la misma región, si bien las microestructuras no comunes permiten diferencia suficiente entre los dos grupos de piezas para permitir el funcionamiento del método de clasificación.

Por último, consideramos que se podría barajar la posibilidad de implantar una RNA como la propuesta en el procesado multifrecuencia en el control de calidad de una línea de fabricación industrial real, dado que tanto la tasa de acierto conseguida (99.9%) como el tiempo de ejecución medio que requiere (0.2492 μ s) no serían factores limitantes en dicho proceso.

7.5. LIMITACIONES Y LÍNEAS FUTURAS

Una limitación del estudio ha sido la adquisición de las impedancias de trabajo en un entorno de laboratorio, alejado de algunas fuentes de ruido eléctrico y vibraciones entre sonda y pieza que pueden estar presentes en los entornos industriales y dificultar la inspección. Con un apantallado correcto de sonda y cableado, con el propio poder de rechazo de los equipos ante cualquier señal interferente fuera de banda y con los filtros adicionales que los equipos suelen incorporar en una línea de fabricación industrial sería posible minimizar los efectos del ruido interferente y las vibraciones mecánicas que pueden dificultar la obtención de tasas de acierto de clasificación elevadas como las obtenidas en el presente trabajo.

Dos líneas futuras principales surgen a partir del trabajo realizado. Por la mejoría que se ha observado en este trabajo al incrementar el número de frecuencias, la primera línea sería utilizar más impedancias tomadas a diferentes frecuencias de trabajo y la segunda línea sería incorporar otras técnicas de preprocesado y otros tipos de RNAs que podrían mejorar el método propuesto.

8. CONCLUSIONES

En el estudio realizado la RNA que realiza clasificación multifrecuencia de las piezas de acero 100Cr6, con denominación F1310 según normativa UNE, consigue una tasa de acierto mejor que las que realizan procesado monofrecuencia. En segundo lugar se ha comprobado que el incremento del número de variables de entrada del procesado multifrecuencia no tiene por qué suponer un incremento en la carga computacional del clasificador respecto de los casos monofrecuencia. Y por último, el tiempo de ejecución necesario para realizar una clasificación multifrecuencia no tiene que ser necesariamente mayor que el empleado en un procesado monofrecuencia, a pesar de la mayor complejidad que tienen a priori las RNAs con mayor número de entradas.

En conjunto, la clasificación multifrecuencia de las piezas de acero ensayado muestra mejores características que la clasificación monofrecuencia con respecto a la tasa de acierto, la carga computacional y el tiempo de ejecución necesario.

AGRADECIMIENTOS

El presente estudio ha sido desarrollado gracias a la tecnología propia de Ingeniería y Sistemas de Ensayos no Destructivos (ISEND), al Subprograma de investigación Torres Quevedo con referencia PTQ-10-02437 y al Departamento de Teoría de la Señal, Comunicaciones e Ingeniería Telemática de la Universidad de Valladolid.

Además el trabajo del segundo autor se ha llevado a cabo gracias a una beca del programa de "Formación de Personal Investigador", financiado por la Universidad de Valladolid y cofinanciado por el Banco Santander.

BIBLIOGRAFÍA

- [1] Sheikh Amiri M, Kashefi M. "Application of eddy current nondestructive method for determination of surface carbon content in carburized steels". *NDT & E International*. 2009. Vol.42-7 p.618-621. DOI: <http://dx.doi.org/10.1016/j.ndteint.2009.04.008>
- [2] Yanzón R C, Bocca J C, Rebollo D, et al. "Predicción de dureza en piezas construidas con acero templado y revenido". *Revista Iberoamericana de Ingeniería Mecánica*. 2009. Vol.13-2 p.22-45.
- [3] Rosado L S, Janeiro F M, Ramos P M, et al. "Defect Characterization With Eddy Current Testing Using Nonlinear-Regression Feature Extraction and Artificial Neural Networks". *Instrumentation and Measurement, IEEE Transactions on*. 2013. Vol.62-5 p.1207-1214. DOI: <http://dx.doi.org/10.1109/TIM.2012.2236729>
- [4] Garcia-Martin J, Gomez-Gil J, Vazquez-Sanchez E. "Non-destructive techniques based on eddy current testing". *Sensors*. 2011. Vol.11-3 p.2525-2565. DOI: <http://dx.doi.org/10.3390/s110302525>
- [5] Cao Q, Liu D, He Y, et al. "Nondestructive and quantitative evaluation of wire rope based on radial basis function neural network using eddy current inspection". *NDT & E International*. 2012. Vol.46-0 p.7-13. DOI: <http://dx.doi.org/10.1016/j.ndteint.2011.09.015>
- [6] Haykin S. *Neural Networks: A Comprehensive Foundation*. 2ª edición. New Jersey: Prentice Hall PTR, 1998. 842p. ISBN: 0132733501
- [7] Duda R O, Hart P E, Stork D G. *Pattern Classification*. 2ª edición. New York: John Wiley & Sons, 2001. 654p. ISBN: 0-471-05669-3
- [8] Chady T, Enokizono M, Sikora R, et al. "Natural crack recognition using inverse neural model and multi-frequency eddy current method". *Magnetics, IEEE Transactions on*. 2001. Vol.37-4 p.2797-2799. DOI: <http://dx.doi.org/10.1109/20.951310>
- [9] Wrzuszczak M, Wrzuszczak J. "Eddy current flaw detection with neural network applications". *Measurement*. 2005. Vol.38-2 p.132-136. DOI: <http://dx.doi.org/10.1016/j.measurement.2005.04.004>
- [10] Mix P E. *Introduction to Nondestructive Testing: a Training Guide*. 2ª edición. New Jersey: Wiley-interscience, 2005. 712p. ISBN: 9780471420293
- [11] Davis J R. *ASM Handbook: Nondestructive Evaluation and Quality Control*. 9ª edición. Materials Park, OH: ASM International, 1989. 937p. ISBN: 0-87170-007-7
- [12] Bishop C M. *Neural Networks for Pattern Recognition*. New York, USA: Oxford University Press, Inc., 1995. 482p. ISBN: 0198538642
- [13] Drachman D A. "Do we have brain to spare?". *Journal of Neurology*. 2005. Vol.64-12 p.2004-2005. DOI: <http://dx.doi.org/10.1212/01.WNL.0000166914.38327.BB>
- [14] Rumelhart D E, McClelland J L. *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*. Cambridge: MIT Press, 1986. 547p. ISBN: 0-262-68053-X
- [15] Levenberg K. "A method for the solution of certain non-linear problems in least squares". *Quarterly Journal of Applied Mathematics*. 1944. Vol.II-2 p.164-168.
- [16] Marquardt D. "An Algorithm for Least-Squares Estimation of Nonlinear Parameters". *SIAM Journal on Applied Mathematics*. 1963. Vol.2-11 p.431-441. DOI: <http://dx.doi.org/10.1137/0111030>
- [17] Chady T, Enokizono M, Sikora R. "Neural network models of eddy current multi-frequency system for nondestructive testing". *Magnetics, IEEE Transactions on*. 2000. Vol.36-4 p.1724-1727. DOI: <http://dx.doi.org/10.1109/20.877775>
- [18] Rao B P C, Raj B, Jayakumar T, et al. "An artificial neural network for eddy current testing of austenitic stainless steel welds". *NDT & E International*. 2002. Vol.35-6 p.393-398. DOI: [http://dx.doi.org/10.1016/S0963-8695\(02\)00007-5](http://dx.doi.org/10.1016/S0963-8695(02)00007-5)