

03063



UNIVERSIDAD NACIONAL
AUTÓNOMA DE
MÉXICO

UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

POSGRADO EN CIENCIA E INGENIERÍA DE LA COMPUTACIÓN

**DESARROLLO DE SISTEMAS
NEURONALES DE LA CLASE ART2 PARA
EL PROCESAMIENTO DE SEÑALES DE
TIPO ULTRASÓNICO**

T E S I S

QUE PARA OBTENER EL GRADO DE:

**MAESTRO EN INGENIERÍA
(COMPUTACIÓN)**

P R E S E N T A:

MARTÍN SOLÍS PÉREZ

**DIRECTORES DE LA TESIS: DR. HÉCTOR BENÍTES PÉREZ
DR. RICARDO BERLANGA ZUBIAGA**

MÉXICO, D. F.

2004.



Universidad Nacional
Autónoma de México



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

Agradecimientos

Se agradece el apoyo económico recibido por parte del proyecto PAPIIT IN106100.

Se agradece la colaboración recibida por parte de la Sección de Bioelectrónica CINVESTAV-Ciudad de México, por facilitar el uso del equipo de medición.

Agradecimientos

A mis tutores, Dr. Héctor Benítez Pérez y Ricardo Berlanga Zubiaga, mi sincero agradecimiento y respeto por haber dirigido atinadamente este trabajo, por su apoyo y tiempo dedicado.

A los sinodales, Dra. Lucia Medina Gómez, Dr. Luis Álvarez Icaza Longoria y Dr. Boris Escalante Ramírez por la revisión, sugerencias y correcciones que enriquecieron la presente tesis.

Se agradece también al Instituto de Matemáticas Aplicadas y en Sistemas y a la propia Universidad Nacional Autónoma de México que me dieron la oportunidad de realizar los estudios de maestría.

Publicaciones

Solís M., Benítez-Pérez H., Medina-Gómez L., Moreno E., y Gonzalez G.; "Pattern Recognition of Decomposed Wavelet Information using ART2 Networks for echoes Analysis"; Enviado a Mathematics and Computing Simulation, 2003.

Solís M., Ernesto Rubio, Héctor Benítez-Pérez, Eduardo Moreno-Hernandez, Lucía Medina-Gómez.; "Pattern Recognition of Wavelets Decomposition using ART2 Networks for echoes Analysis"; 2001 IEEE International Ultrasonics Symposium, pp. 679-682, Atlanta, Estados Unidos, Octubre 2001.

Solís M., Héctor Benítez-Pérez, Eduardo Moreno-Hernández, Lucía Medina-Gómez, Gilberto Gonzalez.; "Pattern Recognition of Wavelets Decomposition using ART2 Networks for echoes Analysis"; IEEE International Ultrasonics Symposium, Munich, Alemania, Octubre 2002. En Prensa.

CONTENIDO

Introducción	6
I Redes Neuronales	8
1.1 Introducción	8
1.2 Generalidades sobre las redes neuronales	9
1.3 Redes no supervisadas	12
1.4 Redes tipo ART	13
1.5 Descripción de la red ART	14
1.6 La Red ART2A	15
1.7 Implicación en el proyecto	16
1.8 Conclusiones	17
II Onduletas	18
2.1 Introducción	18
2.2 Onduletas	22
2.3 La Transformada Continua de Onduleta	26
2.8 Conclusiones	27
III Diseño Experimental	28
3.1 Introducción	28
3.2 Revisión del Ensayo no Destructivo	29
3.3 Descripción del método propuesto	31
3.4 Descripción del Material	35
3.5 Descripción Global	36
3.6 Conclusiones	37
IV Análisis de Resultados	38
4.1 Introducción	38
4.2 Revisión del Ambiente de Experimentación	38
4.3 Señales Obtenidas	41
4.4 Procesamiento de la señal	43
4.5 Procesamiento de la señal con un paso de 10 en 10 señales	46
4.6 Procesamiento de la señal bajo un paso de una señal	49
4.7 Análisis de Resultados	51
Conclusiones	52
Referencias	53
Apéndice A	55

Introducción

Actualmente el ultrasonido es utilizado en un gran número de disciplinas: en la obtención de imágenes médicas, para cortar metales, para pruebas no destructivas en la evaluación de materiales (ensayos no destructivos, END), etc. En este trabajo se usa el ultrasonido para la detección de fracturas en materiales hechos de aluminio.

Las pruebas END usan ondas ultrasónicas de alta frecuencia para evaluar materiales sin afectar su integridad. Esta tecnología se utiliza en variadas industrias (aeroespacial, nuclear) para inspeccionar con un alto grado de seguridad las partes críticas de diferentes materiales, así como para determinar defectos que a la larga provoquen una falla. Otro uso de las pruebas END con ultrasonido es en el control de calidad en los procesos de manufactura de materiales.

Los métodos de ensayos no destructivos pueden ser utilizados en tres tipos de aplicaciones: medidas de magnitudes, detección de fallas y caracterización de materiales. Dentro del primer grupo es frecuente la medida de distancias o espesores de materiales, velocidad de fluidos, densidad de materiales, concentración de disoluciones, etc. El segundo tipo tiene un uso muy fuerte en el control de calidad de estructuras de fabricación o en servicio. Finalmente, la caracterización de materiales por métodos END permite determinar propiedades de los granos del material, o la distribución y tamaño de los poros internos, o evaluar la corrosión y deterioro de los materiales.

Las técnicas ultrasónicas se destacan como las más usadas para medición, detección y evaluación de fallas en materiales que requieren un alto grado de calidad y confiabilidad. Entre las ventajas que presenta el ultrasonido frente a otras técnicas son:

- Se pueden aplicar a cualquier tipo de material sólido, líquido o gaseoso, con la única condición de que existan moléculas capaces de transmitir la perturbación mecánica.
- Permiten detectar defectos o fallas en el interior de los materiales dando como resultado el tamaño y la posición del defecto.

Técnicas para el procesamiento de la señal tales como Transformada Rápida de Fourier (Schmerr, 1998), onduletas (Legendre, et al, 1998) presentan diferentes alternativas para rescatar información caracterizada en primera instancia como ruido.

El problema a solucionar es la detección de fallas en un material de aluminio al 90% . Para tal efecto, se propone utilizar ultrasonido como método de exploración del material y redes neuronales como método de reconocimiento de las fallas.

El objetivo del presente trabajo es detectar fallas dentro de un material de aluminio al analizar los ecos de los pulsos ultrasónicos enviados al material. Para procesar la señal ultrasónica se utiliza la tecnología de onduletas (Legendre, et al, 1998.), y redes neuronales no supervisadas. Primeramente, se descompone la señal en diferentes niveles a través de la

transformada continua de onduleta y como núcleo se propone la onduleta Daubechie 4. Posteriormente, se procesa al grupo de las señales descompuestas por medio de la red neuronal no supervisada. En el presente trabajo se determina la distancia temporal entre dos ecos para este tipo de materiales. Se busca definir a que profundidad del material se localiza la falla.

Para clasificar los patrones generados por los ecos se propone el uso de la red neuronal del tipo Teoría de Resonancia Adaptable clase 2 (ART2, por sus siglas en inglés.) En el capítulo 1, se hace una descripción general de las redes neuronales y se estudia las redes tipo ART. En el presente trabajo se implementa la red neuronal ART2A (su arquitectura está descrita en el capítulo 1) para clasificar los diferentes niveles de descomposición en onduletas del eco recibido durante la prueba no destructiva.

En el capítulo 2 se hace una descripción resumida de la tecnología de las onduletas. No es nuestro objetivo desarrollar la teoría de onduletas en generalidad, únicamente se utiliza como una herramienta para el procesamiento de señales. La teoría de onduletas nos ofrece técnicas muy generales para el procesamiento de señales, por lo que tiene un gran potencial de aplicaciones. Para algunos casos es deseable ver la transformada de onduleta como la descomposición de una señal sobre un conjunto de funciones base (Frazier, 1999.) De hecho, las funciones base se llaman onduletas.

Como se verá en el capítulo 3, no es difícil montar un sistema de pruebas END con ultrasonido. Este consta del envío de pulsos ultrasónicos a un material, así como la recepción del eco modificado por la presencia de fallas en el material. Posteriormente se procesa a la señal recibida en un equipo de cómputo. Es en esta parte donde este trabajo se enmarca. Es decir, en la interpretación cualitativa de la señal que ha sido muestreada durante la prueba END. En este capítulo se desarrolla el método que se utiliza para el procesamiento y clasificación de la señal. En general, en el método se desarrollan e implementan las tecnologías ya mencionadas. Para la descomposición de la señal en diferentes niveles de onduleta se emplea la caja de herramientas *wavetool* de Matlab 6.0. La red neuronal ART2A también se programó en Matlab 6.0. Los listados de los programas se pueden consultar en el apéndice A.

En el capítulo 4 se analizan los datos obtenidos con base a la experimentación propuesta en el capítulo 3. Dichos resultados contemplan los diferentes experimentos llevados a cabo así como la variación de los diferentes parámetros de la red (descritos en el capítulo 2). En ese capítulo se describe el ambiente de experimentación.

Finalmente se presentan las conclusiones generales, las referencias y el apéndice A.

CAPITULO 1

REDES NEURONALES

1.1 Introducción

La estructura de los modelos de las redes neuronales artificiales (red neuronal) se basa en el conocimiento actual que se tiene sobre los sistemas nerviosos biológicos. Las redes neuronales están compuestas de muchos elementos computacionales no lineales que operan en paralelo y están ligados en patrones parecidos a las redes neuronales biológicas. Los elementos computacionales o nodos están conectados entre sí a través de una matriz de pesos que se adaptan durante el uso de la red neuronal con el fin de mejorar su rendimiento.

La red neuronal puede ser vista como una sola unidad computacional, en el sentido de que puede recibir datos de entrada y emitir datos de salida, además únicamente los nodos en la red efectúan el procesamiento de la información. Por esta razón, los nodos se clasifican en tres tipos: de entrada, de recepción de los datos a procesar, los nodos de salida que emiten los datos generados por la red; y los nodos ocultos que envían y reciben datos desde otros nodos de la red.

Los modelos de la red neuronal están definidos por la topología de la red, las características de los nodos, y por las reglas de entrenamiento y aprendizaje. Estas reglas especifican un conjunto inicial de pesos, así como éstos deben adaptarse durante el uso de la red. La adaptación, y aprendizaje es muy importante en las pruebas de END, pues se tiene un número finito de patrones, y la red tiene que aprender los nuevos patrones generados por las diferentes fallas que pueden presentarse en el material a evaluar.

Las redes neuronales pueden ser entrenadas con o sin supervisión. Las redes entrenadas con supervisión como la red de Hopfield y los perceptrones (Lippmann, 1997) se utilizan como memorias asociativas o clasificadores. Estas redes están provistas con información o etiquetas que especifican la clase correcta a la que deben pertenecer los patrones de entrada durante el entrenamiento. Las redes entrenadas sin supervisión, como la red de mapas de Kohonen (Nelles, 2001), usan vectores para formar cúmulos. Ninguna información a priori respecto a la clase correcta se les da a estas redes durante la fase de entrenamiento. En este capítulo se estudia el modelo de redes neuronales no supervisadas del tipo ART (Carpenter et al, 1987.)

Las redes neuronales en la actualidad se aplican en el procesamiento de señales (Luo 1997), por ejemplo, filtrado, estimación de parámetros, reconocimiento de patrones, reconstrucción de señales, detección de señales, comprensión, y transmisión de señales. El tipo de señales puede ser de audio, video, voz, comunicación, ultrasonido, geofísicas, etc.

El objetivo de este capítulo es presentar las características generales de una red neuronal, y se desarrolla el modelo conocido como teoría de resonancia adaptable.

1.2 Generalidades de las Redes Neuronales

Los elementos computacionales que forman a las redes neuronales artificiales se conocen como nodos, unidades, o elementos de procesamiento. Un nodo es un elemento representativo de la unidad conocida como neurona.

La Fig. 1.1, muestra el modelo general de un nodo. Cada nodo está numerado, en la figura se muestra el i -ésimo. Como podemos ver en la Fig. 1.1, un nodo tiene muchas entradas y sólo una salida, que puede estar conectada a otros nodos en la red; con x_j denotaremos el valor de entrada que proviene del j -ésimo nodo y que recibe el i -ésimo nodo, también nótese que x_j es el valor de salida del j -ésimo nodo, y por tanto, la salida del i -ésimo nodo es x_i .

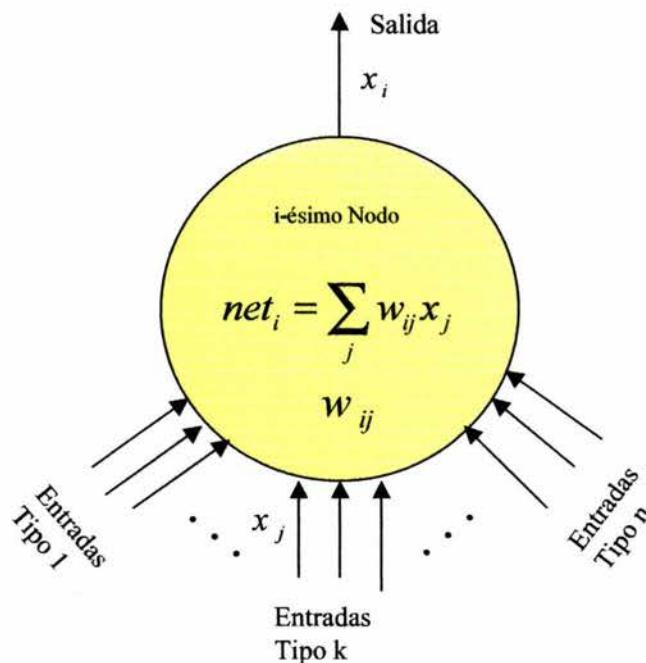


Fig. 1.1 Representación de un nodo de una red neuronal artificial cualquiera. Las conexiones de entrada, que provienen de otros nodos están representadas por las flechas de entrada. Los tipos de datos de cada entrada esta determinada por la naturaleza del problema que se quiere resolver, en el presente trabajo, todas las entradas son del mismo tipo, números reales. Cada conexión de entrada tiene asociada una cantidad, w_{ij} , llamada peso. Solo hay una salida que puede ser la entrada de otros nodos.

Cada conexión del i -ésimo nodo tiene asociada una cantidad llamada peso. El peso que corresponde a la conexión del j -ésimo nodo con el i -ésimo nodo se denota con w_{ij} . Todas estas cantidades tienen sus análogos en el modelo estándar de una neurona: la salida del nodo corresponde con la frecuencia de disparo de la neurona, el peso corresponde con la

fuerza de la conexión sináptica entre neuronas. En este modelo, las cantidades serán números reales. Nótese que las entradas al nodo las hemos agrupado por tipo. Este agrupamiento nos dice que una conexión de entrada en particular puede tener uno o varios efectos. Por ejemplo, la conexión se activa, cuando el peso es positivo, o se inhibe, si el peso es negativo.

Cada nodo calcula un valor neto de entrada cuyo valor depende de todas las conexiones de entrada que llegan al nodo. Típicamente, el valor de entrada neto se obtiene sumando los productos de los pesos con sus respectivos valores de entrada. Es decir, el valor de entrada del i -ésimo nodo se calcula como

$$net_i = \sum_j w_{ij} x_j \quad (1.1)$$

donde el índice j , corre sobre todas las conexiones que llegan al nodo. Una vez que se ha calculado el valor de entrada neto, se procede a calcular el valor de activación, o simplemente la activación, del nodo. El valor de activación es una función explícita $F_i(\cdot)$ de la entrada

$$a_i(t) = F_i(a_i(t-1), net_i(t)) \quad (1.1a)$$

Según la ecuación anterior, el valor de activación también depende de los valores previos de activación. En la mayoría de las redes, el valor de activación y el valor de entrada neto coinciden, por lo que estos términos usualmente se intercambian.

Una vez calculado el valor de activación, se procede a calcular el valor de salida al aplicar la función de activación $f_i(\cdot)$,

$$x_i = f_i(a_i) \quad (1.2)$$

Usualmente $a_i = net_i$, por lo que el valor de salida se calcula como

$$x_i = f_i(net_i). \quad (1.3)$$

El modelo matemático de la red neuronal nos dice que la red va evolucionando en el tiempo, pues como ya se mencionó, el valor de activación depende de los valores previos de activación (1.1a), por lo que se puede pensar que la red es un sistema dinámico. Para describir la red, se hará uso de ecuaciones diferenciales que describen los cambios de la salida respecto del tiempo de los nodos, por ejemplo,

$$\dot{x}_i = g_i(x_i, net_i) \quad (1.4)$$

representa una ecuación diferencial para la salida del i -ésimo nodo. Pero, net_i depende de las salidas de otros nodos, por lo que en realidad tenemos un sistema de ecuaciones diferenciales acopladas.

También es útil considerar al conjunto de los pesos como un sistema dinámico. Porque al estar aprendiendo la red estos valores van a cambiar con el tiempo. Podemos escribir un sistema de ecuaciones diferenciales para los pesos,

$$\dot{w}_{ij} = G_i(w_{ij}, x_i, x_j, \dots) \quad (1.5)$$

donde $G_i(\cdot)$ representa la ley de aprendizaje. El proceso de aprendizaje consiste en encontrar los pesos que codifican el conocimiento que queremos que el sistema aprenda. En muchos modelos de redes neuronales es conveniente describir ciertas cantidades en términos de vectores (ART1, ART2, la red neuronal de Hopfield, etc.) Consideremos una red formada por varias capas con nodos idénticos en cada capa. Supongamos que una capa tiene n nodos, los valores de salida de la capa pueden representarse con un vector columna con n componentes

$$\mathbf{x} = (x_1, x_2, \dots, x_n)^t \quad (1.6)$$

el superíndice t significa transposición. Es decir, \mathbf{x}^t es un vector renglón.

Supongamos que en un vector agrupamos los valores de salida que pasarán a ser valores de entrada para cada nodo de una capa con m elementos. Cada nodo de la capa tendrá n pesos asociados con las conexiones provenientes de la capa subyacente. Entonces hay m vectores de pesos con n componentes cada uno de ellos. El vector de pesos asociado al i -ésimo nodo puede ser escrito como

$$\mathbf{w}_i = (w_{i1}, w_{i2}, \dots, w_{in})^t \quad (1.7)$$

Recordemos que la entrada neta al i -ésimo nodo es una suma de productos de los pesos con las entradas, ver ecuación 1; ésta ecuación puede ser escrita en notación vectorial como un producto escalar

$$net_i = \mathbf{x}^t \mathbf{w}_i = \mathbf{w}_i^t \mathbf{x} \quad (1.8)$$

En resumen, habrá vectores de entrada, salida y de pesos.

Con respecto a la capacidad de aprendizaje de una red existen dos tipos, las redes supervisadas y las no supervisadas. Dentro de las primeras se clasifica al uso del aprendizaje con base al algoritmo de retropropagación (Wang, 1994), de aprendizaje hacia delante (Hassoun, 1995) y de funciones de base radial (Kirby, 2001.) Para el segundo tipo se encuentran los métodos basados en el agrupamiento como son los mapas de organización propia (Nelles, 2001) y la teoría de resonancia adaptable (Carpenter et al, 1987). Dado que

el objetivo de esta tesis es el uso de las redes neuronales como clasificador de patrones solo será revisada la última técnica.

1.3 Redes no supervisadas

El uso principal de las redes no supervisadas es la construcción de patrones en línea. Esto es, con base en información dentro de una ventana de tiempo y sin detener al proceso observado se construye el patrón de referencia. Esta forma de aprendizaje presenta la desventaja de poder ser no inmune al ruido o a la inestabilidad del sistema observado.

Como se mencionó en la sección anterior existen varios métodos para programar la clasificación de patrones en línea:

- Agrupamiento
- Mapas de Organización Propia
- Teoría de Resonancia Adaptable

Los primeros se basan en la separación de la información a partir de grupos. Estos pueden ser de varias dimensiones. Cada grupo es representado a través de un patrón que cumple ciertas características como el centro de masa del grupo a representar o la mínima varianza de este mismo (Abe, 2001.) Técnicas tales como Fuzzy C-means (Höppner et al, 1999) la cual usa la minimización de la norma euclidiana de la diferencia entre el vector a evaluar y el patrón representativo del grupo, presentan la ventaja de un cálculo sencillo para la minimización de errores. Sin embargo, no tiene una alta inmunidad al ruido.

Por otro lado, técnicas como los mapas de organización propia determinan (entrenan) los pesos de la red de manera autónoma de acuerdo a la distribución de los datos de entrada. Cuando una entrada se presenta a la red, la neurona cuyo vector de pesos es el más cercano al espacio de entrada se selecciona como neurona ganadora. Este vector de pesos se modifica de tal forma que se aproxima al vector de entrada. Además, los vectores de peso de las neuronas que están cercanas a la neurona ganadora también se modifican para estar próximos al vector de entrada. Antes de mostrar el algoritmo de entrenamiento de la red, definamos las siguientes cantidades. Denotemos el vector de entrada con $\mathbf{x} = (x_1, \dots, x_m)^t$, sean M el número máximo de iteraciones para el entrenamiento de la red, U el número de neuronas y $\mathbf{w}_i = (w_{i1}, \dots, w_{im})^t$ el vector de pesos entre la entrada y la i -ésima neurona, donde w_{ij} es el peso asociado entre la j -ésima entrada y la i -ésima neurona. El algoritmo de entrenamiento es el siguiente:

- i) Asignar valores al vector de pesos \mathbf{w}_j para $j = 1, \dots, U$.
- ii) Iterar los pasos (iii) y (iv) para $l = 1, \dots, M$. El entrenamiento termina cuando las correcciones hechas a los pesos son menores a un valor especificado de antemano o cuando han transcurrido M iteraciones.
- iii) Buscar la neurona ganadora i que satisface

$$i = \min_{j=1, \dots, U} \|\mathbf{x} - \mathbf{w}_j\|$$

- iv) Modificar los vectores de peso \mathbf{w}_j de las neuronas cercanas a la neurona ganadora para que \mathbf{w}_j este cercano al vector \mathbf{x} :

$$\mathbf{w}_j^{\text{nuevo}} = \mathbf{w}_j^{\text{viejo}} + \varepsilon h_{ij} (\mathbf{x} - \mathbf{w}_j^{\text{viejo}}),$$

donde $0 < \varepsilon < 1$ y $h_{ij} = \exp\left(-\frac{d_{ij}}{\sigma^2}\right)$, aquí d_{ij} es la distancia entre las neuronas i y j

y σ es un parámetro de ajuste. Los parámetros ε y σ deben decrecer durante el entrenamiento para evitar que los vectores de pesos oscilen.

Para clasificar datos de entrenamiento en cúmulos con la red de Kohonen (Nelles, O., 2001), se entrena a la red poniendo el número de neuronas mayor al número de clases (grupos). Después de entrenar la red, la “alimentamos” con un vector de entrada que represente una clase de interés, y asociamos el dato con la neurona ganadora. El conjunto de datos asociado con una neurona forma un grupo. Si un grupo tiene datos que pertenecen a diferentes clases, entonces se divide al grupo en otros grupos que únicamente contengan datos pertenecientes a la misma clase.

1.4 Redes tipo ART

Una de las características de las primeras redes neuronales es que tendían a olvidar la información que ya habían aprendido. Durante el entrenamiento el conocimiento adquirido se codificaba en el sistema ajustando el vector de pesos. Una vez que el entrenamiento se consideraba adecuado, el sistema se ponía en producción, y ya no se permitía ninguna modificación al vector de pesos. Este escenario operacional es aceptable si el dominio del problema está bien definido (acotado) y si es estable. Bajo estas condiciones, usualmente es posible definir un conjunto adecuado de entradas para entrenar al sistema y se procede a resolver el problema. Desafortunadamente en muchas situaciones, el problema no está acotado y es no estable.

Stephen Grossberg (Carpenter G., and Grossberg S., 1988) estudió la situación anterior y se planteó el dilema de la plasticidad: ¿Cómo podría un sistema que aprende permanecer adaptado (plasticidad) y estable sin importar que información este recibiendo? ¿Cómo podría el sistema saber en que momento cambiar su estado de plasticidad a uno estable y viceversa? ¿Cómo podría el sistema retener la información ya aprendida, y continuar aprendiendo nuevos hechos?

Para dar respuestas a las preguntas anteriores, Stephen Grossberg y Gail Carpenter (Carpenter G., and Grossberg S., 1988) desarrollaron la teoría de resonancia adaptable (*Adaptive Resonance Theory*, ART por sus siglas en inglés). ART es una extensión de los esquemas de aprendizaje competitivo. En los sistemas competitivos, los nodos compiten basados en algún criterio, entre ellos mismos, y decimos que el nodo ganador es el que clasifica al patrón de entrada. Pueden presentarse ciertas inestabilidades

en la red, por ejemplo, dos nodos podrían responder al mismo patrón de entrada en diferentes ocasiones.

La clave para resolver el problema de estabilidad y plasticidad es añadir un mecanismo de realimentación entre las capas competitivas y la capa de entrada de la red. Este mecanismo facilita: el aprendizaje de nueva información sin perder la información anterior, y el cambio de estado del modo de plasticidad al estable. Como resultado se tiene la arquitectura de dos redes neuronales que son convenientes para resolver problemas de clasificación de patrones en ambientes reales. Estas arquitecturas se conocen como ART1 y ART2 (Frank et al, 1998). Las redes se diferencian por el tipo de patrones de entrada. La red ART1 requiere que sus patrones de entrada sean binarios, mientras que ART2 es conveniente para procesar patrones continuos.

El nombre de ART dado a la red proviene de la manera en que la red aprende. La información viaja hacia atrás o hacia adelante entre las capas, si el patrón progresa, por lo que se tiene una oscilación estable que es el equivalente en redes neuronales a la resonancia de un sistema físico. Durante este periodo de resonancia la red aprende y se adapta.

1.5 Descripción de la red ART

Las redes ART se desarrollaron para resolver el dilema estabilidad-plasticidad planteado por Carpenter y Grossberg: Un sistema que aprende tiene que cumplir con al menos dos tareas:

- (i) Tiene que adaptarse a la nueva información que recibe. Cómo la red podría aprender nuevos patrones.
- (ii) Tiene que converger a una solución que sea óptima y sin olvidar los patrones ya aprendidos.

Así, el objetivo es diseñar un sistema que sea capaz de adaptarse a la nueva información (plasticidad) sin olvidar o sobrescribir las relaciones que ya conoce (que sea estable.) Como puede notar el lector, en este contexto estabilidad es un sinónimo para convergencia. En las redes ART este conflicto se soluciona al introducir un parámetro de vigilancia. Su objetivo es definir si las relaciones ya aprendidas deben adaptarse en función de la nueva información que está recibiendo el sistema, o si se debe crear un cúmulo que represente a los nuevos datos.

El algoritmo de las redes ART se inicia sin neuronas y las va construyendo conforme va aprendiendo el sistema. En cada iteración, se procede a calcular la distancia que hay entre el centro de los cúmulos de las neuronas y la información de entrada. La neurona ganadora será aquella que minimice la distancia. Si la distancia es menor que el parámetro de vigilancia ρ , entonces la neurona ganadora se actualiza, de acuerdo a cierto algoritmo de adaptación (en la siguiente sección se describe el algoritmo que se utilizó en este trabajo, que corresponde a la red ART2A.) Si no hay neurona ganadora, se genera una nueva neurona que conoce la nueva información.

Claramente, el comportamiento de las redes ART depende fuertemente del parámetro de vigilancia ρ . Valores grandes de ρ generan muy pocas neuronas (cúmulos), mientras que para valores pequeños de ρ posiblemente habrá un cúmulo para cada dato presentado a la red. Como la elección de ρ es crucial, el usuario de la red debe encontrar un buen valor para el parámetro de vigilancia para cada aplicación específica con base a un método de ensayo y error. Otra característica no conveniente en las redes ART, es que su algoritmo de adaptación y aprendizaje depende del orden en que se le presenten los datos durante el proceso de entrenamiento.

1.6 La red ART2A

En esta sección se presenta el algoritmo de la red neuronal ART2A (Frank et al, 1998.) La red ART2A utiliza el ángulo entre los vectores de entrada para medir la similitud de los datos, en la Fig. 1.4, se ilustra la relación entre dos vectores bidimensionales.




Fig. 1.4. La similitud de los patrones de entrada en la red ART2A está dada por el ángulo φ entre los vectores de entrada \mathbf{I} y el prototipo \mathbf{W}_j . La entrada \mathbf{I} es asignada al agrupamiento j si él $\cos \varphi \geq \cos \beta = \rho$ (parámetro de vigilancia.)

Las funciones principales del algoritmo de la red ART2A, de acuerdo a la Fig. 1.4, son las siguientes:

1. Condición sobre los datos. Los componentes de los vectores de entrada \mathbf{A} tienen que ser no negativos. También es necesario que los vectores de entrada sean

unitarios (de norma uno) respecto a la norma Euclidiana, representemos con \mathfrak{N} la función que normaliza los patrones de entrada,

$$\mathbf{I} = \mathfrak{N}(\mathbf{A}) = \frac{\mathbf{A}}{\sqrt{\sum_{i=1}^m a_i^2}} = \frac{\mathbf{A}}{\|\mathbf{A}\|}, \quad \mathbf{A} = (a_1, \dots, a_n) \quad a_i \geq 0 \quad \forall i, \quad \|\mathbf{A}\| > 0. \quad (1.9)$$

2. Elección. Se ejecutan las actividades de la red que van de las capas inferiores a las superiores, lo que nos lleva a un valor prototipo, determinado por,

$$t_j = \mathbf{I} \cdot \mathbf{W}_j$$

Aquí se verifican todos los prototipos para después elegir el ganador.

3. Concordancia. Para elegir el prototipo ganador se busca el índice J que cumpla con la siguiente desigualdad,

$$\rho \leq \mathbf{I} \cdot \mathbf{W}_j = t_j$$

Si se encuentra dicho índice entonces ocurre la resonancia y la adaptación, en caso contrario se agrega un nuevo prototipo.

4. Adaptación. La adaptación del prototipo ganador consiste en acercarlo hacia el vector que representa el patrón de entrada actual,

$$W_j^{nuevo} = \mathfrak{N}(\eta \mathbf{I} + (1 - \eta) W_j^{anterior}) \quad 0 \leq \eta \leq 1.$$

El parámetro η se conoce como parámetro de aprendizaje. Cuando no se encontró ningún prototipo ganador, el parámetro η toma el valor 1.

En las redes ART2A se recomienda no usar el aprendizaje rápido $\eta \approx 1$, porque los prototipos empezaran a saltar entre todos los valores asignados al cúmulo, en lugar de converger a la media.

1.7 Implicación en el Proyecto

Aún cuando existe una diversidad de métodos de entrenamiento en las redes neuronales, como los supervisados y los no supervisados, los cuales son válidos para la clasificación de patrones, se requiere restringir el espacio tomando en cuenta las necesidades puntuales del proyecto. Esto es, debido a necesidades específicas se obtiene una decisión totalmente restringida para una solución viable desde diferentes alternativas.

En este proyecto se optó por las redes neuronales para la construcción de patrones en línea dada su respuesta en tiempo real. En particular se ha trabajado con las redes tipo ART2A (Wang, et al, 1999) dada su rápida respuesta en tiempo y su ligereza en cómputo. Alternativas tales como el uso de Multi-Perceptrones (Guez et al, 1991) para el análisis de ensayos no destructivos se presenta como una opción inmune al ruido pero con alto gasto computacional.

En los capítulos cuatro y cinco se presenta de manera práctica el uso de las redes tipo ART2A para una revisión del tipo B-scan de un material compuesto de aluminio con fallas.

1.8 Conclusiones

En este capítulo se presenta una revisión breve de las redes neuronales buscando enfocar al lector en el tipo de redes que se usa en esta tesis. Aún cuando no es factible eliminar de manera formal cualquier tipo de red, se propone el uso de la clasificación de patrones por medio de redes no supervisadas. En específico las redes tipo ART2A, por su alta velocidad en la clasificación de patrones.

Una interesante línea de investigación queda abierta en el uso de mapas de organización propia por su alta inmunidad al ruido, no obstante requiera una alta cantidad de memoria para una aceptable discriminación de patrones.

Capítulo II

Onduletas

2.1 Introducción

Cada componente de un sistema ultrasónico para pruebas END puede ser modelado como un sistema lineal invariante en el tiempo (Schmerr, 1998.) Es decir, el operador L que modela al sistema cumple con la relación siguiente: si la señal de entrada $f(t)$ se retarda un tiempo τ , entonces la salida también se retarda el mismo tiempo τ , por lo tanto, sí

$$g(t) = Lf(t) \Rightarrow g(t - \tau) = Lf(t - \tau). \quad (2.1)$$

Ahora bien, para tener estabilidad en los cálculos numéricos se necesita que el operador L sea continuo (Rudin, 1986.) Es importante mencionar que los teoremas y demostraciones que aparecen en este capítulo no son obra del autor de ésta tesis. El lector interesado puede consultarlos en la bibliografía correspondiente.

Los sistemas LTI quedan totalmente caracterizados si se conoce su respuesta a un impulso de Dirac $\delta(t)$. Si f es continua, su valor en t se obtiene al integrarla contra el pulso de Dirac (Kolmogorov, 1999.) Sea $\delta_u(t) = \delta(t - u)$, entonces

$$f(t) = \int_{-\infty}^{+\infty} f(u)\delta_u(t) dt. \quad (2.2)$$

La continuidad y linealidad del operador L implica que (Proakis John, Manolakis Dimitris G., 1995)

$$Lf(t) = \int_{-\infty}^{+\infty} f(u)L\delta_u(t) du. \quad (2.3)$$

Sea h la respuesta de L al impulso de Dirac,

$$h(t) = L\delta(t) \quad (2.4)$$

La no-dependencia en el tiempo nos dice que,

$$Lf(t) = \int_{-\infty}^{+\infty} f(u)h(t - u) du = \int_{-\infty}^{+\infty} f(t - u)h(u) du = h(t) * f(t). \quad (2.5)$$

Es decir, un sistema lineal invariante en el tiempo es equivalente a un producto convolución con la respuesta h de L al impulso de Dirac.

Los operadores de convolución tienen como funciones propias las funciones exponenciales complejas $e^{i\omega t}$. Veamos que así es,

$$L e^{i\omega t} = \int_{-\infty}^{\infty} h(u) e^{i\omega(t-u)} du = e^{i\omega t} \int_{-\infty}^{\infty} h(u) e^{-i\omega u} du = \hat{h}(\omega) e^{i\omega t}. \quad (2.6)$$

El valor propio

$$\hat{h}(\omega) = \int_{-\infty}^{\infty} h(u) e^{-i\omega u} du \quad (2.7)$$

se llama la transformada de Fourier de h en la frecuencia angular ω . Al ser las exponenciales complejas $e^{i\omega t}$ funciones propias (vectores propios) de los sistemas invariantes en el tiempo, es tentativo intentar descomponer cualquier función f como una suma de estas funciones propias. Más adelante veremos bajo que condiciones es posible hacerlo. La transformada de Fourier mide cuantas oscilaciones en la frecuencia ω hay en la función f .

Ahora se definirán los dos espacios vectoriales en los que se va a trabajar, el primero de ellos es el espacio $L_1(-\infty, +\infty)$ que es el conjunto de todas las funciones (con dominio en el campo de los números reales y contradominio en el campo de los números complejos) absolutamente integrables en el sentido de Lebesgue sobre la recta real (Rudin, 1986), la norma en este espacio está definida por

$$\|f\| = \left(\int |f|^2 d\mu \right)^{1/2}. \quad (2.8)$$

Por definición, $|f(t)|^2 = f(t)\bar{f}(t)$, en donde $\bar{f}(t)$ es la compleja conjugada de $f(t)$. Además $L_1(-\infty, \infty)$ es un espacio completo, por lo que es un espacio de Banach (Rudin, 1986). Otro espacio importante en el que se trabaja en procesamiento de señales, es el espacio de Hilbert $L_2(-\infty, \infty)$ que es el conjunto de todas las funciones de cuadrado integrable en el sentido de Lebesgue (Rudin, 1986.) En este espacio se tiene definido un producto interior (escalar) y una norma que proviene del producto interior. Sean f y g dos funciones en $L_2(-\infty, \infty)$ se define su producto escalar como

$$\langle f, g \rangle = \int f \bar{g} d\mu \quad (2.9)$$

y la norma de f por

$$\|f\| = \left(\int |f(x)|^2 d\mu(x) \right)^{1/2}. \quad (2.10)$$

A las funciones en $L_2(-\infty, \infty)$ también se les conoce como funciones de energía finita (Proakis, 1995).

El análisis de Fourier dice bajo que condiciones una función f en el espacio $L_1(-\infty, \infty)$ tiene transformada inversa de Fourier (Kolmogorov, 1999).

Teorema. Si una función f pertenece a $L_1(-\infty, \infty)$ y verifica la condición de Dini, es decir,

si la $\int_{-\varepsilon}^{\varepsilon} \frac{f(x+t) - f(x)}{t} dt$ existe para algún $\varepsilon > 0$ perteneciente a los números reales, se tiene que

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \hat{f}(\omega) e^{i\omega t} d\omega. \quad (2.11)$$

Ahora se verá cuando es posible interpretar la transformada de Fourier para funciones en $L_2(-\infty, \infty)$. La dificultad principal consiste en que una función cuadrado integrable no pertenece necesariamente a $L_1(-\infty, \infty)$, es decir, su transformada de Fourier podría no existir. Sin embargo, es posible definir, la transformación de Fourier para toda función f en $L_2(-\infty, \infty)$. Se tiene el siguiente teorema (cuya demostración puede consultarse en la referencia Kolmogorov, 1999) que permite definir la transformada de Fourier en el espacio $L_2(-\infty, \infty)$.

Teorema de Parseval-Plancharel. Para cualquier función f en $L_2(-\infty, \infty)$ la integral

$$g_N(\omega) = \int_{-N}^N f(x) e^{-i\omega x} dx$$

es para cualquier N , una función que pertenece a $L_2(-\infty, \infty)$. Para $N \rightarrow \infty$ las funciones g_N convergen en la métrica del espacio $L_2(-\infty, \infty)$ hacia un límite g tal que,

$$\int_{-\infty}^{+\infty} |g(\omega)|^2 d\omega = 2\pi \int_{-\infty}^{+\infty} |f(x)|^2 dx. \quad (2.12)$$

A esta función g se le conoce como la transformada de Fourier de la función f en $L_2(-\infty, \infty)$. Si f pertenece también a $L_1(-\infty, \infty)$, la función correspondiente g coincide con la transformación habitual de Fourier de la función f .

La propiedad más importante de la transformada de Fourier para el procesamiento de señales es el teorema de convolución. Es otra manera de expresar que las funciones de onda sinusoidales $e^{i\omega t}$ son valores propios del operador convolución.

Teorema de Convolución Sea $f \in L^1(\mathbb{R})$ y $h \in L^1(\mathbb{R})$. La función $g * f \in L^1(\mathbb{R})$ y $\hat{g}(w) = \hat{h}(w)\hat{f}(w)$.

Demostración:

$$\hat{g}(w) = \int_{-\infty}^{+\infty} e^{-i\omega t} \left(\int_{-\infty}^{+\infty} f(t-u)h(u)du \right) dt.$$

Como $|f(t-u)h(u)|$ es integrable en \mathbb{R}^2 , podemos aplicar el teorema de Fubini, hagamos el siguiente cambio de variable $(t, u) \rightarrow (v = t - u, u)$ entonces

$$\hat{g}(w) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} e^{-i(u+v)\omega} f(v)h(u)dudv = \int_{-\infty}^{+\infty} e^{-iv\omega} f(v)dv \int_{-\infty}^{+\infty} e^{-iu\omega} h(u)du$$

por lo tanto,

$$\hat{g}(w) = \hat{h}(w)\hat{f}(w).$$

La respuesta de un sistema lineal invariante en el tiempo $Lf = g = f * h$ puede calcularse a partir de su transformada de Fourier $\hat{g}(w) = \hat{h}(w)\hat{f}(w)$ junto con la formula de inversión de Fourier.

El objetivo que se persigue en el análisis de señales es extraer información relevante de una señal al transformarla. La codificación y el reconocimiento de patrones se hace en el dominio de la transformada, además ciertas propiedades pueden ser evidentes.

Las señales estacionarias $x(t)$, son aquellas cuyas propiedades no evolucionan en el tiempo. La transformada adecuada para el análisis de estas señales es la transformada de Fourier. Los coeficientes $x(w)$, se calculan como se muestra en la ecuación (2.2) a través de un producto interior de la señal con las funciones base, sinusoidales con duración infinita. Como consecuencia, el análisis de Fourier trabaja adecuadamente para señales $x(t)$ con pocas componentes estacionarias. Sin embargo, si se presenta un cambio abrupto en la señal en el tiempo, esta se convierte en una señal no estacionaria $x(t)$. Su transformada $x(w)$ se expande sobre intervalos a lo largo del dominio de la frecuencia. Por lo tanto, se requiere de una herramienta adecuada para el análisis de señales no estacionarias.

El método usual es introducir la dependencia sobre el tiempo en el análisis de Fourier preservando sus propiedades de linealidad. La idea es introducir un parámetro llamado "frecuencia local" para que la transformada de Fourier analice la señal a través de una ventana sobre la cual esta señal es aproximadamente estacionaria. Otra alternativa es modificar las funciones base sinusoidales usadas en la transformada de Fourier por otras funciones base con soporte compacto en el tiempo (y menos concentradas en la frecuencia).

2.2 Onduletas

La teoría de onduletas ofrece un conjunto de técnicas que han sido desarrolladas de manera independiente para implantar aplicaciones de procesamiento de señales, por ejemplo, procesamiento en multirresolución de señales, en visión computacional, para comprimir imágenes, para el procesamiento de señales ultrasónicas, y expansión de funciones en series de onduletas. La teoría de onduletas cubre una gran área de estudio, permite analizar señales continuas y discretas en el tiempo.

La transformada continua de onduleta (CWT, por sus siglas en inglés) es útil para el procesamiento de señales no estacionarias. Es una alternativa a la transformada de Fourier en tiempo corto (Goswami, 1999) (STFT, por sus siglas en inglés), y para la transformada de Gabor (Gabor, 1946). La diferencia básica es la siguiente, mientras que STFT utiliza una ventana de tiempo para el análisis de la señal, la CWT usa ventanas pequeñas en frecuencias altas, y ventanas grandes en bajas frecuencias (Goswami, 1999).

En algunas aplicaciones, como es en el presente trabajo, es conveniente ver la CWT como una técnica que nos permite descomponer una señal sobre un conjunto de funciones base, que de hecho se conocen como onduletas. Ellas se obtienen a partir de una onduleta prototipo por medio de dilaciones, contracciones (escalamiento) y corrimientos. Así, en la CWT, la noción de escala se presenta como una alternativa a la frecuencia, dando origen a la representación *tiempo-escala*.

Existen varios tipos de transformadas onduleta, y dependiendo de la aplicación se elegirá la más adecuada. Para una señal continua en el tiempo, el tiempo y los parámetros de escala deben ser continuos, por lo que se tiene que definir la transformada continua de onduleta. Alternativamente existe la transformada discreta de onduleta, que se usa en el procesamiento de señales discretas en el tiempo.

La teoría de onduletas ha sido desarrollada recientemente en un marco unificado, aunque ideas similares se analizaron a principios del siglo XX (Haar, 1910). La idea de descomponer una señal en varias escalas y analizarla en diferentes resoluciones surgió de manera independiente en varios campos de las matemáticas, física e ingeniería. A mediados de los ochentas, Morlet geofísico, Grossman físico teórico y Meyer matemático, construyeron el fundamento matemático que sustenta la teoría de las onduletas.

Definición. (Onduleta) Una onduleta es una función en $L^2(\mathbb{R})$ que tiene promedio cero:

$$\int_{-\infty}^{\infty} \psi(t) dt = 0. \quad (2.13)$$

A las onduletas se les puede dilatar usando un parámetro s llamado parámetro de escala; también se les puede trasladar por medio del parámetro u :

$$\psi_{u,s}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-u}{s}\right). \quad (2.14)$$

Se puede construir onduletas ψ de tal manera que la familia \mathfrak{S} de onduletas trasladadas y expandidas:

$$\mathfrak{S} = \left\{ \psi_{j,n}(t) = \frac{1}{\sqrt{2^j}} \psi\left(\frac{t-2^j n}{2^j}\right) : j, n \in \mathbb{Z} \right\}, \quad (2.15)$$

forme una base ortonormal de $L^2(\mathbb{R})$.

Las onduletas ortonormales expandidas por el factor 2^j permiten ver las variaciones de la señal a una resolución 2^{-j} . La construcción de estas bases permite hacer un estudio de *multirresolución* de la señal. Formalmente, la aproximación de una función a la resolución 2^{-j} se define como una proyección ortogonal sobre un espacio $\mathbf{V}_j \subset L^2(\mathbb{R})$. El espacio \mathbf{V}_j reagrupa todas las aproximaciones posibles a la resolución 2^{-j} . Recuérdese que la proyección ortogonal de la función f es la función $f_j \in \mathbf{V}_j$ que minimiza $\|f - f_j\|$.

Definición. (*Multirresolución*) Una familia de subespacios cerrados $\{\mathbf{V}_j : j \in \mathbb{Z}\}$ de $L^2(\mathbb{R})$ es una aproximación multirresolución si satisface las siguientes seis propiedades:

- (i) Para todo $j, k \in \mathbb{Z}$, $f(t) \in \mathbf{V}_j \Leftrightarrow f(t-2^j k) \in \mathbf{V}_j$ (2.16)
- (ii) Para todo $j \in \mathbb{Z}$, $\mathbf{V}_{j+1} \subset \mathbf{V}_j$
- (iii) Para todo $j \in \mathbb{Z}$, $f(t) \in \mathbf{V}_j \Leftrightarrow f\left(\frac{t}{2}\right) \in \mathbf{V}_{j+1}$
- (iv) $\lim_{j \rightarrow +\infty} \mathbf{V}_j = \bigcap_{j=-\infty}^{+\infty} \mathbf{V}_j = \{0\}$
- (v) $\lim_{j \rightarrow -\infty} \mathbf{V}_j = \bigcup_{j=-\infty}^{+\infty} \mathbf{V}_j = L^2(\mathbb{R})$
- (vi) Existe θ tal que $\{\theta(t-n) : n \in \mathbb{Z}\}$ es una base de Riesz de \mathbf{V}_0 .

La propiedad (i) dice que el subespacio \mathbf{V}_j es invariante ante cualquier traslación proporcional a la escala 2^j . La inclusión (ii) es una propiedad de causalidad, pues dice que una aproximación a la resolución 2^{-j} contiene toda la información necesaria para computar una resolución más burda 2^{-j-1} . Si dilatamos las funciones en \mathbf{V}_j por 2, entonces los detalles se amplifican en un factor de 2, y así (iii) define una aproximación a una resolución más burda. Cuando la resolución 2^{-j} tiende a cero, (iv) implica que se han perdido todos

los detalles de f , es decir, la proyección de la señal f sobre el espacio V_j cuando $j \rightarrow +\infty$ es igual a cero:

$$\lim_{j \rightarrow +\infty} \|P_{V_j} f\| = 0.$$

De otra manera, si la resolución 2^{-j} tiende a $+\infty$, la propiedad (v) obliga a que la aproximación de la señal converja a la señal original:

$$\lim_{j \rightarrow -\infty} \|f - P_{V_j} f\| = 0.$$

La existencia de una base de Riesz $\{\theta(t-n): n \in \mathbb{Z}\}$ de V_0 regala un teorema de discretización. La función θ puede interpretarse como una celda de resolución unidad. Para computar varias resoluciones de una señal, se necesita calcular sus componentes ortogonales sobre diferentes espacios $\{V_j: j \in \mathbb{Z}\}$ de $L^2(\mathbb{R})$. Según la definición de una base de Riesz, existen $A, B > 0$ tal que si $f \in V_0$ puede ser descompuesto:

$$f(t) = \sum_{n=-\infty}^{+\infty} a[n] \theta(t-n) \quad (2.18)$$

con

$$A\|f\|^2 \leq \sum_{n=-\infty}^{+\infty} |a[n]|^2 \leq B\|f\|^2. \quad (2.19)$$

Esta expresión garantiza que la expansión de la señal sobre $\{\theta(t-n): n \in \mathbb{Z}\}$ es numéricamente estable.

La aproximación de f en la resolución 2^{-j} se define como la proyección ortogonal $P_{V_j} f$ sobre V_j . Para calcular esta proyección, se debe encontrar un base ortonormal del espacio V_j . El siguiente teorema permite ortogonalizar una base de Riesz $\{\theta(t-n): n \in \mathbb{Z}\}$ y construye una base ortogonal para cada espacio V_j dilatando y trasladando una función ϕ llamada *función de escala*.

Teorema(Goswami Jaideva, 1999). Sea $\{V_j: j \in \mathbb{Z}\}$ una aproximación multirresolución y ϕ la función de escala cuya transformada de Fourier es

$$\hat{\phi}(\omega) = \frac{\hat{\theta}(\omega)}{\left(\sum_{k=-\infty}^{+\infty} |\hat{\theta}(\omega + 2k\pi)|^2 \right)^{1/2}} \quad (2.20)$$

Definamos

$$\phi_{j,n}(t) = \frac{2}{\sqrt{2^j}} \phi\left(\frac{t-n}{2^j}\right) \quad (2.21)$$

Entonces la familia $\{\phi_{j,n} : n \in \mathbb{Z}\}$ es una base ortonormal de $\mathbf{V}_j \forall j \in \mathbb{Z}$.

Demostración,

El objetivo es construir una base ortonormal, tómesese una función $\phi \in \mathbf{V}_0$. Ahora se expande ésta función en términos de la base de Riesz $\{\theta(t-n) : n \in \mathbb{Z}\}$:

$$\phi(t) = \sum_{k=-\infty}^{+\infty} a[n] \theta(t-n) \quad (2.22)$$

Calcúlese la transformada de Fourier a la expresión anterior,

$$\hat{\phi}(\omega) = \hat{a}(\omega) \hat{\theta}(\omega), \quad (2.23)$$

donde \hat{a} es una serie de Fourier con periodo 2π con energía finita. Para calcular \hat{a} se expresa la condición de ortogonalidad de $\{\phi(t-n) : n \in \mathbb{Z}\}$ en el dominio de Fourier. Sea $\bar{\phi}(t) = \phi^*(-t)$. Se necesita que para cualesquiera $n, p \in \mathbb{Z}$,

$$\langle \phi(t-n), \phi(t-p) \rangle = \int_{-\infty}^{+\infty} \phi(t-n) \phi^*(t-p) dt = \phi * \bar{\phi}(p-n) = \delta[n] \quad (2.24)$$

Si se calcula la transformada de Fourier de esta igualdad se llega a que

$$\sum_{k=-\infty}^{+\infty} |\hat{\phi}(\omega + 2k\pi)|^2 = 1. \quad (2.25)$$

Por otra parte, la transformada de Fourier de $\phi(t) * \bar{\phi}(t)$ es $|\hat{\phi}(\omega)|^2$, que junto con la ecuación (2.20) obliga a que

$$\hat{a}(\omega) = \frac{1}{\left(\sum_{k=-\infty}^{+\infty} |\hat{\theta}(\omega + 2k\pi)|^2 \right)^{\frac{1}{2}}}. \quad (2.26)$$

Para encontrar una aproximación de f sobre el espacio \mathbf{V}_j se requiere expandir la función en términos de la base ortogonal de funciones de escala

$$P_{\mathbf{V}_j} f = \sum_{n=-\infty}^{+\infty} \langle f, \phi_{j,n} \rangle \phi_{j,n} \quad (2.27)$$

los productos interiores

$$a_j[n] = \langle f, \phi_{j,n} \rangle \quad (2.30)$$

dan una aproximación discreta en la escala 2^j . La ecuación anterior se puede escribir como un producto convolución

$$a[n] = \int_{-\infty}^{\infty} f(t) \frac{1}{\sqrt{2^j}} \phi\left(\frac{t-2^j n}{2^j}\right) dt = f * \bar{\phi}_j(2^j n), \quad (2.31)$$

con $\bar{\phi}_j(t) = \sqrt{2^{-j}} \phi(2^{-j} t)$. La energía de la transformada de Fourier $\hat{\phi}$ típicamente está concentrada en $[-\pi, \pi]$. Como consecuencia, la transformada de Fourier $\sqrt{2^j} \hat{\phi}^*(2^j \omega)$ de $\bar{\phi}_j(t)$ concentra su energía en el intervalo $[-2^{-j} \pi, 2^{-j} \pi]$. Entonces la aproximación discreta $a_j[n]$ es un filtro pasabajos de la función f hecha un muestreo a intervalos 2^j .

2.3 La transformada continua de onduleta

Al igual que la transformada de Fourier, la transformada continua de onduleta puede medir las variaciones en tiempo-frecuencia de las componentes espectrales de la señal, sin embargo, permite tener una resolución diferente en tiempo-frecuencia. La CWT correlaciona la señal $f(t)$ con la onduleta $\psi_{u,s}(t)$, ecuación (2.14), y se calcula por medio de la ecuación,

$$Wf(u, s) = \int_{-\infty}^{\infty} f(t) \frac{1}{\sqrt{s}} \bar{\psi}\left(\frac{t-u}{s}\right) dt. \quad (2.32)$$

Al aplicar la fórmula de Parseval (2.12) a la ecuación (2.32), se obtiene una integración respecto a la frecuencia,

$$Wf(u, s) = \int_{-\infty}^{\infty} f(t) \frac{1}{\sqrt{s}} \bar{\psi}\left(\frac{t-u}{s}\right) dt = \int_{-\infty}^{\infty} \hat{f}(\omega) \frac{1}{\sqrt{s}} \hat{\bar{\psi}}_{u,s}(\omega) d\omega. \quad (2.33)$$

Como se puede observar en la ecuación anterior, los coeficientes de la transformada $Wf(u, s)$ depende de los valores de $f(t)$ y de su transformada de Fourier $\hat{f}(\omega)$ sobre la región tiempo-frecuencia donde la energía de $\psi_{u,s}(t)$ y $\hat{\psi}_{u,s}(\omega)$ se concentra. Así, los armónicos que varían en el tiempo pueden detectarse a partir de la posición y escala de los coeficientes onduleta que tienen una gran amplitud.

En el dominio del tiempo, la onduleta $\psi_{u,s}(t)$ esta centrada en la posición u con una anchura proporcional al valor s . Su transformada de Fourier es,

$$\hat{\psi}_{u,s}(t) = e^{-iut} \sqrt{s} \hat{\psi}(s\omega) \quad (2.34)$$

donde $\hat{\psi}$ es la transformada de Fourier de ψ .

La transformada de onduleta también puede detectar y caracterizar transitorios por medio de escalamiento. Supóngase que la señal ψ es real. Como tiene un promedio igual a cero, su coeficiente onduleta mide la variación de la señal $f(t)$ en una vecindad de u cuyo radio es proporcional a s . Las transiciones en señales con radio muy pequeño generan coeficientes onduleta con amplitud grande. Se pueden detectar singularidades al analizar las escalas y los máximos locales de la transformada onduleta.

2.4 Conclusiones

En este capítulo se mostró que las onduletas y la SFTF son una alternativa para el análisis de señales. Las onduletas forman una base ortogonal, localizadas en tiempo y frecuencia, del espacio de Hilbert $L_2(-\infty, \infty)$.

La tecnología de onduletas es un conjunto de técnicas que se desarrollaron de manera independiente en varios campos del conocimiento. La unificación conceptual de ésta tecnología permitió conocer los mecanismos matemáticos involucrados, y permitió desarrollar nuevas aplicaciones.

La teoría matemática de la aproximación sugiere que una base de funciones debe elegirse de tal manera que la señal puede ser aproximada con un número pequeño de vectores pertenecientes a la base del espacio vectorial.

Capítulo III

Diseño Experimental

3.1 Introducción

En este capítulo se presenta la descripción del método propuesto en esta tesis para el procesamiento y clasificación de la señal. En general el proceso se desarrolla con las dos técnicas ya trabajadas en capítulos anteriores. Dicho método utiliza señales obtenidas a partir de la exploración de un material por medio de Ensayos No Destructivos (END). El procedimiento consta inicialmente de un pre-procesamiento de la señal con la finalidad de normalizarla y obtener su envolvente, como se mencionó en el capítulo 2, en la red ART2A se necesita que los datos de entrada tengan componentes positivas y que estén normalizados. Una vez logrado este pre-procesamiento se realiza el procesamiento de la señal con base a la descomposición de onduletas (daubechies 4) en 50 niveles para después ser clasificadas por medio de una red neuronal no supervisada. Se eligió la base daubechies 4 por su semejanza cualitativa con la señal a procesar. Lo que se busca es que al proyectar la señal en la base de onduletas se obtenga el mayor número de coeficientes iguales a cero. Para que así, la información inherente a la señal este concentrada en los niveles de la onduleta.

Teniendo ya un banco de patrones que representan a diversas características del material, el siguiente paso es la clasificación de las señales por medio de la red neuronal sin necesidad del uso de onduletas, dado que estas ya han sido representadas con anterioridad.

Ahora bien para el caso de estudio, la red neuronal debe detectar distinciones entre objetos y ecos de grano para un grupo de muestras en particular. Los parámetros de la red resolverán la convergencia para discriminar entre estos dos tipos de ecos (Guez et al., 1991). Como se revisa en la sección tres, la red neuronal propone la clasificación de diferentes escenarios, entendiendo por estos a los distintos tipos de eco a partir de la distancia temporal medida por medio de señales obtenidas del proceso de ensayos no destructivos.

Cabe hacer hincapié que el procedimiento revisado en este capítulo propone la sustitución del uso de la transformada continua de onduleta por la clasificación de patrones. Esto es, con base a la comparación de vectores que representen la información ya procesada a través dicha transformada.

Es importante mencionar que se propone el uso de onduletas en lugar del análisis de Fourier, debido a que éstas presentan de manera natural una descomposición en niveles de multi-resolución. Esta descomposición representa patrones que son clasificados por la red neuronal.

Como colofón del trabajo de integración desarrollado entre estas dos técnicas se definió que el número de niveles en la descomposición de la onduleta tendría que ser compatible con el desempeño de la red neuronal. Por lo cual, se realizaron distintos ensayos para determinar

este número de niveles ad-hoc a la red. El resultado es el ya mencionado número de 50 niveles de descomposición.

Este capítulo se divide en seis secciones. La primera es la introducción al procedimiento propuesto, la segunda sección es una revisión de la técnica de ensayos no destructivos, la tercer es una descripción del método propuesto. La cuarta sección es una breve descripción del material a revisar. La quinta sección es una revisión global del método. Por último se presenta conclusiones preliminares relacionadas al trabajo de integración.

3.2 Revisión del Ensayo No Destructivo

Los métodos END pueden ser utilizados en tres tipos de aplicaciones: medidas de magnitudes, detección de defectos y caracterización de materiales (Gómez-Ullate, 1999.) En el primer grupo es frecuente la medida de distancias o espesores de materiales, velocidad de fluidos, densidad de materiales, concentración de disoluciones, etc. El segundo tipo tiene un uso muy fuerte en control de calidad de estructuras de fabricación o en servicio. Finalmente, la caracterización de materiales por métodos END permite determinar propiedades de los granos del material, o la distribución y tamaño de los poros internos, evaluar la corrosión o deterioro de los materiales, etc.

Una característica común de los métodos de END es que siguen métodos indirectos, es decir, determinan la característica buscada en el producto a partir de otra propiedad relacionada con ella. Así, el espesor de un material puede determinarse midiendo el tiempo de vuelo de un pulso ultrasónico cuya velocidad de propagación en el material resulta conocida.

Las técnicas ultrasónicas se destacan como las más ampliamente utilizadas para medición (distancias, espesores, velocidad, densidad, etc.), y detección y evaluación de defectos en materiales que requieran un alto grado de calidad y fiabilidad. Entre las ventajas que presentan los ultrasonidos frente a otras técnicas cabe destacar:

Se pueden aplicar a cualquier tipo de material sólido, líquido o gaseoso, con la única condición de que existan moléculas capaces de transmitir la perturbación mecánica.

Permiten detectar defectos en el interior de los materiales dando como resultado el tamaño y la posición del defecto. La Fig. 3.1 muestra la revisión básica de un material a partir de END, aquí se tienen dos materiales, el primero de acoplamiento y el segundo a revisión. El material a revisar consta de dos caras (C_1 y C_2). El objetivo es revisar el contenido del material por medio de la distancia temporal establecida por el tiempo de vuelo de la señal ultrasónica dividido entre dos. La distancia (d) que tiene algún defecto con respecto a la cara inspeccionada por el transductor se encuentra relacionada de manera lineal con el eco de la señal como se muestra en la Fig. 3.1. Si no existe tal defecto en el material, la señal recibida contendrá el eco debido al fondo del material.




Fig. 3.1 Descripción del uso de Ensayos No Destructivos con base al uso de la técnica de ultrasonido

Las técnicas para el procesamiento de la señal tales como Transformada Rápida de Fourier (Schmerr, 1998), onduleta (Legendre et al, 2001) o *splines* (Xiao et al, 2002) presentan diferentes alternativas para rescatar información caracterizada en primer instancia como ruido.

En END ultrasónico hay tres tipos de desplegados que se usan para presentar la información de las fallas. El primer tipo de desplegado se conoce como A-scan, en el osciloscopio se presenta una gráfica bidimensional, con un sistema de coordenadas rectangular, en la que el tiempo de un pulso ultrasónico se representa como un desplazamiento ordenado a lo largo del eje de las abscisas. En esta presentación, los pulsos reflejados se muestran como un evento. Este es el tipo más común para desplegar la prueba END. Un segundo tipo es el B-scan, que consiste en el movimiento lineal del transductor a lo largo del material a inspeccionar con el objetivo de generar una representación gráfica bidimensional en la que se despliegan las discontinuidades de los ecos vistos desde la parte superior de la superficie de prueba.

Por último el tercer tipo conocido como C-scan, se obtiene una imagen bidimensional a partir de un recorrido del sensor sobre la superficie superior de la pieza a inspeccionar (Schmerr, 1998).

La Fig. 3.2 muestra como el transductor presenta la señal de eco fondo recogida al evaluar un material. En este caso se encuentra un defecto a una distancia dada entre el inicio del material a evaluar y el fondo del mismo. Estos dos se presentan por el eco con un contenido de ruido, el cual proviene de la evaluación del aluminio debido a sus impurezas. En el capítulo siguiente se hará una descripción más a detalle de la información recuperable en la evaluación de este material.

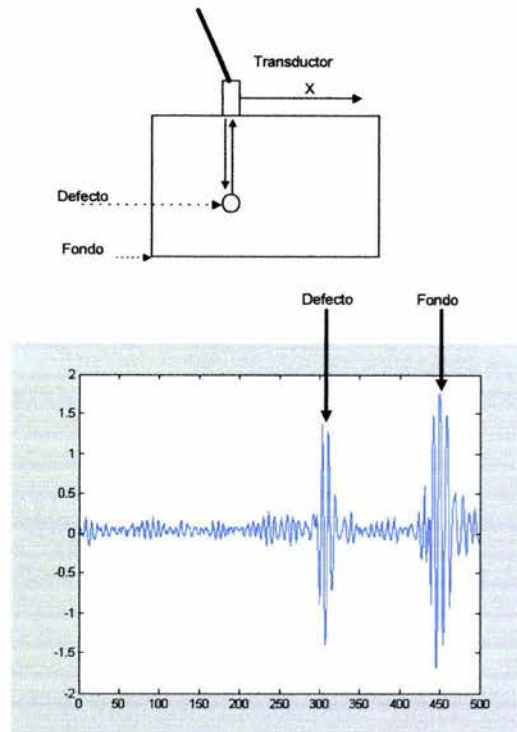


Fig. 3.2 Diagrama esquemático en el uso de Ensayo No Destructivos para la detección de fallas utilizando la técnica B-Scan

3.3 Descripción del Método Propuesto

En este capítulo se describe el sistema END que se utilizó en el trabajo para analizar materiales de aluminio, y tratar de determinar si existe alguna falla en el material de evaluación. Inicialmente los dispositivos que componen nuestro sistema de pruebas END son descritos así como la terminología que se usa.

En la Fig. 3.3 se muestra el arreglo experimental que se usó para la evaluación del material. En el experimento se utilizaron los siguientes elementos:

1. Un pulsador. Compuesto por una tarjeta del tipo MATEC SR9000 (SR9000, MATEC, 1999) de 100 MHz.
2. Un transductor tipo gama a 2.25 MHz, que funciona en modo pulso-eco de la marca KrautKrammer (KrautKrammer, 1999).
3. Digitalizador. El mismo osciloscopio tiene esta función. Este dispositivo es un Tektronix modelo TDS 340 *two channel*. Se usó una base de tiempo de 20 microsegundos, y se tomaron 25 millones de muestras por segundo (frecuencia de muestreo).

4. Un escáner tipo *Hydrophase Scanning System* fabricado por *Specialty Engineering Associates* (SEA), y un tanque de agua.
5. Computadora con procesador Pentium II con sistema operativo Windows 98 y software de programación MATLAB 6.0.




Fig. 3.3. Diagrama esquemático del experimento.

El experimento se llevó a cabo sobre un tipo de material compuesto de aluminio al 90%. Se hizo una revisión conocida como B-Scan por el movimiento lineal del transductor. Este experimento consta del uso de un tanque con agua para acoplamiento de impedancias entre el transductor y el material a revisar. La distancia que existe entre este elemento y el transductor no es considerable debido a que la velocidad del sonido en el agua es mucho menor que en el aluminio (Krautkrämer et al., 1983). Debido a esto, hubo un retraso en la adquisición de la señal.

El movimiento lineal del transductor en la revisión del material es de manera discreta con un paso de 0.635 milímetros por lo que se obtuvieron alrededor de 110 muestras a evaluar. Cabe señalar que cada muestra es equidistante entre sus vecinas, esto con el objeto de tener un barrido lineal del material. Dicho recorrido lineal se lleva a cabo bajo el uso de un robot de dos grados de libertad que mueve al transductor con velocidad constante sobre el eje lineal con la precisión antes señalada.

La Fig. 3.4 muestra el diagrama general del método llevado a cabo con respecto a los diferentes tipos de programas desarrollados para la evaluación y clasificación de las señales. Los programas desarrollados para el procesamiento de la señal utilizan al ambiente MATLAB 6.0 (en la PC Pentium II con Windows 98) como base. Estos programas se presentan en el apéndice A en la forma de pseudo-código.




Fig. 3.4. Método propuesto para la evaluación del material

La señal eco procedente del transductor es un vector con 500 puntos que requiere un pre-procesamiento consistente en normalizar el vector sin un cruce por cero. Durante la normalización también se lleva a cabo su transformada de Hilbert para finalmente trabajar con una envolvente de la señal. Dicha normalización es requerida en las dos posibilidades del procesamiento de la señal (onduletas y redes neuronales). Como consecuencia, al final del recorrido lineal se tendrá una matriz de 110×500 elementos, considerando el número total de muestras.

Durante el procesamiento se descompone a la señal muestreada reflejada por el material en 50 niveles con la transformada continua de onduleta tipo daubechies 4 (Frazier, 1999). El resultado de este proceso es una matriz con coeficientes constantes de la onduleta de cada nivel llamada matriz de descomposición. Una vez obtenida la matriz de descomposición, esta es procesada por la red neuronal ART2A para que clasifique un número finito de patrones. Estos patrones llegan a constituir distintas señales descompuestas por medio de su representación en onduletas. Para efectos del experimento se elige un número finito de señales cercano al diez por ciento de un primer barrido del material. Como será revisado en el siguiente capítulo es posible llegar a utilizar la totalidad de las señales durante el entrenamiento de la red debido a las condiciones de experimentación.

Este procedimiento es aplicado a la placa de aluminio para generar una base de datos de patrones que registran las señales del tipo sin fallas con ecos de fondo, sin fallas con ecos de fondo y borde y con fallas. Dicha base de datos se forma a partir de la matriz de pesos de la red neuronal formada con respecto a los patrones. Esta matriz es conocida como matriz de patrones.

Una vez obtenida la matriz de patrones, ésta se utiliza para evaluar el material sin recurrir a la técnica de la transformada continua onduleta. En la Fig. 3.5 se muestra el diagrama de flujo del método propuesto. En este proceso se distinguen dos condiciones principales la detección de una falla o la sola declaración del eco fondo. Es importante mostrar que si una falla no ha sido clasificada entre los patrones de la red se requiere el uso de la descomposición de la transformada continua onduleta para procesar la señal. De esto se puede deducir que los parámetros de aprendizaje y de entrenamiento juegan un papel básico en los umbrales de clasificación de patrones.

Habr  que recordar que el experimento se lleva a cabo la evaluaci3n del material a lo largo del eje de la cara superior (ver Fig. 3.4). Durante la evaluaci3n, s  hay alguna falla cuyo patr3n no este registrado en la red neuronal, la transformada continua onduleta procesa la informaci3n para generar la matriz con los coeficientes onduleta.

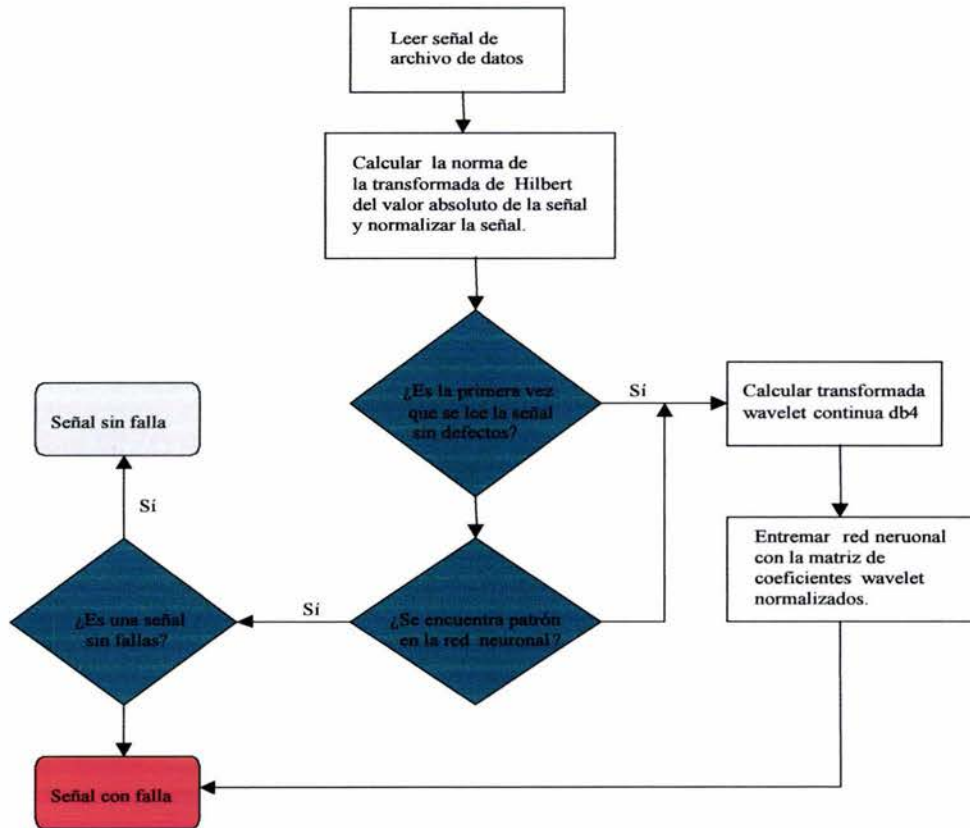


Fig. 3.5 Diagrama de flujo del algoritmo para el procesamiento de las se ales

La Fig. 3.6 muestra el uso de la red neuronal integrada con la transformada continua onduleta. En este diagrama se hace hincapi  en la estrategia dividida en los dos pasos ya explicados. El primer paso consiste en el entrenamiento de la red y el segundo en la clasificaci3n de la se al sin uso de la t cnica de la onduleta. Como se mencion3, si el vector analizado no es cercano a ninguno de los patrones existentes se requiere hacer un procesamiento de este por medio de la transformada continua onduleta. Cabe hacer menci3n que para cualquiera de estos dos pasos el pre-procesamiento de la se al es necesario para tener una base com n de comparaci3n.

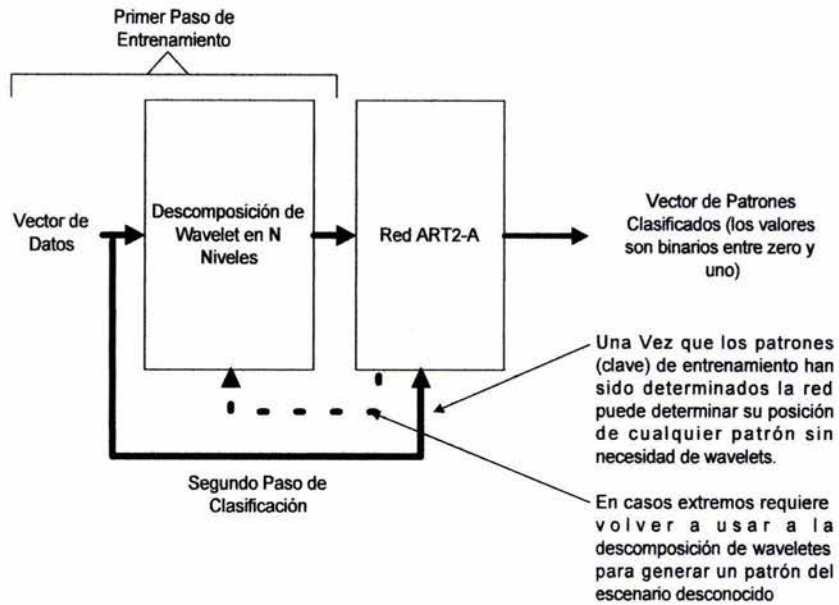


Fig. 3.6 Descripción del uso de la Red Neuronal en conjunto con Onduletas

Una vez establecida la descripción general del método propuesto es necesario hacer una revisión del caso de estudio. Este se presenta en la siguiente sección.

3.4 Descripción del Material

El material a estudiar (Fig. 3.7) es un prisma rectangular cuyas dimensiones son $7 \times 7 \times 4$ cm. Este material es de aluminio con un 90% de pureza.




Fig. 3.7 El material de muestra es un prisma rectangular cuyas dimensiones son $7 \times 7 \times 4$ cm. El material esta formado de aluminio con un 90% de pureza.

El mismo material con tres fallas de 2 cm de profundidad y con un diámetro de 0.5 cm se muestra en la Fig. 3.8. A cada una de las fallas se les nombra como falla A, B y C respectivamente. En la Fig. 3.8 se muestra el material y la posición de las fallas medidas respecto a la cara superior, o cara 1. Las medidas se toman a lo largo de la cara 4 (Fig. 3.8), teniendo al cero en la cara 1 y la distancia máxima en la cara 3.




Fig. 3.8. Material de evaluación. A lo largo del eje que está sobre cara 1 se movió el transductor. Las posiciones de las fallas A, B y C se miden con respecto de la cara 4, sus posiciones están a 3.335 cm, 4.168 cm y 5.138 cm respectivamente.

Se eligió este tipo de material por sus características homogéneas en la evaluación de la técnica antes mencionada (Sección 3.3). Este prisma presenta una serie de fallas parecidas que tienen su principal diferencia por su ubicación dentro de la geometría del material.

Como ya se ha mencionado el material es inspeccionado a lo largo de la cara 1 teniendo como inicio del recorrido la cara 4 y finalizando en la cara 2. La flecha de color blanco indica este recorrido.

3.5 Descripción Global

Habiendo construido las diferentes secciones del sistema, resta su integración física. El diagrama esquemático del experimento se muestra en la Fig. 3.9. Dicha integración consta del generador/receptor de pulsos (MATEC SR9000), el módulo de conversión digital (Osciloscopio Tektronix modelo TDS 340 *two channel*) y el módulo de procesamiento de señales el cual fue implantado en MATLAB 6.0. Este último consta de la integración de la red neuronal con la herramienta de onduletas (Daubechies 4).

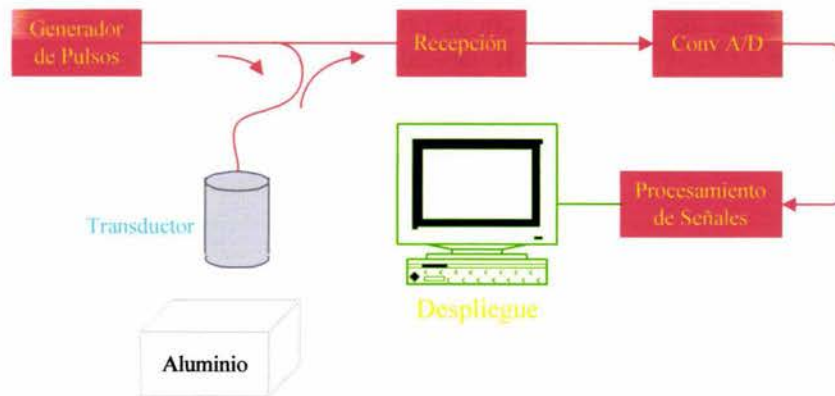


Fig. 3.9 Implantación final del Sistema

Las pruebas se realizan de la siguiente forma, el transductor es excitado por medio de la tarjeta SR9000. Una vez excitado el transductor la señal es propagada a través del agua hasta llegar al componente a examinar. La señal es rebotada a través del material y el medio acuoso. El eco es recibido por el transductor y la tarjeta SR9000. Esta señal es la salida de dicha tarjeta, la cual es digitalizada por el Osciloscopio para después procesar la señal resultante mediante el procedimiento de la clasificación de patrones antes descrita.

3.6 Conclusiones

El presente capítulo muestra la integración propuesta de varias técnicas para el análisis de muestras de aluminio mediante Ensayos No Destructivos. Esta revisión propone un método de clasificación de patrones para determinar fallas en materiales.

El uso de redes neuronales se presenta como una alternativa viable para el análisis de fallas con un uso intermedio de una técnica ya conocida como las onduletas. Aún cuando se requiere un entrenamiento exhaustivo en la red para poder sustituir de manera viable a la transformada de Daubechies.

Capítulo IV

Análisis de Resultados

4.1 Introducción

En este capítulo se presentan los resultados con base a la experimentación propuesta en el capítulo anterior. Dichos resultados contemplan los diferentes experimentos llevados a cabo así como la variación de los diferentes parámetros de la red. Con base a estas variaciones un grupo de gráficas es revisado para dar una idea de como trabaja el método propuesto.

Durante este capítulo se da una revisión del ambiente de experimentación, entendiendo por éste, los diferentes experimentos a ser planteados así como los rangos de modificación de los parámetros de aprendizaje y vigilancia. Así mismo, se presenta una revisión del tipo de señal con la que se trabaja y cuales son las características que presenta.

A partir de esto, se presentan una serie de gráficas donde se explora el comportamiento del método con respecto a los experimentos propuestos. Por último, se da un análisis de los resultados obtenidos de manera global haciendo hincapié en las ventajas que presenta esta propuesta.

4.2 Revisión del Ambiente de Experimentación

A partir del estudio realizado en los capítulos anteriores resta determinar el ambiente de experimentación para llevar a cabo la clasificación de fallas de manera adecuada, y sobre todo repetible. Para tal efecto, se examinará el material ya mostrado en el capítulo anterior que consiste de aluminio al 90%. En una de las caras del prisma rectangular se hacen tres perforaciones con la finalidad de que el modelo los detecte como defectos en el material.

Ahora bien, ya establecido el experimento mostrado en el capítulo anterior, la tarjeta Matec envía los pulsos ultrasónicos al material de aluminio por medio del transductor. Este último cumple la función de enviar los pulsos y recibir los ecos de la señal ultrasónica al ser reflejada en la cara inferior o por un defecto del material. El robot con tres grados de libertad se encarga de mover el transductor a lo largo de una línea recta sobre la cara superior del material, y así llevar a cabo un barrido del tipo B-Scan. Los ecos que resultan de la inspección del material se capturan en archivos de datos. Dichas muestras son procesadas por medio de una serie de programas en Matlab 6.0 para determinar y clasificar defectos. El primer paso es entrenar la red neuronal ART2A con una serie de señales que contengan únicamente información sobre el eco de fondo del material. Estas señales tienen que haber sido descompuestas por medio de la transformación continua de onduletas. Una vez obtenidas estas señales la red neuronal las clasifica. Para tal motivo se requiere ajustar una serie de parámetros de la red no-supervisada. La red neuronal ART2A usa dos

parámetros conocidos como de vigilancia y de aprendizaje. Durante el entrenamiento de la red se ha determinado que estos parámetros son básicos para que esta aprenda y clasifique los patrones que le son presentados.

Además, también influye el orden en que las señales se introducen a la red para que ésta pueda distinguir una de otra. La primera señal que debe conocer la red es aquella que contenga solo el eco de fondo. Las señales subsecuentes tienen que llevar el orden del movimiento lineal del transductor. Por lo que la i -ésima señal capturada es la i -ésima señal presentada a la red para su entrenamiento.

El pre-procesamiento llevado a cabo es el cálculo de la envolvente de cada vector (señal) sin utilizar la red neuronal ni la transformada continua ondulatoria, es decir, se aplicó únicamente la transformada de Hilbert a los vectores normalizados con componentes positivas. Así, se generó una matriz H en la que el renglón i almacena el módulo de la transformada de Hilbert del i -ésimo vector (señal).

La Fig. 4.1 muestra la gráfica de contorno de la matriz H . Como se puede observar, en este procesamiento se reconocen por inspección a los tres defectos del material más un defecto no existente encerrado en el recuadro rojo. Con este método, las reflexiones de las señales ultrasónicas cercanas a la cara lateral (cara 2) e inferior (cara 3) del material producen un defecto no existente. Posteriormente se verá que utilizando la red neuronal esta confusión no se presenta. Cabe señalar que la constante presentada alrededor de los 70 milímetros a lo largo del número total de patrones coincide con el eco de fondo del material.

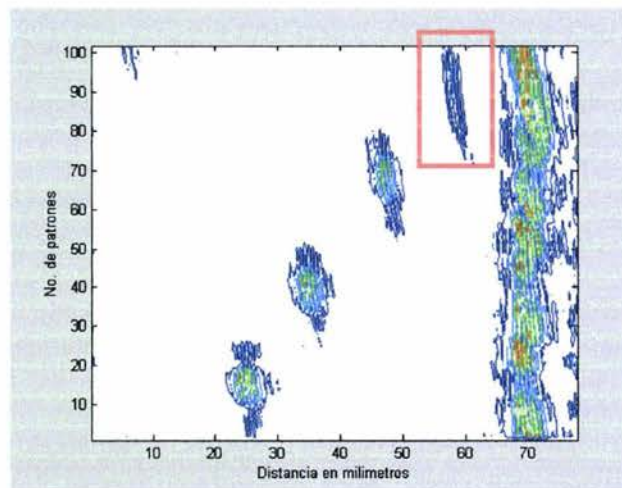


Figura 4.1 Gráfica de contorno de la matriz H . En el recuadro aparece un supuesto defecto que no existe en el material que se analizó. Su aparición se debe a las reflexiones del ultrasonido en las caras lateral (cara 2) e inferior (cara 3) del material

Una vez descrito el pre-procesamiento de cada señal se determina el procedimiento utilizando onduletas y la red neuronal ART2A como estrategia alternativa para el procesamiento y clasificación de fallas. Con base en esta técnica se busca eliminar los efectos no deseados de los bordes y esquinas del material a explorar.

Una vez que se adquiere la señal con solo el eco de fondo, se procede a calcular la transformada continua onduleta con 40 niveles usando la daubechie 4 (db4). Después de haber realizado el procesamiento de la señal se obtiene la matriz de coeficientes onduleta para proceder a entrenar a la red neuronal normalizando previamente los vectores que componen a la matriz de coeficientes. Es en esta sección donde la red neuronal empieza su entrenamiento.

Para esta tesis se llevó a cabo dos tipos de entrenamientos, el primero con señales de eco fondo cada 5 pasos de recorrido lineal y el segundo con señales de eco fondo cada diez pasos de recorrido lineal. Esto tiene un impacto en la clasificación de las señales, el cual es revisado en la sección 4.4.

Para ambos casos y habiendo entrenado a la red neuronal, cualquier señal que provenga de la lectura del eco de fondo del material, la red lo buscará como parte de su matriz de pesos. Si este ya fue clasificado se procede a verificar si corresponde a una señal sin falla, si esto es así, se emite el mensaje de “señal sin fallas”, en caso contrario, “señal con falla”. Esto con el afán de determinar en línea si existen fallas en el interior del material. Durante este procedimiento se busca delimitar a la matriz de pesos con información representativa del material revisado. Esto por supuesto depende de la correcta selección de parámetros de la red neuronal.

En caso de que no se encuentre el patrón en la matriz de pesos de la red neuronal, este se clasifica como un nuevo patrón que ha descubierto alguna inconsistencia en el material. Para completar el entrenamiento de la red se calcula la transformada continua onduleta nuevamente con 50 niveles de resolución con la onduleta db4. Con esta información se procede a entrenar la red para que clasifique el defecto o la singularidad que encontró inicialmente. Como se mencionó en el párrafo anterior la detección *correcta* de este patrón depende enteramente de los parámetros de la red neuronal y de manera indirecta de la normalización de la señal a revisar.

Habiendo establecido la importancia de los parámetros de aprendizaje y vigilancia de la red neuronal (Frank et al., 1998), es necesario plantear como se espera que varíen. Dado que las señales son normalizadas dichos parámetros tienen que oscilar entre cero y uno. Así mismo y dada la experiencia obtenida durante el entrenamiento de la red se determinaron una serie de rangos en los cuales el contorno de las fallas es aceptable. En la tabla 4.1 se listan los valores de los parámetros de vigilancia utilizados para la medición del eco de fondo y la clasificación de fallas en el material.

Parámetro de vigilancia: ρ	Parámetro de aprendizaje: η
0.75	0.1, 0.2, 0.3 y 0.4
0.80	0.1, 0.2, 0.3 y 0.4
0.85	0.1, 0.2, 0.3 y 0.4

Tabla 4.1 Valores Propuestos para los Parámetros de Aprendizaje y Vigilancia

Durante la medición del eco de fondo se obtuvieron 105 archivos de datos relacionados con el movimiento lineal del transductor. El primer archivo contiene la señal sin ruido, en el segundo se tiene a la señal que se generó al mover el transductor hacia la derecha por medio del robot una distancia correspondiente a un paso establecido. Para la siguiente señal se corre al transductor con base al mismo paso, así sucesivamente hasta recorrer la toda la cara 1. Por lo que, en cada archivo se tiene la historia del recorrido del transductor y la conformación del material visto desde una cara. Un análisis desde dos caras es factible con base al uso de redes como los mapas de organización propia. Esto queda como parte del trabajo a futuro a realizar.

Dado que el paso presenta un movimiento equidistante, se trabajó con dos tipos de entrenamiento en la red. En el primero se le presenta a la red neuronal la señal correspondiente de la serie de 5 en 5 archivos. Para el segundo entrenamiento se le presenta a la red neuronal la señal correspondiente de la serie de 10 en 10 archivos. Para ambos casos se entrena a la red neuronal con valores dados en la tabla 4.1. Este espaciamiento permite determinar si la red con los parámetros elegidos propone un resultado viable. Entendiendo por viable, la selección de patrones similares y la no clasificación de supuestos patrones cuando su representación ya existe en la matriz de pesos. Los resultados de estas dos evaluaciones son presentados en las secciones 4.4 y 4.5.

4.3 Señales Adquiridas

Una vez establecido el experimento, así como sus variaciones, en esta sección se presenta una serie de resultados basados en el pre-procesamiento de las señales sin y con ruido.

En la Fig. 4.2 se muestra la primera señal con solo el eco de fondo a una distancia de 70 mm. Dicha señal es obtenida de un material sin fallas. La segunda gráfica muestra el módulo normalizado de su transformada de Hilbert.




Fig. 4.2. Señal eco-fondo de un material sin fallas. Su representación del módulo normalizado de su transformada de Hilbert.

Para la Fig. 4.3 se presenta además del eco de fondo, la respuesta del sistema ultrasónico bajo la presencia de una falla en el material. Como se mostró en la Fig. anterior, el fondo se encuentra a 70 mm de distancia. Por lo que respecta, a la falla encontrada, ésta se localiza a 48 mm. La segunda parte de dicha Fig. despliega el módulo normalizado de su transformada de Hilbert. Cabe señalar que en ambos casos, la falla se encuentra representada a los 48 mm de distancia temporal.

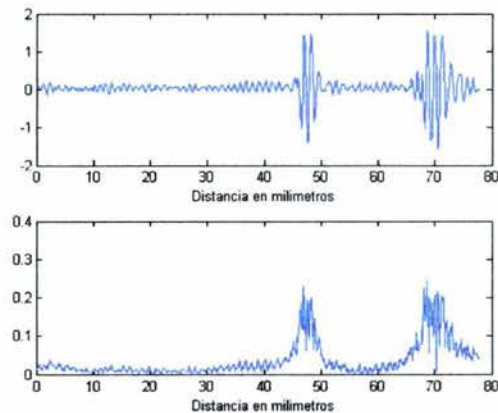


Fig 4.3. Señal eco-fondo con presencia de una falla en el material a una distancia de 48 mm. Su transformada de Hilbert está representada en la segunda parte de esta Fig.

4.4 Procesamiento de la Señal

En el presente análisis se verá que los valores de ρ y η son necesarios para que la red neuronal identifique los patrones que recibe como entrada sin generar una sobre-población de estos. Entendido por esto último, una sobre-generación de patrones similares. Cabe hacer mención que la medida de similitud se convierte en una representación heurística por la naturaleza propia de las redes neuronales. Esto tendrá un efecto de mayor importancia en la separación de fallas existentes en el material.

La matriz de pesos de la red neuronal almacena los patrones clasificados para su comparación con los vectores de entrada que provengan de la transformada continua ondulada o de señales crudas provenientes del digitalizador.

En la Fig. 4.4 se muestra la gráfica de la matriz de pesos de la red neuronal. Todas las graficas de esta figura se obtuvieron con un valor para ρ de 0.75, y los valores que se tomaron para η fueron 0.1, 0.2, 0.3 y 0.4. Para este experimento se tomaron muestras cada cinco mediciones durante el recorrido lineal del transductor sobre el material. Esto quiere decir, que de acuerdo al paso del robot de 0.635 mm, se adquirió una señal cada 3.175 mm.




Fig. 4.4. Gráficas de la matriz de pesos que se obtuvo al entrenar la red con $\rho = 0.75$ y $\eta = 0.1$ en (a), 0.2 en (b), 0.3 en (c) y 0.4 en (d). A lo largo del eje horizontal se indica la profundidad en milímetros del material, y a lo largo del eje vertical se representa el número de patrones clasificados por la red neuronal.

Como se puede observar en la Fig. 4.4 el inciso (a) presenta tres defectos. El primero a una distancia temporal de 27mm, el segundo a 37 mm, y el tercero a 50 mm. Conforme η se incrementó, el número de patrones clasificados disminuyó con lo que también se perdió la

resolución en el enfoque del barrido tipo B-Scan del material. Es notable mostrar que bajo una configuración de parámetros “correctos” la red neuronal no logró la clasificación del efecto producido por la esquina formada por las caras 2 y 3 del material. Sin embargo, cuando estos parámetros no son elegidos de manera “correcta” se obtiene el efecto contrario en el enfoque del barrido. Es decir, no se logra distinguir defectos a una alta profundidad.

El término “correcto” en este caso, se define a partir de la revisión fuera de línea del contorno de la matriz de pesos por parte del usuario con el fin de determinar si las fallas reportadas corresponden a sus pares reales o físicas. Por ejemplo, para el caso de la Fig. 4.4b se considera que este contorno no es “correcto” debido a que no presenta la tercera falla del material. Así mismo, la ubicación en milímetros de dichas fallas tiene que coincidir con la distancia real para llamar a la matriz de pesos “correcta”. Estas dos son las únicas condiciones establecidas para la evaluación posterior de la clasificación de patrones en el material con fallas.

La Fig. 4.5 muestra el contorno de la matriz de pesos para el experimento con base a una ρ de 0.8 y η igual a 0.1, 0.2, 0.3 y 0.4. En el inciso a, se detectaron tres fallas con las mismas distancias que en la Fig. 4.4 del mismo inciso. Sin embargo, se obtuvo la presencia no deseable del efecto de la esquina correspondiente a las caras 2 y 3. Aun cuando éste es de menor amplitud que el presentado en la Fig. 4.1, el usuario no puede reportar a dicho contorno como “correcto”. El mismo caso se presenta en el inciso b, pero su efecto es mucho menor, lo cual puede ser determinado como “correcto”. Para el inciso c, las fallas son detectadas de manera correcta, sin embargo, el recorrido lineal no se presenta de completa. Por lo que la tercer falla es declarada como existente aun cuando su información es incompleta. Para el caso del inciso d, el contorno es declarado no “correcto” debido a que la falla tres no es presentada de ninguna forma. De la misma forma que en la Fig. 4.4 cuando se incrementa el valor de η el número de patrones clasificados disminuye. Esto provoca el efecto no focalización en el barrido del material. El haber dado un incremento de ρ no presenta una ventaja significativa sobre la localización de las fallas.




Fig. 4.5. Gráfica de contorno de la matriz de pesos de la red neuronal con $\rho = 0.8$ y $\eta = 0.1$ en (a), 0.2 en (b), 0.3 en (c) y 0.4 en (d). Los ejes coordenados que se muestran en dicha gráfica corresponden al número de patrones y su respectiva distancia en mm.

Por otro lado, La Fig. 4.6 muestra el contorno de la matriz de pesos para el experimento con base a una ρ de 0.85 y η igual a 0.1, 0.2, 0.3 y 0.4. En este caso, para todos los incisos se denota el resultado de la sobre-valoración del parámetro ρ . Esto es, no se logra eliminar el efecto de la esquina y la matriz de pesos presenta una baja inmunidad al ruido. Las gráficas de contorno no presentan alguna diferencia factible para los diferentes incisos. Además, el número de patrones no disminuye, por lo que se concluye que la red neuronal bajo estas condiciones no clasifica. Dado lo anterior y con base en nuestra definición de “correcto” se determina que los valores nos son los adecuados.




Fig. 4.6. Gráfica de contorno de la matriz de pesos de la red neuronal con $p = 0.85$ y $\eta = 0.1$ en (a), 0.2 en (b), 0.3 en (c) y 0.4 en (d). Los ejes coordenados que se muestran en dicha gráfica corresponden al número de patrones y su respectiva distancia en mm.

Por lo tanto, para los experimentos mostrados con anterioridad y con un paso de 5 en 5 señales (3.175 mm), los valores óptimos de p y η son 0.75 y 0.1 respectivamente, porque se obtuvo el menor número de patrones para la clasificación satisfactoria. Dos puntos son importantes en este análisis, el número de patrones y el resultado correcto del contorno de la matriz de pesos. El primer punto permite tener una red eficiente en términos de uso de memoria y rapidez computacional. El segundo permite visualizar la localización de las fallas sin conflictos de fantasmas como el presentado por la esquina del material. Dicho conflicto es descrito con anterioridad.

Ahora bien, el paso del recorrido lineal es una variable durante este experimento, para justificar lo dicho se lleva a cabo la misma experimentación bajo dos condiciones distintas. La primera con un paso de 10 en 10 señales. La segunda con un paso de una en una señal. Los resultados de ambos experimentos se muestran en las secciones siguientes.

4.5 Procesamiento de la señal con un paso de 10 en 10 señales

En este conjunto de experimentos se modifica el paso del recorrido lineal del robot. Este es ahora de 10 en 10 señales, lo que significa que cada 6.35 mm se toma una señal para ser procesada. En este sentido se le presenta a la red neuronal una señal cada 6.35 mm, por lo que, con base a las condiciones de p y η se determinará si hay o no un nuevo patrón que clasificar, y según sea el caso, se usará la técnica de onduletas para su clasificación.

En la Fig. 4.7 se muestra la gráfica de contorno de la matriz de pesos de la red neuronal, con $\rho = 0.75$ y $\eta = 0.1, 0.2, 0.3$ y 0.4 . En este caso, para los incisos a, b y c, el efecto producido por la esquina del material no aparece. Según esta figura (incisos a, b y c), el primero está a una distancia temporal de 27mm, el segundo a 37 mm, y el tercero a 50 mm. En el inciso d, la red neuronal solo clasifica dos defectos, por lo que la matriz de pesos no es correcta, pues no pudo localizar el tercer defecto.




Fig. 4.7. Gráfica de contorno de la matriz de pesos de la red neuronal con $\rho = 0.75$ y $\eta = 0.1$ en (a), 0.2 en (b), 0.3 en (c) y 0.4 en (d). Los ejes coordenados que se muestran en dicha gráfica corresponden al número de patrones y su respectiva distancia en mm.

En la Fig. 4.8 se muestra la gráfica de contorno de la matriz de pesos de la red neuronal, con $\rho = 0.8$ y $\eta = 0.1, 0.2, 0.3$ y 0.4 . Para estos valores de ρ y η , la red neuronal logró clasificar los tres defectos del material, además sus distancias temporales coinciden con los de las Figs. 4.4 y 4.7. Para η igual a 0.4 (inciso d) la red neuronal necesitó menos patrones para su entrenamiento en este experimento. Dado esto la red neuronal presenta la respuesta más eficiente en el consumo de memoria. Cabe señalar que para este inciso se considera que su gráfica de entorno es “correcta”.




Fig. 4.8. Gráfica de contorno de la matriz de pesos de la red neuronal con $\rho = 0.8$ y $\eta = 0.1$ en (a), 0.2 en (b), 0.3 en (c) y 0.4 en (d). Los ejes coordenados que se muestran en dicha gráfica corresponden al número de patrones y su respectiva distancia en mm.

En la Fig. 4.9 se muestra la gráfica de contorno de la matriz de pesos de la red neuronal, con $\rho = 0.85$ y $\eta = 0.1, 0.2, 0.3$ y 0.4. En este caso, la red neuronal no pudo eliminar el efecto esquina, y la red neuronal presenta sensibilidad al ruido. Las gráficas de contorno no presentan alguna diferencia factible para los diferentes incisos, por lo que se concluye que la red neuronal bajo estas condiciones no clasifica y su respuesta de contorno es no "correcta".




Fig. 4.9. Contorno de la matriz de pesos con $\rho = 0.85$ y $\eta = 0.1$ en (a), 0.2 en (b), 0.3 en (c) y 0.4 en (d). Los ejes coordenados corresponden al número de patrones y su respectiva distancia en mm.

Para Este experimento se deduce que ρ requiere un valor cercano a 0.75 para obtener una respuesta "correcta". Aún cuando con un valor de 0.8 y una η de 0.4 la respuesta es satisfactoria pero el número de patrones se incrementa.

4.6 Procesamiento de la señal bajo un paso de una señal

El último experimento realizado entrena la red neuronal recibiendo todas las señales sucesivamente. En la Fig. 4.10 se muestra la gráfica de contorno de la matriz de pesos de la red neuronal, con $\rho = 0.75$ y $\eta = 0.1, 0.2, 0.3$ y 0.4 . En los incisos a y b la red pudo clasificar las tres fallas del material, cuyas distancias temporales coinciden con la Fig. 4.4. En los incisos c y d la red no pudo clasificar, por lo tanto, su respuesta se considera no "correcta". Cabe señalar que el número de patrones es relativamente bajo por lo cual la red neuronal no consume mucho espacio en memoria.




Fig. 4.10 Gráfica de contorno de la matriz de pesos de la red neuronal con $\rho = 0.85$ y $\eta = 0.1$ en (a), 0.2 en (b), 0.3 en (c) y 0.4 en (d). Los ejes coordenados que se muestran en dicha gráfica corresponden al número de patrones y su respectiva distancia en mm

La Fig. 4.11 muestra la respuesta de la red para $\rho = 0.8$ y $\eta = 0.1, 0.2, 0.3$ y 0.4 . En este caso, los incisos a y b despliegan las gráficas de contorno las cuales no son inmunes al ruido y presentan el problema "efecto esquina" ya antes mencionado. Como es obvio, estas dos respuestas son declaradas como no "correctas". Para el caso del inciso c, se exhiben los tres defectos, sin embargo, el número de patrones no es eficiente en comparación a las respuestas obtenidas en los experimentos anteriores. Cabe señalar, que el tercer defecto no es completamente distinguible, lo cual es una desventaja, para futuros trabajos con base a un barrido tipo C-Scan (Schmerr, 1998) en una sola dimensión. Para el inciso d, la

respuesta es satisfactoria, sin embargo, presenta la misma deficiencia respecto al número de patrones como sucede en el inciso anterior. Con base a este análisis preliminar se determina que el inciso c cumple con definición de “correcto” aun cuando es no deseable utilizar estos parámetros para el entrenamiento de la red. Por último, el inciso d se le declara como “correcto” pero deficiente por el alto número de patrones clasificados.




Fig. 4.11. Gráfica de contorno de la matriz de pesos de la red neuronal con $\rho = 0.85$ y $\eta = 0.1$ en (a), 0.2 en (b), 0.3 en (c) y 0.4 en (d). Los ejes coordenados que se muestran en dicha gráfica corresponden al número de patrones y su respectiva distancia en mm

La Fig. 4.12 muestra la respuesta de la red bajo los parámetros $\rho = 0.85$ y $\eta = 0.1, 0.2, 0.3$ y 0.4. Para todos los incisos las gráficas de contornos son no “correctas” debido a la sobre clasificación de patrones y su alta sensibilidad al ruido. Es importante hacer mención que se presenta un efecto de repetición de la información a lo largo del eje llamado “No. De Patrones”, dicho efecto es debido a la sobre clasificación que no es mas que una generación de cúmulos repetidos. EL parámetro que determina esta situación es $\rho = 0.85$.

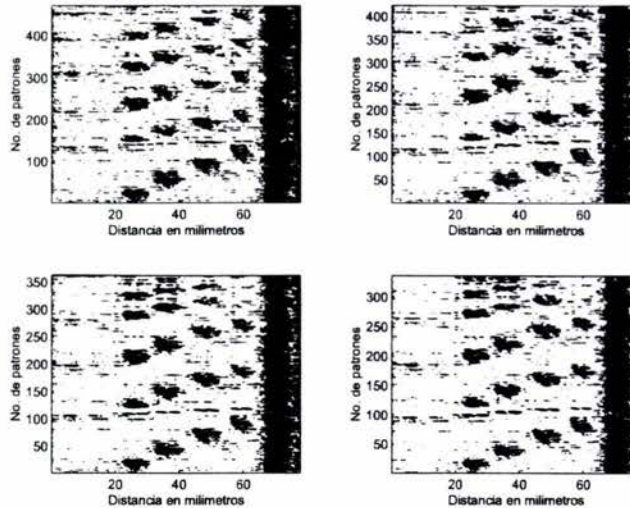


Fig. 4.12. Gráfica de contorno de la matriz de pesos de la red neuronal con $\rho = 0.85$ y $\eta = 0.1$ en (a), 0.2 en (b), 0.3 en (c) y 0.4 en (d). Los ejes coordenados que se muestran en dicha gráfica corresponden al número de patrones y su respectiva distancia en mm

4.7 Análisis de Resultados

En este capítulo se presentan los resultados correspondientes a varios experimentos realizados para mostrar las ventajas y desventajas del método propuesto en el capítulo anterior. Se proponen distintos experimentos donde se exhibe a la red neuronal con una sobre clasificación así como su baja inmunidad al ruido. Esto con el afán de mostrar la importancia en la selección de los parámetros ρ y η . Cabe señalar que los valores obtenidos para esto caso de estudio (material de aluminio al 90%) son intrínsecos a éste. Es decir, si se revisa algún otro material se tiene que llevar a cabo el mismo proceso inspección y entrenamiento de la red.

Por otro lado, una de las ventajas que presenta esta aproximación es su alta inmunidad al ruido previa selección de parámetros como se muestra en las Figs. 4.4, inciso a, 4.7 incisos a, b, c. Una ventaja adicional es el número de patrones clasificado que hace de la red una implantación ligera en términos del consumo de memoria.

Con respecto a la combinación de técnicas tales como las onduletas y la red tipo ART2A se concluye lo siguiente, se obtiene un híbrido que presenta la ventaja de la clasificación con una alta inmunidad al ruido con una respuesta eficiente en el tiempo. Por lo que respecta a la sensibilidad de la red, ρ y η pueden variar hasta un 10% de su valor óptimo sin que se vea afectado el desempeño de la red.

Conclusiones

En esta tesis se propuso un método para la detección de fallas en materiales hechos de aluminio, para ello, se usó la tecnología de onduletas y la red neuronal tipo ART2A. Este se desarrolla en tres etapas; la primera con respecto a la teoría de onduletas, la segunda de acuerdo al uso de redes neuronales y la tercera con base a la integración del procedimiento con un robot de dos grados de libertad sobre una base plana.

Los resultados obtenidos en esta tesis permiten demostrar que el uso de la red discrimina errores propios de la geometría del material a examinar. Aún cuando esto depende enteramente de la “acertada” elección de los parámetros de aprendizaje y vigilancia.

El objetivo de esta tesis se cumple desde el punto de vista de la revisión de externa del caso de estudio. Aún cuando se requieran establecer parámetros con base en la experiencia como son la elección de la onduleta, y los parámetros de la red neuronal, se logra en esta red una integración de varios dispositivos para la clasificación de señales.

Como trabajo futuro se presenta el uso de las redes con base a mapas del conocimiento. Tal es el caso de las redes tipo ARTMAP. Así mismo, es necesario identificar y desarrollar la onduleta óptima del caso de estudio esto teniendo en cuenta las características de las señales a analizar. Cabe señalar que es de interés ampliar el estudio del método propuesto a la revisión de materiales compuesto como es el caso de los polímeros con alta resistencia mecánica.

Referencias

- Abe S., "Pattern Classification Neuro-fuzzy Methods and their Comparison", Springer-Verlag, 2001.
- Carpenter G. and Grossberg S., "The art of Adaptive pattern recognition by self-organizing neural network", IEEE Computer, pp. 77-87, 1988.
- Fa-Long Luo, "Applied Neural Networks for Signal Processing", Cambridge University Press, 1997.
- Frank T., Kraiss K., and Kuhlen T., "Comparative Analysis of Fuzzy ART and ART-2A Network Clustering Performance", IEE Transactions on Neural Networks, Vol. 9, No. 3, pp. 544-559, 1998.
- Frazier, M. W.; "A Introduction to Wavelet through Linear Algebra"; Springer, 1999.
- Gómez-Ullate, L.; "Curso de Ensayos No Destructivos por Ultrasonidos"; página en internet: www.iai.csic.es/users/end/eindex.html, Grupo Trends, Departamento de Sistemas, Instituto de Automática Industrial, CSIC, España, 1999.
- Goswami Jaideva C., Chan Andrew K., "Fundamentals of Wavelets Theory, Algorithms, and Applications", John Wiley & Sons, 1999.
- Guez Y., Donohue K., and Bilgutay N., "A Neural Architecture for Ultrasonic Nondestructive Testing", Ultrasonic Symposium, pp. 777-780, 1991
- Gabor D., "Theory of Comunication", J. of IEEE, Vol 93, pp 429-457, 1946.
- Haar A., "Zur Theorie der Orthogonalen Funktionen systeme", Math. Annal, Vol. 69, pp 331-371, 1910.
- Hassoun M., "Fundamentals of Artificial Neural Networks", The MIT Press, 1995.
- Höppner F., Klawonn F., Kruse R., Runkler T., "Fuzzy Cluster Analysis", John Wiley & Sons, LTD, 1999.
- Kirby M., "Geometric Data Analysis", John Wiley & Sons, INC. 2001.
- Krautkrämer, J., y Krautkrämer, H.; "Ultrasonic Testing of Materials"; Springer-Verlag, Third Edition, Berlin Heidelberg New-York, USA, 1983.
- Krautkramer, Manual; "Ultrasonic Transducers Fon Nondestructive Testing"; Krautkramer Companies Inc., 1999.

Legendre, S., Groyette J., y Massicotte, D. ; "Ultrasonic NDE of Composite Materials Structures using Wavelets Coefficients"; NDT& International, Elsevier Science Ltd, No. 34, pp. 31-37, 2001.

Lippmann R., "An Introduction to Computing with Neural Nets", IEEE ASSP Magazine, pp. 36-54, 1987.

Kolmogorov A. N., Fomin S. V., "Elements of the Theory of Functions and Functional Analysis", Dover 1999.

MATEC, Manual; "SR-9000 Pulser/Reciver Card, Manual"; Matec Instrument Companies Inc., Masachussets, USA, 1999.

Nelles, O., " Nonlinear Systems Identification"; Springer-Verlag, 2001.

Proakis John G., Manolakis Dimitris G., "Digital Signal Processing Algorithms and Applications", Prentice Hall, 3rd edition 1995.

Rudin Walter, "Real and Complex Analysis", McGraw Hill, 3rd edition 1986.

Schmerr, L. W.; "Fundamentals of Ultrasonic Nondestructive Evaluation"; Plenum, Press, New York, 1998.

Wang X. Z., Chen B. H., Yang S. H., McGreavy C., "Applications of wavelets and neural networks to diagnostic system development, 2, an integrated framework and its application", Computers & Chemical Engineering Elsevier, pp. 945-954, 1999.

Xiao, G., Brady, J., Noble, J., y Bucher, M.; "Nonrigid Registration of 3-D free hand Ultrasound Images of the Breast"; IEEE Transactions on Medical Imaging, Vol. 21, No. 4, pp. 405-412, 2002.

Apéndice A

Programa que implanta la red Neuronal ART2A

```
function [W, pos] = art2a(I, add)
% Implementación de una red neuronal tipo ART2A.
%
% [W pos] = art2(I, add)
% W : Matriz de pesos de la red neuronal
% pos: Posición de la neurona ganadora
% I : vector de datos de entrada: M X 1
%

% *** Valores de inicio ***
etha = 0.4 ;      % etah = 0.3, rho = 0.8 para señales con eco
rho = 0.85 ;
fname = 'mart2a.mat' ;

fd = fopen(fname, 'r') ;

if fd == -1 & add == 1      % Es la primera vez. Se crea la red
    W = I ;
    [M pos] = size(W) ;
    save(fname, 'W') ;
    return
end

fclose(fd) ;
load(fname) ;      % La red ya existe, cargamos matriz de pesos desde de la memoria permanente
[M N] = size(W) ;

T = W' * I ;      % Aplicamos matriz de pesos al vector de entrada
[m j] = max(T) ;  % Se busca neurona ganadora y registramos su posición en j

if ( m > rho )      % Si es mayor al parámetro de vigilancia
    W(:, j) = etha*I + (1 - etha)*W(:,j) ; % Se aplica ley de aprendizaje
    pos = j ;
    save(fname, 'W') ;      % Se registra el aprendizaje
    return
else
    pos = N + 1 ;
end

if add == 1
    W(:, pos) = I ;      % Se agrega nuevo patrón
    save(fname, 'W') ;      % Guardamos matriz pesos actual
end
```

Programa que determina si existe una falla en el material.

```
function [W, Pos, fault] = fault_art2a(signal)
% [W, Pos, fault] = fault_art2a(signal)
%
% W : Martiz de pesos de la red neuronal ART2
% Pos : Renglones que se modificaron
% fault : Si se encontro una falla, fault = 1, sino fault = 0
% signal : señal que vamos a procesar

fault = 0 ;
fname = 'mart2a.mat' ;
fd = fopen(fname, 'r') ;
if fd == -1
    fprintf('Codificando señal sin fallas\n') ;
    [W Pos] = wtrain_art2a(signal, 'db4') ; % Es la primera vez
    [n good] = size(W) ;
    save('nde.mat', 'good') ;
    fprintf('good = %1d\n\n', good) ;
    return
end
fclose(fd) ;

load('nde.mat') ;
load('mart2a.mat') ;
[M N] = size(W) ;

x = signal ;
%fprintf('Buscando patron en la red ART2A\n') ;
[W p] = art2a(x, 0) ;
fprintf('Patron en renglon %d de la red ART2A\n', p) ;
if p <= good
    Pos = p ;
    fault = 0 ;
    return
end

if p > good & p <= N
    fault = 1 ;
    Pos = p ;
    return
end

if p > N
    fprintf('Clasificando nuevo patron\n') ;
    [W Pos] = wtrain_art2a(signal, 'db4') ;
    fault = 1 ;
end
```


Programa que entrena la red neuronal, primero se invoca a la Transformada Continua de Onduleta.

```
function [W, Pos] = wtrain_art2a(signal, wavelet)
% W = wtrain_art2a(signal, wavelet, win)
%
% W    : Matriz de pesos de la red neuronal ART2
% signal : señal que vamos a procesar (1000 datos)
% wavelet: Familia de wavelets
% win   : Ventana para graficar

fprintf('Calculando transformada continua wavelet...\n');
C = abs(cwt(signal, 1:40, wavelet));
[m, n] = size(C);

for i=1:m
    for j=1:n
        if C(i, j) < 0.0001
            C(i, j) = 0.0;
        end
    end
end

fprintf('La red ART2A está aprendiendo...\n');
for i=1:m
    x = C(i,:);
    nor = norm(x);
    if nor ~= 0
        x = x/nor;    % Se necesita normalizar x, requisito de ART2A
    end
    [W p] = art2a(x', 1);
    Pos(i) = p;
end
```