

DETECCIÓN DE DEFECTOS MECÁNICOS INTERNOS EN LÁMINAS DE CFRP
BASADA EN UN CLASIFICADOR TIPO RNA Y EL ALGORITMO DE
CONTRASTE CTFF

JHOAN DAVID OSPINA MUÑOZ

UNIVERSIDAD DEL VALLE
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA
PROGRAMA ACADÉMICO DE INGENIERÍA ELECTRÓNICA
CALI, DICIEMBRE DE 2016

DETECCION DE DEFECTOS MECÁNICOS INTERNOS EN LAMINAS DE CFRP
BASADA EN UN CLASIFICADOR TIPO RNA Y EL ALGORITMO DE
CONTRASTE CTFF

JHOAN DAVID OSPINA MUÑOZ

DIRECTORES:
ANDRÉS DAVID RESTREPO GIRÓN, Ph.D.
WILFREDO ALFONSO MORALES, Ph.D.

UNIVERSIDAD DEL VALLE
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA
PROGRAMA ACADÉMICO DE INGENIERÍA ELECTRÓNICA
CALI, DICIEMBRE DE 2016

Resumen

Las técnicas de ensayo no destructivo en la industria están en constante evolución, ya que permiten examinar los materiales sin alterar de forma permanente las propiedades físicas, químicas o mecánicas. Adicionalmente, las técnicas de ensayo termográfico no destructivo, permiten estimar la calidad de manera rápida, sencilla y sin contacto. Desde este enfoque, se plantea detectar los defectos en láminas de plástico reforzado con fibra de carbono (CFRP) aplicando Redes Neuronales Artificiales como clasificador de una secuencia de imágenes IR usando características de contraste obtenidas a través de la técnica de compensación térmica de fondo mediante filtrado (CTFF).

Los resultados obtenidos en este estudio demuestran que la técnica CTFF resultó ser más efectiva en la clasificación de defectos en las láminas CFRP usando una arquitectura *feedforward* con algoritmo de entrenamiento de entropía cruzada con *softmax*. Con una topología de 17 neuronas en la capa oculta, para la secuencia de 157Hz se obtuvo un porcentaje de clasificación 96.4% y una sensibilidad de 96.16%; mientras que con 12 neuronas en la capa oculta, para la secuencia de 90Hz se obtuvo un porcentaje de clasificación de 98.6% y una sensibilidad de 98.13%.

Tabla de Contenido

Resumen.....	iii
Tabla de Contenido	iv
1. Introducción	1
1.1 Objetivos.....	3
1.1.1 Objetivo general	3
1.1.2 Objetivos específicos	3
1.2 Antecedentes.....	3
1.2.1 Antecedentes Internacionales.....	¡Error! Marcador no definido.
1.2.2 Antecedentes Nacionales	¡Error! Marcador no definido.
1.2.3 Antecedentes Regionales	¡Error! Marcador no definido.
1.3. Bosquejo del libro	5
2. Técnicas para la detección y clasificación de fallas usando termografía activa.....	6
2.1 Materiales Compuestos	6
2.1.1 Características de los materiales compuestos.....	¡Error! Marcador no definido.
2.1.2 Materiales compuestos reforzados con fibras.....	7
2.2 Termografía Infrarroja (TI)	8
2.2.1 Condiciones para la aplicación de la termografía infrarroja	8
2.3 Termografía activa como método de ensayo no destructivo.....	9
2.4 Técnicas de termografía infrarroja activa.....	10
2.4.1 Termografía Lock-In	10

2.4.2 Termografía por calentamiento mediante escalón de calor	10
2.4.3 Termografía pulsada (PT).....	10
2.4.4 Vibrotermografía	11
2.5 Técnicas de mejoramiento de contraste térmico	11
2.5.1 Contraste absoluto diferencial modificado (CAD-m)	11
2.5.2 Compensación térmica de fondo mediante filtrado (CTFF).	13
2.6 Detección de defectos usando redes neuronales	18
2.7 Resumen	20
3. Metodología	21
3.1 Sistema para la extracción de características.....	21
3.2 Down-Sampling	23
3.3 Caracterización de las Imágenes de Contraste CTFF	24
3.4 Cálculo y Definición de las Características de Interés de las Imágenes con Contraste CTFF	26
3.4.1 Perfiles térmicos de los pixeles seleccionados	27
3.4.2 Aplicación de ruido gaussiano a los perfiles térmicos.....	28
3.5 Detección de defectos usando Redes Neuronales (RNA)	29
3.5.2 Redes perceptrón multicapa (MLP)	29
3.5.1 Redes de base radial (RBF)	33
3.6 Entrenamiento de la RNA a partir de los parámetros estimados en las imágenes con el contraste CTFF	35
3.6.1 Arquitectura MLP	35
3.6.2 Arquitectura RBF	35
3.7 Selección de la RNA más adecuada	36
3.7.1 Selección de la topología MLP	36

3.7.2 Selección de la mejor topología RBF.....	36
3.8 Plantilla generada por el sistema de detección de defectos	37
3.9 Matriz de confusión.....	38
3.10 Protocolo de pruebas.....	40
3.11 Observaciones Generales	41
4. Análisis de Resultados	42
4.1 Aplicación del contraste CTFF al banco de secuencias	43
4.2 Selección de la mejor red a partir de los resultados del entrenamiento de las RNA para el contraste CTFF	43
4.2.1 Resultados de las redes MLP para el banco de secuencias	44
4.2.2 Resultados de las RBF para el banco de secuencias.....	45
4.3 Plantilla generada por el sistema de detección de defectos de las imágenes con el contraste CTFF.	47
4.3.1 Plantilla generada por las redes MLP para el banco de secuencias.....	47
4.3.2 Plantilla generada por la red RBF para el banco de secuencias	54
4.3.3 Análisis comparativo entre MLP y RBF para las secuencias de 157Hz y 90Hz con el contraste CTFF	60
4.4 Resultados para el contraste CAD-m	60
4.4.2 Resultados de las redes MLP con el contraste CAD-m	61
4.4.4 Resultados de las redes RBF con el contraste CAD-m	68
4.4.5 Análisis comparativo entre arquitecturas MLP y RBF para las secuencias de 157Hz y 90Hz con el contraste CAD-m	73
4.5 Análisis comparativo entre el contraste CTFF y CAD-m.....	74
4.5.1 Análisis con las topologías escogidas para CTFF y CAD-m.....	74
4.6 Conclusiones	75

5. Conclusiones	76
5.1 Conclusiones Generales.....	76
5.2 Trabajos futuros.....	77
6. Referencias.....	78

1 Introducción

Aunque existen diferentes técnicas de fabricación de materiales compuestos, en general, su síntesis se basa en la laminación de diferentes capas delgadas, de manera que las fibras en cada capa se orientan acorde con las especificaciones del diseño. Debido a fallas de fabricación, un uso prolongado o al estrés mecánico excesivo, se presentan diferentes tipos de defectos internos, siendo el más común la *delaminación*, o separación entre capas constitutivas del material. El riesgo de no detectar a tiempo estas delaminaciones y otros tipos de fallas en los materiales compuestos, es que el sometimiento continuo a las tensiones mecánicas normales para las que fueron contruidos, hace que los defectos internos crezcan en tamaño hasta generar una fractura del material. La consecuencia de un fenómeno como éste puede llevar no solo a pérdidas económicas sino también humanas.

El empleo de las diferentes técnicas de ensayos no destructivos (END) en la industria para la evaluación de todo tipo de materiales y procesos es cada vez mayor, ya que permite realizar inspecciones sin alterar de forma permanente la propiedades físicas, químicas o mecánicas de los elementos (Rafael, 2015). En la actualidad existen varios métodos de END para la inspección de materiales, El objetivo de aplicar las técnicas de END se centra en descubrir cualquier tipo de falla que afecte al material a tal punto que se podría saber cuándo debe ser reparado o sustituido (Duan, Servais, Genest, Castañedo, Maldague, 2012). La escogencia de una técnica apropiada para la detección de fallas depende de las características del material que se desea inspeccionar. Las técnicas de END se pueden clasificar en 6 categorías: inspección visual, evaluación radiográfica, evaluación por corrientes de Eddy y partículas magnéticas, evaluación con ultrasonido, termografía infrarroja, y evaluación con líquido penetrante.

La técnica de secuencias con termografía infrarroja (TI), es una de las más recientemente utilizadas, y tiene un campo muy amplio para su aplicación. Para aplicar la técnica de TI es necesario tener claras las condiciones para la detección

de fallas de los materiales compuestos; algunas condiciones necesarias son: que exista una diferencia de temperatura o contraste térmico entre el objeto de interés y su alrededor, y tener las herramientas adecuadas para registrar esta información de temperatura.

Posterior a la captura de la información, se pueden emplear diversos métodos de extracción de características y clasificadores que permitan discriminar los defectos. Los avances en las ciencias computacionales, han permitido a la humanidad desarrollarse en áreas del conocimiento que antes se pensaban inalcanzables, nuevas técnicas numéricas permiten desarrollos rápidos, precisos y confiables (Alejandro, 2010). Para la clasificación de defectos en las secuencias de TI se pueden utilizar redes neuronales artificiales (RNA), máquinas de soporte vectorial (MSV), entre otros. Las RNA son máquinas de aprendizaje que han sido empleadas con éxito en diversas aplicaciones como la clasificación de patrones y están basadas en el comportamiento del cerebro humano. Dado que una de sus características funcionales es la extracción del conocimiento a partir de la información de entrada, se han utilizado con éxito para clasificar bases de datos grandes, en las cuales difícilmente se puede inferir de manera automática la separación de clases con características comunes.

Por otra parte, el problema de la detección y caracterización termográfica de defectos en materiales compuestos ha sido abordado en el grupo PSI desde hace algunos años con los trabajos de (Benítez, Loaiza, & Caicedo, 2011) y (Restrepo, 2013). Como resultado de este trabajo se han propuesto diferentes técnicas de mejoramiento del contraste térmico en las imágenes termográficas; una de ellas es la compensación térmica de fondo mediante filtrado (CTFF) que hace un uso particular de la mediana estadística. Con este método y un algoritmo basado en puntos de máxima energía se obtuvieron buenos resultados en la detección de fallas (alrededor del 90%), aunque con un número significativo de falsos positivos. Este trabajo presenta un sistema de detección de fallas en materiales compuestos usando secuencias de termografía infrarroja. Para ello, se hace uso de

clasificadores basados en RNA con dos arquitecturas: Perceptrón Multicapa (MLP, por sus siglas en inglés) y Redes de Base Radial (RBF), con el objetivo de determinar la arquitectura más adecuada que permita discriminar zonas de los materiales compuestos con y sin fallas. Con los resultados obtenidos, es posible hacer un análisis comparativo entre dos técnicas de contraste: CAD-m (Contraste Absoluto Diferencial Modificado, propuesto por [\(Benitez, 2008\)](#)) y el contraste CTFF, tal que se pueda determinar cuál es el más apropiado para la determinación de fallas en láminas de plástico reforzado con fibra de carbono.

1.1 Objetivos

1.1.1 Objetivo general

Desarrollar un sistema de detección de defectos mecánicos internos en láminas de CFRP, basado en una red neuronal artificial aplicada a una secuencia de imágenes IR contrastadas por *compensación térmica de fondo mediante filtrado* (CTFF).

1.1.2 Objetivos específicos

- Revisar los elementos conceptuales relevantes de las RNA usadas en la detección de defectos de laminación mediante inspección termográfica.
- Seleccionar las características más discriminantes de las imágenes de contraste CTFF que permitan la detección de defectos internos en placas de CFRP.
- Implementar un sistema basado en una RNA y en la información de contraste CTFF para la detección de defectos internos.
- Validar el desempeño del sistema de detección propuesto.
- Realizar un estudio comparativo usando trabajo típico de referencia.

1.2 Antecedentes

En [\(Santey & Almond, 1997\)](#) se presenta una aplicación utilizando RNA para obtener el tamaño y la profundidad de un defecto. En este trabajo se utilizaron 5

parámetros experimentales bien definidos para la caracterización del defecto, con límites aceptables para precisión y exactitud. Además se utilizaron datos sintéticos para el entrenamiento y la validación de la red neuronal, teniendo en cuenta que el tamaño de los defectos solo se puede inspeccionar cuando hay un solo defecto en la muestra inspeccionada. Esto se debe a que los parámetros utilizados para calcular el diámetro son muy difíciles de determinar cuando existen varios defectos en la muestra. Otro de los casos utilizando RNA es el trabajo realizado por [\(Vallerand, Darabi, & Maldague, 1999\)](#) el cual está enfocado en el entrenamiento y la validación de las RNA con datos obtenidos a partir de la termografía de fase pulsada, observando así que los datos de fase entregan mejores resultados que los de amplitud en términos de detección de defectos, ya que los datos de amplitud se ven afectados por el calentamiento no uniforme. En general se ha tenido un buen resultado al utilizar la inteligencia artificial en este tipo de sistemas tal y como se describe en el trabajo realizado por [\(Allende, Mirapeix, Conde, Cobo, & Iopez, 2009\)](#) que tiene como objetivo la validez de una técnica de procesamiento basado en la selección de características y RNA aplicada a la soldadura. Una de las soluciones concluyó que la red neuronal artificial realiza la identificación espectral con un grado muy positivo de éxito tras varias pruebas de soldaduras experimentales.

Por otro lado, las herramientas utilizadas en los sistemas de detección de defectos son muy importantes para detectar cualquier tipo de defecto en materiales industriales, lo cual se puede evidenciar en el trabajo realizado por [\(Jaramillo, Fandiño, Benitez, Orjuela, & Castellanos, 2012\)](#) en el cual se propone utilizar la metodología multi-resolución, la cual fue probada usando tres especímenes de (CFRP) defectuosos en los cuales habían defectos a diferentes profundidades. Además de esto utilizaron otras dos muestras hechas de plexiglás TM y aluminio con agujeros de fondo plano circulares a diferentes profundidades, mostrando que la metodología propuesta en este experimento es invariante del material o defecto, tal y como se evidencia en el trabajo de [\(Bison, y otros, 1996\)](#) donde el material utilizado es plástico (PVC). En este trabajo se propone dos redes perceptrón

multicapa (MLP) que funcionan como detectores de defectos en PVC. En este trabajo se utilizan las curvas de contraste térmico normalizadas, obteniendo como salidas los puntos defectuosos y no-defectuosos, permitiendo identificar delaminaciones al interior de un cuerpo opaco de una manera satisfactoria.

Por ultimo en el trabajo realizado por [\(Benitez, 2008\)](#) se desarrolló un trabajo con diferentes métodos de detección y caracterización de defectos mediante máquinas de aprendizaje, como diferentes tipos de redes neuronales artificiales y máquinas de soporte vectorial. Basados en el Contraste Absoluto Diferencial (CAD) y el Contraste Absoluto Diferencial modificado (CAD-m). Después de implementar el sistema de detección de defectos se obtuvieron mejores resultados para los contrastes CAD y CAD-m, que para contrastes y métodos utilizados anteriormente.

1.3. Bosquejo del libro

Esta tesis está organizada en 6 capítulos. A partir del capítulo 2 se presentan las características más importantes de los materiales compuestos y se describe la Termografía Infrarroja como uno de los principales métodos en las técnicas de ensayos no destructivos. Por otro lado, se describen los contrastes CTFF y CAD-m, nombrando algunos trabajos donde las Redes Neuronales Artificiales en la detección de defectos han sido implementadas. El capítulo 3 describe la metodología planteada para la caracterización de las secuencias, la descripción de las arquitecturas Perceptrón Multicapa (MLP) y Redes de Base Radial (RBF), el entrenamiento de dichas redes y la validación sobre el sistema. El capítulo 4 presenta los resultados de implementar las arquitecturas MLP y RBF utilizando los contrastes CTFF y CAD-m, haciendo un análisis comparativo entre los contrastes para determinar con cual se obtiene un mejor sistema de detección de defectos. El capítulo 5 presenta las conclusiones del trabajo realizado y se presentan algunos posibles trabajos que pueden continuar en esta temática.

2 Técnicas para la detección y clasificación de fallas usando termografía activa

En este capítulo se describen las características de los materiales compuestos, en especial el CFRP (Plástico reforzado con fibra de carbono), abarcando las diferentes técnicas de termografía activa, los métodos de contraste CTFF y CAD-m y la descripción de trabajos donde se han utilizado Redes Neuronales Artificiales (RNA) para la detección de defectos.

2.1 Materiales Compuestos

Los materiales compuestos se caracterizan por ser combinaciones macroscópicas de dos o más materiales diferentes. Los materiales individuales que hacen parte del compuesto tienen propiedades físicas y mecánicas independientes, intentando tomar las mejores características funcionales de cada uno, en pro del producto. Estos compuestos traen muchos beneficios como la resistencia, la rigidez, la relación resistencia/peso, debido a la introducción de fibras fuertes y rígidas. Una característica de estos materiales compuestos, respecto a los endurecidos por dispersión, es el aumento de la resistencia a temperatura ambiente así como a temperaturas elevadas. Se suelen emplear varios materiales compuestos reforzados como: el refuerzo de acero en estructuras, el refuerzo de fibra de vidrio sobre polímeros y el refuerzo con fibras de boro o carbono.

Las principales características de los materiales compuestos son:

- *Alta resistencia:* Tienen una alta resistencia en relación a su peso.
- *Baja densidad:* Proporcionan una buena resistencia por unidad de peso.
- *Flexibilidad de formas:* Debido a que las fibras de refuerzo se trabajan con mayor facilidad que otra variedad de materiales, se pueden realizar una gran variedad de formas y acabados.

- *Comportamiento a fatiga*: Dado que los materiales compuestos no tienen una estructura ordenada por ser materiales amorfos, no sufren los mismos efectos de fatiga que los metales.
- *Consolidación de partes*: Los materiales compuestos permiten el ensamble de componentes, por lo tanto, se reduce el número de elementos y de uniones.
- *Alta resistencia dieléctrica*: Son aislantes eléctricos.
- *Reducción de costos de mantenimiento*: Al tener una muy buena resistencia a la fatiga y la corrosión se reducen las tareas de mantenimiento y los costos de reparación.

Materiales compuestos reforzados con fibras: Los materiales compuestos reforzados con fibras en su mayoría tienen mejor resistencia al desgaste, mejor rigidez y mejor relación resistencia-peso. Aunque suelen ser frágiles, en una matriz más blanda, el material de la matriz transmite la fuerza de las fibras, las cuales soportan casi el total de la fuerza aplicada. Además, la resistencia del compuesto puede ser alta a temperaturas elevadas y a la temperatura ambiente.

Las fibras de carbono, conformadas por átomos de carbono unidos entre sí en cristales que son prácticamente alineados en paralelo al eje longitudinal de la fibra, ofrecen una alta resistencia en función del volumen (lo hace fuerte para su tamaño). La fibra de carbono es el desarrollo con mayores ventajas en el campo de los materiales compuestos, ya que uniendo estas fibras sintéticas con varias resinas, se pueden lograr materiales bajos en densidad, muy resistentes y duraderos. La fibra de carbono es un material muy versátil, ideal para la construcción de aviones y máquinas aeroespaciales, así como para las diferentes construcciones civiles y algunas aplicaciones militares. Sin embargo, el costo es elevado respecto a otros materiales similares como la fibra de vidrio y las fibras de plástico. Algunas de sus propiedades son:

- Baja densidad, en comparación con otros elementos como el acero (4.5 veces menor).

- Resistencia a agentes externos.
- Gran capacidad de aislamiento térmico.
- Elevada resistencia mecánica.
- Resistencia a la corrosión.
- Resistencia a las variaciones de temperatura.

2.2 Termografía Infrarroja (TI)

La termografía infrarroja (TI) es una técnica que estudia el calor distribuido sobre la superficie de un cuerpo con el fin de estimar cualquier tipo de anomalía en un material. La termografía puede usarse bajo dos esquemas: la termografía pasiva la cual trabaja con la radiación térmica natural del propio sistema a evaluar o por su interrelación con otras fuentes o flujos de calor, y la termografía activa la cual requiere calentar previamente el material o el sistema bajo estudio, con el fin de tener la posibilidad de captar diferencias de temperatura que de otra manera y en condiciones naturales no se tendrían o serían imperceptibles ([Restrepo, 2013](#)).

2.2.1 Condiciones para la aplicación de la termografía infrarroja

La condición más importante para la aplicación de termografía infrarroja es que exista una diferencia de temperatura o contraste térmico entre el objeto de interés, sean individuos en una escena o defectos internos en una muestra de material, y sus alrededores. ([Benítez, Loaiza, & Caicedo, 2011](#)).

La termografía activa, como técnica de END, permite generar un contraste de temperatura en los materiales a ser evaluados cuando existe algún tipo de defecto en el material. Esto es importante ya que se tiene en cuenta el tipo de defecto del material, las propiedades termofísicas de los defectos internos, así como las delaminaciones, las cuales deben ser diferentes a las del material inspeccionado cuando existen defectos.

2.3 Termografía activa como método de ensayo no destructivo

Las imágenes térmicas posibilitan la observación más detallada del estado del material, haciendo más fácil detectar algo fuera de lo común. Es por ello que la termografía infrarroja (TI) se posiciona como una herramienta seria, fiable y precisa en comparación a otras técnicas de ensayo no destructivo. (Daniel, 2006)

Algunas ventajas de la TI como ensayo no destructivo (END) son:

- Carácter no invasivo al no requerir contacto con el material inspeccionado.
- Facilidad de la implementación de las técnicas experimentales, así como la rapidez en la inspección.
- Solo se requiere el examen sobre una superficie del material.
- No hay exposición a radiaciones peligrosas para la salud humana.
- Las aplicaciones de la TI son muy variadas.
- En ciertos casos, es la única técnica que entrega resultados satisfactorios.

La TI también tiene algunas desventajas como:

- Diferentes valores de emisividad según los materiales inspeccionados y las condiciones ambientales.
- Las pérdidas de calor por convección o radiación causan perturbaciones en el contraste térmico.
- La absorción de la radiación infrarroja en la atmosfera hace que la distancia entre el sensor IR y la superficie evaluada este en un rango de muy pocos metros.
- Dificultad para generar un calentamiento uniforme sobre la superficie del objeto.
- Necesidad de una rata considerable de adquisición de las imágenes térmicas debido a la naturaleza transitoria de los contrastes térmicos.
- Se requiere una vista entre el sensor IR y la superficie examinada.
- El pobre contraste o una baja SNR pueden provocar falsas alarmas.
- Generalmente los defectos detectables son poco profundos.

2.4 Técnicas de termografía infrarroja activa

Existen cuatro técnicas usadas en el ensayo termográfico no destructivo (ETND) que se diferencian entre sí por la forma como son adquiridos y procesados los datos.

2.4.1 Termografía Lock-In

La termografía *Lock-In* está basada en la detección remota de ondas térmicas generadas en el interior de una muestra. La generación de estas ondas se lleva a cabo mediante la aplicación periódica de calor, por ejemplo, una onda seno modulada mediante la aplicación de calor con lámparas, de tal manera que al final se producen imágenes de fase y magnitud. El término Lock-In hace referencia a la necesidad de monitorear la dependencia exacta en el tiempo entre la señal de salida y la señal de referencia en la entrada.

2.4.2 Termografía por calentamiento mediante escalón de calor

En este tipo de inspección, la temperatura es monitoreada durante la aplicación de un pulso escalón de calor que puede durar varios segundos o minutos dependiente del grosor del material que está siendo inspeccionando.

2.4.3 Termografía pulsada (PT)

Es el procedimiento más común en END con TI, y el que ha permitido que la termografía en general adquiriera relevancia en el campo del END al superar dos grandes problemas presentados en su aplicación práctica: la repetitividad de los resultados y su capacidad para ser automatizada. Una de las razones de su importancia dentro de la TI es la rapidez de inspección cuando un pulso térmico es aplicado sobre la muestra para producir diferenciales de temperatura. Generalmente, un pulso térmico muy corto, que dura unos cuantos milisegundos, es aplicado sobre materiales de alta conductividad (como aluminio), mientras que otros deben ser aplicados por varios segundos cuando es aplicado en materiales de baja conductividad (como plástico y grafito epóxico). Esta técnica implica el uso de

un pulso de calor y el registro del descenso de temperatura sobre la muestra. (Benítez, Loaiza, & Caicedo, 2011).

El proceso de estimulación debe permanecer como no destructivo y no debe interferir con el uso futuro de la pieza inspeccionada, por lo cual no es muy recomendada para la inspección de obras de arte (Carlomagno & Carosena, 2001).

2.4.4 Vibrotermografía

Es una técnica activa del ETND la cual analiza el calor liberado por los efectos de vibraciones mecánicas (20 a 40 KHz) inducidas externamente a la estructura inspeccionada. (Benítez, Loaiza, & Caicedo, 2011). La vibrotermografía también existe en la modalidad de ultrasonido de baja frecuencia con modo de transmisión continuo, haciendo que el objeto se caliente por microvibración en una sub-área de la muestra inspeccionada. Por lo tanto, si existe algún tipo de defecto, éste se podrá observar en las imágenes infrarrojas.

2.5 Técnicas de mejoramiento de contraste térmico

2.5.1 Contraste absoluto diferencial modificado (CAD-m)

El CAD-m es una mejora considerable del método CAD, ya que es un método que permite calcular el comportamiento temporal de la temperatura sobre un área no defectuosa, teniendo en cuenta el grosor de la lámina y el ancho del pulso térmico generado para calentarla.

El CAD-m pretende sobreponerse a las limitaciones del método CAD, recurriendo a una teoría llamada cuadripolos térmicos, a través de la transformada de Laplace de las ecuaciones diferenciales espacio-temporales del modelo en una dimensión para la transferencia térmica. Debido a esto, el CAD-m se extrae sin compensar el efecto de la duración del pulso (Restrepo, 2013). De esto procedimiento se tiene la siguiente ecuación:

$$\Delta T(t)_{CADm} = T(t) - \frac{L^{-1} \left[\frac{\coth \sqrt{\frac{sh^2}{\alpha}}}{\sqrt{s}} \right]_t}{L^{-1} \left[\frac{\coth \sqrt{\frac{sh^2}{\alpha}}}{\sqrt{s}} \right]_{t'}} T(t') \quad (2.1)$$

Donde h es el grosor de la placa, α es la difusividad térmica del material, y s es la variable compleja de Laplace. Finalmente con la compensación del efecto del ancho de un pulso cuadrado de calor, se obtiene:

$$\Delta T(t)_{CADm} = T(t) - \frac{L^{-1} \left\{ \frac{1}{s} [1 - e^{-(t_f)s}] \left[\frac{\coth \sqrt{\frac{sh^2}{\alpha}}}{\sqrt{s}} \right] \right\}_t}{L^{-1} \left\{ \frac{1}{s} [1 - e^{-(t_f)s}] \left[\frac{\coth \sqrt{\frac{sh^2}{\alpha}}}{\sqrt{s}} \right] \right\}_{t'}} T(t') \quad (2.2)$$

En la *figura 2-1* se puede observar la corrección realizada por el CAD-m en los perfiles térmicos temporales con relación a los resultados entregados por el CAD.




Figura 2-1. Corrección mediante el CAD-m(a la derecha) de los perfiles térmicos obtenidos con el CAD(a la izquierda). (Benitez, 2008).

2.5.2 Compensación térmica de fondo mediante filtrado (CTFF).

La idea principal de este método de contraste térmico es distinguir y extraer de manera automática el fondo de la imagen entre los posibles defectos que contrasten con él. En las secuencias tomadas con termografía IR activa el fondo está constituido por la parte sana del material, es por esto que el fondo tiene entonces la información sobre el calentamiento no uniforme. Debido a que la información corresponde a una frecuencia muy baja, se aplica un filtro pasa-bajo selectivo el cual aísla la componente del calentamiento de fondo, basándose únicamente en la información de intensidad de los píxeles y no en la definición a priori de parámetros intrínsecos del material (Gonzales, 2002).

Un filtro típico para la eliminación de ruido impulsional en una imagen conservando la información que se tiene de baja frecuencia espacial, es un filtro mediana. Sin embargo, la propuesta se fundamenta en emplear el filtro mediana con el fin de extraer el perfil de calentamiento de fondo, para lo cual se hace necesario asumir que los posibles defectos constituyen los detalles principales a eliminar de la imagen original (Restrepo, 2013).

La figura 2-2 muestra el comportamiento que tiene el filtro mediana para recuperar la información de fondo. La mediana toma el valor central del vector de los datos ordenados, de donde se deduce teóricamente que el área máxima en píxeles A_{max} de una región defectuosa (formada por uno o más píxeles cercanos entre sí) está enmarcada dentro de un *kernel* cuadrado de M píxeles tal que: $A_{max} = \frac{M^2}{2} - 1$ (Restrepo, 2013).




Figura 2-2. a) Imagen artificial que simula un defecto en blanco sobre un fondo negro b) Datos de intensidad ordenados de menor a mayor

Se observa entonces que la máscara o kernel requerido para tal operación puede llegar a tener unas dimensiones considerables de acuerdo con el tamaño de los defectos. Para reducir el tiempo de ejecución que demanda normalmente una máscara de filtro mediana tan grande se hace uso del método de compensación térmica de fondo mediante filtrado (CTFF), el cual se describe a continuación:

- Lo primero que se realiza es la extracción de todas las imágenes capturadas creando así una secuencia con la información de la temperatura respecto al tiempo justo después de la excitación de calor. Luego de esto se resta una de las imágenes frías (no incluidas en la secuencia), con el fin de mejorar el contraste y eliminar ruido de la cámara infrarroja. Como paso previo, también debe inspeccionarse los píxeles anómalos que se puede tener de fabricación y se deben corregir. Así mismo, se considera el filtrado de la secuencia para atenuar el ruido aleatorio presente en las imágenes, obteniendo como consecuencia, la imagen de referencia I_{ref} , que de requerirse, para cualquier cálculo posterior, sería la primera imagen de la secuencia resultante.
- La máscara para el filtro mediana debe cumplir con el requerimiento de cubrir un área lo suficientemente extensa de la imagen como para filtrar el perfil de calentamiento no uniforme, eliminando así los contrastes abruptos causados por los defectos. Tampoco es recomendable tener una máscara muy grande.
- Para disminuir el tiempo, conservando el tamaño de la región procesada durante el cálculo del valor mediana, se opta por una estrategia en la que se discriminan algunos píxeles de la región, cada pixel se separa de sus vecinos analizados por una cantidad de n píxeles en cuatro direcciones cardinales




Figura 2-3. Máscara modificada para el filtro mediana diezmado (Restrepo, 2013)

La figura 2-3 presenta un ejemplo del cálculo del valor filtrado para el píxel central de la máscara, en una región cuadrada de M píxeles de lado (máscara $M \times M$) en un tiempo equivalente a la aplicación clásica de filtro mediana con una máscara de M/n píxeles de lado. A la máscara anterior se le denomina *máscara diezmada*. Es necesario expandir cada lado de los sectores de la imagen en un ancho igual a $(M-1)/2$ píxeles reteniendo, en principio, el valor de los píxeles del borde del sector de la imagen original, antes de aplicar el filtro. (Restrepo, 2013).

- Debido a que la máscara pretende abarcar una región muy grande de la imagen, los bordes tienden a afectarse. Para ello, se lleva a cabo una extrapolación de los bordes de tal manera que al expandirlos se conserve el comportamiento térmico al avanzar a la periferia de una imagen. A este procedimiento se le denomina *expansión lineal de bordes* y consiste en tomar una porción adecuada de la periferia de cada termograma, tal como se observa en la figura 2-4.




Figura 2-4. Expansión de bordes de un termograma (Restrepo, 2013)

Una vez se hace el filtrado mediana sobre cada uno de los termogramas de la secuencia original, se obtiene la secuencia de calentamiento de fondo que es la evolución de calor en el espécimen evaluado, si este no presenta defectos internos; es decir, que llamando a esta secuencia de calentamiento como $s^c(t)$ y siendo f y c el total de filas y columnas de cada imagen respectivamente, se tiene:

$$s^c(t) = F_{med}^{M,n} \left(I_t(P_{i,j}) \right), \quad \forall i, j, t, \text{ con } i = 1 \dots f, j = 1 \dots c \quad (2.3)$$

Siendo $S_{i,j}(t)$ y $S_{i,j}^c(t)$ las secuencias original y de calentamiento de fondo evaluadas en un pixel de coordenadas (i,j) para el tiempo t . Por lo tanto se tiene la siguiente ecuación para el contraste absoluto:

$$\Delta T_{CTFF}(t) = S_{i,j}(t) - S_{i,j}^c(t), \quad \forall i, j, t \quad (2.4)$$

- Ejecutando la ecuación anterior para todas las imágenes (barrido en el tiempo), se obtiene la secuencia compensada. La *figura 2-5* compara un perfil espacial de un termograma original con el perfil de calentamiento de fondo obtenido después del filtro mediana para luego mostrar el resultado de la resta entre los dos.




Figura 2-5.a) compensación entre un perfil original y el perfil de calentamiento de fondo estimado; b) resultado de la resta entre los dos perfiles anteriores (Restrepo, 2013).

La ecuación 2.5 resume el procedimiento de compensación, donde a un termograma con defectos se le resta la imagen estimada sin defectos para el mismo instante t (termograma de calentamiento de fondo), obteniendo así el termograma compensado (contraste térmico).

$$termo_o - termo_{cf} = termo_c \quad (2.5)$$

Siendo $termo_o$ el termograma original, $termo_{cf}$ el termograma de calentamiento de fondo y $termo_c$ el termograma compensado, tal como se muestra en la figura 2-6.




Figura 2-6. Comparación entre un termograma original, su perfil de calentamiento de fondo, y su versión contrastada (Restrepo, 2013).

2.6 Detección de defectos usando redes neuronales

Los principios utilizados para el desarrollo de las RNA surgen del funcionamiento básico de las redes neuronales biológicas. Los atributos básicos de una RNA se dividen en dos tipos: la arquitectura y la neurodinámica. La arquitectura define la estructura de la red, en otras palabras el número de neuronas artificiales y su interconectividad. La neurodinámica establece las propiedades, esto es, como aprende, asocia, compara, clasifica, etc. Una neurona está constituida por un conjunto de entradas, a las cuales se le asigna un peso específico dentro del

cálculo, además de un ajuste que le permite producir una señal de salida ([Socha & Ortiz, 2005](#)).

Las RNA están compuestas de muchos elementos sencillos que operan en paralelo, el diseño de la red está determinado en su mayoría por conexiones entre sus elementos. La idea de las redes neuronales fue concebida originalmente como un intento de modelar el cerebro humano, esto es, entender cómo funciona y opera el cerebro.

Debido a la naturaleza no lineal de la detección y caracterización de defectos en el ETND, el problema de la estimación de parámetros de defectos ha sido estudiado durante varios años por diferentes grupos de investigación. A pesar que se han desarrollado varios modelos analíticos, numéricos y empíricos para la estimación de propiedades térmicas de materiales y de la profundidad de defectos en los mismos, estos temas de investigación aún permanecen como áreas de investigación vigentes en el campo de los ETND ([Nakamura, Sakagami, Harada, & Kubo, 2008](#)), Las RNA son conocidas por sus capacidades de aprendizaje y han sido empleadas en los últimos años como detectores y estimadores de parámetros de defectos ya que pueden resolver problemas no lineales con datos con ruido o faltantes.

El trabajo realizado por ([Prabhu & Winfree, 1993](#)) propone el uso de redes perceptrón multicapa (MLP) para la detección de defectos en fuselajes de aeronaves. Las redes fueron entrenadas usando como patrones de entrada curvas de evolución temporal de temperatura y porcentaje del defecto (corrosión) como patrones de salida. El resultado es muy satisfactorio debido a los altos porcentajes de clasificación correcta de los defectos.

El trabajo realizado en ([Tretout, y otros, 1995](#)) utilizó RNA para inspeccionar estructuras aeroespaciales hechas por materiales compuestos. Se utilizaron como patrones de entrada datos relacionados con contraste térmico y termografía. Como datos de entrenamiento se utilizaron 500 curvas simuladas de temperatura, donde

la mitad correspondían a datos defectuosos y la otra mitad a datos no defectuosos. El mejor desempeño se obtuvo con curvas de contraste térmico donde se detectaron inserciones de teflón hasta 1.5 mm.

2.7 Resumen

Este capítulo presentó una revisión general de los conceptos respecto a las técnicas de contraste utilizando TI como método de END en materiales compuestos, especialmente en CFRP. Por otra parte se presentaron los contrastes CTFF y CAD-m, que son contrastes para el mejoramiento de las secuencias termográficas, así como para la selección de características discriminantes que podrían hacer que la clasificación de defectos sean mucho más eficientes. Finalmente, se citan algunos trabajos enfocados en la detección de defectos utilizando RNA como una herramienta ideal en la clasificación de defectos en láminas compuestas.

3 Sistema de Detección De Defectos con el Contraste CTFF Utilizando RNA

En este capítulo se describen las herramientas necesarias para la selección de características de las imágenes de contraste CTFF. Este capítulo también describe el funcionamiento de las dos arquitecturas de RNA utilizadas, sus topologías y los criterios de selección para elegir la arquitectura más adecuada, tal que cumpla con los requerimientos necesarios para la detección de defectos en placas de CFRP.

En la figura 3-1 se muestra de manera gráfica las etapas que componen el sistema de detección de defectos.




Figura 3-1 etapas del sistema de detección de defectos aplicando el contraste CTFF y utilizando RNA.

En los bloques 1 y 6 se tienen las secuencias de 157Hz y 90Hz respectivamente, a las cuales se les aplica Down-Sampling y el contraste CTFF, luego de esto se procede a seleccionar manual y aleatoriamente algunos píxeles para obtener sus perfiles térmicos tal como muestra en los bloques 3 y 8. Las características obtenidas de los perfiles térmicos en cada secuencia (157Hz y 90Hz), son ingresadas como datos de entrada a las arquitecturas MLP y RBF como se muestra en el bloque 4. Luego del entrenamiento de las RNA para la detección de defectos se generan

varias plantillas a partir de los resultados arrojados por la RNA en cada caso, las cuales son contrastadas con las plantillas originales que se presentan en el bloque 5.

3.1 Sistema para la extracción de características

Para la parte experimental se tienen dos secuencias de imágenes termográficas obtenidas utilizando termografía activa sobre láminas de material compuesto (CFRP), realizado bajo el auspicio del grupo de investigación en Visión Infrarroja Multipolar (MIVIM). Las dos secuencias están tomadas a 157Hz y 90Hz respectivamente. Estas secuencias fueron tomadas del material real con simulación de defectos, y a las cuales les fueron aplicados los contrastes CTFF (Restrepo, 2013), y CAD-m (Benitez, 2008). Para la extracción de características se cuenta con una GUI (Figura 3-2) creada en MatLab al interior del grupo PSI (Restrepo, 2013), la cual permite aplicar los contrastes CTFF y CAD-m de las secuencias nombradas anteriormente. La GUI también cuenta con otro tipo de contrastes y herramientas para la obtención de las características que no se utilizarán en este trabajo.




Figura 3-2 Herramienta utilizada para la aplicación de los contrastes en la secuencia.

3.2 Down-Sampling

Para proceder a la extracción de características de los bancos de secuencia, se realiza un pre-procesamiento en la secuencia. El proceso consiste en definir los límites inferior y superior de los termogramas descartando aquellos que se consideren irrelevantes. Luego, se ejecuta una reducción de frecuencia según el distanciamiento de las imágenes que se desean escoger para la nueva secuencia. Este procedimiento es llamado sub-muestreo o *down-sampling* y busca obtener secuencias con menos termogramas tal que se mantengan las características originales, haciendo que el esfuerzo computacional para el entrenamiento del clasificador disminuya. En la *figura 3-3* se puede observar el procedimiento que se realiza para pasar de la secuencia original a la secuencia recortada.



Figura 3-3. Procedimiento para recorte de secuencia

Donde $x(n)$ corresponde al sistema de entrada con una frecuencia representada por la variable **frecuencia_e**, y $y(m)$ es la salida del sistema con la frecuencia de muestreo deseada representada por **frecuencia_s**. En la ecuación 3.1 se describe como obtener la frecuencia de salida (**frecuencia_s**) en relación a la frecuencia de entrada (**frecuencia_e**), siendo D el factor por el cual se divide la frecuencia original para obtener las muestras equidistantes y así obtener un sistema equivalente con diferente tasa de muestreo.

$$\text{frecuencia}_s = \frac{\text{frecuencia}_e}{D} \quad (3.1)$$

Para este trabajo se realizó un pre-procesamiento para los bancos de secuencia de 157Hz y 90Hz, definiendo los límites inferiores de 10 y 3, los límites superiores de 450 y 207, con factores de $D=15$ y 6.89, respectivamente. Aplicando el *down-sampling* con los valores mostrados anteriormente se obtiene una frecuencia de

muestreo de 6.66Hz y 14.5Hz seleccionando un total de 30 termogramas, tal que no se ve afectado el sistema original pero reduciendo en número de características de los patrones de entrenamiento; esto disminuye el esfuerzo computacional para el entrenamiento del clasificador.

El down sampling se puede llevar a cabo en una muestra del perfil térmico por pixel sin alterar sus características debido a la dinámica de la temperatura en la lámina.

3.3 Caracterización de las Imágenes de Contraste CTFF

Para observar los resultados de aplicar el contraste CTFF se llevó a cabo un experimento con una muestra de material compuesto CFPR, que contiene varias inserciones de teflón de distintos tamaños y ubicadas a diferentes profundidades. Esto se hace como simulación de los defectos que se pueden producir en el material. El CFRP es un material muy usado en la industria aeronáutica y en la aeroespacial, debido a que es altamente eficiente y muy resistente; sin embargo, se puede ver afectado por impactos de materiales extraños, delaminaciones y porosidades. En la *figura 3-4* se muestra una imagen de la secuencia en un instante de tiempo dado, aplicando el contraste CTFF.




Figura 3-4. Secuencia con el contraste CTFF en el instante 1.7s




Figura 3-5. Termograma 3D aplicando el contraste CTFF (intensidad de contraste vs coordenadas de la imagen)

Como se puede observar en la *figura 3-5* es claro que se obtiene una mejor uniformidad de fondo con el contraste CTFF. Esta técnica presenta un comportamiento suave y uniforme con respecto a su distribución por encima del nivel cero de fondo. Es por esto que con esta técnica se alcanza un mayor acercamiento a la forma de un perfil térmico ideal.

Para la obtención de los perfiles térmicos se hace un análisis desde la GUI, la cual permite seleccionar pixeles en cualquier termograma de la secuencia de manera manual o por coordenadas del pixel, tal como se muestra en la *figura 3-6*, lo que permite obtener los perfiles térmicos de cada pixel a lo largo de la secuencia.




Figura 3-6. Selección de perfiles térmicos a partir de la GUI

Los perfiles térmicos de los pixeles contenidos en cualquiera de los termogramas de la secuencia con el contraste CTFF, son una buena herramienta para la selección de zonas defectuosas debido a que hay una mayor concentración de temperatura

en una zona defectuosa. Las *figuras 3-7 y 3-8* presentan los perfiles térmicos de dos pixeles ubicados en una zona defectuosa y en una zona sana del material respectivamente.




Figura 3-7. Perfil térmico de un pixel ubicado en un defecto en el instante $t=1.7s$




Figura 3-8. Perfil térmico de un pixel ubicado en una zona no defectuosa en el instante $t=1.7s$

3.4 Cálculo y Definición de las Características de Interés de las Imágenes con Contraste CTFF

La caracterización es quizá la parte más importante para entrenar una RNA, ya que la eficiencia para clasificar depende exclusivamente de los datos de entrada; debido

a esto, es fundamental seleccionar las características más discriminantes para entrenar el sistema tal que este responda con un mínimo error y así se tengan la menor cantidad de píxeles mal clasificados. Para la secuencia de 157Hz se tiene una dimensión de las imágenes de 193×193 *píxeles*, con una secuencia de 30 imágenes; es decir, la secuencia a 157Hz posee una dimensionalidad de $193 \times 193 \times 30$. Para la secuencia de 90Hz se tiene una dimensión de las imágenes de 470×475 *píxeles* y 30 imágenes de la secuencia ($470 \times 475 \times 30$).

Los pasos a seguir para la selección de características en ambas secuencias usando contrastes CTFF y CAD-m son:

- Se definen los datos de entrenamiento, los cuales están constituidos por 23 defectos y zonas no defectuosas (se han descartado dos defectos que son prácticamente invisibles).
- Se procede a tomar 6 píxeles aleatoriamente de forma manual por cada defecto ($6 \times 23 = 138$ píxeles), luego de esto se toman otros 12 píxeles de la misma forma hasta completar 150 píxeles. En las zonas no defectuosas se toman 150 píxeles nuevamente de forma manual y aleatoria: De cada uno de estos píxeles se extraerán los perfiles térmicos, los cuales tendrán la información de temperatura respecto al tiempo.
- Dado que el número de muestras es pequeño, se aplica ruido gaussiano a los perfiles térmicos de los píxeles seleccionados, para evitar el problema de *over-fitting* en el clasificador (Montes, Cardenas, & Miguel, 2009), obteniendo entonces un total de 600.

3.4.1 Perfiles térmicos de los píxeles seleccionados

La selección de los píxeles se realizó de forma aleatoria tomando coordenadas por filas de defectos tal como se muestra en la *figura 3-9*.




Figura 3-9. Perfiles térmicos tomados de la fila 3 de defectos en el instante $t=1.06s$ para la secuencia de 157Hz.

En la figura 3-9 se puede observar los perfiles térmicos pertenecientes a la tercera fila de defectos de la secuencia de 157Hz, donde se obtienen diversas respuestas ante la misma profundidad del defecto; sin embargo, estos perfiles resultan apropiados para el sistema de clasificación que se desea implementar, el cual debe distinguir entre defecto y no defecto.

3.4.2 Aplicación de ruido gaussiano a los perfiles térmicos

Con el propósito de evitar *over-fitting*, se aplicó ruido gaussiano a los 300 perfiles térmicos obtenidos inicialmente. A partir de éstos, se generan otros 300 perfiles térmicos (con ruido), que se adicionan para duplicar el número de patrones de la muestra. Esto se realiza para ambas secuencias de 157Hz y 90Hz.

En la ecuación 3.2 se describe matemáticamente la aplicación del ruido gaussiano, donde σ es la desviación estándar, μ es la media aritmética y x es un valor aleatorio, seguida por la ecuación 3.3, la cual representa la función del ruido aditivo. Para este trabajo se aplica una desviación estándar de 0.08 y una media de cero, los cuales son parámetros de ruido suave que no cambia la señal de manera abrupta.

$$p(x) = \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{\frac{-(x-\mu)^2}{2\sigma^2}} \quad (3.2)$$

$$\text{ruido aditivo} = \text{patron} + p(x) \quad (3.3)$$

En la *figura 3-10* se puede observar el resultado de aplicar ruido gaussiano a un perfil térmico ubicado en una zona defectuosa, obteniéndose variaciones poco severas en el comportamiento de los defectos en la lámina.




Figura 3-10. Ruido gaussiano aplicado a perfil térmico de un pixel en una zona defectuosa para la secuencia de 157Hz.

3.5 Detección de defectos usando Redes Neuronales (RNA)

Las características obtenidas para la detección de defectos corresponden al número de perfiles térmicos obtenidos de los pixeles seleccionados. Para efectos de este trabajo se opta por escoger dos tipos de redes: la RBF (redes de base radial) y una MLP (perceptrón multicapa).

3.5.2 Redes perceptrón multicapa (MLP)




Figura 3-11. Perceptrón multicapa

Las MLP son conocidas por la capacidad que tienen para realizar transformaciones matemáticas entre conjuntos de variables, también por su baja sensibilidad al ruido y sus capacidades de aprendizaje y generalización. Este tipo de redes han sido utilizadas a lo largo del tiempo en detectores y estimadores de parámetros de defectos ya que resuelven problemas no lineales con datos con ruido o faltantes (Caicedo & Sotelo, 2009).

La distribución de neuronas en el caso de una MLP se realiza formando niveles o capas de un número de neuronas determinado, cada una dependiendo de su situación dentro de la red. Con esto se pueden distinguir tres tipos de capas: capa de entrada, capa oculta y capa de salida. Como se puede observar en la figura 3.11, la capa de entrada recibe directamente la información que contienen los parámetros de entrada externos a la red, la capa oculta no tiene contacto directo con el exterior y puede estar conformada por una varias capas ocultas e incluso diferentes conexiones, lo que finalmente termina por describir la tipología de la red; y la capa de salida transfiere la información de la red hacia el exterior.

Por otro lado, los algoritmos de aprendizaje dependen de la función que se desea optimizar. En redes MLP es común utilizar el error cuadrático medio (MSE) como medida para sintonizar los pesos sinápticos de la red a través del algoritmo *backpropagation*. Por otro lado, existe otro tipo de medida que usa un mecanismo de activación *softmax* y usa la función de aptitud de *entropía cruzada* para el error. Este último resulta muy adecuado para resolver problemas de clasificación tipo *ad-hoc*; es decir, aquellos donde las neuronas de salida se activan por cada clase, siendo el número de neuronas de salida igual al número de clases que se quiere clasificar. De este modo, si j es el número de clases, $\theta = \{\theta_1, \dots, \theta_{j-1}\}$ es el conjunto asociado a la red neuronal y $\theta_j = \{\beta^j, W\}$ es el conjunto asociado al nodo de salida j (Pedro, 2009). El modelo funcional se presenta en la ecuación 3.6.

$$f_i(x, \theta_j) = \beta_0^j + \sum_{i=1}^M \beta_i^j B_i(x, w_i), \quad 1 \leq j \leq J - 1 \quad (3.6)$$

Siendo $\beta^j = \{\beta_0^j, \beta_1^j, \dots, \beta_M^j\}$ el valor de las conexiones entre la capa oculta y la capa de salida para el nodo j . Para interpretar las salidas de los nodos de la capa de salida se utiliza un enfoque probabilístico que considera la función de activación *softmax* en cada uno de dichos nodos (Pedro, 2009) ,la cual se puede ver en la ecuación 3.7.

$$g_j(x, \theta_j) = \frac{e^{f_j(x, \theta_j)}}{\sum_{i=1}^J e^{f_i(x, \theta_i)}} \quad (3.7)$$

Siendo $g_j(x, \theta_j)$ la probabilidad de que el patrón x pertenezca a la clase j . La transformación *softmax* produce estimaciones positivas en todas las salidas, siendo la suma de todas ellas igual 1; debido a esto, son interpretadas como la probabilidad de pertenencia a la clase correspondiente.

Por tratarse de probabilidades de pertenencia a una clase, no es necesario calcular todas las salidas ya que, por ejemplo, la probabilidad de la última salida $g_j(x, \theta_j)$ se puede obtener en función del resto como se muestra en la ecuación 3.8. De esta forma se puede simplificar el modelo considerando la salida del último nodo de la capa de salida constante e igual a cero, es decir $f_j(x, \theta_j) = 0$. Se tiene entonces que este nodo no será entrenado, y de esta manera se reduce el número de coeficientes a estimar y la carga computacional resultante.

$$1 - \sum_{i=1}^{J-1} g_j(x, \theta_i) \quad (3.8)$$

Teniendo en cuenta las consideraciones mencionadas anteriormente, la arquitectura de RNA para problemas de clasificación se refleja en la *figura 3-12*.




Figura 3-12. Modelo de red utilizado para problemas de clasificación (Pedro, 2009)

Por otro lado, para establecer una medida que determine la bondad de los modelos MLP, se considera la función de entropía cruzada del error. Si se utiliza el conjunto de datos de entrenamiento $D = \{(X_n, Y_n); 1 \leq n \leq N\}$ entonces, la función de entropía se representa con la ecuación 3.9 para J clases:

$$l(\theta; g) = -\frac{1}{N} \sum_{n=1}^N \sum_{l=1}^J y_n^{(l)} \log g_l(x_n, \theta_1) \quad (3.9)$$

La ventaja de utilizar como función de error $l(\theta; g)$ en lugar de $(1 - C)$ está en que la primera es una función continua, lo que permite un entrenamiento que converja a soluciones óptimas de forma robusta. Por esto, la primera medida de aptitud para maximizar C es una transformación estrictamente decreciente del error de entropía $l(\theta; g)$ (Fernandez, 2010) y está dada por la ecuación 3.10.

$$A(g) = \frac{1}{1 + l(\theta; g)} \quad (3.10)$$

Donde g es el modelo de funciones de base sigmoides.

3.5.1 Redes de base radial (RBF)




Figura 3-13. Red de base radial

Una de las ventajas más conocidas de las RBF es su sencillez. Esto se debe a que una vez las formas de los centroides han sido detalladas y los centros definidos, se tiene un modelo lineal cuyos parámetros pueden ser fácilmente obtenidos mediante mínimos cuadrados. Las funciones de base radial son fáciles de construir, fáciles de entrenar y la solución a los valores de sus pesos se puede encontrar rápidamente. Las RBF proveen un modelo muy flexible y entregan un buen desempeño en una gran cantidad de aplicaciones tanto en problemas de regresión, de estimación de parámetros y de clasificación (Benitez, 2008).

Aunque una RBF posee una estructura similar a la MLP, su diferencia radica en la capa oculta, donde una RBF está formada por funciones gaussianas. Las RBF han sido utilizadas en aplicaciones similares a las realizadas con MLP, solo que se caracterizan por agrupar inicialmente el conjunto de patrones cumpliendo su labor de aproximador universal, para luego procesar la información en la capa de salida de forma similar a las MLP. Este comportamiento hace que pueda ser aplicado con éxito a la identificación de sistemas no lineales (Caicedo & Sotelo, 2009).

Los nodos ocultos de las redes neuronales RBF presentan funciones de tipo local o kernel. Cada uno de los nodos RBF realiza una aproximación local independiente del espacio de búsqueda, normalmente mediante una campana de Gauss. La capa de salida de tipo lineal aúna el efecto independiente de cada nodo, sumando cada

valor obtenido. La idea es que cada nodo este ubicado en el entorno de un punto, el centro del espacio de búsqueda conformado por las variables de entrada y además con un radio determinado. El proceso de aprendizaje de la RBF consistirá en ir moviendo dichos nodos a lo largo del espacio de búsqueda, para ajustarlos de la mejor forma a los datos de entrenamiento (Pedro, 2009).

La función de activación entonces será equivalente a la función de distancia al patrón de entrada x (tomando como centro de la RBF el vector w_j) y la función de transferencia será una función de tipo gaussiana así como se muestra en la ecuación 3.11

$$B_j(x, w_j) = e^{-\frac{1}{2} \left(\frac{d(x, w_j)}{r_j} \right)^2} \quad (3.11)$$

Siendo $w_j = \{w_{j1}, w_{j2}, \dots, w_{jk}\}$ y la distancia definida como se muestra en la ecuación 3.12.

$$d(x, w_j) = \|x - w_j\| = \sqrt{\sum_{i=1}^k (x_i - w_{ji})^2} \quad (3.12)$$

Así entonces en comparación con las MLP, las redes RBF presentan la ventaja de que cada nodo en la capa oculta es un elemento local en el modelo, lo que hace que para un determinado patrón solo algunas unidades ocultas se activen. Esta característica facilita el entrenamiento, disminuyendo el número de óptimos locales y regiones planas de la superficie de error, al desaparecer gran parte de las interacciones entre los pesos (Pedro, 2009). Por otra parte el entrenamiento de las neuronas de la capa oculta de la RBF es no supervisado mientras que el entrenamiento de las neuronas de salida es supervisado. Es por ello que una RBF posee un aprendizaje híbrido que incrementa el número de neuronas en la capa oculta que mejor representan el conjunto de patrones, mientras disminuye el error en la capa de salida.

3.6 Entrenamiento de la RNA a partir de los parámetros estimados en las imágenes con el contraste CTFF

Partiendo de las características encontradas y modificadas a partir de un criterio de selección aleatorio, se procede a entrenar dos arquitecturas de RNA que se describen a continuación:

3.6.1 Arquitectura MLP

Para el entrenamiento de la RNA se utilizan las características tomadas de las secuencias con el contraste CTFF, donde se propone una metodología para la etapa de detección de defectos donde se prueban diferentes topologías.

Lo primero a tener en cuenta para el entrenamiento de la MLP son los datos de entrada, los cuales contienen la información de los perfiles térmicos de algunos píxeles ubicados en los defectos y zonas sanas. En este caso se escoge un porcentaje de 15% para validación, 15% para prueba y 70% para entrenamiento, con esto se tiene un tamaño fijo de los conjuntos. De esta manera se procede a entrenar las diferentes topologías de red y obtener el error cuadrático medio (MSE) de cada una. Se consideró cambiar el número de neuronas de la capa oculta desde 3 hasta 30, realizando 50 entrenamientos para cada caso.

3.6.2 Arquitectura RBF

Para el caso de la RBF también se tiene que escoger la mejor topología para el sistema de detección para ambas secuencias con ambos contrastes, en este caso se tiene como criterio de parada el error y el *spread* ya que en este tipo de red el entrenamiento en la capa oculta es no-supervisado.

La RNA tipo RBF más óptima será aquella que tenga un menor número de neuronas en la capa oculta con el menor error posible, teniendo en cuenta que entre más pequeño sea el error al que se quiere llegar, la red necesitará más neuronas en la capa oculta para poderlo alcanzar.

Como datos de entrada se realizan diferentes entrenamientos haciendo un barrido con un error porcentual comprendido entre 4% y 4.9% y un spread que varía entre 0.2 y 2 en el caso de la secuencia de 157Hz y un barrido de error entre el 2% y 2.9% con un spread que varía entre 0.1 y 1 para la secuencia de 90Hz.

3.7 Selección de la RNA más adecuada

Como se ha nombrado en las secciones anteriores, para realizar el sistema de detección de defectos es fundamental tener un error mínimo en la detección de defectos ya que de esto depende la eficiencia del sistema.

La selección de la topología de RNA tanto MLP como RBF más adecuada para este sistema se centró en la topología que presente la mayor sensibilidad respecto a las métricas de la matriz de confusión y lo haga con el menor costo computacional.

3.7.1 Selección de la topología MLP

La información obtenida a partir de la base de datos que se genera con el entrenamiento de las diferentes topologías de redes neuronales MLP se analiza para la estimación de los errores máximo, mínimo, media aritmética y desviación estándar. El criterio de selección se basa en encontrar la red neuronal que tenga el menor MSE con base a la detección de defectos y que presente el menor número de neuronas en la capa oculta.

3.7.2 Selección de la mejor topología RBF

Después del entrenamiento se obtiene una base de datos que contiene 100 topologías diferentes. Debido a que cada una de ellas tiene un criterio de parada diferente, las redes entrenadas tendrán diferentes números de neuronas en la capa oculta. De esta manera se procede a seleccionar la mejor topología de red, generando un recuadro con las 100 redes representadas por diferentes colores según el número de neuronas en la capa oculta. Para la selección de la mejor

topología RBF se sigue el criterio de seleccionar la red que genera el menor costo computacional y tiene un MSE mínimo en la selección de defectos.

3.8 Plantilla generada por el sistema de detección de defectos

Para generar la plantilla a partir del aprendizaje obtenido por la RNA se tienen dos plantillas sacadas de las secuencias originales, las cuales indican las zonas donde están situados los defectos y las zonas sanas. Las *figuras 3-14 y 3-15* muestran las plantillas originales para las secuencias de 157Hz y 90Hz respectivamente.




Figura 3-14 Plantilla para la secuencia de 157Hz




Figura 3-15 Plantilla para la secuencia de 90Hz

Como se puede observar en las *figuras 3-14 y 3-15* los defectos están representados con el color rojo mientras que las zonas sanas están representadas con el azul oscuro de fondo, como se puede ver hay 23 defectos en ambas secuencias. El clasificador debería reproducir esta plantilla a partir de los datos obtenidos con el entrenamiento de la misma.

Se procede a hacer un barrido de todos los píxeles de cada termograma de las secuencias reales para tener la información de todos los píxeles y así poder generar las plantillas utilizando el sistema de detección de defectos previamente entrenado. En el mejor de los casos lo que se espera obtener es dos plantillas con un número

de falsos positivos y falsos negativos muy bajo, ya que esto indicará que el sistema de detección de defectos implementado con la RNA es muy eficiente.

Para elegir las mejores topologías de ambas arquitecturas se realiza un filtrado con las mejores soluciones encontradas, tal como se describe a continuación:

MLP: Consiste en seleccionar las 6 topologías con el menor MSE como primera prioridad, en caso de empate se elige aquella con la menor desviación estándar, es decir, la topología con menor variabilidad. Si en ambos casos las topologías siguen siendo iguales se procede a mirar la mediana de los datos, para escoger la topología que tenga la mediana más baja ya que esto indica que la concentración de los datos está centrada en los valores mínimos de los entrenamientos.

RBF: Se eligen 6 topologías que presenten el menor costo computacional, luego de esto se procede a medir el MSE de cada una de las 100 redes, enfocándose solamente en las topologías seleccionadas inicialmente y escogiendo la red con el menor MSE, esto hace que se tengan las mejores redes de las topologías, con prioridad en el bajo costo computacional.

3.9 Matriz de confusión

Para obtener la matriz de confusión a partir de las nuevas láminas, se hace la comparación de las láminas obtenidas con los clasificadores y la plantilla original correspondiente a cada resolución (157Hz y 90Hz). Para realizar esta comparación se usan las medidas de desempeño de la tabla 3-1.

Tabla 3-1. Valores que aporta la matriz de confusión para cada plantilla

		clases obtenidas			
		total poblacion	positivo	negativo	
clases actuales	positivo		verdadero positivo(VP)	falso negativo(FN)	sensibilidad $\frac{VP}{VP + FN}$ definición: porcentaje de positivos correctamente identificados
	negativo		falso positivo(FP)	verdadero negativo(VN)	especificidad $\frac{VN}{FP + VN}$ definición: porcentaje de negativos correctamente identificados
		exactitud $\frac{VP + VN}{FP + VN + VP + FN}$	precisión $\frac{VP}{VP + FP}$		
		definición: porcentaje de acierto con el total de la poblacion	definición: proximidad de la clasificacion a los valores reales		

La convención descrita en la tabla 3-1 es la que se aplicara a las matrices de confusión obtenidas de las RNA, para definir parámetros como la sensibilidad, la especificidad, la exactitud y la precisión.

Los variables descritas en la tabla y utilizadas para calcular los parámetros descritos anteriormente se describen a continuación:

Verdadero Positivo (VP): pixel perteneciente a un defecto correctamente clasificado.

Verdadero Negativo (VN): pixel perteneciente a una zona sana correctamente clasificado.

Falso positivo (FP): pixel perteneciente a una zona sana incorrectamente clasificado.

Falso Negativo (FN): pixel perteneciente a un defecto incorrectamente clasificado.

Una vez se tienen los valores de la tabla 3-1 se identifica la mejor red de acuerdo al porcentaje de positivos correctamente identificados, es decir, la topología que obtenga una mayor sensibilidad.

3.10 Protocolo de pruebas

Se propone como protocolo de validación los pasos descritos en la Tabla 3-2.

Tabla 3-2. Protocolo de validación de pruebas

Protocolo de pruebas	
Pasos	Procesamiento
1. Placa CFRP	Se cargan los bancos de secuencias (157Hz y 90Hz)
2. Perfiles térmicos	Se realiza un barrido de los perfiles térmicos de cada pixel, es decir se extraen los 37.249 perfiles térmicos de cada pixel en cada termograma de la secuencia de 157Hz y 223.250 perfiles térmicos de cada pixel para la secuencia de 90Hz.
3. Red	Se asigna como patrón de entrada de la red entrenada los perfiles térmicos de cada pixel, obteniendo a la salida la condición de defecto/no defecto.
4. Nueva lámina (construida a partir de los resultados de la RNA)	Con el resultado de la red se llena esta lámina respetando la posición en la que se encuentra el pixel que se clasificó.
5. Matriz confusión	Con la nueva lámina se construye la matriz de confusión en donde se especifica las confusiones de cada clase y los aciertos de cada una de ellas.
6. Análisis de resultados	Se determina la precisión, sensibilidad, especificidad y exactitud del algoritmo.

7. Conclusiones	Se determina que tan exitoso es el sistema desarrollado para la detección de defectos.
-----------------	--

3.11 Observaciones Generales

Los bancos de secuencia utilizados para este trabajo fueron modificados aplicando *down-sampling*, ya que al usar la termografía pulsada, la toma de muestras de la temperatura respecto al tiempo no representan cambios significativos en la curva del perfil térmico para las frecuencias de muestreo de 157Hz y 90Hz; por lo tanto, las características tomadas de los termogramas de la nueva secuencia no cambian abruptamente respecto a la secuencia original.

Para la selección de la mejor topología de RNA se tiene en cuenta la red neuronal con el menor error cuadrático medio en la detección de defectos, teniendo en cuenta principalmente las redes que utilicen el menor número de neuronas en la capa oculta.

El sistema de detección debe ser capaz de detectar cualquier tipo de defectos sin importar a que profundidad se encuentren, es decir, ser capaz de distinguir los defectos con diferente intensidades térmicas.

4 Análisis de Resultados

En este capítulo se presentan los resultados obtenidos de las características tomadas del banco de secuencias, al implementar el sistema de detección de defectos basado en RNA, tal que se encuentre una arquitectura y una topología que garanticen un menor costo computacional y el menor error posible. Además de eso este capítulo también contiene un análisis comparativo con el trabajo realizado en la parte de detección de defectos de la tesis doctoral realizada por (Benitez, 2008).




Figura 4-1. Etapas pertenecientes al análisis de resultados y análisis comparativos del sistema de detección de defectos

En la figura 4-1 se pueden observar las etapas del análisis de resultados, donde primero se comparan la plantilla generada por la RNA con la plantilla original de cada secuencia; luego de esto se procede a analizar la matriz de confusión haciendo uso de las métricas de desempeño como: sensibilidad, especificidad, exactitud y precisión. El mismo procedimiento se sigue con el contraste CAD-m y se procede a hacer el análisis comparativo de ambos contrastes, por último se establece cuál de los contrastes es el más apropiado para el sistema de detección de defectos y cual arquitectura funciona mejor para cada caso.

4.1 Aplicación del contraste CTFF al banco de secuencias

La aplicación del contraste CTFF mejora las secuencias que fueron objeto de estudio tal y como se muestra en las *figuras 4-1 y 4-2*, para 157Hz y 90Hz respectivamente.




Figura 4-1. a) Secuencia original de 157Hz en el instante 1.5s b) Secuencia original de 157Hz con el contraste CTFF en el instante 1.5s




Figura 4-2. a) Secuencia original de 90Hz en el instante 1.02s b) Secuencia original de 90Hz con el contraste CTFF en el instante 1.02s

4.2 Selección de la mejor red a partir de los resultados del entrenamiento de las RNA para el contraste CTFF

El entrenamiento en este caso se realizó para los dos tipos de redes y para las dos resoluciones (90Hz y 157Hz), usando el contraste CTFF. A continuación se muestran los resultados para la selección de la mejor topología en cada caso.

4.2.1 Resultados de las redes MLP para el banco de secuencias

Para el entrenamiento de las redes MLP se realizó un barrido de 3 hasta 30 neuronas en la capa oculta con incrementos de 1, y 50 entrenamientos para cada topología de red con las mismas coordenadas de píxeles para cada secuencia.

En las *figura 4-3 y 4-4* se muestran los resultados de los parámetros de selección, basados en el error por cada topología de red para las MLP. En estas figuras se observan el valor mínimo de MSE para cada 50 entrenamientos (línea en color magenta), el error máximo (línea en verde), la media aritmética de los datos (línea en negro) y la desviación estándar (línea en rojo).




Figura 4-3. Error mínimo, media aritmética, error máximo y desviación estándar de los entrenamientos realizados en las diferentes topologías MLP para la secuencia de 157Hz




Figura 4-4. Error mínimo, media aritmética, error máximo y desviación estándar de los entrenamientos realizados en las diferentes topologías MLP para la secuencia de 90Hz

De las *figuras 4-5 y 4-6* se pueden extraer las mejores redes para cada secuencia a partir de los datos obtenidos en los entrenamientos.




Figura 4-5. a) diagrama de cajas de los entrenamientos b) diagrama de errores




Figura 4-6. a) diagrama de cajas de los entrenamientos b) diagrama de errores

Como se puede observar en las *figuras 4-5 y 4-6* se muestra el diagrama de cajas el cual muestra como el error mínimo se consigue para la topología de 14 neuronas en la capa oculta para la secuencia de 157Hz, y en el caso de la secuencia de 90Hz se tienen varios errores mínimos situados en cero, por lo cual se escoge la topología con 12 neuronas en la capa oculta la cual es aquella menor número de neuronas.

4.2.2 Resultados de las RBF para el banco de secuencias

Con las 100 topologías de redes para cada secuencia se forman dos matrices de colores, las cuales se pueden ver en las *figuras 4-7 y 4-8*, donde cada recuadro indica el número total de neuronas en la capa oculta. Las filas representan los

valores de error MSE mínimo, mientras que las columnas representan los valores de spread.




Figura 4-7. a) diagrama de colores de las topologías RBF para la secuencia de 157Hz b) diagrama de colores en 3D de las topologías RBF para la secuencia de 157Hz




Figura 4-8. a) diagrama de colores de las topologías RBF para la secuencia de 90Hz b) diagrama de colores en 3D de las topologías RBF para la secuencia de 90Hz

En las figuras 4-7a y 4-8a se pueden observar las diferentes topologías representadas con distintos colores según sea el número de neuronas en la capa oculta. Por su parte, en las figura 4-7b y 4-8b se puede observar el mismo diagrama en tercera dimensión para cada caso respectivamente, evidenciando que el color rojo es el que representa a las topologías con el número más alto de neuronas en la capa oculta, mientras que el color azul es el color que representa a las neuronas con menor número de neuronas en la capa oculta.

De las 100 topologías resultantes se escogió como la mejor la topología con 10 neuronas en la capa oculta y 2 neuronas en la capa oculta respectivamente, un error

aproximado de 4,3% y 2.9% y un *spread* de 0.4 y 0.2 como se indica en las *figuras* 4-9 y 4-10.




Figura 4-9. Selección de la mejor topología RBF para la secuencia de 157Hz



Figura 4-10. Selección de la mejor topología RBF para la secuencia de 90Hz

4.3 Plantilla generada por el sistema de detección de defectos de las imágenes con el contraste CTFF.

4.3.1 Plantilla generada por las redes MLP para el banco de secuencias

Para generar la plantilla a partir de algunas topologías MLP se tienen en cuenta las mejores para cada secuencia para realizar un filtrado presentado la sección 3.8. En las *figuras* 4-11 y 4-12 se muestran las topologías seleccionadas para cada secuencia, teniendo en cuenta los picos con el menor error mínimo mostrados en las *figuras* 4-11b y 4-12b, en las que se observan las redes escogidas con círculos

de color rojo. En el diagrama de cajas mostrado en las figuras 4-11a y 4-12a se observan las topologías escogidas con rectángulos verdes.




Figura 4-11. a) diagrama de cajas de los entrenamientos con las topologías elegidas para la secuencia de 157Hz b) diagrama de errores con las topologías elegidas para la secuencia de 157Hz




Figura 4-12. a) diagrama de cajas de los entrenamientos con las topologías elegidas para la secuencia de 90Hz b) diagrama de errores con las topologías elegidas para la secuencia de 90Hz

Tabla 4-1. Características de las topologías seleccionadas para la secuencia de 157Hz

Topología (# de neuronas en la capa oculta)	Error mínimo porcentual de los entrenamientos	Media aritmética de los entrenamientos	Desviación estándar de los entrenamiento
4 neuronas	3.5%	0.0518	0.0085
7 neuronas	3.5%	0.0494	0.0068
14 neuronas	2.6%	0.0490	0.0078
17 neuronas	3%	0.0503	0.0086
24 neuronas	3.3%	0.0502	0.0080
27 neuronas	2.8%	0.0523	0.0105

Tabla 4-2. Características de las topologías seleccionadas para la secuencia de 90Hz

Topología (# de neuronas en la capa oculta)	Error mínimo porcentual de los entrenamientos	Media aritmética de los entrenamientos	Desviación estándar de los entrenamiento
12 neuronas	0%	0.0027	0.0014
18 neuronas	0%	0.0024	0.0012
22 neuronas	0%	0.0023	0.0012
24 neuronas	0%	0.0027	0.0014
25 neuronas	0%	0.0022	0.0009
27 neuronas	0%	0.0026	0.0015

Con las topologías contenidas en las tablas 4-1 y 4-2, se procedió a generar las plantillas, las cuales son presentadas en las *figuras 4-13 y 4-14*, para la secuencia de 157Hz y 90Hz respectivamente.




Figura 4-13. Plantillas generadas por las diferentes topologías seleccionadas para la secuencia de 157Hz a) 4 neuronas b) 7 neuronas c) 14 neuronas d) 17 neuronas e) 24 neuronas f) 27 neuronas




Figura 4-14. Plantillas generadas por las diferentes topologías seleccionadas para la secuencia de 90Hz a) 12 neuronas b) 18 neuronas c) 22 neuronas d) 24 neuronas e) 25 neuronas f) 27 neuronas

Con las plantillas generadas por cada topología se procede a comparar con la original de las secuencias de 157Hz y 90Hz mostradas en las *figuras 3-13 y 3-14* respectivamente. La comparación se hace a través de las matrices de confusión para cada plantilla generada como se muestra en las *figuras 4-15 y 4-16*.




Figura 4-15. Matrices de confusión de las plantillas generadas para la secuencia de 157Hz a) 4 neuronas b) 7 neuronas c) 14 neuronas d) 17 neuronas e) 24 neuronas f) 27 neuronas




Figura 4-16. Matrices de confusión de las plantillas generadas para la secuencia de 90Hz
a) 12 neuronas b) 18 neuronas c) 22 neuronas d) 24 neuronas e) 25 neuronas f) 27 neuronas

Con los datos obtenidos de las matrices de confusión mostradas en las *figuras 4-15* y *4-16* se aplican las fórmulas contenidas en la tabla 3-2, con las cuales se obtiene valores para la sensibilidad, especificidad, exactitud y precisión como se muestra en las tablas 4-3 y 4-4.

Tabla 4-3. Datos de las matrices de confusión para las topologías de la secuencia de 157Hz

topología	VP	VN	FP	FN	sensibilidad	especificidad	exactitud	precisión
4 neuronas	1562	34009	1598	80	95,13%	95,51%	95,50%	49,43%
7 neuronas	1558	33829	1778	84	94,88%	95,01%	95,00%	46,70%
14 neuronas	1564	34556	1051	78	95,25%	97,05%	96,97%	59,81%
17 neuronas	1579	34344	1263	63	96,16%	96,45%	96,44%	55,56%
24 neuronas	1570	34478	1129	72	95,62%	96,83%	96,78%	58,17%
27 neuronas	1562	33651	1956	80	95,13%	94,51%	94,53%	44,40%

Tabla 4-4. Datos de las matrices de confusión para las topologías de la secuencia de 90Hz

topología	VP	VN	FP	FN	sensibilidad	especificidad	exactitud	precisión
12 neuronas	5234	214802	3114	100	98,13%	98,57%	98,56%	62,70%
18 neuronas	5213	214966	2950	121	97,73%	98,65%	98,62%	63,86%
22 neuronas	5227	214834	3082	107	97,99%	98,59%	98,57%	62,91%
24 neuronas	5229	214887	3029	105	98,03%	98,61%	98,60%	63,32%
25 neuronas	5223	215038	2878	111	97,92%	98,68%	98,66%	64,47%
27 neuronas	5235	214756	3160	99	98,14%	98,55%	98,54%	62,36%

Como se puede observar en la tabla 4-3 y 4-4 se tienen valores de mayor sensibilidad para las topologías que presentan 17 y 27 neuronas en la capa oculta y que corresponden a las secuencias de 157Hz y 90Hz respectivamente. Por otra parte para la secuencia de 90Hz se tiene la segunda sensibilidad más alta con la topología de 12 neuronas en la capa oculta, con apenas un 0.01% de diferencia respecto de la primera nombrada anteriormente, en este caso es válido decir que para un menor costo computacional sin afectar prácticamente la sensibilidad se escogería la topología de 12 neuronas en la capa oculta.

Se concluye por último que las mejores redes MLP para el sistema de detección de defectos con las secuencias de 157Hz y 90Hz utilizando el contraste CTFF son las que utiliza 17 y 12 neuronas en la capa oculta respectivamente.

4.3.2 Plantilla generada por la red RBF para el banco de secuencias

Para generar las plantillas de las secuencias de 157Hz y 90Hz a partir de algunas topologías RBF, se tiene en cuenta las mejores topologías con menor costo computacional y el menor error posible. Usando los MSEs presentados en las tablas 4-5 y 4-6, se eligieron las topologías por número de neuronas en la capa oculta con el menor MSE. Los colores indican el número de neuronas en la capa oculta tal como fueron presentados en las *figuras 4-7 y 4-8*. Adicionalmente, las celdas de color amarillo fueron descartadas por tener un número alto de neuronas.

Tabla 4-5. Error cuadrático medio para las RBF de 157Hz

0,3053	0,3012	0,3030	0,3078	0,3048	0,3080	0,3092	0,3055	0,3038	0,3047
0,3053	0,3034	0,3097	0,3060	0,3048	0,3080	0,3091	0,3047	0,3040	0,3047
0,3053	0,3063	0,3105	0,3059	0,3055	0,3092	0,3091	0,3037	0,3033	0,3043
0,3053	0,3077	0,3105	0,3080	0,3055	0,3092	0,3075	0,3036	0,3022	0,3045
0,3053	0,3077	0,3105	0,3080	0,3077	0,3092	0,3075	0,3036	0,3026	0,3043
0,3053	0,3077	0,3105	0,3089	0,3059	0,3067	0,3076	0,3035	0,3024	0,3038
0,3053	0,3077	0,3105	0,3080	0,3048	0,3067	0,3097	0,3035	0,3020	0,3039
0,3053	0,3077	0,3079	0,3080	0,3048	0,3067	0,3097	0,3038	0,3020	0,3035
0,3053	0,3077	0,3079	0,3083	0,3048	0,3042	0,3087	0,3033	0,3001	0,3032
0,3053	0,3077	0,3079	0,3083	0,3071	0,3033	0,3057	0,3044	0,3016	0,3019

Tabla 4-6. Error cuadrático medio para las RBF de 90Hz

0,1785	0,1621	0,1554	0,1546	0,1541	0,1542	0,1546	0,1543	0,1549	0,1545
0,1785	0,1621	0,1564	0,1551	0,1541	0,1546	0,1546	0,1543	0,1553	0,1544
0,1785	0,1621	0,1564	0,1551	0,1549	0,1546	0,1554	0,1548	0,1553	0,1542
0,1785	0,1621	0,1564	0,1564	0,1549	0,1548	0,1551	0,1548	0,1543	0,1549
0,1785	0,1621	0,1564	0,1559	0,1550	0,1546	0,1551	0,1551	0,1543	0,1545
0,1785	0,1621	0,1564	0,1568	0,1560	0,1553	0,1556	0,1554	0,1557	0,1554
0,1785	0,1621	0,1564	0,1568	0,1562	0,1553	0,1556	0,1554	0,1557	0,1554
0,1785	0,1621	0,1564	0,1568	0,1562	0,1560	0,1555	0,1553	0,1557	0,1554
0,2104	0,1721	0,1564	0,1568	0,1560	0,1556	0,1555	0,1554	0,1551	0,1555
0,2163	0,1733	0,1564	0,1568	0,1572	0,1556	0,1555	0,1554	0,1551	0,1555

La selección para cada secuencia se presenta en las *figuras 4-17* donde las topologías escogidas están marcadas con una estrella amarilla. Con estas topologías se construyeron las plantillas presentadas en las *figura 4-18 y 4-19*. Adicionalmente, se presentan las matrices de confusión obtenidas de estas topologías en las *figuras 4-20 y 4-21*.




Figura 4-17 a) topologías RBF escogidas para la secuencia de 157Hz b) topologías RBF escogidas para la secuencia de 90Hz




Figura 4-18. Plantillas generadas por las diferentes topologías RBF seleccionadas para la secuencia de 157Hz a) 10 neuronas b) 12 neuronas c) 13 neuronas d) 14 neuronas e) 15 neuronas f) 16 neuronas




Figura 4-19. Plantillas generadas por las diferentes topologías RBF seleccionadas para las secuencia de 90Hz a) 2 neuronas b) 5 neuronas c) 6 neuronas d) 7 neuronas e) 8 neuronas f) 9 neuronas




Figura 4-20. Matrices de confusión de las plantillas generadas para la secuencia de 157Hz a) 10 neuronas b) 12 neuronas c) 13 neuronas d) 14 neuronas e) 15 neuronas f) 16 neuronas




Figura 4-21. Matrices de confusión de las plantillas generadas para la secuencia de 90Hz
a) 2 neuronas b) 5 neuronas c) 6 neuronas d) 7 neuronas e) 8 neuronas f) 9 neuronas

Con los datos obtenidos se calculan los porcentajes para la sensibilidad, especificidad, exactitud y precisión como se muestra en las tablas 4-7 y 4-8.

Tabla 4.7. Datos de las matrices de confusión para las topologías de la secuencia de 157Hz

topología	VP	VN	FP	FN	sensibilidad	especificidad	exactitud	precisión
10 neuronas	1572	34452	1155	70	95,74%	96,76%	96,71%	57,65%
12 neuronas	1559	34612	995	83	94,95%	97,21%	97,11%	61,04%
13 neuronas	1527	34810	797	115	93,00%	97,76%	97,55%	65,71%
14 neuronas	1528	34718	889	114	93,06%	97,50%	97,31%	63,22%
15 neuronas	1534	34708	899	108	93,42%	97,48%	97,30%	63,05%
16 neuronas	1567	34671	936	75	95,43%	97,37%	97,29%	62,60%

Tabla 4.8. Datos de las matrices de confusión para las topologías s de la secuencia de 90Hz

topología	VP	VN	FP	FN	sensibilidad	especificidad	exactitud	precisión
2 neuronas	5049	213032	4884	285	94,66%	97,76%	97,68%	50,83%
5 neuronas	5185	215591	2325	149	97,21%	98,93%	98,89%	69,04%
6 neuronas	5144	215864	2052	190	96,44%	99,06%	99,00%	71,48%
7 neuronas	5056	213245	4671	278	94,79%	97,86%	97,78%	51,98%
8 neuronas	5204	214173	3743	130	97,56%	98,28%	98,27%	58,16%
9 neuronas	5166	215839	2077	168	96,85%	99,05%	98,99%	71,32%

Como se puede observar en la tabla 4-7 y 4-8 se tienen valores de mayor sensibilidad para las topologías que presentan 10 y 8 neuronas en la capa oculta y que corresponden a las secuencias de 157Hz y 90Hz respectivamente. No obstante se tienen valores de sensibilidad muy buenos para la mayoría de topologías en ambas secuencias y se podrían utilizar algunas con menor costo computacional, sin afectar de manera abrupta la sensibilidad del sistema de detección.

En este caso se concluye que las mejores topologías RBF para las secuencias de 157Hz y 90Hz son las de 10 y 8 neuronas en la capa oculta respectivamente, siendo estas las de mayor sensibilidad.

4.3.3 Análisis comparativo entre MLP y RBF para las secuencias de 157Hz y 90Hz con el contraste CTFF

Con los resultados obtenidos para las secuencias de 157Hz y 90Hz con MLP y RBF, se hace un análisis comparativo teniendo en cuenta la topología seleccionada para cada caso como se muestra en las tablas 4-9 y 4-10. Basado en el análisis de sensibilidad se encuentra que las redes MLP obtuvieron un mejor desempeño.

Tabla 4-9. Datos de las topologías seleccionadas para la secuencia de 157Hz

tipo de red	VP	VN	FP	FN	sensibilidad	especificidad	exactitud	precisión
MLP	1579	34344	1263	63	96,16%	96,45%	96,44%	55,56%
RBF	1572	34452	1155	70	95,74%	96,76%	96,71%	57,65%

Tabla 4-10. Datos de las topologías seleccionadas para la secuencia de 90Hz

tipo de red	VP	VN	FP	FN	sensibilidad	especificidad	exactitud	precisión
MLP	5234	214802	3114	100	98,13%	98,57%	98,56%	62,70%
RBF	5204	214173	3743	130	97,56%	98,28%	98,27%	58,16%

4.4 Resultados para el contraste CAD-m

Para el análisis comparativo de los resultados obtenidos para el sistema de detección de defectos de las imágenes con el contraste térmico CTFF se escogió el trabajo de (Benitez, 2008), en el que se aplica el contraste CAD-m.

La aplicación del contraste CAD-m permite mejorar la representación termográfica de forma considerable tal y como se muestra en las *figuras 4-22 y 4-23*, para los casos de secuencias de 157Hz y 90Hz respectivamente.




Figura 4-22. a) Secuencia original de 157Hz en el instante 1.5s b) Secuencia original de 157Hz con el contraste CAD-m en el instante 1.5s




Figura 4-23. a) Secuencia original de 90Hz en el instante 1.5s b) Secuencia original de 90Hz con el contraste CAD-m en el instante 1.5s

Al igual que las secciones anteriores, se implementó la metodología para la selección de topologías y arquitectura más adecuada usando la técnica de contraste CAD-m en las dos resoluciones (90Hz y 157Hz), con el fin de hacer el análisis comparativo con el contraste CTFF.

4.4.2 Resultados de las redes MLP con el contraste CAD-m

Llevando a cabo la misma metodología utilizada en la sección 4.1 y 4.2 se procedió a seleccionar las mejores topologías de red MLP para las secuencias de 157Hz y 90Hz respectivamente como se muestra en las *figuras 4-24 y 4-25*.




Figura 4-24. a) diagrama de cajas de los entrenamientos para la secuencia de 157Hz b) diagrama de errores para la secuencia de 157Hz




Figura 4-25. a) diagrama de cajas de los entrenamientos para la secuencia de 90Hz b) diagrama de errores para la secuencia de 90Hz

En la tabla 4-11 y 4-12 se muestran las características de las topologías seleccionadas para ambas secuencias, mientras que las figuras 4-26 y 4-27 se presentan las plantillas generadas para el contraste CAD-m.

Tabla 4-11. Características de las topologías seleccionadas para 157Hz

Topología (# de neuronas en la capa oculta)	Error mínimo porcentual de los entrenamientos	Media aritmética de los entrenamientos	Desviación estándar de los entrenamiento
11 neuronas	0%	0.0106	0.0053
15 neuronas	0%	0.0113	0.0113
20 neuronas	0.16%	0.0101	0.0054
24 neuronas	0.16%	0.0077	0.0051
28 neuronas	0%	0.0081	0.0051
29 neuronas	1.16%	0.0075	0.0052

Tabla 4-12. Características de las topologías seleccionadas para 90Hz

Topología (# neuronas en la capa oculta)	Error mínimo porcentual de los entrenamientos	Media aritmética de los entrenamientos	Desviación estándar de los entrenamiento
14 neuronas	0%	0.0023	0.0014
26 neuronas	0%	0.0021	0.0013
27 neuronas	0%	0.0022	0.0013
28 neuronas	0%	0.0017	0.0013
29 neuronas	0%	0.0016	0.0013
30 neuronas	0%	0.0014	0.0014





Figura 4-26. Plantillas generadas por las diferentes topologías seleccionadas para 157Hz
a) 11 neuronas b) 15 neuronas c) 20 neuronas d) 24 neuronas e) 28 neuronas f) 29 neuronas



*Figura 4-27. Plantillas generadas por las diferentes topologías seleccionadas para 90Hz
a) 14 neuronas b) 26 neuronas c) 27 neuronas d) 28 neuronas e) 29 neuronas f) 30
neuronas*

Con las plantillas generadas para cada topología de cada secuencia se procede a comparar, usando las matrices de confusión, cada plantilla con la original de la secuencia de 157Hz y 90Hz mostradas en las *figuras 3-13 y 3-14* respectivamente. Las matrices de confusión para cada plantilla generada como se muestra en las *figura 4-28 y 4-29*.




Figura 4-28. Matrices de confusión de las plantillas generadas a) 11 neuronas b) 15 neuronas c) 20 neuronas d) 24 neuronas e) 28 neuronas f) 29 neuronas




Figura 4-29. Matrices de confusión de las plantillas generadas a) 14 neuronas b) 26 neuronas c) 27 neuronas d) 28 neuronas e) 29 neuronas f) 30 neuronas

Con los datos obtenidos de las matrices de confusión mostradas en las *figuras 4-28* y *4-29* se calculan los valores para la sensibilidad, especificidad, exactitud y precisión mostrados en las tablas 4-13 y 4-14.

Tabla 4-13. Datos de las matrices de confusión para las topologías de la secuencia de 157Hz

topología	VP	VN	FP	FN	sensibilidad	especificidad	exactitud	precisión
11 neuronas	1575	33935	1672	67	95,92%	95,30%	95,33%	48,51%
15 neuronas	1558	34097	1510	84	94,88%	95,76%	95,72%	50,78%
20 neuronas	1565	33960	1647	77	95,31%	95,37%	95,37%	48,72%
24 neuronas	1586	34233	1374	56	96,59%	96,14%	96,16%	53,58%
28 neuronas	1573	34367	1240	69	95,80%	96,52%	96,49%	55,92%
29 neuronas	1555	34221	1386	87	94,70%	96,11%	96,05%	52,87%

Tabla 4-14. Datos de las matrices de confusión para las topologías de la secuencia de 90Hz

topología	VP	VN	FP	FN	sensibilidad	especificidad	exactitud	precisión
14 neuronas	5241	212165	5751	93	98,26%	97,36%	97,38%	47,68%
26 neuronas	5243	212347	5569	91	98,29%	97,44%	97,46%	48,49%
27 neuronas	5257	211093	6823	77	98,56%	96,87%	96,91%	43,52%
28 neuronas	5217	210462	7454	117	97,81%	96,58%	96,61%	41,17%
29 neuronas	5255	210440	7476	79	98,52%	96,57%	96,62%	41,28%
30 neuronas	5181	210546	7370	153	97,13%	96,62%	96,63%	41,28%

Como se puede observar en la tabla 4-13 y 4-14 se tienen valores de mayor sensibilidad para las topologías que presentan 24 y 27 neuronas en la capa oculta y que corresponden a las secuencias de 157Hz y 90Hz respectivamente, no obstante se tienen valores de sensibilidad muy buenos para la mayoría de topologías en ambas secuencias y se podrían utilizar algunas con menor costo computacional, sin afectar de manera abrupta la sensibilidad del sistema de detección.

En este caso se concluye que las mejores topologías MLP para las secuencias de 157Hz y 90Hz son las de 24 y 14 neuronas en la capa oculta respectivamente, esto debido a que en la secuencia de 90Hz solo existe una diferencia en sensibilidad de

0.3% con respecto a la de mayor sensibilidad, pero con una reducción considerable en la complejidad computacional, respecto a los elementos de procesamiento.

4.4.4 Resultados de las redes RBF con el contraste CAD-m

Llevando a cabo la misma metodología descrita en la sección 3.8 y a partir de las topologías de red obtenidas con los diferentes criterios de parada utilizados en el proceso de selección para las secuencias de 157Hz y 90Hz, se obtuvo el MSE de cada una de las redes las cuales se pueden ver en las tablas 4-15 y 4-16.

Tabla 4-15. Error cuadrático medio para las RBF de 157Hz

0,3974	0,3383	0,3535	0,3867	0,3359	0,3338	0,3472	0,3479	0,3473	0,3379
0,3981	0,3383	0,3652	0,3867	0,3299	0,3338	0,3472	0,3499	0,3444	0,3413
0,3981	0,3411	0,3652	0,3884	0,3355	0,3432	0,3556	0,3500	0,3435	0,3380
0,4080	0,3459	0,3652	0,3884	0,3385	0,3354	0,3580	0,3374	0,3476	0,3367
0,4011	0,3491	0,3904	0,3884	0,3400	0,3354	0,3586	0,3374	0,3433	0,3367
0,4011	0,3491	0,3815	0,3908	0,3362	0,3359	0,3586	0,3563	0,3317	0,3420
0,3880	0,3599	0,3815	0,3908	0,3415	0,3359	0,3506	0,3506	0,3317	0,3420
0,3880	0,3599	0,3815	0,3908	0,3431	0,3285	0,3506	0,3506	0,3317	0,3382
0,4069	0,3599	0,3815	0,3908	0,3388	0,3285	0,3557	0,3481	0,3381	0,3470
0,4069	0,3599	0,3815	0,3998	0,3388	0,3285	0,3485	0,3539	0,3420	0,3415

Tabla 4-16. Error cuadrático medio para las RBF de 90Hz

0,2883	0,2126	0,2487	0,2155	0,2026	0,1718	0,1680	0,1653	0,1706	0,1678
0,2845	0,2126	0,2426	0,2155	0,2026	0,1817	0,1680	0,1653	0,1706	0,1669
0,2845	0,2126	0,2450	0,2155	0,1980	0,1817	0,1680	0,1653	0,1795	0,1684
0,2845	0,2126	0,2472	0,2155	0,1980	0,1943	0,1680	0,1837	0,1862	0,1656
0,2845	0,2126	0,2472	0,2155	0,1936	0,1943	0,1680	0,1837	0,1871	0,1680
0,2845	0,2126	0,2472	0,2155	0,1942	0,1943	0,1865	0,1837	0,1908	0,1680
0,2845	0,2126	0,2472	0,2155	0,1949	0,1943	0,1865	0,1837	0,1948	0,1699
0,2845	0,2126	0,2472	0,2136	0,1949	0,1974	0,1865	0,1837	0,1948	0,1686
0,2819	0,2126	0,2472	0,2090	0,1960	0,1974	0,1865	0,1837	0,1913	0,1686
0,2819	0,2126	0,2472	0,2136	0,1960	0,1974	0,1865	0,1837	0,1959	0,1686

Las celdas de color amarillo indican las redes que no se seleccionaron y los demás colores se asignaron a cada topología de red escogida respectivamente, donde un mismo color indica una misma topología. Una vez realizado el análisis del MSE entre las redes con la misma topología, se eligieron las marcadas con estrellas en cada secuencia como se muestra en las *figuras 4-30a y 4-30b*.




Figura 4-30. a) Topologías RBF escogidas para la secuencia de 157Hz b) Topologías RBF escogidas para la secuencia de 90Hz

Con las topologías escogidas, se generaron las plantillas para cada una de ellas como se observa en las *figura 4-31 y 4-32*. Por otro lado, se obtuvieron las matrices de confusión de estas topologías para determinar respecto a estos resultados la topología con arquitectura RBF más apropiada para la detección de defectos con contraste CAD-m. Las matrices son presentadas en las *figuras 4-33 y 4-34* para cada secuencia.




Figura 4-31. Plantillas generadas por las diferentes topologías seleccionadas para la secuencia de 157Hz a) 21 neuronas b) 22 neuronas c) 23 neuronas d) 24 neuronas e) 25 neuronas f) 26 neuronas




Figura 4-32. Plantillas generadas por las diferentes topologías seleccionadas para la secuencia de 90Hz a) 10 neuronas b) 11 neuronas c) 12 neuronas d) 13 neuronas e) 14 neuronas f) 15 neuronas




Figura 4-33. Matrices de confusión de las plantillas generadas a) 21 neuronas b) 22 neuronas c) 23 neuronas d) 24 neuronas e) 25 neuronas f) 26 neuronas




Figura 4-34. Matrices de confusión de las plantillas generadas a) 10 neuronas b) 11 neuronas c) 12 neuronas d) 13 neuronas e) 14 neuronas f) 15 neuronas

Con los datos obtenidos de las matrices de confusión mostradas en las *figuras 4-34* y *4-35* se calculan los porcentajes para la sensibilidad, especificidad, exactitud y precisión como se muestra en las tablas 4-17 y 4-18.

Tabla 4-17. Datos de las matrices de confusión para las topologías de la secuencia de 157Hz

topología	VP	VN	FP	FN	sensibilidad	especificidad	exactitud	precisión
21 neuronas	1490	33272	2335	152	90,74%	93,44%	93,32%	38,95%
22 neuronas	1558	33766	1841	84	94,88%	94,83%	94,83%	45,84%
23 neuronas	1394	32330	3277	248	84,90%	90,80%	90,54%	29,84%
24 neuronas	1404	32376	3231	238	85,51%	90,93%	90,69%	30,29%
25 neuronas	1409	32399	3208	233	85,81%	90,99%	90,76%	30,52%
26 neuronas	1501	33789	1818	141	91,41%	94,89%	94,74%	45,22%

Tabla 4-18. Datos de las matrices de confusión para las topologías de la secuencia de 90Hz

topología	VP	VN	FP	FN	sensibilidad	especificidad	exactitud	precisión
10 neuronas	4951	207259	10657	383	92,82%	95,11%	95,05%	31,72%
11 neuronas	5048	195486	22430	286	94,64%	89,71%	89,82%	18,37%
12 neuronas	5150	202998	14918	184	96,55%	93,15%	93,24%	25,66%
13 neuronas	4777	213962	3954	557	89,56%	98,19%	97,98%	54,71%
14 neuronas	5118	202171	15745	216	95,95%	92,77%	92,85%	24,53%
15 neuronas	5068	195152	22764	266	95,01%	89,55%	89,68%	18,21%

Como se puede observar en la tabla 4-17 y 4-18 se tienen valores de mayor sensibilidad para las topologías que presentan 22 y 12 neuronas en la capa oculta y que corresponden a las secuencias de 157Hz y 90Hz respectivamente.

4.4.5 Análisis comparativo entre arquitecturas MLP y RBF para las secuencias de 157Hz y 90Hz con el contraste CAD-m

Con los resultados obtenidos para las secuencias de 157Hz y 90Hz con MLP y RBF, se hace un análisis comparativo teniendo en cuenta la topología seleccionada para cada caso como se muestra en las tablas 4-19 y 4-20.

Tabla 4-19. Datos de las topologías seleccionadas para la secuencia de 157Hz

tipo de red	VP	VN	FP	FN	sensibilidad	especificidad	exactitud	precisión
MLP	1586	34233	1374	56	96,59%	96,14%	96,16%	53,58%
RBF	1558	33766	1841	84	94,88%	94,83%	94,83%	45,84%

Tabla 4-20. Datos de las topologías seleccionadas para la secuencia de 90Hz

tipo de red	VP	VN	FP	FN	sensibilidad	especificidad	exactitud	precisión
MLP	5241	212165	5751	93	98,26%	97,36%	97,38%	47,68%
RBF	5150	202998	14918	184	96,55%	93,15%	93,24%	25,66%

Usando la sensibilidad como criterio de selección, se tiene que para ambas secuencias las redes de tipo MLP son las más apropiadas.

4.5 Análisis comparativo entre el contraste CTFF y CAD-m

4.5.1 Análisis con las topologías escogidas para CTFF y CAD-m

Para el análisis comparativo de los dos contrastes, se especifican los datos obtenidos para las topologías escogidas en cada secuencia para cada contraste como se puede observar en la tabla 4-21.

Tabla 4-21. Datos de las topologías seleccionadas para cada secuencia en cada contraste

contraste	secuencia	tipo de red	VP	VN	FP	FN	sensibilidad	especificidad	exactitud	precisión
CTFF	157Hz	MLP	1579	34344	1263	63	96,16%	96,45%	96,44%	55,56%
	90Hz	MLP	5234	214802	3114	100	98,13%	98,57%	98,56%	62,70%
CAD-m	157Hz	MLP	1586	34233	1374	56	96,59%	96,14%	96,16%	53,58%
	90Hz	MLP	5241	212165	5751	93	98,26%	97,36%	97,38%	47,68%

De los datos mostrados en la tabla 4-21 se puede decir que con las topologías seleccionadas para el contraste CAD-m en ambas secuencias se tiene una mayor sensibilidad para la detección de defectos; sin embargo, con las topologías seleccionadas para el contraste CTFF se logra que el sistema sea más exacto, más preciso y con una mayor especificidad en la detección de defectos que con el contraste CAD-m. En este caso, dependiendo de los requerimientos del sistema de detección de defectos se debe elegir la técnica de contraste más adecuado.

Por otro lado, las diferencias en la sensibilidad no son muy significativos entre ambas técnicas, por lo que podría concluirse que la técnica CTFF resulta ser más apropiada para la detección de defectos en láminas CFRP.

4.6 Conclusiones

- Cuando se comparan los contrastes CTFF y CAD-m se obtiene que ninguno es superior al otro en todos los parámetros, lo que hace que los dos contrastes puedan ser utilizados dependiendo la prioridad que se le quiera dar al sistema.
- Para el contraste CTFF se logran mejores resultados en sensibilidad con MLP, sin embargo para los valores de especificidad, exactitud y precisión se logran mejores resultados con RBF.
- El sistema de detección basado en las secuencias con el contraste CTFF con RBF son superiores en sensibilidad, especificidad, exactitud y precisión que las secuencias con el contraste CAD-m.
- En general los sistemas son buenos con ambos contrastes en parámetros como la sensibilidad, la especificidad y la exactitud pero tienen una precisión baja en todos los casos.

5 Conclusiones

5.1 Conclusiones Generales

- Comparando los resultados del banco de secuencias se logró un mayor porcentaje de sensibilidad, especificidad y exactitud para la secuencia de 90Hz utilizando MLP y RBF con las secuencias contrastadas con CTFF y CAD-m, Debido a esto, se puede concluir que a mayor resolución de la secuencia mejor será la clasificación de los defectos en la RNA.
- Con las topologías escogidas para el sistema con la aplicación de ambos contrastes, se tiene una mayor sensibilidad para el contraste CAD-m con las topologías de 24 y 14 neuronas en la capa oculta para las secuencias de 157Hz y 90Hz respectivamente; sin embargo el costo computacional de las topologías utilizadas para el sistema de detección basado en el contraste CTFF es menor con topologías de 17 y 12 neuronas en la capa oculta para las secuencias de 157Hz y 90Hz respectivamente, y se presenta una diferencia en el porcentaje de sensibilidad de 0.43% y 0.42%, lo que hace que cualquiera de los sistemas sea fiable y con una sensibilidad muy aproximada para ambos contrastes.
- Los porcentajes más altos de especificidad, exactitud y precisión se lograron con la arquitectura RBF de 6 neuronas en la capa oculta basada en las imágenes de contraste CTFF, obteniendo además un porcentaje de sensibilidad del 97.56%, además de esto se caracteriza por ser el tercer costo computacional más bajo de las topologías, lo que hace esta arquitectura una muy buena herramienta para el sistema de detección.
- Las topologías MLP seleccionadas pre-filtrado para las secuencias de 157Hz y 90Hz utilizando CTFF y CAD-m tuvieron un promedio porcentual de sensibilidad, de especificidad y de exactitud por encima del 95%, mientras que la precisión en el caso de CAD-m se obtuvo un promedio porcentual para las secuencias de 157Hz y 90Hz de 51.73% y 43.9% respectivamente, y para CTFF 52,35% y 63,27% respectivamente, de lo anterior se infiere que el sistema es sensible,

especifico y exacto pero no es preciso en la detección de defectos; sin embargo se logra una mejor precisión al mejorar la resolución para el caso de CTFF, pero para el contraste CAD-m sucede lo contrario.

- Para las topologías RBF se tiene una mejor precisión en el sistema para la secuencia de 157Hz utilizando CTFF, mientras que para CAD-m empeora la precisión para ambas secuencias.
- Con el contraste CTFF se obtiene mejores resultados utilizando MLP y RBF para especificidad, exactitud y precisión en la detección de defectos comparado con el contraste CAD-m, sin embargo utilizando el contraste CAD-m se obtienen mejores resultados para la sensibilidad que con el contraste CTFF en ambas secuencias.

5.2 Trabajos futuros

A pesar de obtener unos buenos resultados en la clasificación de los defectos con las arquitecturas de RNA propuestas, para poder generalizar el concepto que al aplicar el contraste CTFF se obtienen los mejores resultados, se deben realizar pruebas con otras técnicas de contraste térmico como las que propone ([Restrepo, 2013](#)), implementando la metodología propuesta.

Aunque se obtienen buenos resultados para los contrastes CTFF y CAD-m con la caracterización realizada en este trabajo, se pueden proponer otros métodos de caracterización de las secuencias para reducir la complejidad computacional, el uso de recursos y los tiempos de procesamiento.

Para la arquitectura MLP se implementó el algoritmo de entropía cruzada con *softmax*, el cual presenta unos buenos resultados. Sin embargo se puede emplear el sistema de detección con otros algoritmos de la arquitectura MLP, para tener una idea general del funcionamiento del sistema con las redes perceptrón multicapa.

6 Referencias

- A, Obbadi, S, Belattar. (2006). *Characterization of delamination by a thermal method of non destructive testing*. Maldague: facultad ciencia de procesamiento de señal y laboratorio de energía.
- Alejandro, L. (2010). *Detección de defectos mediante el uso de redes neuronales artificiales y optimización de resultados con lógica neuro difusa*. México DF: Tesis Doctoral, Instituto politécnico nacional, Escuela superior de ingeniería mecánica y eléctrica.
- Allende, G., Mirapeix, J., Conde, O., Cobo, A., & Iopez, J. (2009). NDT & E International. *Spectral processing technique based on feature selection and artificial neural networks for arc-welding quality monitoring*, (págs. 56-63).
- Benitez, H. (2008). *Contribución a la Caracterización de Defectos en Termografía Infrarroja mediante Maquinas de Aprendizaje*. Cali, Colombia: Tesis doctoral, Universidad del Valle, Facultad de Ingeniería.
- Benítez, H., Loaiza, H., & Caicedo, E. (2011). *Termografía Activa Pulsada en Inspección de Materiales. Técnicas Avanzadas de Procesado*. Cali, Colombia: Colección de Ciencias Físicas, Exactas y Naturales. 1ª edición.
- Bison, P., Bressan, C., Di Sarno, R., Grinzato, E., Marinetti, S., & Manduchi, G. (1996). *Thermal nde of delamination in plastic materials by neural network processing*. Padova, Italia.
- Caicedo, E., & Sotelo, J. A. (2009). *un aproximación práctica a las redes neuronales artificiales*. Cali: Programa Editorial Universidad del Valle.
- Carlomagno, G., & Carosena, M. (2001). Infrared thermography in the restoration of cultural propieties. *Proc. SPIE 4360, Thermosense XXIII*, (págs. 203-216). Orlando, FL.

- Daniel, A. (2006). *contribuciones a las técnicas no destructivas para evaluación y prueba de procesos y materiales basadas en radiaciones infrarrojas*. Santander, España: Tesis Doctoral, Universidad de Cantabria, Escuela Técnica Superior De Ingenieros Industriales y de Telecomunicaciones.
- Darabi, Akbar. (2000). *Detection and Estimation of Defect Depth in Infrared Thermography Using Artificial Neural Networks and Fuzzy Logic*. Quebec: Université Laval, Faculté des Sciences et de Génie.
- Duan, Servais, Genest, Castañedo, Maldague. (2012). *Un estudio de fiabilidad en termografía infrarroja activa para la inspección de materiales compuestos*. Escuela de la Ciencia e Ingeniería de los Materiales, Universidad de aeronáutica y astronáutica de Beijing.
- F, J. (2012). *redes neuronales y preprocesado de variables para modelos y sensores en bioingeniería*. Valencia, España: Tesis Doctoral, Universidad Politécnica de Valencia, departamento de ingeniería electrónica.
- Fernandez, J. C. (2010). *Ensembles de redes neuronales constituidos mediante algoritmos híbridos multiobjetivo para optimizar la precisión y la sensibilidad*. Granada, España: Editorial de la Universidad de Granada.
- Gonzales, R. (2002). *digital image processing*. prentice hall segunda edición.
- Jaramillo, B., Fandiño, H., Benitez, H., Orjuela, S., & Castellanos, G. (2012). Multi-resolution analysis for region of interest extraction in thermographic nondestructive evaluation. *Image Processing: Algorithms and Systems X; and Parallel Processing for Imaging Applications II*. Manizales, Colombia.
- Montes, Cardenas, & Miguel. (2009). "website my works". Obtenido de <http://wwwae.ciemat.es/~cardenas/docs/lessons/sobreajuste.pdf>
- Nakamura, S., Sakagami, T., Harada, S., & Kubo, S. (2008). Quantitative evaluation of defect depth in concrete structures using Fourier analysis for sequential thermal data. *Proc. SPIE 6939, Thermosense XXX*. Orlando, FL.

- Pedro, G. (2009). *Nuevos Modelos de Redes Neuronales Evolutiva y Regresion Logistica Generalizada utilizando Funciones de Base*. . Granada, España: Editorial de la Universidad de Granada.
- Prabhu, D. R., & Winfree, W. (1993). Neural network based processing of thermal NDE data for corrosion detection. En D. O. Thompson, & D. E. Chimenti, *Review of Progress in Quantitative Nondestructive Evaluation* (págs. 775-782). New York: Springer US.
- Rafael, H. (2015). *contribuciones al pre-procesado, procesado y análisis en termografía infrarroja aplicados a ensayos no destructivos*. Santander, España: Tesis Doctoral, Universidad de Cantabria, Escuela Técnica Superior De Ingenieros Industriales y de Telecomunicaciones.
- Restrepo, A. (2013). *Contribución a la solución del problema de detección y caracterización de defectos en termografía activa mediante procesamiento espacio-temporal de secuencias de imágenes infrarrojas*. Cali, Colombia: Tesis doctoral, Universidad del Valle, Facultad de Ingeniería.
- Santey, M., & Almond, D. (1997). An artificial neural network interpreter for transient thermography image data . (págs. 291-295). Inglaterra: Elsevier Ltd.
- Socha, D., & Ortiz, G. (2005). *Aplicación de redes neuronales MLP a la predicción de un paso en series de tiempo*. Bogotá, Colombia, Bogotá, Colombia.
- Tretout, H., David, D., Marin, J., Dessendre, M., Couet, M., & I., A.-P. (1995). An evaluation of artificial neural networks applied to infrared thermograph inspection of composite aerospace structures. En D. O. Thompson, & D. E. Chimenti, *Review of Progress in Quantitative Nondestructive Evaluation* (págs. 827-834). New York: Springer US.
- Vallerand, S., Darabi, A., & Maldague, X. (1999). Defect detection in pulsed thermography: An comparison of Kohonen and perceptron neuronal networks. *SPIE conference on Thermosense XX*. Orlando, FL.

