

Inteligencias artificiales y ensayos ultrasónicos para la detección de defectos^(*)

Gerardo Barrera Cardiel*, María de los Ángeles Fabián Álvarez*,
Miguel Vélez Martínez* y Luis Villaseñor**

Resumen

Uno de los problemas más serios dentro del análisis de la calidad de uniones soldadas es la localización e identificación de los defectos que se producen en la elaboración de dichas uniones. Como solución a este problema se propone la técnica de clasificación, por medio de la técnica de redes neuronales, para la localización e identificación en línea de defectos, tanto en piezas unidas por las técnicas convencionales (aporte de material-arco eléctrico) como por fricción, entre otras, mediante el uso de patrones de señales ultrasónicas. Las redes neuronales propuestas son: Kohonen y Perceptron por Multicapas, todo en un ambiente de instrumentación virtual. Actualmente, las técnicas más utilizadas en este campo son las basadas en el análisis radiológico (aplicación de rayos X) y en el análisis ultrasónico (aplicación de ondas ultrasónicas). El método de rayos X, además de ser peligroso al trabajar con radiación, requiere de personal, que además de su especialización tenga licencia del organismo oficial correspondiente, por lo que su uso es restringido. El método de ultrasonido, a pesar de ser el que más se usa como ensayo no destructivo para la detección de defectos volumétricos, y sin contar con la limitación que supone el aspecto geométrico de la pieza, requiere también de personal con amplia experiencia en la interpretación de los ecogramas que, sin embargo, no necesita requisitos de autorización oficial, además de que su ejecución podría consumir mucho más tiempo que la alternativa de rayos X, lo que necesariamente encarece el ensayo. La técnica propuesta demuestra ser un método libre de riesgos personales, fiable, barata y sencilla de implantar para la solución de este importante problema.

Palabras clave

Inteligencia artificial. Ultrasonido. Discontinuidad. Pulso-eco. Instrumentación virtual.

Artificial intelligence and ultrasonic tests in detection of defects

Abstract

One of the most serious problems in the quality control of welded unions is the location, identification and classification of defects. As a solution to this problem, a technique for classification, applicable to welded unions done by electric arc welding as well as by friction, is proposed; it is based on ultrasonic signals. The neuronal networks proposed are Kohonen and Multilayer Perceptron, all in a virtual instrument environment. Currently the techniques most used in this field are: radiological analysis (X-rays) and ultrasonic analysis (ultrasonic waves). The X-ray technique in addition to being dangerous requires highly specialized personnel and equipment, therefore its use is restricted. The ultrasonic technique, in spite of being one of the most used for detection of discontinuities, requires personnel with wide experience in the interpretation of ultrasonic signals; this is a time-consuming process which necessarily increases its operation cost. The classification techniques that we propose turn out to be safe, reliable, inexpensive and easy to implement for the solution of this important problem.

Keywords

Artificial intelligence. Ultrasound. Discontinuity. Pulse-echo. Virtual instrumentation.

(*) Trabajo recibido el día 9 de diciembre de 1999 y aceptado en su forma final el día 5 de julio de 2001.

(*) Instituto de Investigaciones Metalúrgicas, Universidad Michoacana, Apt. Post. 52-B Morelia, Mich. CP 58000, Teléfono: (52 4) 316 8355, Fax: (52 4) 316 7414, gbarrera@zeus.ccu.umich.mx

(**) Instituto de Física y Matemáticas, Universidad Michoacana, Apt. Post. 2-82 Morelia, Mich. CP 58040, Teléfono: (52 4) 327 1997, villasen@zeus.ccu.umich.mx

1. INTRODUCCIÓN

No hay duda de que uno de los problemas más serios dentro del análisis de la calidad de las uniones soldadas es la localización e identificación de los defectos que se hayan producido o generado en dicha unión. Tradicionalmente, en lo que respecta a métodos volumétricos, los métodos más utilizados en este campo son dos: el ensayo radiológico (aplicación de rayos X) y el ensayo ultrasónico (aplicación de ondas ultrasónicas). El primero, además de ser peligroso, requiere de personal con permisos o licencia para manejo de fuentes radioactivas, por lo que su uso es restringido. El segundo método requiere solo de personal especializado en la interpretación de los ecogramas. Debido a que su ejecución requiere mucho tiempo, necesariamente, los costos de las pruebas de control de calidad son altos, lo que impacta, de alguna manera, en el costo final del producto. Sin embargo, el método de ultrasonido es el que más se usa como ensayo no destructivo para la detección de defectos si nos atenemos al aspecto volumétrico de la pieza a ensayar.

Es claro que para abaratar los altos costos y el tiempo que tarda en efectuarse un ensayo ultrasónico es necesario que el "experto" que lleva a cabo dichos ensayos sea tan rápido e infalible como sea posible. Muchas veces dicha tarea es difícil para un ser humano y se ha observado que después de un cierto período de tiempo la eficiencia en su desempeño declina substancialmente. Por estas razones, para cumplir eficientemente con dicha tarea es conveniente utilizar un sistema automático, robotizado, que además contenga toda la experiencia del experto humano, de modo que su eficiencia sea comparable a la máxima obtenida con el procedimiento manual tradicional.

Por otro lado, el análisis de ecogramas es una tarea sumamente compleja que requiere de un amplio conocimiento en el reconocimiento, interpretación y clasificación de patrones de ecos ultrasónicos que llevan a la toma de decisiones sobre si una unión soldada, por ejemplo, está bien llevada a cabo o contiene discontinuidades y si estas discontinuidades, por su magnitud, pueden ser toleradas o se requiere rechazar la pieza o si, en un momento dado, ésta puede ser reparada y evitar, de esa manera, la pérdida total de la misma.

1.1. El ensayo de ultrasonido

Una onda ultrasónica, que se propaga desde el transductor hasta el material objeto del ensayo, se

transmite a través de varias interfases con diferente impedancia acústica^[1]. Debido a esto se produce una pérdida de energía a causa de la reflexión y transmisión del sonido, que puede ser considerable en el caso de interfaces de aire. Con el objetivo de minimizar esta pérdida se usan dos tipos de acoplamiento del transductor:

A) Agente acoplante de contacto. En la técnica de contacto el transductor es presionado manualmente contra la superficie del objeto a ensayar para reducir el espesor del acoplante a un mínimo (Fig. 1a). Como acoplante se puede usar glicerina, aceite, miel, etc. Este espesor debe ser tal que su frecuencia de resonancia sea mayor que el rango de respuesta espectral del transductor.

B) Acoplamiento por inmersión. Esta técnica utiliza típicamente agua como acoplante (Fig. 1b).

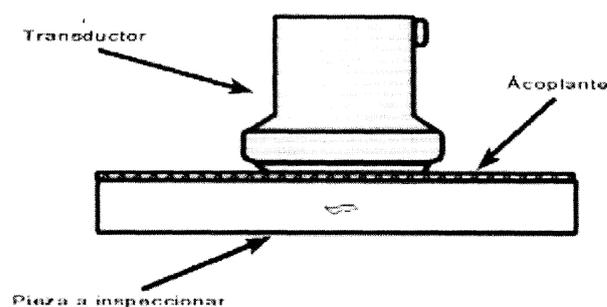


Figura 1a. Ensayo ultrasónico utilizando la técnica "acoplante de contacto".

Figure 1a. Ultrasonic test using the "contact couplant" technique.

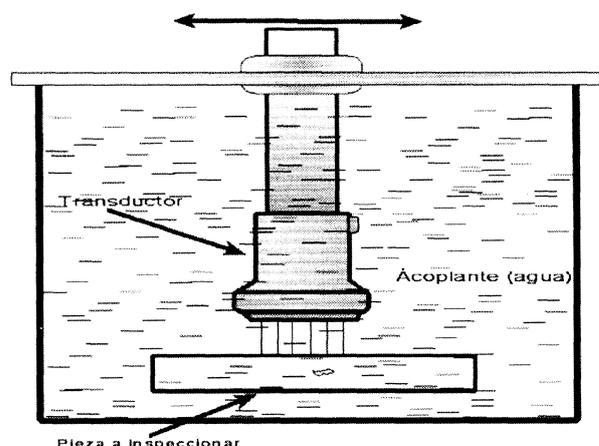


Figura 1b. Ensayo ultrasónico utilizando la técnica "acoplante por inmersión".

Figure 1b. Ultrasonic test using the "immersion couplant" technique.

La distancia en agua entre el transductor y el objeto de ensayo es lo suficientemente grande para separar, en el dominio del tiempo, las reflexiones de la superficie de este objeto de ensayo y la señal excitadora (emisión) del transductor; además se requiere mantener cierta separación entre las reflexiones internas del objeto a ensayar y las reflexiones repetitivas en el trayecto en el agua. Este ajuste es necesario para prevenir interferencias entre los diversos reflectores y simplificar la evaluación de la repuesta.

En este artículo se discuten sólo resultados basados en la técnica de contacto, aunque el esquema propuesto es igualmente aplicable a la técnica de inmersión.

1.1.1. Parámetros del ensayo por contacto "pulso-eco"

Los sistemas de "pulso-eco" pueden usar dos parámetros para detectar y caracterizar discontinuidades:

1. Amplitud de la reflexión en la pared contraria en el dominio del tiempo.
2. Respuesta espectral.

Una vista esquemática de una respuesta típica tipo "pulso-eco" se muestra en la figura 2. El tiempo de la onda ultrasónica en su camino de ida y vuelta, el espectro de potencias, la pendiente de la envolvente espectral y la transformada ondeleta, entre otras, se utilizan para examinar la respuesta^[2] de los ecos ultrasónicos. Cuando la localización en el tiempo, de las componentes de frecuencia, es importante, como es el caso de las señales no esta-

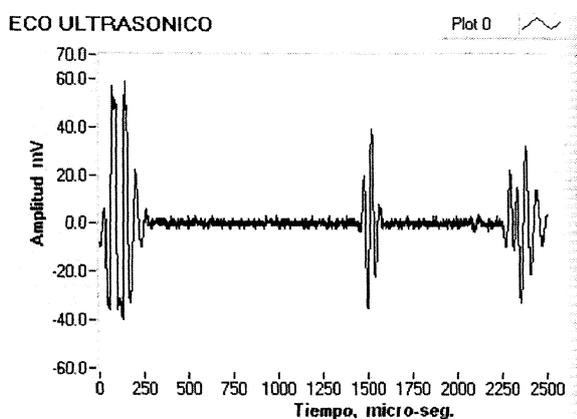


Figura 2. Respuesta típica pulso-eco. La escala vertical es voltaje (mv) y la horizontal tiempo (is.).

Figure 2. Pulse-echo typical response. The vertical scale is voltage (mv), the horizontal is time (is.).

cionarias (es decir, en las que la frecuencia varía con el tiempo), se debe utilizar una transformación que proporcione una representación "tiempo" contra frecuencia. La transformada ondeleta (*wavelet*) es capaz de proveer información de tiempo y frecuencia al mismo tiempo. El análisis de estos parámetros se hace con sistemas digitales basados en computadoras; las señales digitalizadas y analizadas por una computadora permiten una gran variedad de opciones y constituyen una herramienta de análisis muy poderosa.

1.1.2. Amplitud de la reflexión opuesta

La reflexión opuesta (eco de fondo) sirve para medir la atenuación del material y detectar anomalías debido a que éstas afectan la energía incidente de la onda acústica ultrasónica. Este parámetro es un indicador rápido de discontinuidades y es ampliamente usado para detectar laminaciones, porosidades, microgrietas, falta de fusión, escoria atrapada, etc.

La amplitud de la reflexión opuesta es un indicador indirecto y puede ser sensible a fuentes irrelevantes, por ejemplo geometría y rugosidad superficial, variaciones en las condiciones del ensayo por la rugosidad superficial, así como la cara opuesta pueden causar cambios en la amplitud de la reflexión del eco de fondo. En una sección posterior se hablará de otras características de este tipo de señales que pueden ser tomadas en cuenta al momento de diseñar un sistema de clasificación para hacerlo más robusto.

1.2. Sistemas expertos

Una de las fases que tienen un gran impacto en los procesos de investigación y desarrollo es sin duda alguna la obtención de un esquema que, de alguna manera, interprete e imite al proceso o fenómeno real bajo estudio. Las técnicas tradicionales de modelado matemático (modelos lineales y no lineales^[3]) con frecuencia introducen un grado de incertidumbre muy grande^[4], por lo que son poco confiables en el mundo real.

En los últimos años se ha consolidado una nueva técnica que imita tanto la forma de razonar del ser humano como la forma en que éste toma decisiones; esta técnica se conoce como "diseño de sistemas expertos o sistemas inteligentes^[5]". Esta técnica consiste en trasladar la experiencia de un maestro o experto humano a un modelo matemático que aprende el conocimiento y la experiencia

de dicho experto. Este esquema incorpora la forma de tomar decisiones del experto para una serie de situaciones que se pudieran presentar en la vida real en el sistema bajo estudio. Las áreas del conocimiento humano implicadas en el presente trabajo tienen que ver con redes neuronales. La mayor justificación del uso de las redes neuronales artificiales (RNA) es su habilidad para “ver” y “aprender” relaciones en conjuntos de datos complejos que no pueden ser fácilmente percibidos por humanos. El proceso de aprendizaje de las RNA puede dividirse en: supervisado, no supervisado (auto-organizado) y estocástico. En la primera categoría la red más utilizada es conocida como Perceptron Multicapas^[5] con regla de retro-propagación. Este tipo de red requiere de grandes tiempos de aprendizaje pero puede ser más exacto.

En la segunda categoría, mapas de características autoorganizados, existe una red muy popular conocida como Kohonen^[5], este método es rápido aunque relativamente inexacto. Los métodos de aprendizaje estocásticos emplean procesos aleatorios y distribuciones probabilísticas para minimizar adecuadamente el error de la red.

2. EXPERIMENTACIÓN

Las mediciones ultrasónicas se llevaron a cabo con el método de “pulso-eco” en combinación con la técnica de contacto como se ilustra en la figura 1a.

2.1. Equipo utilizado

Las pruebas fueron realizadas con un PC a 150 MHz., un osciloscopio digital HP con interfase GPIB y serial y un pulsador Panametrics 5800PR. Para los ensayos por el método de contacto se utilizó un transductor de 5 MHz., cuyas principales características son:

Frecuencia:	5 MHz.
Tipo de incidencia del haz:	Focalizado.
Diámetro del material piezoeléctrico:	12,7 mm.
Foco:	5 cm.

La frecuencia de muestreo se seleccionó en base a la frecuencia máxima del espectro del primer eco de la pared posterior (eco de fondo), la cual fue de 4,0 MHz. La señal de voltaje se produce por el pulsador-receptor, el cual se puede definir como una fuente de ráfagas cortas de voltaje (pulsos). Esta señal eléctrica excita el material piezoeléctrico del transductor produciendo una señal ultrasónica

que se transmite por el medio acoplante, en el caso de ensayo por contacto o, por el agua, en el caso del ensayo de inmersión, regresando al transductor el cual por medio del cristal convierte la señal ultrasónica en señales eléctricas, estas señales retornan al pulsador-receptor, a partir del cuál se pueden visualizar mediante el osciloscopio (Fig. 3). Por medio del puerto serial de la PC se captura las señales de estos ecos para su análisis posterior. Las condiciones impuestas y que se mantuvieron constantes durante todos los ensayos fueron:

Modo:	Pulso -Eco.
PRF:	5,0 MHz. (frecuencia de pulso de repetición).
Energía:	25 IJ.
Amortiguamiento:	50 Ohms.
Filtro pasa altas:	1 MHz.
Filtro pasa bajas:	35 Mhz.
Ganancia:	40 Db.
Sensibilidad:	55,3 dB.

Para simular los defectos se utilizaron bloques de acero (AISI 1018) a los que se practicó una serie de taladros en diferentes partes, es decir, en forma aleatoria. Se utilizaron cuatro diferentes diámetros para simular los defectos: 3,175, 2,778, 2,381 y 1,984 mm.; las perforaciones se hicieron a diferentes profundidades, también de forma aleatoria (a partir de la superficie de inspección). Todos los ensayos se llevaron a cabo por duplicado y en algunos casos se tomaron hasta tres muestras por defecto. También se tomaron los ecos de diferentes zonas ausentes de taladros con el doble propósito de tener una referencia de la magnitud de ecos con y sin defectos; estos ecos se usaron también para el cálculo de la velocidad del sonido en los bloques de acero correspondientes.

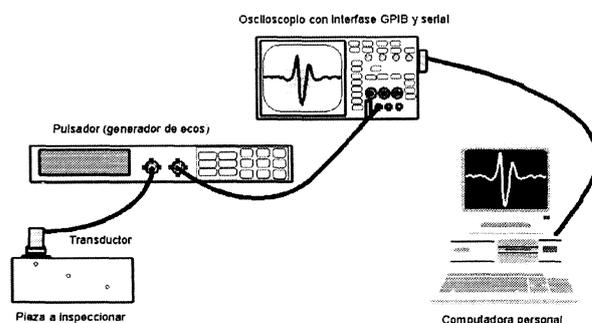


Figura 3. Arreglo experimental usado para los ensayos ultrasónicos.

Figure 3. Experimental set up used for the ultrasonic test.

Para la captura, tratamiento y análisis de las señales digitalizadas de los ecos se escribió un programa en un ambiente de instrumentación virtual de LabVIEW^[6] (lenguaje G). En este mismo ambiente de instrumentación virtual se diseñaron las interfaces para el diseño y entrenamiento de las redes neuronales a través de una herramienta conocida como DataEngine^[7].

2.2. Extracción de características

Para el entrenamiento de las redes propuestas hay que extraer de los ecos algunas características que permitan una clasificación rápida y confiable de los defectos. Para extraer el conjunto óptimo de características de los datos, primero se determinó que las posibles características que pueden formar parte de dicho conjunto son las siguientes:

1. Integral del eco ultrasónico.
2. Número de líneas que sobrepasan un límite (una amplitud mínima).
3. Pico de frecuencia.
4. Distorsión armónica total.
5. Desviación estándar.
6. Coeficiente de atenuación.
7. Pendiente de la envolvente.
8. Integral del eco procesado mediante la transformada ondeleta.

Con las características anteriores se hizo una búsqueda del conjunto apropiado de éstas para el entrenamiento de las redes neuronales, la búsqueda se realizó siguiendo los siguientes pasos:

- a) Se elaboraron varios subconjuntos de características.
- b) Se entrenaron las redes con cada uno de éstos.
- c) Se verificó el desempeño de ambas redes con cada subconjunto.

Después de realizar varias pruebas se determinó que el subconjunto de características que presentó el mejor desempeño en ambas redes (Kohonen y MLP), para los ecos obtenidos mediante acople por contacto, fue el integrado por las características siguientes:

1. Integral del eco ultrasónico.
2. Distorsión armónica total.
3. Coeficiente de atenuación.
4. Pendiente de la envolvente.

2.3. Diseño de las redes Kohonen y Perceptron Multicapas

La red Kohonen consta de dos capas, la capa de entrada y la capa Kohonen. La primera tiene igual número de neuronas que el número de características del conjunto elegido, es decir, la integral del eco, la distorsión armónica total, el coeficiente de atenuación y la pendiente de la envolvente. Por esto la capa de entrada tiene 4 neuronas. La capa Kohonen, normalmente, es un arreglo bidimensional de neuronas, la forma de elegir el número adecuado de neuronas para cada dimensión es a prueba y error y depende entre otras cosas, del problema a resolver, las características de los datos y de la cantidad del conjunto de datos para el entrenamiento. Para este problema en particular, la capa Kohonen esta compuesta de un arreglo bidimensional de 8x6 neuronas, es decir de 48 en total. Hay que hacer notar que la clasificación se hará en base a las clases elegidas, es decir, 5 en este caso ya que se trata de clasificar ecos para los 4 diferentes diámetros ensayados y los ecos de secciones de la pieza que no tiene defecto alguno. Los parámetros esenciales que se necesitan especificar en este tipo de red, con sus valores correspondientes, son:

- a) Orden de presentación: secuencial.
- b) Razón de aprendizaje inicial: 0,5.
- c) Factor de razón de aprendizaje: 0,9.
- d) Radio de aprendizaje inicial: 2,00.
- e) Factor de radio de aprendizaje: 0,9.

En el caso de la red Perceptron Multicapas (MLP), ésta está constituida por capas: la capa de entrada, la(s) capas ocultas y la capa de salida. El número de neuronas de la capa de entrada debe ser igual al número de características del problema, siendo 4, para este caso, el número de neuronas. El número de neuronas de la capa de salida debe ser igual al número de clases, es decir, para este caso en particular se tienen 5 neuronas. Después de un análisis del problema se determinó que dos capas ocultas eran suficientes para resolverlo. El número de neuronas en estas capas se determinó nuevamente a prueba y error, quedando éste en 5 neuronas en la primera capa y 4 en la segunda. En este punto se tuvo muy presente no elegir el mismo número de neuronas en ambas capas ya que según KrishnaKumar^[8] éstas presentan la peor robustez de las redes empleadas actualmente.

Para elegir los parámetros necesarios en esta red se experimentó con muchas combinaciones de

valores, buscando la mejor clasificación posible^[7]. Los valores que mejores resultados presentan son:

- a) Método de aprendizaje: Retropropagación con momento y decaimiento.
- b) Estrategia de aprendizaje: Regla Delta en un solo paso.
- c) Razón de aprendizaje: 0,1.
- d) Orden de presentación: aleatoria.
- e) Máximo error de entrenamiento: 0,010.
- f) Número de épocas: 1000.
- g) Momento: 0,2.
- h) Decaimiento: 0,98.

3. RESULTADOS

En el presente trabajo sólo se entrenaron las redes para bloques de acero perforados simulando discontinuidades, pero ambos tipos de redes fueron programadas de tal manera que pueden entrenarse para cualquier tamaño de orificio, para otra discontinuidad es inclusive para cualquier otro tipo de material que se requiera sin hacerles cambios significativos, sólo se requiere realizar la base de datos correspondiente para entrenar a la red con esa información y de ser necesario hacer algunos pequeños ajustes (como especificar el número de características del nuevo conjunto seleccionado) para el buen desempeño de la misma. Además, en el caso de la red MLP se tendrían que hacer algunos ajustes al programa una vez que, si se desea, por ejemplo, aumentar las clases a clasificar se tendría que observar cómo se ven afectadas las capas ocultas de la red y, de ser necesario, aumentar las neuronas en dichas capas o, inclusive, aumentar las capas ocultas que sean necesarias hasta conseguir el mejor desempeño de la red.

Ambas redes realizan la evaluación de forma automática, de manera que el operador sólo proporciona como único dato el espesor de la pieza. Los dos métodos presentan la característica de que, cuando detectan una discontinuidad, además de especificar el diámetro de la misma, proporcionan su localización con respecto a la pared posterior de la pieza.

Una propiedad de la red MLP es su capacidad de especificar si un eco no pertenece a ninguna de las clases predeterminadas, la cual no es posible implementar con una red Kohonen debido al algoritmo del cual hace uso.

3.1. Clasificación con la red Kohonen

Para el presente trabajo se adquirieron 120 ecos ultrasónicos para entrenamiento y 10 ecos para clasi-

ficación, los cuales se muestran en la tabla I. Cada bloque tiene 12 perforaciones de un mismo diámetro y fueron taladrados a profundidades y localizaciones aleatorias. La inspección ultrasónica de los 4 bloques se llevó a cabo dos veces para tener ecos suficientes para hacer una validación estadística de los datos, lo que quiere decir que se tuvieron, al menos, 2 señales de la misma perforación. También se adquirió la señal de los ecos de zonas libres de defectos de los 4 diferentes bloques de acero. Los resultados obtenidos mediante esta red se muestran en la tabla II. Como se sabe, la clasificación de una red Kohonen es una pertenencia estricta a una sola clase (0 ó 1), por lo que en la tabla II se puede observar que, sólo un archivo, no fue clasificado correctamente, el de diámetro 2,381 mm, eco 8, lo que significa que la red lo clasificó como un defecto de 2,78 mm. Esto podría mejorarse con más datos ya que la diferencia en diámetros es muy pequeña, de casi 0,4 mm. Sin embargo se puede decir que la red tiene un buen desempeño: eficiencia del 90 %. Es conveniente mencionar que también se llevó a cabo una clasificación de los defectos en 2 clases con defecto y sin defecto, es decir, el sistema debería ser capaz de decir si el eco en turno tenía o no un defecto. En este caso la eficiencia en clasificación fue del 100 % (Tabla IV).

3.2. Clasificación con la red Perceptron Multi-capas

Se utilizó la misma base de datos, de características y clases para la clasificación con el modelo de red

Tabla I. Ecos obtenidos por contacto para probar la eficiencia de las redes neuronales propuestas

Table I. Echoes obtained by contact to test the efficiency of the proposed neuronal networks

Nombre del Archivo	Clase
Eco 1	SIN DISCONT.
Eco 2	SIN DISCONT.
Eco 3	D = 3,175 mm.
Eco 4	D = 3,175 mm.
Eco 5	D = 2,778 mm.
Eco 6	D = 2,778 mm.
Eco 7	D = 2,381 mm.
Eco 8	D = 2,381 mm.
Eco 9	D = 1,984 mm.
Eco 10	D = 1,984 mm.

Tabla II. Resultados de la red Kohonen para las pruebas por contacto*Table II. Kohonen net results for the contact test*

	SIN DEF.	D=3,175 mm	D=2,778 mm	D=2,381 mm	D=1,984 mm
Eco 1	1,0000	0,0000	0,0000	0,0000	0,0000
Eco 2	1,0000	0,0000	0,0000	0,0000	0,0000
Eco 3	0,0000	1,0000	0,0000	0,0000	0,0000
Eco 4	0,0000	1,0000	0,0000	0,0000	0,0000
Eco 5	0,0000	0,0000	1,0000	0,0000	0,0000
Eco 6	0,0000	0,0000	1,0000	0,0000	0,0000
Eco 7	0,0000	0,0000	0,0000	1,0000	0,0000
Eco 8	0,0000	0,0000	1,0000	0,0000	0,0000
Eco 9	0,0000	0,0000	0,0000	0,0000	1,0000
Eco 10	0,0000	0,0000	0,0000	0,0000	1,0000

MLP. La clasificación de una red MLP no es una pertenencia estricta a una sola clase (0 ó 1), es decir, puede producir clasificaciones en todo este rango de valores, asignando valores como 0,7 ó 0,3. Para el proceso de clasificación se usaron los mismos archivos (Tabla I), que fueron usados para la prueba de la red Kohonen. Los resultados arrojados de la clasificación se muestran en la tabla III, en la que se puede observar que dos archivos no fueron clasificados correctamente (eficiencia del 80 %), correspondientes a los ecos 5 y 6 con diámetro de 2,778 mm. La eficiencia se puede aumentar incrementando el número de ejemplos para entrenamiento de las clases que, inicialmente, no son clasificadas en forma correcta. La clasificación en 2 clases; con defecto y sin defecto, los resultados

fueron mas que satisfactorios ya que mostraron un 100 % de clasificación correcta (Tabla IV).

3.3. Cálculo de la localización del defecto

Otra de las facetas incorporadas a los clasificadores fue la de ubicar el defecto, es decir, pronosticar la localización de la discontinuidad tomando como referencia la parte posterior de la pieza inspeccionada. Para llevar a cabo esta tarea se incorporó una rutina en la que se detectan los picos de frecuencia del defecto y el de pared posterior y por medio de la técnica de tiempo de vuelo y una vez que se conoce la velocidad del sonido en el material de ensayo, se calcula la profundidad a la que el defecto se encuentra. Esta rutina de cálculo

Tabla III. Resultados de la red MLP para las pruebas por contacto*Table III. MLP net results for the contact test*

	SIN DEF.	D=3,175 mm	D=2,778 mm	D=2,381 mm	D=1,984 mm
Eco 1	0,841	0,000	0,001	0,000	0,000
Eco 2	0,737	0,000	0,002	0,000	0,000
Eco 3	0,000	0,715	0,175	0,015	0,000
Eco 4	0,000	0,908	0,045	0,035	0,000
Eco 5	0,000	0,000	0,000	0,041	0,000
Eco 6	0,000	0,000	0,001	0,004	0,000
Eco 7	0,000	0,000	0,021	0,875	0,008
Eco 8	0,000	0,000	0,046	0,912	0,002
Eco 9	0,000	0,000	0,000	0,001	0,996
Eco 10	0,000	0,000	0,002	0,294	0,774

Tabla IV. Resumen del número de neuronas empleadas por los modelos RNA y porcentaje de clasificación correcta del ensayo por contacto

Table IV. Resume, number of neurons employed for the RNA models and percentage of correct classification in the contact test

TIPO DE RED	2 Clases				5 Clases					
	Neuronas	1ª	2ª	Neuronas	%Clasi.	Neuronas	1ª	2ª	Neuronas	%Clasi.
KOHONEN	Entrada	Dimensión	Dimensión	Salida	Correcta	Entradas	Dimensión	Dimensión	Salida	Correcta
MLP	4	8	6	2	100	4	6	5	90	
		C.Oculto1	C.Oculto2							
	4	5	4	2	100	4	5	4	5	85

se hace normalmente mediante el uso de cursores en el osciloscopio mismo. En la figura 4 se muestra parte del programa desarrollado para dicho cálculo. Hay que recordar que los programas están hechos en un ambiente de programación grafica también conocido como lenguaje "G".

4. CONCLUSIONES

Los métodos de clasificación de discontinuidades de ultrasonidos por "pulso-eco" son capaces de dar información suficiente para detectar con muy buena precisión, tanto el diámetro como la posición de un defecto dado. La instrumentación virtual brinda una herramienta de control, captura y análisis de datos muy poderosa que puede ser fácilmente implantada en línea. El sistema experto de-

sarrollado detecta y clasifica discontinuidades encontradas en piezas de acero, por medio del uso de redes neuronales artificiales. El sistema es flexible, de forma que puede ser modificado y/o escalado sin realizarle cambios significativos.

En relación al desempeño de las redes se puede decir que, en el caso de Kohonen, se obtuvo una eficiencia del 90 % y que el desempeño de la MLP fue del 80 %. En relación a las características para el entrenamiento de las redes, concluimos que, para obtener una buena clasificación es más importante elegir las características adecuadas de las señales de los ecos que el clasificador a usar y que existe un conjunto óptimo de características para el entrenamiento: por debajo o más allá de éste conjunto óptimo el desempeño de la red decrece. Finalmente, encontramos que los ejemplos para el

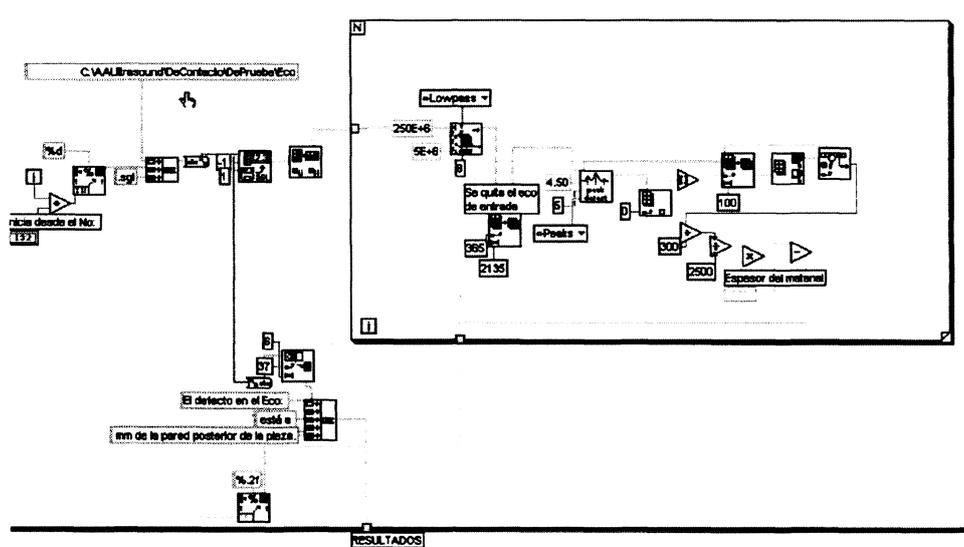


Figura 4. Subrutina, I.V., diseñada para el cálculo de la localización del defecto.

Figure 4. Subroutine, V.I., designed for the calculus of defect localization.

entrenamiento de las redes deben elegirse de tal manera que sean suficientes y representativos del problema a clasificar.

REFERENCIAS

- [1] J. KRAUTKRAMER, *Ultrasonic testing of Materials*, Springer-Verlag 1990.
- [2] L.W. SCHMEER, *Fundamentals of Ultrasonic Nondestructive Evaluation*, Plenum, 1998.
- [3] G.E.P. BOX, W.G. HUNTER y J.S. HUNTER, *Statistics for experimenters*, John Wiley and Sons, 1978.
- [4] E. KREYSZING, *Introducción a la estadística matemática*, Limusa, 1974.
- [5] P.H. WINSTON, *Inteligencia Artificial*, Tercera edición, Addison-Wesley Iberoamericana, 1994.
- [6] *LabVIEW*, National Instruments, Manuales y Tutoriales, LabVIEW 5.1, 1999. <http://www.ni.com>
- [7] *Dataengine, Data Mining by Intelligent Data Analysis*, Manuales y Tutoriales. Management Intelligenter Technologien GmbH. <http://www.mitgmbh.de>
- [8] K. KRISHNAKUMAR, *Robustness of neural networks*,. Dept. of Aerospace Engineering, The University of Alabama, Tuscaloosa, Al. 35487-0280.