



CIATEC

SISTEMA NEURONAL-DIFUSO APLICADO AL RECONOCIMIENTO  
Y EVALUACIÓN DEL DAÑO EN ACEROS AL CARBÓN SA 210  
GRADO A1 APOYADO EN ESTADÍSTICA DESCRIPTIVA

# Tesis

QUE PARA OBTENER EL GRADO ACADEMICO DE

Doctor en Ciencia y Tecnología  
en la Especialidad de Ingeniería  
Industrial y de Manufactura

PRESENTA

Edgar Augusto Ruelas Santoyo

Director

Dr. José Antonio Vázquez López

Co director

Dr. Javier Yañez Mendiola

León, Guanajuato, México, Noviembre del 2015



## **AGRADECIMIENTOS**

Debo agradecer de manera muy especial y sincera al Dr. José Antonio Vázquez López y al Dr. Javier Yáñez Mendiola por aceptar realizar la presente tesis doctoral bajo su dirección. Su apoyo y confianza en mi trabajo además de su capacidad para guiar mis ideas ha sido un aporte invaluable, no solamente en el desarrollo de esta tesis, sino también en mi formación como investigador. Las ideas propias, siempre enmarcadas en su orientación y rigurosidad, fueron la clave del éxito.

Agradezco al Dr. Ismael López Juárez, pues siempre ha encontrado un momento para aportar valiosas sugerencias y experiencia para dar mayor valor al trabajo realizado.

Agradezco mucho al Maestro Antonio Quijas Cervantes, por confiar mí para pertenecer a una gran casa de estudios como es CIATEC además de su gran apoyo durante mi formación doctoral.

A mis padres, por haberme proporcionado una excelente educación basada en valores y el ejemplo, sólo así pude haber re-direccionado mis esfuerzos. A mi madre, por haberme enseñado que con trabajo y constancia pero sobre todo confianza en ti mismo es posible lograr cualquier meta. A mi padre, por mostrarme la vida de una forma diferente a través de sus consejos y confiar en mí en todo momento.

A mis hermanos, por el apoyo incondicional y comprensión que me han brindado siempre.

Al departamento de Mecánica y Materiales de LAPEM, por su valiosa ayuda y compartir sus conocimientos además de confiar en la aportación del presente trabajo de investigación.

## RESUMEN

El presente trabajo de investigación describe el desarrollo de un sistema integral inteligente capaz de reconocer patrones metalográficos y estimar el daño en el acero al carbón SA 210 grado A-1. El sistema está compuesto por una arquitectura de lógica difusa desarrollada tomando como base estadística descriptiva y la red neuronal artificial perceptrón multicapa aplicada en el reconocimiento de patrones metalográficos. El procesamiento digital de las imágenes metalográficas es llevado a cabo caracterizando las texturas de las imágenes mediante dos diferentes técnicas. Una caracterización es llevada a cabo mediante estadísticos de primero, segundo, tercer orden y la segunda es la generación de un histograma.

Los patrones estudiados se encuentran en la microestructura de los materiales de acero al carbón SA 210 grado A-1. La propuesta permite estimar el daño presente en el material a partir de la determinación de los estados físicos del material; las muestras de acero estuvieron sometidas a condiciones de trabajo reales, tales como la conducción de vapor y agua a altas temperaturas, sufriendo en consecuencia deterioro que no es fácilmente detectable por medios estándar metalográficos. Los patrones estudiados en la microestructura del material fueron: perlita laminar, esferoidización y grafitización. La microestructura se revela a partir de imágenes obtenidas por un microscopio invertido metalográfico (Olympus - GX71) en el Laboratorio de Pruebas de Equipos y Materiales de la Comisión Federal de Electricidad México. (LAPEM-CFE). Los resultados mostraron que la estimación de daños y el reconocimiento de patrones presentes en los diversos materiales examinados se diagnosticaron correctamente con el sistema desarrollado, en comparación con el experto humano.

## **ABSTRACT**

This research describes the development of an intelligent integrated system able to estimate the damage to carbon steel; the system is integrated by a fuzzy logic architecture developed from descriptive statistics and an artificial neural network multilayer perceptron applied to the recognition of metallographic patterns. The digital processing of metallographic images is carried out to characterize the textures of images using two different techniques. A characterization is carried out using statistical first, second, third order and the second is the generation of a histogram.

The patterns studied were associated to the microstructure of carbon steel (SA 210 Grade A-1). The proposal allowed estimating the damage present in the material from the determination of the physical states of the material. Steel samples were tested in real conditions of operation, such as high temperatures and humidity, suffering deterioration that it was difficultly detected by standard metallographic methods. The patterns studied in the microstructure of the material were: laminate perlite, spheroidization and graphitization. The microstructure was revealed from images obtained by an inverted metallographic microscope (Olympus - GX71) in the Testing Equipment and Materials Laboratory of the Federal Electricity Commission in Mexico. (LAPEM - CFE). The results showed that the damage estimation and pattern recognition in the material were correctly predicted with the developed system compared to the human expert.

## TABLA DE CONTENIDO

RESUMEN .....	II
ABSTRACT .....	III
ÍNDICE DE FIGURAS .....	VII
ÍNDICE DE TABLAS .....	VII
ÍNDICE DE ECUACIONES.....	VIII
<b>CAPÍTULO 1. MARCO DE REFERENCIA .....</b>	<b>1</b>
1.1 INTRODUCCIÓN .....	1
1.2 DEFINICIÓN DEL PROBLEMA .....	4
1.3 JUSTIFICACIÓN .....	5
1.4 OBJETIVO GENERAL .....	6
1.4.1 OBJETIVOS ESPECÍFICOS .....	6
1.5 HIPÓTESIS.....	7
<b>CAPÍTULO 2. FUNDAMENTOS TEÓRICOS.....</b>	<b>8</b>
2.1 ESTADO DEL ARTE.....	8
2.1.1 Métodos de segmentación por umbralización .....	11
2.2 MARCO TEÓRICO .....	16
2.2.1 Diagrama hierro-carbono.....	16
2.2.2 Perlita Laminar .....	18
2.2.3 Esferoidización .....	19
2.2.4 Grafitización .....	20
2.3 Procesamiento digital de imágenes .....	22
2.3.1 Modelado global de textura .....	23
2.3.2 Aproximaciones estadísticas .....	24
2.3.3 Estadísticos basados en las matrices de coocurrencia .....	25
2.3.4 Estadísticos basados en las diferencias en el nivel de gris .....	27
2.3.5 Estadísticos basados en las matrices de longitud de secuencia .....	28
2.3.6 Aproximaciones basadas en filtros .....	29
2.3.7 Métodos basados en la transformada de Fourier .....	29
2.3.8 Métodos basados en los filtros Gabor .....	30

2.3.9	Métodos basados en la transformada Wavelet .....	31
2.3.10	Segmentación mediante el método Otsu.....	33
2.4	LÓGICA DIFUSA .....	34
2.4.1	Concepto fundamental de la lógica difusa.....	35
2.4.2	Concepto de verdad difusa.....	36
2.4.3	Teoría de conjuntos difusos .....	36
2.4.4	Definición de un conjunto difuso.....	37
2.4.5	Propiedades de los conjuntos difusos .....	38
2.4.6	Números e intervalos difusos .....	39
2.4.7	Principio de extensión .....	39
2.4.8	Representaciones de conjuntos difusos.....	40
2.4.9	Funciones de membresía .....	41
2.4.10	Variables lingüísticas.....	44
2.4.11	Modificadores lingüísticos .....	44
2.4.12	Operaciones con conjuntos difusos.....	44
2.4.13	Relaciones difusas .....	45
2.4.14	Razonamiento con lógica difusa.....	46
2.4.15	Defusificación .....	46
2.5	REDES NEURONALES ARTIFICIALES .....	46
2.5.1	Definición de neurona artificial .....	46
2.5.2	Procesos de aprendizaje en sistemas neuronales .....	48
2.5.3	El perceptrón .....	48
2.5.4	Limitaciones del perceptrón.....	50
2.5.5	Evolución al perceptrón multicapa.....	51
2.5.6	Propiedades del perceptrón multicapa. ....	56
<b>CAPÍTULO 3. PROCEDIMIENTO DE INVESTIGACIÓN .....</b>		<b>60</b>
3.1	PROCESAMIENTO DIGITAL DE LA IMAGEN .....	61
3.1.1	Caracterización de la imagen metalográfica por medio de un histograma...62	
3.1.2	Caracterización de la imagen metalográfica por medio de estadísticos .....	69
3.1.3	Extracción de estadísticos.....	70
3.1.4	Porcentaje de fases.....	71
3.2	Clasificación-reconocimiento de patrones metalográficos .....	73

3.3	Desarrollo del sistema de lógica difusa.....	75
3.3.1	Fusificación .....	75
3.3.2	Inferencia.....	77
3.3.3	Defusificación .....	78
<b>CAPÍTULO 4. RESULTADOS</b>	.....	<b>79</b>
CONCLUSIONES.....		84
RECOMENDACIONES .....		85
REFERENCIAS BIBLIOGRÁFICAS.....		86
ANEXOS.....		101

## ÍNDICE DE FIGURAS

Figura 1.1 Patrones metalográficos estudiados. ....	1
Figura 1.2 Planta generadora de energía y recolección de muestras de acero. ....	2
Figura 1.3 Esquema actual para el análisis metalográfico del acero al carbón. ....	3
Figura 1.4 Arquitectura del sistema propuesto. ....	6
Figura 2.1 Diagrama Hierro-Carbono. ....	16
Figura 2.2 Patrón metalográfico perlita laminar. ....	18
Figura 2.3 Patrón metalográfico esferoidización. ....	20
Figura 2.4 Falla por sobrecalentamiento prolongado. ....	20
Figura 2.5 Patrón metalográfico grafitización. ....	21
Figura 2.6 Patrón metalográfico grafitización. ....	22
Figura 2.7 Arquitectura de la neurona y función de activación. ....	47
Figura 2.8 Arquitectura del perceptrón. ....	49
Figura 2.9 Margen de caracterización del perceptrón. ....	51
Figura 2.10 Función de activación sigmoide. ....	52
Figura 2.11 Arquitectura del perceptrón multicapa. ....	52
Figura 2.12 Función de activación tangente hiperbólica. ....	57
Figura 3.1 Metodología propuesta para el desarrollo del sistema inteligente. ....	61
Figura 3.2 Diagrama de proceso para el procesamiento de la imagen metalográfica. ....	62
Figura 3.3 Redimensión de la imagen. ....	63
Figura 3.4 Filtro de la imagen grafitización e histograma ....	64
Figura 3.5 Filtro de la imagen perlita laminar e histograma ....	64
Figura 3.6 Segmentación del patrón metalográfico mediante el Método Otsu. ....	66
Figura 3.7 Segmentación de la imagen. ....	67
Figura 3.8 Grafitización procesamiento digital. ....	68
Figura 3.9 Perlita laminar procesamiento digital. ....	68
Figura 3.10 Aplicación de la transformada de Wavelet. ....	69
Figura 3.11 Proceso para la obtención de estadísticos. ....	70
Figura 3.12 Dirección de búsqueda de secuencias. ....	71
Figura 3.13 Diagrama de proceso para calcular el porcentaje de ferrita. ....	72
Figura 3.14 Etapas para el cálculo del porcentaje de ferrita. ....	72
Figura 3.15 Procedimiento de clasificación-reconocimiento. ....	73
Figura 3.16 Fusificación del porcentaje de ferrita. ....	76
Figura 3.17 Fusificación patrón metalográfico. ....	76
Figura 3.18 Fusificación estimación del daño. ....	77
Figura 4.1 Superficie de afectación. ....	83

## ÍNDICE DE TABLAS

Tabla 2.1 Funciones de pertenencia. ....	43
Tabla 3.1 Características estadísticas. ....	71
Tabla 3.2 Dimensión de la matriz de entrenamiento y prueba. ....	73

Tabla 3.3 Topologías entrenadas por histograma.....	74
Tabla 3.4 Topologías entrenadas mediante estadísticos.....	74
Tabla 3.5 Topologías de RNA's seleccionas.....	74
Tabla 3.6 Reglas de inferencia utilizadas en el sistema de lógica difusa.....	77
Tabla 4.1 Caracterización del patrón metalográfico mediante el histograma.....	80
Tabla 4.2 Comparación de técnicas para caracterización del patrón perlita laminar.....	80
Tabla 4.3 Comparación de técnicas para caracterización del patrón esferoidización.....	81
Tabla 4.4 Comparación de técnicas para caracterización del patrón grafitización.....	81
Tabla 4.5 Prueba de hipótesis.....	82

## ÍNDICE DE ECUACIONES

Ecuación 2.1 Grado de membresía.....	37
Ecuación 2.2 Igualdad de conjuntos difusos.....	38
Ecuación 2.3 Inclusión de un conjunto en otro.....	38
Ecuación 2.4 Soporte de un conjunto difuso.....	38
Ecuación 2.5 Núcleo de un conjunto difuso.....	38
Ecuación 2.6 Altura de un conjunto difuso.....	38
Ecuación 2.7 Adición extendida.....	40
Ecuación 2.8 Sustracción extendida.....	40
Ecuación 2.9 Producto extendido.....	40
Ecuación 2.10 Cociente extendido.....	40
Ecuación 2.11 Representación conjunto difuso.....	41
Ecuación 2.12 Aprendizaje de la regla delta.....	49
Ecuación 2.13 Calculo de delta.....	49
Ecuación 2.14 Calculo de delta.....	49
Ecuación 2.15 Regla de aprendizaje del perceptrón.....	50
Ecuación 2.16 Regla de aprendizaje del perceptrón.....	50
Ecuación 2.17 Error instantáneo.....	54
Ecuación 2.18 Valor promedio del error cuadrado.....	54
Ecuación 2.19 Regla de la cadena.....	54
Ecuación 2.20 Peso de cada delta.....	54
Ecuación 2.21 Derivada parcial.....	54
Ecuación 2.22 Ubicación de la neurona en la red.....	54
Ecuación 2.23 Gradiente local.....	55
Ecuación 2.24 Función sigmoide.....	56
Ecuación 2.25 Conjunto de datos.....	59
Ecuación 3.1 Varianza entre clases.....	65
Ecuación 3.2 Probabilidad de cada clase.....	65
Ecuación 3.3 Probabilidad de cada clase.....	65
Ecuación 3.4 Promedios de clases.....	66
Ecuación 3.5 Promedio de clase.....	66
Ecuación 3.6 Varianza de cada clase.....	66
Ecuación 3.7 Varianza de cada clase.....	66

Ecuación 3.8 Transformada Wavelet. ....	69
Ecuación 3.9 Función de base 2D. ....	69
Ecuación 3.10 Función de base 2D. ....	69
Ecuación 3.11 Dirección de búsqueda de secuencia. ....	71
Ecuación 3.12 Calculo de porcentaje de ferrita. ....	72
Ecuación 3.13 Cálculo de la defusificación. ....	78
Ecuación 4.1 Sensibilidad. ....	79
Ecuación 4.2 Especificidad. ....	79
Ecuación 4.3 Exactitud. ....	79
Ecuación 4.4 Estadístico de prueba. ....	82

# CAPÍTULO 1. MARCO DE REFERENCIA

## 1.1 INTRODUCCIÓN

El Laboratorio de Pruebas de Equipos y Materiales (LAPEM) es una organización de la Comisión Federal de Electricidad que tiene como objetivo atender las necesidades del sector eléctrico nacional e internacional, proporcionando estudios de ingeniería especializada, pruebas de laboratorio y campo a equipos y materiales. Una de las necesidades específicas del LAPEM es la emisión de diagnósticos en sobre la continuidad de uso de equipos y materiales, lo que convierte dicha tarea en una operación centralizada en la disponibilidad del experto. A lo largo del capítulo se aborda la necesidad y objetivo del desarrollo de un sistema inteligente capaz de emitir un diagnóstico de reemplazo para conductores de acero al carbón SA 210 en condiciones de altas temperaturas, dichas condiciones son parte del ambiente habitual en que se desempeñan los conductores en las plantas termoeléctricas de México.

La metalografía es la disciplina que estudia microscópicamente y a partir de imágenes las características estructurales de un metal o de una aleación [1]. Dichas imágenes revelan el tratamiento mecánico y térmico del metal y, bajo un conjunto de condiciones dadas, pueden predecir los comportamientos del metal. El comportamiento del acero al carbón SA 210 grado A-1 presenta patrones metalográficos desde el inicio y al final de su vida útil, ver Fig. (1.1). 1.1 (a) perlita laminar, 1.1 (b) esferoidización y 1.1 (c) grafitización.

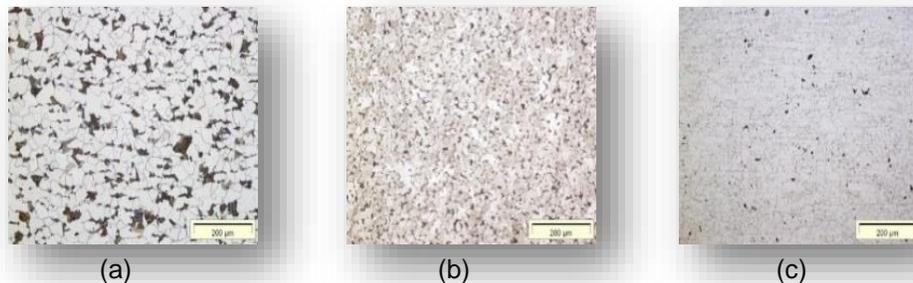


Figura 1.1 Patrones metalográficos estudiados.

De acuerdo con [1], cada grano de perlita está formado por láminas de cementita y ferrita. Los granos por su forma alargada se denominan láminas de ahí el nombre de perlita laminar, y micro estructuralmente hablando es el estado más estable del acero al carbón. Otra forma en que puede aparecer la mezcla de ferrita y cementita es la cementita globular o esferoidización. La transformación se realiza al someter el material a temperaturas cercanas al  $A_1$  ( $723^{\circ}\text{C}$ ), la esferoidización de la perlita reduce la resistencia del acero al carbón. Posteriormente, la descomposición de la cementita en ferrita y grafito, conocida como grafitización, puede ocasionar fallas o agrietamiento en los aceros al carbón. El origen de la fase de grafitización comienza con la formación de grafitos en la interface ferrita-cementita, y presencia de carburos pequeños en las fronteras de grano a temperaturas por encima del  $A_1$  [1], durante el proceso de grafitización la dureza y resistencia decrece progresivamente.

El programa de mantenimiento en una planta generadora de energía incluye la vigilancia sobre la salud en las estructuras metálicas, las cuales conducen vapor de agua y son sometidas a grandes presiones y temperaturas. Estos conductos provienen de la turbina y generador. Rutinariamente, se toman muestras de metal de diferentes conductores y se almacenan en una base de datos con el fin de ser analizadas por un experto en el área a partir de una imagen generando altos costos asociados. Ver Fig. (1.2)

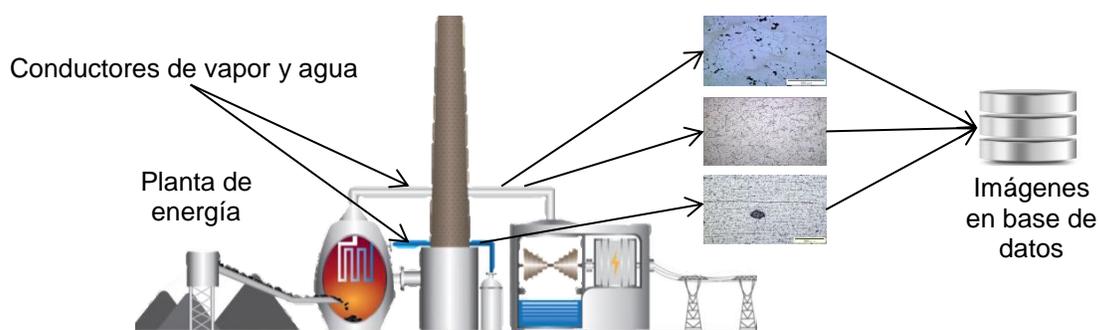


Figura 1.2 Planta generadora de energía y recolección de muestras de acero.

Debido a que el acero al carbón SA 210 es el material más utilizado como conductor, es sometido a condiciones de altas temperaturas generando diferentes estados en su microestructura de forma repetitiva y bajo condiciones similares pudiendo así denominar patrones metalográficos a las fases de perlita laminar, esferoidización y

grafitización. Los patrones metalográficos actualmente como primera instancia deben ser diagnosticados por expertos en la disciplina a partir de una imagen microestructural del material. Como segunda instancia el experto valora en base al patrón metalográfico el grado de afectación del material, ver Fig. (1.3). La calidad del diagnóstico sobre la presencia de algún patrón metalográfico en el acero así como la estimación del daño en el material depende en gran medida de la experiencia del experto.

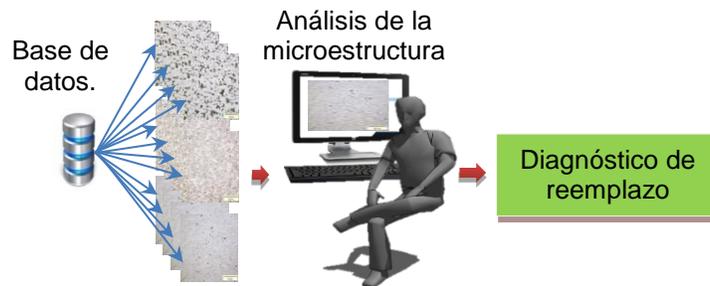


Figura 1.3 Esquema actual para el análisis metalográfico del acero al carbón.

Cabe mencionar que los diagnósticos para el grado de afectación realizados en el Laboratorio de Pruebas de Equipos y Materiales (LAPEM), son únicamente del tipo lingüísticos, es decir, se emiten resultados como: sin afectación, incipiente, inicial, parcial, y avanzada afectación, lo cual es subjetivo al no tener una escala establecida.

En el presente trabajo de tesis, se muestra que es posible realizar una estimación cuantitativa del daño en aceros al carbón en una escala establecida de  $[0,10]$  siendo el cero el estado más sano del material. Además el sistema propuesto es capaz de realizar una clasificación-reconocimiento del patrón metalográfico presente en el material por medio de un sistema integral neuronal-difuso aplicado al procesamiento digital de imágenes metalográficas y soportado mediante estadística descriptiva, logrando el desarrollo de un sistema inteligente para el diagnóstico del grado de afectación del acero al carbón apoyado en el tratamiento digital de imágenes metalográficas que está orientado a corroborar el diagnóstico hecho por un experto e incluso a sustituir la aportación de este experto.

El sistema neuronal-difuso trabaja en dos etapas. La primera es de reconocimiento y clasificación mientras que la segunda etapa es de estimación. La red neuronal artificial

(RNA) se emplea para realizar la primera etapa y el sistema de lógica difusa para la segunda. De este modo, los materiales, o propiamente dicho, sus imágenes son procesadas digitalmente para reconocer y clasificar los patrones metalográficos ubicados en la microestructura del material. Posteriormente, el sistema de lógica difusa estima de forma cuantitativa el grado de afectación presente en el material tomando como entradas el patrón metalográfico y la cantidad de ferrita concentrados en el mismo.

Después de una breve introducción del tema a tratar, la tesis se organiza de la siguiente forma: en el capítulo 1 se muestra el marco de referencia sobre el trabajo de investigación. En el capítulo 2 se plasma el estudio del estado del arte y el marco teórico, destacando las técnicas y herramientas más importantes para lograr los resultados esperados. El capítulo 3 se compone por una descripción de los materiales y métodos utilizados como: la red neuronal artificial, el procesamiento digital de la imagen y el sistema difuso. Los resultados de experimentaciones y pruebas del sistema conforman el capítulo 4. Posteriormente se da paso a las conclusiones y recomendaciones.

## **1.2 DEFINICIÓN DEL PROBLEMA**

El desgaste generado en las tuberías de acero al carbón genera cambios en la microestructura del material tales como: la perlita laminar, esferoidización y grafitización, dichos patrones metalográficos representan un nivel de desgaste, el diagnóstico sobre la presencia de los patrones metalográficos es realizado por expertos dentro del Laboratorio de Pruebas de Equipos y Materiales (LAPEM), de este modo el análisis sobre la presencia del algún patrón metalográfico además de la estimación del deterioro en el material es centralizado y basado únicamente en la experiencia del experto, un aspecto importante en la forma de realizar el diagnóstico es que se emiten resultados lingüísticos como: sin afectación, incipiente, inicial, parcial, y avanzada afectación, lo cual es subjetivo al no tener una escala establecida.

El objetivo e importancia de un diagnóstico está directamente relacionado con la recomendación de reemplazo o continuidad del material que en este caso es el acero

al carbón SA 210, en ambos casos si se emite un dictamen desacertado la organización de la cual proviene el material dañado tendrá costos inapropiados. En el caso de emitir un diagnóstico de reemplazo errado se perderá tiempo de vida útil del material, por otro lado, al recomendar la continuidad de uso de forma incorrecta el material sufrirá una falla en operación pasando así a un mantenimiento correctivo inesperado, además de que la falla podría repercutir en otros equipos pudiendo generar costos elevados.

### **1.3 JUSTIFICACIÓN**

El desarrollo de un sistema inteligente que estime el deterioro presente en el material dentro de una escala establecida surge de la necesidad de emitir un diagnóstico de reemplazo del material conductor, además de automatizar el proceso de análisis ya que el experto humano puede no estar disponible o puede haber una escasez de tales especialistas altamente cualificados para tomar la decisión.

El sistema inteligente resuelve dos tareas al igual que el experto humano para emitir un diagnóstico de deterioro. La primera tarea es la clasificación-reconocimiento del patrón metalográfico presente en la imagen metalográfica mediante una RNA perceptrón multicapa, la segunda tarea es la estimación del daño sufrido en el material por medio de lógica difusa. La clasificación-reconocimiento del patrón metalográfico es información que no tiene un límite claro para estimar un deterioro cuantitativo en el material es por ello que el experto emite diagnósticos lingüísticos. La lógica difusa permite trabajar con información no exacta ligada a variables lingüísticas y obtener información definida [2], para mejorar la estimación del deterioro en el material adicionalmente se procesa información como la cantidad de ferrita presente en la imagen metalográfica y pasar de un diagnostico cualitativo a uno cuantitativo.

De acuerdo con [3], la RNA perceptron multicapa presenta cualidades por encima de las redes de una capa simple. Las redes feedforward son eficientes en aplicaciones de clasificación-reconocimiento de patrones. Para dar paso a la etapa de clasificación-reconocimiento de los patrones metalográficos es indispensable generar una señal de entrada para la RNA, para ello las imágenes metalográficas son analizadas como

texturas, de acuerdo a lo estudiado en la sección pasada, los métodos estadísticos son un referente en la caracterización de texturas, se basan en el análisis de la distribución espacial de los niveles de gris en la imagen. Dependiendo del número de píxeles usados para definir los rasgos locales, los métodos estadísticos pueden ser clasificados a su vez en estadísticos de primer orden (EPO), de segundo orden (Gray Level Co-ocurrence Matrices; GLCM) o de tercer orden (Gray Level Run Length Matrix; GLRLM). La arquitectura básica del sistema propuesto se presenta en la Fig. (1.4). Los códigos del sistema propuesto fueron desarrollados en el entorno del programa Matlab® 2012<sup>a</sup> incluyendo la interface de usuario.

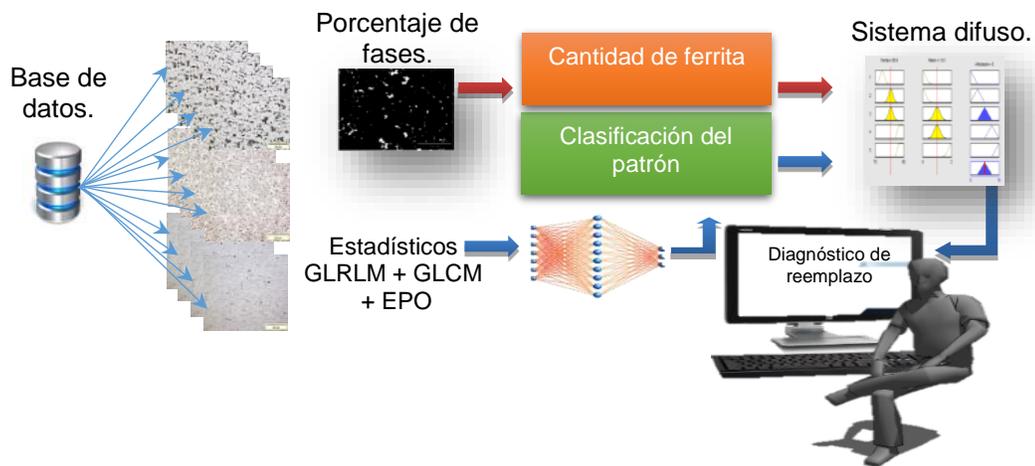


Figura 1.4 Arquitectura del sistema propuesto para la estimación del deterioro en el material.

## 1.4 OBJETIVO GENERAL

Desarrollar un sistema inteligente para el diagnóstico del grado de afectación y reconocimiento de patrones metalográficos presentes en el acero al carbón SA 210, apoyado en el tratamiento digital de imágenes micro estructurales de los materiales con una orientación a corroborar el diagnóstico hecho por un experto e incluso a sustituir la aportación del experto.

### 1.4.1 OBJETIVOS ESPECÍFICOS

1. Establecer protocolos de clasificación-reconocimiento por medio de la red neuronal artificial perceptrón multicapa para el reconocimiento de los patrones metalográficos perlita laminar, esferoidización y grafitización presentes en las

microestructuras del acero al carbón SA 210 sometido a condiciones de altas temperaturas.

2. Demostrar que es posible establecer una estimación del deterioro en el acero al carbón SA 210 en una escala establecida de [0,10], a partir de un sistema de lógica tomando como variables de entrada el porcentaje de fases y la clasificación-reconocimiento del patrón metalográfico.
3. Definir una metodología adecuada de procesamiento digital para la imagen metalográfica que caracterice de forma eficiente la microestructura del material y permita una correcta clasificación-reconocimiento a partir de la red neuronal artificial perceptrón multicapa.
4. Definir un procedimiento eficiente para localizar y sumar áreas de perlita en la imagen metalográfica con el fin de calcular el porcentaje de ferrita.

## **1.5 HIPÓTESIS**

1. Los patrones metalográficos presentes en la microestructura de un acero al carbón son clasificados correctamente por medio del procesamiento digital de la imagen metalográfica y una red neuronal artificial.
2. La integración de protocolos de lógica difusa, RNA's y procesamiento digital de imágenes soportados en estadística descriptiva, permite desarrollar un sistema inteligente capaz de clasificar y reconocer patrones metalográficos, además de establecer un diagnóstico cuantitativo del deterioro en aceros al carbón con resultados similares a los de un experto humano.

## **CAPÍTULO 2. FUNDAMENTOS TEÓRICOS**

### **2.1 ESTADO DEL ARTE**

Las redes neuronales han cubierto funciones de clasificación-reconocimiento y estimación de condiciones físicas dentro del área de los materiales. Por otro lado la lógica difusa ha brindado soluciones eficientes al procesar información con cierto grado de incertidumbre. Tanto las redes neuronales como la lógica difusa son herramientas con tareas específicas pero cada una de ellas requiere de información de entrada para comenzar su operación, atendiendo dicha necesidad el procesamiento digital de imágenes se ha convertido en un referente para brindar gran cantidad de informan a partir de una imagen, haciéndolo de forma automática.

Se han realizado investigaciones donde se comprobaron los beneficios de la integración entre RNA's, sistemas difusos y procesamiento digital de imágenes en el campo de los materiales. En [4], se compararon RNA's auto-organizadas y una multicapa en la clasificación de piezas de acero obteniendo mejores resultados con una RNA multicapa incluso en el costo computacional. El procesamiento de imágenes en los materiales fue estudiado por [5], donde a partir de un algoritmo de segmentación se llevó a cabo el control de calidad de piezas fabricadas por fundición. Otro uso de las RNA's en materiales se ha visto abordado para resolver tareas de estimación, en los estudios realizados por [6] y [7], se utilizaron redes neuronales capaces de predecir características específicas de los materiales tales como fallo por fatiga y calidad de soldadura respectivamente.

En cuanto a la integración de la lógica difusa en el área de los materiales, se propuso que es una herramienta eficiente para modelar el crecimiento de fases boruradas de aceros [8], el trabajo de [9], demostró que un sistema de inferencia difusa cuenta con mayor precisión que un método de regresión tradicional para la estimación del esfuerzo durante la deformación en aleaciones de titanio.

En [10], se utilizó una red neuronal artificial perceptrón multicapa para predecir la deformación en placas de acero después de un proceso de calentamiento. La red

neuronal es entrenada a partir de estadísticos obtenidos del análisis de elemento finito efectuado en las placas. Los estudios realizados por [11], demostraron que una red neuronal de retro-propagación obtiene mejores resultados que los modelos de regresión al estimar condiciones de operación en la fabricación de alambre de descarga, durante la experimentación la red neuronal artificial es alimentada mediante datos históricos de cada una de las condiciones de operación. El trabajo realizado por [12], propone el uso de redes neuronales artificiales para modelar la rugosidad en aceros mecanizados. Además dejó ver en claro una tendencia sobre el uso de las RNA's en dicha tarea, utilizando diferentes arquitecturas de redes neuronales con distintos métodos de entrenamiento.

Una integración entre lógica difusa y redes neuronales en el área de los materiales se llevó a cabo por [13], en la investigación se propone el uso de lógica difusa para tratar entradas a la RNA con información imprecisa. El objetivo de la investigación fue mejorar la previsión de la demanda de acero a partir del sistema neuro-difuso. La investigación realizada por [14], se planteó el uso de una red neuronal artificial para modelar y predecir las fuerzas de corte y rugosidad respectivamente en aceros fundidos obteniendo resultados eficientes. La red neuronal artificial fue entrenada a partir de estadísticos calculados por medio de experimentaciones.

Una integración de procesamiento digital de imágenes y redes neuronales en el área de los materiales fue abordado por [15], la investigación propuso una metodología capaz de realizar una clasificación de seis tipos de defectos en la fabricación de aceros, en la metodología se utilizan filtros pasa-bajas y umbralización para la detección del defecto en la imagen. La propuesta desarrollada por [16], integró el uso de elemento finito y redes neuronales artificiales para estimar el desgaste producido en el acero de forjado. Una ventaja del sistema es tomar únicamente dos variables de entrada: temperatura y espesor del material. Los estudios de [17] y [18] proponen alternativas para realizar estimaciones en el deterioro del acero maquinado mediante una red neuronal perceptrón multicapa, la estimación es realizada mediante el análisis de la velocidad de avance y profundidad de corte consideradas como variables del modelo. En [19]

se utilizó, una red neuronal probabilística para predecir la microdureza en aceros al carbón, la estimación se realizó a partir de catorce parámetros que afectan la microdureza por efectos de temperatura. Otra técnica utilizada para estimar el daño en materiales en conjunto con las redes neuronales artificiales es la emisión acústica, [20]. Para este caso se generaron siete estadísticos de la señal acústica y posteriormente fueron utilizados como entrenamiento de la red neuronal artificial, obteniendo una buena eficiencia de cómputo.

Un aspecto importante en el área de materiales es la estimación de parámetros que pudieran afectar el tiempo de vida de algún material. El trabajo de [21], estima el nivel de la capa de revestimiento de carbonitruro de cromo sobre aceros lo cual puede ocasionar un desgaste excesivo en el acero. La estimación se realiza mediante una red neuronal artificial perceptrón multicapa y fue entrenada por medio de diecisiete parámetros estadísticos que afectan el espesor de la capa. Lo propuesto por [22], fue llevar a cabo una caracterización y clasificación de microestructuras del hierro fundido a partir del análisis de señales ultrasónicas y redes neuronales artificiales. Vale la pena señalar que la clasificación micro estructural se realizó mediante el uso de señales de retro-dispersión adquiridas durante el pulso de eco ensayos no destructivos.

Una integración entre una red neuronal artificial probabilística y un sistema difuso fue llevada a cabo para establecer parámetros de fabricación de aceros. Los parámetros utilizados fueron la temperatura de recocido inter-crítico y contenido de carbono [23]. En [24], se estableció una integración entre un sistema óptico usando el procesamiento digital de imágenes y una red neuronal artificial, con el fin de medir la rugosidad del acero 1040. El sistema fue programado en Matlab y obtuvo resultados eficientes.

La tarea resuelta en [25], fue clasificar seis tipos de defectos en aceros a partir de la integración entre un sistema de visión y una red neuronal artificial. La propuesta ha sido probada en un entorno de producción real obteniendo un éxito del 87%. El trabajo desarrollado por [26], propone un sistema automatizado enfocado a la predicción de la rugosidad de la superficie de piezas de acero, a través de un sistema de visión

artificial que está integrado con una red neuronal artificial. Las imágenes de la superficie son procesadas mediante la transformada de Fourier bidimensional para obtener las características de la textura presente en la imagen.

La investigación presentada por [27], muestra que la incertidumbre en el daño ocasionado en estructuras metálicas puede resolverse mediante un enfoque basado en la lógica difusa, el sistema propuesto obtuvo una eficiencia en la estimación del daño igual a 95%. En [28], se propone un sistema de lógica difusa tipo-2 para el monitoreo de daños en herramientas metalmeccánicas, las entradas al sistema difuso son generadas a partir de una emisión acústica. Una ventaja del sistema difuso es que también procesa la incertidumbre generada por la propia señal acústica. Los sistemas de lógica difusa permiten evaluar y predecir variables importantes en el área de los materiales, como lo presentado por [29], donde se estableció un modelo de lógica difusa de dos capas para evaluar y predecir la erosión en aceros dúctiles con aplicaciones en ingeniería, el sistema trabaja con siete variables de entrada. Dentro de [30] y [31], se integró el uso de métodos de optimización con sistemas difusos para poder emitir un diagnóstico de daños. Las variables de entrada son generadas a partir de estadísticos producto de un análisis de elemento finito. Una ventaja del método que proponen es que además de estimar el daño permite localizarlo a lo largo de la estructura.

De acuerdo a la revisión realizada se concluye que la incorporación del procesamiento de imágenes como señal de entrada a un sistema proporciona una señal automática y con información importante, el uso de una RNA como método de clasificación y la lógica difusa como mecanismo de estimación de estados físicos en los materiales brinda buenos resultados.

### **2.1.1 Métodos de segmentación por umbralización**

Existen diferentes planteamientos sobre los cuales se aplican técnicas de segmentación por umbralización, especialmente en aplicaciones que requieren procesar cantidades elevadas de datos, distinguiéndose entre umbralización global y local. La umbralización global es aquella en la cual se establece un único umbral para

segmentar la imagen, útil cuando solamente existen dos regiones de píxeles. Una de las aplicaciones más comunes es extraer un objeto del fondo de una imagen. La umbralización local o multiumbralización en la que se determinan varios umbrales, cada uno de los cuales separa las regiones que identifican los diferentes objetos. El trabajo presentado por [32], fue pionero en la utilización de métodos de umbralización local; dentro de la umbralización local difusa también se encuentran diversas investigaciones al respecto, entre ellas la de [33].

Una extensión del método de umbralización local es el de umbral dinámico, en el que se define para cada píxel una zona vecina  $N$  a la que se asigna un valor de umbral adecuado. Un ejemplo se puede encontrar en [34], así como en [35]. Para este caso es imprescindible disponer de un método para calcular el valor umbral adecuado de manera automática. Sobre este contexto se han desarrollado diversas investigaciones presentándose varias técnicas de segmentación que, por lo general, se diseñan para resolver un problema en particular. En la investigación de [36], compararon los resultados de siete técnicas de umbralización, concluyendo que el método de Otsu es el que mejores resultados proporciona, con un alto grado de uniformidad y logrando además una correlación mejor que el  $k$ -means para los valores de umbral óptimo.

Lo presentado por [37], es una amplia revisión bibliográfica en la cual se pueden encontrar los principales métodos de umbralización por histograma, bajo la cual se analizan, por ejemplo, los picos, valles y curvaturas del histograma suavizado [38]. También existen los métodos de umbralización basados en agrupamiento, donde las muestras de niveles de gris se agrupan en dos partes, objeto y fondo, o alternativamente se modelan como una mezcla de dos gaussianas, como en [39], y [40], o el método de umbral iterativo [41], también conocido como ISODATA, además del método de umbralización por mínimo error [42] y el de agrupamientos difusos [43].

Así pues, determinar el umbral óptimo es una de las etapas más importantes en los procesos de segmentación y clasificación. La determinación de umbral resulta útil en aplicaciones basadas en compresión y recuperación de imágenes, como por ejemplo [44], que mediante técnicas de BTC (block truncation coding) y algoritmos genéticos

comprimen y recuperan imágenes en color. Las técnicas BTC requieren determinar el umbral óptimo para cada bloque puesto que pasan por un proceso de binarización por bloque y por componente espectral.

La umbralización se aplica incluso a sistemas de control, donde para calibrar la dosis de herbicida precisó de un procesamiento previo de imágenes del cultivo que determinara tanto el estado de crecimiento de la mala hierba como el índice de cobertura, para ello se utilizaron técnicas de segmentación por binarización [45]. Los resultados muestran que de los cuarenta métodos de umbralización probados con imágenes en escala de gris, los seis con mejor calidad promedio fueron: Cluster-Kittler, Cluster-Lloyd, Cluster-Otsu, Entropy-Kapur, Entropy-sahoo y Entropy-Yen, aplicados por [46] y [47].

En [48], se realizó un análisis comparativo de doce técnicas de umbralización, entre las que se encuentra el método de Otsu, argumentando que ésta es una de las técnicas que ha proporcionado muy buenos resultados en umbralización. Probando imágenes bajo luz controlada y no controlada, en el análisis comparativo se evaluó la uniformidad y la inspección visual. En cuanto a la uniformidad, Otsu se clasifica dentro de los tres mejores, y en cuanto a la inspección visual el método de Otsu consiguió los mejores resultados de entre todos los analizados. Dentro del estudio de [49], se evaluaron treinta algoritmos de umbralización con imágenes en escala de gris, clasificándolos en globales y locales e incluyendo el algoritmo de Otsu en ambas clasificaciones. Puesto que existen numerosos algoritmos de umbralización, éstos se han aplicado a diferentes aéreas de estudio, en algunos casos como apoyo tanto en clasificación supervisada como no supervisada. Por ejemplo, en visión de robots no tripulados el procesamiento en tiempo real exige algoritmos robustos, por lo que lo ideal es simplificar la información mediante binarización. Dentro de [50], se diseñó una estrategia para guiar un robot aéreo mediante visión en carreteras aplicando una estrategia de umbral adaptativo para binarizar la imagen y encontrar las líneas de carretera. Otro de los campos en que se aplica procesamiento en tiempo real es en la industria, por ejemplo en la avícola para clasificar el huevo defectuoso [51]. Otro ejemplo se expone en [52], donde lo aplican para segmentar las líneas eléctricas

captadas por sensores aerotransportados. Continuando con la segmentación de imágenes aerotransportadas, [53], una función importante es la clasificación de objetos creados por el hombre apoyándose en algunas técnicas de umbralización. En [54], clasifican las calles y caminos con imágenes aéreas. Un aspecto importante en el trabajo presentado por [55], es la aplicación de un histograma directo con el fin de mejorar las imágenes captadas por diferentes tipos de sensores aerotransportados. El trabajo de [56], así como lo presentado por [57], aplican un proceso de binarización de la imagen a color durante la segmentación con el fin de discernir entre plantas de cultivo, malas hierbas y suelo.

En el estudio de [58], proponen utilizar la información proporcionada por las distribuciones de los niveles espectrales a través del análisis de los correspondientes histogramas de las imágenes que contienen las texturas. Dentro de los trabajos de segmentación en color, [59], así como [60], identifican a partir del histograma pequeñas variaciones del color con el fin de suprimirlas, consiguiendo así un cierto suavizado y con ello la homogenización de las regiones de texturas. Dentro de la investigación de [60], desarrollan una segmentación por umbralización de imágenes RGB, si bien los umbrales de cada banda se obtienen mediante el análisis de los valores, medios, máximos y mínimos que selecciona el experto en la materia. Los estudios realizados por [61] y [62], procesan imágenes multispectrales aplicando segmentación mediante  $k$ -means-cluster, consiguen la binarización mediante técnicas de bordes, logrando identificar edificios y calles.

En cuanto a los trabajos en los cuales se aplica multi-umbralización [63], proponen un método basado en dos etapas. La primera es una multi-umbralización gruesa, mediante un filtro de espacio escalar, seleccionando manualmente el número de clases. En la segunda etapa aplican técnicas de agrupamiento del tipo Fuzzy  $k$ -means para refinar la segmentación, ajustando posteriormente el número de clases. Continuando con la multi-umbralización, en [64], aplican clasificación basada en píxeles para el análisis de una zona ribereña con imágenes LIDAR, de manera que clasifican la corriente central de los arroyos determinando los umbrales empíricamente.

En el ámbito de clasificación de imágenes de alta resolución, tales como las proporcionadas por el satélite IKONOS, dentro de [65], desarrollaron un trabajo para clasificar la vegetación existente, en el cual normalizan las diferencias de los índices de vegetación (NDVI) y seleccionan de forma manual, con base a la visualización del histograma de NDVI, un determinado umbral, el cual se aplica para discernir entre dos tipos de vegetación. El trabajo concluye afirmando que hace falta un esquema de soporte teórico sólido que permita determinar el umbral. Además de la existencia de los diferentes métodos de umbralización simples, también se han desarrollado diversas aplicaciones sobre la combinación de éstos. Dentro de ellas se encuentran las de [66], que aplican un modelo de segmentación automática de texturas en imágenes agrícolas, en el cual como paso previo a la clasificación se desarrolla una metodología de binarización, aplicando los algoritmos de manera independiente y también combinados. Finalmente, después de comparar los resultados, afirman que el modelo de combinación de algoritmos proporcionó mejores resultados que los individuales.

El Trabajo de [67], también combinan tres métodos de umbralización durante la segmentación de imágenes hemisféricas de los entornos forestales analizados con fines de inventarios forestales y mantenimiento. El resultado de cada método de segmentación dependerá del algoritmo en concreto, del valor de los parámetros y de la medida de similitud/disimilitud adoptada. Es decir para realizar el agrupamiento de los objetos, es necesario determinar cuándo dos objetos del espacio son parecidos y cuándo no. Con este fin se definen las funciones de similitud o de disimilitud, entre las que se encuentran las métricas o distancias.

## 2.2 MARCO TEÓRICO

### 2.2.1 Diagrama hierro-carbono

Cualquier estudio sobre la constitución y estructura de aceros y fundiciones debe partir del diagrama de equilibrio hierro-carbono. Muchas de las características básicas de este sistema influyen en el comportamiento de los aceros. El diagrama  $Fe - C$  provee las bases para construir el conocimiento tanto en aceros al carbono, como en la inmensa variedad de aceros aleados, ver Fig. (2.1). Primeramente debe ser señalado que el diagrama de equilibrio normal realmente representa el equilibrio metaestable entre el hierro y el carburo de hierro (cementita). La cementita es metaestable, y el verdadero equilibrio debe estar entre el hierro y el grafito. El grafito está presente en las fundiciones de hierro ( $2 - 4\%C$  en peso), usualmente es difícil de obtener este equilibrio de fases en los aceros ( $0.03 - 1.5\%C$  en peso). Por lo tanto, el equilibrio metaestable entre el hierro y el carburo de hierro debe ser estudiado por su relevancia en el comportamiento de la mayoría de los aceros [1].

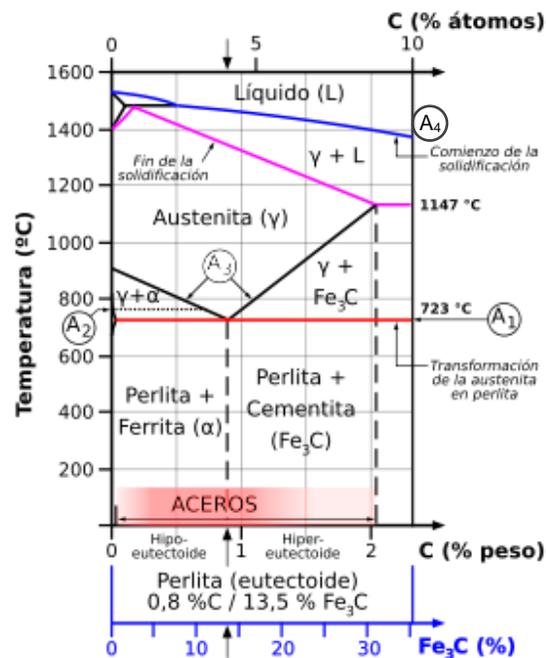


Figura 2.1 Diagrama hierro-carbono.

Existen varios puntos críticos en el diagrama que son importantes desde los puntos de vista básico y práctico. Primeramente se tiene la temperatura  $A_1$  a la cuál se

presenta la reacción eutectoide a 723°C en el diagrama binario. En segundo lugar está la temperatura  $A_3$ , donde la ferrita se transforma a austenita, en el hierro puro esto sucede a 910°C, pero la temperatura de transformación va disminuyendo a medida que aumenta el contenido de carbono. El tercer punto es  $A_4$ , donde la austenita se transforma a ferrita a los 1390°C, misma que se incrementa a medida que aumenta el contenido de carbono. El punto  $A_2$  es el punto de Curie, donde el hierro cambia de la condición ferromagnética a la paramagnética. Esta temperatura es de 769°C para el hierro puro, sin involucrar cambio en la estructura cristalina. Las fases de ferrita, cementita y perlita son entonces los principales constituyentes de la microestructura de los aceros al carbono que han sido sujetos a velocidades de enfriamiento relativamente lentas para evitar la formación de fases metaestables.

**Ferrita:** está formado por una solución sólida de inserción de carbono en hierro alfa. Es el constituyente más blando de los aceros pero es el más tenaz y maleable, su resistencia a la tracción es de  $28 \text{ N/mm}^2$  y su alargamiento de 35%. Su solubilidad máxima es de 0,008% C. Si el acero es muy pobre en carbono, su estructura está formada casi en su totalidad por granos de ferrita cuyos límites pueden revelarse fácilmente con el microscopio, después de un ataque con ácido nítrico diluido [1].

**Cementita:** Es un constituyente que aparece en fundiciones y aceros. Es el carburo de hierro con fórmula  $\text{Fe}_3\text{C}$ . Es muy frágil y duro, teniendo sobre 840 Vickers, y es muy resistente al rozamiento en las fundiciones. Se funde por encima de 1950 °C, y es termodinámicamente inestable a temperaturas inferiores a 1200 °C [1].

**Perlita:** Está formada por una mezcla eutectoide de dos fases, ferrita y cementita. Su estructura está constituida por láminas alternadas de ferrita y cementita, siendo el espesor de las láminas de ferrita superior al de las de cementita, estas últimas quedan en relieve después del ataque con ácido nítrico, lo cual hace que en la observación microscópica se revelen por las sombras que proyectan sobre las láminas de ferrita. La perlita es más dura y resistente que la ferrita, pero más blanda y maleable que la cementita. Se presenta en forma laminar, reticular y globular [1].

### 2.2.2 Perlita Laminar

La perlita es un constituyente compuesto por el 86,5% de ferrita y el 13,5% de cementita. Como la fase mayoritaria es la ferrita, las propiedades estarán más próximas a las de la ferrita: dureza 200 brinell, resistencia:  $80 \text{ kg/mm}^2$ , alargamiento: 15% y resiliencia:  $10 \text{ kg/mm}^2$ . Su forma laminar es la más frecuente: son láminas alternadas de las 2 fases que forman el constituyente bifásico. El espacio inter-laminar puede ser variable, dependiendo de las condiciones de obtención de ese acero. Cuanto más fina sea la estructura, menor espacio inter-laminar y presentará mayor dureza. Esto hace que las propiedades mecánicas puedan variar sus valores, es decir, las propiedades antes citadas son valores promedio. La razón de este comportamiento radica en los fenómenos que ocurren en los límites de fases ( $\alpha$  y cementita), ver Fig. (2.2). En primer lugar, hay un alto grado de adherencia entre las dos fases en el límite. Por lo tanto, la resistencia y la rigidez de la fase cementita restringe la deformación de la fase ferrita, más blanda, en las regiones adyacentes al límite; es decir, la cementita refuerza a la ferrita. Este grado de reforzamiento es más elevado en la perlita fina porque es mayor la superficie de límites de fases por unidad de volumen del material. Además, los límites de fases sirven de barrera para el movimiento de dislocaciones, del mismo modo que los límites de grano [1].

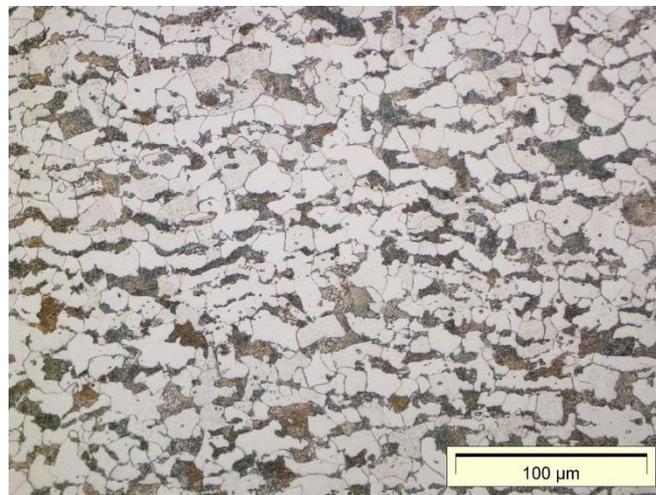


Figura 2.2 Patrón metalográfico perlita laminar.

### 2.2.3 Esferoidización

El patrón metalográfico de esferoidización se presenta cuando las partículas de  $Fe_3C$  aparecen como esferas incrustadas en una matriz continua de fase  $\alpha$ , en lugar de las láminas alternadas de ferrita y cementita de la perlita o de las partículas alargadas de  $Fe_3C$  en una matriz ferrítica, ver Fig. (2.3). Si un acero con microestructura de perlita laminar se calienta hasta una temperatura inferior a la eutectoide  $A_1$  durante un período de tiempo largo, se forma una nueva microestructura denominada esferoidita, cementita globular o esferoidal, pudiendo sufrir un deterioro debido al sobrecalentamiento prolongado. Ver Fig. (2.4). Las primeras etapas de la esferoidización involucra la siguiente secuencia de eventos:

1. Las placas de cementita se rompen en intervalos más o menos regulares por el crecimiento de los canales en las placas.
2. La relación de forma de los fragmentos de las placas se reduce progresivamente a un valor de uno, así los fragmentos de las placas se transforman en esferas.
3. El diámetro promedio de las esferas se incrementa por la eliminación de las esferas más pequeñas y por el crecimiento de las más grandes (coalescencia).

La esferoidización de la perlita afecta las propiedades mecánicas, generalmente reduciendo la resistencia e incrementando la ductilidad. La dureza no comienza a disminuir hasta que la primera etapa de la esferoidización ha sucedido en una gran proporción de las colonias de perlita, pero después crece progresivamente con la secuencia de esferoidización, hasta que se haya desarrollado un sistema de esferas uniformes [1].



Figura 2.3 Patrón metalográfico esferoidización.

Sobrecalentamiento prolongado. Este tipo de falla, es el resultado de la exposición a largos períodos de operación con temperaturas ligeramente superiores a las de diseño, un incremento lento en el nivel de esfuerzos o temperatura, o bien, la acumulación de periodos de sobrecalentamiento excesivo. El daño por termofluencia en los aceros, se presenta a lo largo de los límites de grano con una orientación de 90° de la dirección de esfuerzos aplicados.



Figura 2.4 Falla por sobrecalentamiento prolongado.

#### 2.2.4 Grafitización

La nucleación de grafitos o grafitización se lleva a cabo sobre la interfase ferrita cementita, y en carburos pequeños en las fronteras de grano; la velocidad de crecimiento de los nódulos está controlada por la velocidad de difusión del carbono, desde el carburo hacia el grano, y la velocidad de disolución del carburo, ver Fig. (2.5). Durante el proceso de grafitización la dureza decrece progresivamente hasta un valor

considerablemente menor, en comparación del que se tiene en las muestras sin grafitizar. En distintos aceros al carbono la cementita se revierte hacia su forma termodinámicamente más estable, sin embargo la cinética de la reacción varía en algunos órdenes de magnitud para los diferentes aceros. La grafitización aparece a una velocidad máxima a temperaturas por arriba de la temperatura  $A_1$  ocasionando daños como el sobre calentamiento repentino, ver Fig. (2.6) [1].

La formación del grafito se presenta en 3 etapas:

1. Descomposición de la cementita.
2. Difusión del carbono libre dentro de la ferrita.
3. Precipitación del grafito de acuerdo a un proceso de nucleación y crecimiento en sitios privilegiados.

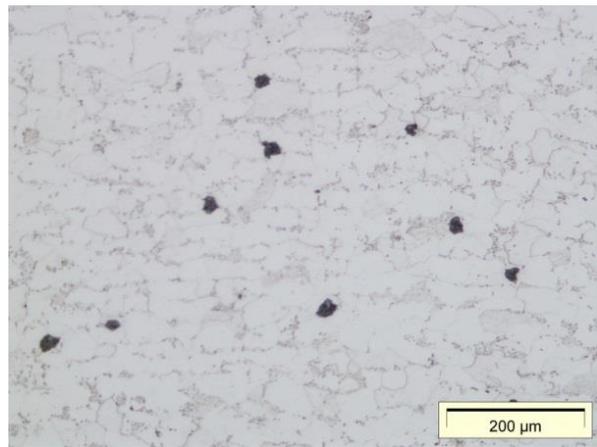


Figura 2.5 Patrón metalográfico grafitización.

Sobrecalentamiento repentino. Este tipo de falla ocurre cuando por algún incidente, un tubo se expone a temperaturas excesivamente altas (decenas de grados mayores a las normales), hasta un punto en el que se presenta la deformación plástica y casi siempre la consecuente ruptura. El término repentino o a corto plazo, indica que el tiempo de exposición a la temperatura elevada fue relativamente corto, comparado con la vida en servicio del tubo. Estas fallas se presentan tanto en tubos refrigerados con agua, así como en los refrigerados con vapor. Normalmente, en las fallas por sobrecalentamiento repentino, los tubos sufren una considerable deformación en el material, con abombamiento e importante reducción de espesor [1].



Figura 2.6 Patrón metalográfico grafitización.

### 2.3 Procesamiento digital de imágenes

El análisis y modelado de texturas es una de las tareas de bajo nivel más importantes del campo de la visión por computador, siendo la base para procesos de más alto nivel, como la identificación de objetos o superficies en imágenes médicas, aéreas, de ámbito industrial, etc. Al igual que no es posible dar una definición precisa y global del concepto de textura, tampoco es posible encontrar una técnica que permita caracterizar completamente una textura dada, ni extraer los descriptores apropiados para cualquier tipo de aplicación. De hecho, en los últimos treinta años han ido apareciendo en la literatura un gran número de técnicas de caracterización de textura, donde el modelado realizado está muy enfocado al campo de aplicación para el que ha sido desarrollado. La mayoría de las aproximaciones existentes tratan de describir la textura de una forma global, mediante vectores de características (normalmente con un gran número de elementos), lo que permite evaluar la similitud entre texturas en base a la comparación de dichos vectores [68]. Esto permite obtener muy buenos resultados en aplicaciones como la segmentación [69] o la clasificación de texturas [70], o en problemas de recuperación basada en contenido donde la consulta es realizada mediante una imagen de muestra [71]. Asimismo, este tipo de descriptores que caracterizan globalmente la textura han sido aplicados con éxito en el ámbito de la síntesis de textura [72].

Sin embargo, lo más común para el ser humano es describir la textura mediante ciertas propiedades poco precisas basadas en su percepción, como el grosor, la direccionalidad o la regularidad [73]. Este hecho, ampliamente aceptado por la

comunidad científica de visión por computador, propició la aparición de técnicas que tratan de caracterizar la textura mediante una estimación computacional de estas propiedades perceptuales. El uso de dichas técnicas permite discriminar las texturas de un modo parecido a como lo haría el ser humano, pues, en lugar de comparar vectores de características que no tienen un significado comprensible por el usuario, se busca la similitud entre sus propiedades perceptuales. Así, este tipo de aproximaciones es muy utilizado en campos como la recuperación de imágenes basada en contenido o la descripción semántica de imágenes [74], donde se realiza un análisis del contenido visual para proporcionar al usuario unos resultados acordes a lo esperado.

### **2.3.1 Modelado global de textura**

La mayor parte de aproximaciones sobre el modelado de textura forman parte de este grupo de técnicas, se trata de valores computacionales que describen la textura en su conjunto. En la literatura se pueden encontrar diversas formas de clasificar estas técnicas, en función del tipo de análisis realizado sobre la textura. A finales de los años 70, el trabajo presentado por [75], realizó una revisión de las técnicas existentes hasta el momento, proponiendo una primera división en dos categorías principales: aproximaciones estadísticas y aproximaciones estructurales. Los descriptores pertenecientes a la primera categoría serían adecuados para el análisis de micro-texturas, mientras que los correspondientes al segundo grupo únicamente darían buenos resultados con texturas que pueden representarse adecuadamente mediante primitivas y sus reglas de ubicación. Aunque se admite en su trabajo que no existe una frontera clara entre ambas categorías, dicha división gozó de gran aceptación durante cerca de dos décadas, y fue también considerada en las revisiones realizadas unos años más tarde por [76] y [77]. Posteriormente, ya a finales de los 90, dentro de la investigación de [78], establecieron una nueva división de estas técnicas en cuatro categorías distintas, la cual sigue siendo una de las más utilizadas hoy en día: aproximaciones estadísticas, aproximaciones geométricas, aproximaciones basadas en modelos y aproximaciones basadas en filtros. Los métodos geométricos serían una generalización de los métodos estructurales, mientras que los métodos basados en

modelos asumen que la textura se ajusta a un determinado modelo estocástico y la representan mediante los parámetros que definen dicho modelo. Por último, las aproximaciones basadas en filtros se fundamentan en el análisis espectral de la imagen.

### **2.3.2 Aproximaciones estadísticas**

De los primeros métodos estadísticos, que fueron utilizados para la caracterización de texturas, y que hoy en día siguen siendo un referente en este campo, se basan en el análisis de la distribución espacial de los niveles de gris en la imagen. Para ello, se calculan rasgos locales en ciertos puntos de la imagen (normalmente para cada píxel), y se extrae un conjunto de estadísticos acerca de la distribución de estos rasgos, lo que permite caracterizar la textura. Dependiendo del número de píxeles usados para definir los rasgos locales, los métodos estadísticos pueden ser clasificados a su vez en estadísticos de primer orden (se toman los píxeles individualmente), de segundo orden (se toman parejas de píxeles) o de orden superior (se ven involucrados tres o más píxeles).

Los estadísticos de primer orden son aquellos que se obtienen a partir del histograma de niveles de gris de la imagen, como la media, la varianza, el coeficiente de asimetría o la curtosis. A pesar de que la capacidad de estos estadísticos para caracterizar la textura es muy limitada, han sido empleados en algunas aplicaciones simples de inspección de superficies, como en [79] y [80], debido a su sencillez y rapidez de cálculo. El principal inconveniente de estos estadísticos es que no tienen en cuenta la posición relativa de los píxeles, por lo que se pierde la información espacial. Para capturar las dependencias espaciales en los niveles de gris, que constituyen una información muy relevante en la caracterización de la textura, es necesario aplicar métodos basados en estadísticos de segundo orden o de orden superior. En este sentido, fueron de vital importancia los estudios realizados por [81], acerca de los distintos modelos estadísticos y su relación con la discriminación entre texturas por parte del ser humano. De acuerdo a dichos estudios, únicamente las diferencias en las distribuciones de probabilidad de segundo orden permiten discriminar espontáneamente las texturas, es decir, que dos texturas no pueden ser discriminadas

“sin esfuerzo” si coinciden sus estadísticos de segundo orden, mientras que las diferencias en las distribuciones de orden superior son insuficientes o irrelevantes. A raíz de dichos trabajos, creció el interés de muchos investigadores en el modelado de textura basado en estadísticos de segundo orden, surgiendo varias aproximaciones entre las que destacan las basadas en las matrices de coocurrencia y las basadas en las diferencias en el nivel de gris.

Posteriormente, aparecieron varios contraejemplos a la conjetura planteada por [82], incluyendo uno del propio [82], donde se demostraba que el uso de estadísticos de orden superior también lograba un alto grado de discriminabilidad de textura [83]. Las aproximaciones más destacables en este caso son las basadas en las matrices de longitud de secuencia, las basadas en el espectro de textura y las basadas en el operador de patrón binario local.

### **2.3.3 Estadísticos basados en las matrices de coocurrencia**

Estos estadísticos son sin duda los más conocidos y más ampliamente usados en la literatura. Las matrices de coocurrencia de niveles de gris, también llamadas matrices de dependencia espacial o GLCM (Gray Level Co-occurrence Matrices), son histogramas bidimensionales que representan la dependencia espacial entre dos niveles de gris separados una cierta distancia  $d$  a lo largo de una dirección  $\theta$ . Así, para cada distancia  $d$  y dirección  $\theta$  es posible calcular una matriz de coocurrencia distinta, donde el elemento  $(i, j)$  representa el número de pares de píxeles de la imagen que, estando separados esa distancia  $d$  en la dirección  $\theta$ , tienen un nivel de gris  $i$  y  $j$ , respectivamente. Puesto que el uso directo de las matrices de coocurrencia como descriptor de textura resulta inviable, debido a su tamaño, lo que se suele hacer es aplicar sobre ella un conjunto de estadísticos que permitan extraer la información más relevante. Así, dependiendo de las posiciones relativas usadas para calcular las matrices de coocurrencia (según los distintos valores fijados para  $d$  y  $\theta$ ), y de los estadísticos aplicados sobre ellas, podemos encontrar en la literatura varias aproximaciones al modelado de textura. La más conocida es la propuesta por [84], que aun después de casi 40 años, sigue siendo un referente en la caracterización de

textura. El trabajo realizado por [84], propuso la utilización de 14 estadísticos distintos, entre los que se encuentran el contraste, la correlación, la varianza y la entropía (basada en la teoría de la información), y sugirió su aplicación sobre matrices de coocurrencia calculadas para una distancia  $d = 1$  y ángulos  $\theta = 0^\circ, 45^\circ, 90^\circ, 135^\circ$ , obteniendo así cuatro valores distintos para cada estadístico. Para lograr descriptores de textura independientes de la rotación [84], propuso calcular la media y el rango sobre los cuatro valores obtenidos para cada estadístico. De esta forma, el vector de características que describe la textura está formado por 28 elementos. A raíz del trabajo de [84], surgieron nuevas aproximaciones al modelado de textura basado en las matrices de coocurrencias, muchas de ellas motivadas por una reducción del número de características propuestas, debido a la fuerte correlación existente entre ellas. Así, [85] realizó un estudio en el que concluía experimentalmente que seis de las características extraídas de las matrices de coocurrencia eran las más relevantes para la caracterización de texturas: energía, contraste, varianza, correlación, entropía y momento de diferencia inverso.

Posteriormente en [86], extendieron dicho estudio, analizando la correlación entre esos seis estadísticos, y concluyeron que la energía y el contraste son las características más significativas para discriminar entre distintas texturas. La investigación de [87], empleó una versión modificada del criterio de análisis discriminante múltiple [88], para seleccionar un subconjunto de las características extraídas de la matriz GLCM, seleccionando las cuatro con el mayor ratio de varianza. El vector de características obtenido fue aplicado en la clasificación de imágenes tomadas con microscopio. Un año más tarde, en [89], se propone el uso de cuatro estadísticos (energía, entropía, contraste y momento de diferencia inverso) para el modelado de texturas correspondientes a rocas, y su aplicación en la recuperación de imágenes en este tipo concreto de bases de datos.

Más recientemente, dentro de [90], se propuso un algoritmo de recuperación de imágenes genérico donde plantea el uso de los que considera los cuatro estadísticos más importantes: energía, contraste, entropía y correlación. Asimismo, propone unas medidas de similitud con las que pueden comparar los vectores de características

obtenidos. Por otro lado, en [91], se plantea un modelado de textura basado en seis estadísticos (homogeneidad, contraste, entropía, disimilitud, segundo momento y correlación), que es aplicado en la clasificación de imágenes de satélite pancromáticas.

Como se puede apreciar, no existe un criterio unánime a la hora de establecer los estadísticos de segundo orden más adecuados para caracterizar la textura, sino que se proponen distintos modelos según la aplicación concreta para la que van a ser empleados. Donde sí existe una mayor unanimidad es en la elección de los valores  $d$  y  $\theta$  con los que calcular las matrices de coocurrencia, pues generalmente se usan los mismos sugeridos por [84], ( $d = 1$  y  $\theta = 0^\circ, 45^\circ, 90^\circ, 135^\circ$ ). No obstante, existen varios trabajos [92] y [93], en los que se argumenta que es imposible discriminar entre cualquier posible pareja de texturas si únicamente es utilizada una distancia  $d$ . En ellos se plantea el cálculo de las matrices de coocurrencia para varias distancias ( $d = 1, 2, 3, 4$ ), aplicando los distintos estadísticos a cada una de ellas. Sin embargo, este tipo de aproximaciones no ha tenido mucho éxito en la literatura, pues suponen un coste computacional demasiado elevado y, en general, el uso de una sola distancia (normalmente  $d = 1$ ) es suficiente para la mayoría de aplicaciones.

#### **2.3.4 Estadísticos basados en las diferencias en el nivel de gris**

Los métodos basados en las diferencias en el nivel de gris, también conocidos como métodos GLD (Gray Level Differences), fueron propuestos inicialmente por [94], y, como cita el propio autor, son muy similares a los basados en las matrices de coocurrencia. La principal diferencia consiste en que, en lugar de calcular un histograma bidimensional para parejas de niveles de gris separados una cierta distancia  $d$  a lo largo de una dirección  $\theta$ , se calcula un histograma unidimensional para las diferencias absolutas entre esas parejas de niveles de gris. De esta forma, se obtiene un vector donde el  $i$ -ésimo elemento representa el número de pares de píxeles de la imagen que, estando separados una distancia  $d$  en la dirección  $\theta$ , tienen una diferencia absoluta de valor  $i$  en el nivel de gris [95]. Por tanto, la información capturada por dicho vector corresponde a la distribución del contraste local en

diferentes direcciones (normalmente  $\theta = 0^\circ, 45^\circ, 90^\circ, 135^\circ$ ). Al igual que se comentó en la sección anterior, debido a su tamaño, no se suele usar dicho vector como descriptor de textura, sino que se aplica sobre él un conjunto de estadísticos para extraer la información más relevante. En la propuesta inicial de [96], planteaba el uso de cuatro estadísticos para la caracterización de textura: media, entropía, contraste y segundo momento angular. En general, la capacidad de discriminación de estos modelos es muy similar a la de los modelos basados en las matrices de coocurrencia, lo cual es comprensible debido a su semejanza.

### **2.3.5 Estadísticos basados en las matrices de longitud de secuencia**

En el uso de matrices de longitud de secuencia para el modelado de textura de orden superior, se ven involucrados más de dos píxeles de la imagen. Un conjunto de píxeles consecutivos con idéntico (o similar) nivel de gris constituyen lo que se conoce como una secuencia de nivel de gris, siendo la longitud de secuencia el número de píxeles que forman dicho conjunto. La matriz de longitud de secuencia de nivel de gris, más conocida por sus siglas en inglés como GLRLM (Gray Level Run Length Matrix), es un histograma bidimensional donde el elemento  $(i, j)$  representa el número de veces que aparece una secuencia de nivel de gris  $i$  con longitud  $j$ . Normalmente, se suelen considerar las cuatro direcciones principales para la búsqueda de secuencias ( $0^\circ, 45^\circ, 90^\circ, 135^\circ$ ), obteniendo cuatro matrices GLRLM. La existencia de secuencias de píxeles con exactamente el mismo nivel de gris es un planteamiento poco realista para imágenes naturales, por lo que los niveles de gris se suelen agrupar en rangos. Así, algunos autores como [95] y [96], proponen el uso de agrupaciones equidistribuidas, mientras que otros, como en [97], consideran seis particiones siguiendo una escala logarítmica.

Al igual que en los métodos descritos anteriormente, es necesario aplicar un conjunto de estadísticos sobre cada una de estas matrices para obtener los vectores de características correspondientes. Tradicionalmente, se ha considerado el uso de cinco estadísticos: énfasis en secuencias cortas o SRE (Short Run Emphasis), énfasis en secuencias largas o LRE (Long Run Emphasis), no uniformidad en el nivel de gris o

GLN (Grey Level Nonuniformity), no uniformidad en la longitud de secuencia o RLN (Run Length Nonuniformity) y porcentaje de secuencia o RP (Run Percentage). Han surgido nuevos modelos en los que se propone la incorporación de otros estadísticos para mejorar diversas carencias del original. Así, por ejemplo, en [97], se plantea el uso de dos características adicionales, que permiten discriminar texturas que, teniendo valores similares de SRE y LRE, difieren en la distribución del nivel de gris de las secuencias: énfasis en secuencias de nivel de gris bajo o LGRE (Low Grey-Level Run Emphasis) y énfasis en secuencias de nivel de gris alto o HGRE (High Grey-Level Run Emphasis). En un estudio más reciente, proponen cuatro nuevos estadísticos basados en la combinación de los anteriores, comprobando la mejora producida en la clasificación de un conjunto de imágenes de células. Uno de los problemas más importantes que afectan a este tipo de métodos es su alta sensibilidad al ruido de la imagen [98].

### **2.3.6 Aproximaciones basadas en filtros**

En este tipo de aproximaciones se emplean técnicas de procesamiento de señal, aplicando diversos filtros sobre la imagen y usando las respuestas obtenidas para extraer los descriptores de textura. Se pueden emplear aproximaciones tanto en el dominio espacial como frecuencial para capturar la información relevante de la imagen. Sin embargo, a raíz de varios estudios psicológicos que evidencian que el sistema visual humano realiza un análisis frecuencial de la imagen [99], se popularizó el uso de técnicas espectrales, donde los descriptores de textura son extraídos de la distribución de la energía en el dominio de la frecuencia. Entre ellos, destacan los métodos basados en la transformada de Fourier, donde únicamente se tiene en cuenta la información frecuencial de la imagen, y los métodos basados en los filtros Gabor y en las wavelets, que tienen en cuenta tanto la información frecuencial como la espacial. A continuación se resumen brevemente cada una de estas aproximaciones.

### **2.3.7 Métodos basados en la transformada de Fourier**

El espectro de potencia de Fourier es una representación bidimensional de la imagen en el dominio frecuencial, de la cual se pueden extraer un gran número de

características de la textura. La mayoría de estas características se basan en la suma de los coeficientes de Fourier de zonas del espectro con forma de anillo, cuñas o sectores. Por ejemplo en [100], se plantea la extracción de un vector de 16 características, formado a partir de la intersección de cuatro anillos concéntricos con un radio exponencial y cuatro cuñas de anchura 45°.

Algunos autores, como [101], además de la suma de coeficientes, proponen también la extracción de ciertos estadísticos del espectro de Fourier, como la inercia, la entropía o la anisotropía, obteniendo vectores de características formados por 28 elementos. Otros autores, como [102] y [103], proponen aproximaciones basadas en los picos espectrales, donde, una vez detectados los picos principales en los coeficientes del espectro, se extraen características como: su frecuencia, dirección, área y potencia relativa.

En la práctica, los métodos basados en la transformada de Fourier tienen un comportamiento muy pobre, debido principalmente a la falta de información espacial. Así, estudios comparativos, concluyen que estos descriptores tienen una menor capacidad de discriminación que los basados en las matrices de coocurrencia o los basados en las diferencias en el nivel de gris, obteniendo peores resultados en tareas de clasificación.

### **2.3.8 Métodos basados en los filtros Gabor**

Las aproximaciones basadas en filtros Gabor son muy populares en la actualidad, siendo consideradas por algunos autores como el estado del arte en el modelado de textura [104]. Los filtros Gabor fueron introducidos originalmente por [105], siendo extendidos posteriormente por [106], al caso bidimensional.

Un filtro de Gabor bidimensional consiste en una onda sinusoidal orientable modulada por una envolvente Gaussiana, lo que permite realizar un análisis frecuencial de la imagen orientado y localizado. De esta forma, a diferencia de la transformada de Fourier, también se está considerando información del dominio espacial. Además, según los estudios psicofísicos realizados por [107], se descubrió que los campos

receptivos de las células simples de la corteza cerebral pueden ser modelados mediante funciones Gabor, por lo que el filtrado de imágenes con estas funciones tiene un comportamiento similar al del sistema visual humano. En estas aproximaciones, el modelado de textura se realiza aplicando un banco de filtros Gabor, que son una serie de filtros ubicados a distintas frecuencias y con distintas orientaciones en el dominio espectral, lo que permite capturar la energía contenida en diferentes escalas y orientaciones en la imagen. El vector de características que describe la textura estará formado por estadísticos obtenidos de la respuesta a cada uno de los filtros. Por lo general, se suelen utilizar estadísticos de primer orden, como la media y la desviación estándar [108]. Uno de los principales inconvenientes de los filtros Gabor es que, al no ser ortogonales, generan características redundantes a diferentes escalas. Para diseñar el banco de filtros, lo que se suele hacer en la práctica es seleccionar tres parámetros: la frecuencia central del filtro con mayor frecuencia, el número total de frecuencias y el número total de orientaciones.

En la literatura no existe unanimidad a la hora de seleccionar estos parámetros, lo que ha dado lugar a un gran número de aproximaciones. Así, por ejemplo, el trabajo de [109], propone un banco de 24 filtros, partiendo de cuatro frecuencias y cuatro orientaciones, mientras que [110], plantea aumentar el número de frecuencias a siete, obteniendo 28 filtros. Una de las aproximaciones más conocidas y más ampliamente usadas, es la de [108], donde se propone un banco de 24 filtros en base a cuatro frecuencias y seis orientaciones. Más recientemente, se puede encontrar propuestas como la de [111] o la de [112], con 24 y 36 filtros, respectivamente, o la de [113] que plantean un banco de 288 filtros.

### **2.3.9 Métodos basados en la transformada Wavelet**

Este tipo de aproximaciones son muy similares a las basadas en filtros Gabor, pues también son capaces de localizar en el espacio las características espectrales de la imagen, pero con la ventaja de que existe menos correlación entre ellas. Numerosos autores han contribuido al desarrollo de la transformada wavelet, siendo destacables los trabajos de [114], donde aparece la primera mención a las wavelets, de [115], por

su investigación en el análisis multi-resolución, o de [116], que desarrollo unas wavelets orto-normales que se convirtieron en el pilar de las bases actuales.

Una wavelet es una función oscilatoria de pequeña dimensión (concentrada en el espacio), por lo que posee una localización espacial y frecuencial a la vez. La transformada wavelet permite descomponer señales jerárquicamente usando una familia de funciones de este tipo, que es generada a partir de una única función prototipo llamada wavelet madre, mediante translaciones y cambios de escala. Para poder aplicar esta transformación sobre imágenes, lo más común es emplear bancos de filtros, cuyos coeficientes son derivados de las funciones wavelets. Dada una imagen, la transformada wavelet la descompone en una sub-imagen de baja frecuencia y un conjunto de detalles de alta frecuencia. La componente de baja frecuencia es obtenida mediante un suavizado progresivo de la imagen original, mientras que las imágenes de detalle reflejan la información perdida durante esa operación.

Es posible encontrar en la literatura una gran variedad de aproximaciones que proponen un modelado de textura basado en wavelets, dependiendo de la familia de funciones empleada, del modo de aplicación de la transformada o de las características extraídas. Así, en lo referente a la familia de funciones, existen aproximaciones donde se usan wavelets de Haar [117], de Daubechies [118], de Coiflets [119] o de Symlets [120].

En general, no existe un criterio definido para evaluar la calidad de las diferentes familias de wavelets, pues depende en gran medida de la tarea concreta para la que es usada. Por otro lado, dependiendo del modo en el que se aplique la transformada, se pueden encontrar aproximaciones en las que se usa directamente la transformada wavelet discreta (DWT) [121], y aproximaciones donde se emplean variantes de esta, como la wavelet frames discreta [121] o la wavelet packet [122]. Estas dos extensiones, conocidas como “transformadas redundantes”, proponen una descomposición de la imagen sin re-muestreos, y tienen la ventaja de ser invariantes frente a traslaciones. Además, estudios comparativos como el de [123], apuntan a que

estas transformadas redundantes obtienen mejores resultados en clasificación y discriminación de texturas que la DWT, por lo que son muy populares.

Una vez aplicada la descomposición wavelet, es necesario extraer un vector de características que permita modelar la textura. Lo que se suele hacer es calcular ciertos estadísticos a partir de las sub-imágenes de baja frecuencia y, sobre todo, de las componentes de detalle. En general, se usan estadísticos de primer orden, como la energía o los extraídos de histogramas, y estadísticos de segundo orden, como los obtenidos de la matriz de coocurrencia de las sub-imágenes. De todos ellos, el más usado en la literatura es la energía 1, pues, según algunos estudios, como el de [123] y [124], es una de las características más importantes para la discriminación de texturas en este tipo de aproximaciones. El trabajo de [125], indica que el uso de medidas de varianza combinadas con las de energía mejora el comportamiento de los modelos.

### **2.3.10 Segmentación mediante el método Otsu**

La segmentación debe verse como un proceso que a partir de una imagen, se obtiene una representación de la misma en la que cada píxel tiene asociada una etiqueta distintiva del objeto al que pertenece. Así, una vez segmentada la imagen dada, se podría formar una lista de objetos, consistentes en las agrupaciones de los píxeles que posean la misma etiqueta.

En [126], se define la segmentación como: la extracción de un objeto de interés de una imagen arbitraria. Por otro lado en el trabajo de [127], la definen como: la subdivisión de una imagen en sus partes constituyentes. Para [128], así como para [129], se trata de una operación de bajo nivel relacionada con la partición de las imágenes, mediante la determinación de regiones disjuntas y homogéneas, es decir, consiste en extraer las características principales que permitan aislar objetos considerados de interés o de importancia de acuerdo al problema que se plantee.

Si se da una segmentación completa, la segmentación termina cuando los objetos extraídos de la imagen se corresponden unívocamente con las distintas regiones

disjuntas a localizar en la misma. En el caso contrario, en escenas complejas, el resultado de la segmentación podría ser un conjunto de regiones homogéneas superpuestas, en cuyo caso, la imagen parcialmente segmentada deberá ser sometida a un tratamiento posterior con el fin de conseguir una segmentación completa.

Uno de los métodos de segmentación más utilizados es el método de Otsu llamado así en honor a Nobuyuki Otsu, que lo propuso en 1979. Es una técnica no paramétrica y no supervisada de umbralización óptima para separar dos clases entre sí. Cada clase viene caracterizada por su centroide y por el área que forma la unión de los puntos asociados a dicho centroide. El algoritmo busca la maximización de la distancia entre las dos clases y la minimización de sus áreas. En concreto, se utiliza la varianza, que es una medida de la dispersión de valores en cada clase, en el caso que se ocupa el presente trabajo, se trata de la dispersión de los niveles de gris. Dado que son dos las clases involucradas, se calcula el cociente entre ambas variancias y se busca un valor umbral para el que este cociente sea máximo, aplicando un procedimiento que utiliza únicamente los momentos acumulados de orden cero y primer orden del histograma en nivel de gris [130]. La operación umbral es considerada como la división de los píxeles de una imagen de  $L$  niveles de gris en dos grupos, de forma intuitiva por ejemplo objetos y fondo. Es decir, una imagen en escala de gris se puede modelar como una función de intensidad bidimensional de tamaño  $N (m \times n)$ , donde  $m$  es el número total de filas, y  $n$  el número de columnas. Los elementos de la imagen  $i(x, y)$  se representan por los  $L$  niveles de gris ( $i = 0, 1, 2, \dots, L - 1$ ). El número de píxeles en el nivel  $i$  se denota por  $h(i)$ , de esta forma es posible construir el histograma, que incluye todos los niveles de intensidad o de gris. El histograma se normaliza y se considera como una distribución de probabilidad.

## 2.4 LÓGICA DIFUSA

La incertidumbre está presente en muchas situaciones de las actividades humanas, esta incertidumbre es producto de lo incompleto o lo inexacto del conocimiento acerca de las características de un ambiente de estudio. La incertidumbre modifica

completamente la forma de acción y la toma de decisiones lógicas, por lo que es necesario tener un método adecuado para enfrentarla, [131]. De los diferentes estudios realizados al respecto, la incertidumbre puede ser clasificada en dos tipos básicos que son:

- El primer tipo de incertidumbre es debido a la falta de información, por lo que el estado futuro de un sistema no puede ser conocido o determinado completamente. Este tipo de incertidumbre es cuantitativo y tiene un carácter estocástico y ha sido manejado por la teoría de la probabilidad y la estadística.
- El segundo tipo de incertidumbre es la vaguedad con respecto a la descripción del significado semántico de los eventos, fenómenos o declaraciones en sí mismas. Este tipo de incertidumbre es de tipo cualitativo.

La salida de un evento estocástico es verdadera o falsa. Sin embargo, en la situación donde un evento en sí mismo no está bien definido, la salida puede ser dada por una cantidad diferente de verdadero (uno) o falso (cero). Esto es, la salida en presencia de la vaguedad puede ser cuantificada por un grado de creencia. En la mayoría de las ciencias se ha tenido preferencia por la probabilidad y la estadística como modelo matemático para representar la incertidumbre, y en especial porque han manejado básicamente la incertidumbre del primer tipo, mientras que el segundo tipo de incertidumbre, aparece cuando se trata de representar los conceptos cualitativos del pensamiento humano [131].

La lógica difusa trata de presentar un modelo matemático para manejar el segundo tipo de incertidumbre, es decir, cuando los conceptos son vagos y no se tiene certeza de cual sea el grado de verdad de dicho concepto, o su definición no proporcione una base para obtener un valor numérico preciso [131].

#### **2.4.1 Concepto fundamental de la lógica difusa**

Con respecto al punto anterior, es posible deducir que la lógica difusa tiene como fundamento el concepto de verdad parcial, es decir, los valores entre completamente verdadero y completamente falso; la lógica difusa difiere de la lógica clásica en que

las declaraciones no son ya bi-valores: verdadero o falso, encendido o apagado. Se sabe que en la lógica tradicional un objeto toma un valor de cero o uno; en la lógica difusa, una declaración puede asumir cualquier valor real entre 0 y 1, representando el grado para el cual un elemento pertenece a un conjunto dado [132].

La lógica difusa entonces puede ser considerada como un conjunto de la lógica convencional (lógica de Boole), y no debe de ser considerada como una simple teoría, sino más bien como una metodología que permite generalizar cualquier teoría específica de una forma discreta a una forma continua (difusa). La lógica difusa es un enfoque matemático para resolver problemas. Se distingue por producir resultados exactos de datos vagos o imprecisos, y es especialmente útil en computadoras y aplicaciones electrónicas. Ya que mientras que el cerebro humano puede razonar con incertidumbres, imprecisiones y juicios; las computadoras sólo pueden manipular valores precisos. La lógica difusa es un intento por combinar estas dos técnicas. Intenta introducir el manejo de la vaguedad para producir resultados precisos.

#### **2.4.2 Concepto de verdad difusa**

Debido a que la lógica difusa considera una graduación continua de valores de verdad variando desde completamente falso hasta completamente verdadero, entonces se define que la verdad de una declaración o valor como la confianza o el grado que tiene de que la declaración o valor sea correcto. Esta verdad es medida numéricamente con valores que van desde cero (completamente falso) hasta uno (completamente verdadero) incluyendo, por supuesto, todos los valores intermedios (verdad parcial). El concepto anterior de verdad parcial puede ser extendido para evaluar la verdad de la combinación, relación o comparación de declaraciones basadas en este concepto de verdad difusa. Por ejemplo, se podría evaluar la verdad de la combinación de dos declaraciones:  $A \text{ AND } B$ , o también  $A \text{ OR } B$ ; [132], lo cual produce resultados diferentes a los obtenidos con la lógica de primer orden.

#### **2.4.3 Teoría de conjuntos difusos**

En las matemáticas, el concepto de conjunto es muy simple, pero muy importante. Un conjunto es simplemente una colección de cosas. Las cosas o pertenecen al conjunto

o no pertenecen, similar a la idea en la lógica de que las declaraciones son o verdaderas o falsas. Las matemáticas clásicas están familiarizadas con los llamados conjuntos discretos. La lógica difusa establece la idea de un conjunto difuso, definiendo a un conjunto difuso como aquel en el cual los objetos pueden pertenecer para diferentes grados, llamados grados de membresía o confianza [132]. El grado de membresía o confianza de pertenecer a un conjunto difuso también puede ser valorado como un número que varía desde cero (absolutamente falso) hasta 1 (absolutamente verdadero) incluyendo los valores intermedios (verdad parcial); o puede emplearse una escala similar. Un conjunto difuso representa la aplicabilidad del elemento a un conjunto. Es decir, un elemento puede no ser totalmente representativo de un conjunto dado, pero tienen por lo menos alguna similitud con el concepto que el conjunto representa. Esta idea simple de diferentes grados de membresía en un conjunto difuso es extremadamente útil ya que permite utilizar palabras descriptivas; tales como cerca, casi, aproximado, donde el grado de membresía representa la confianza de que este descriptor sea verdadero para cualquier elemento considerado. El uso de palabras descriptivas permite usar el lenguaje ordinario al describir cosas en una forma precisa. Es decir, es posible asignar variables lingüísticas a un conjunto difuso para representar un concepto completo.

#### 2.4.4 Definición de un conjunto difuso

La interpretación original de un conjunto difuso proviene de una generalización del concepto clásico de subconjunto ampliado a la descripción de nociones vagas e imprecisas [133]. Esta generalización se realiza como sigue:

1. La membresía de un elemento a un conjunto es un concepto difuso.
2. Dicha membresía puede ser cuantificada por un grado. Dicho grado se conoce generalmente como grado de membresía de dicho elemento con respecto al conjunto y toma un valor en el intervalo de  $[0,1]$ . De una forma más precisa podemos definir un conjunto difuso como sigue: Un conjunto difuso  $A$  sobre un universo de discurso  $\Omega$  es un conjunto de pares, ecu. (2.1):

$$\begin{aligned} &\text{Ecuación 2.1 Grado de membresía.} \\ A = \{ \mu_a(x) : x \in \Omega, \mu_a(x) \in [0,1] \} &\quad (2.1) \end{aligned}$$

Donde  $\mu_a(x)$  es el grado de membresía de  $x$  con respecto al conjunto  $A$ .

### 2.4.5 Propiedades de los conjuntos difusos

Existen ciertas características o propiedades que son comunes a los conjuntos difusos, a continuación presentaremos algunas de ellas, solamente las necesarias para poder entender el resto de este capítulo. Igualdad de conjuntos difusos: Dos conjuntos difusos  $A$  y  $B$  definidos sobre un conjunto universo  $\Omega$ , se dicen que son iguales, denotado como  $A = B$ , si y solo si se cumple la ecu. (2.2):

$$\begin{aligned} &\text{Ecuación 2.2 Igualdad de conjuntos difusos.} \\ &\forall x \in \Omega, \mu_A(x) = \mu_B(x) \end{aligned} \quad (2.2)$$

Inclusión de un conjunto en otro: Dados dos conjuntos difusos  $A$  y  $B$  definidos sobre un conjunto universo  $\Omega$ , decimos que  $A$  está incluido en  $B$ ; si y solo si se cumple la ecu. (2.3):

$$\begin{aligned} &\text{Ecuación 2.3 Inclusión de un conjunto en otro.} \\ &\forall x \in \Omega, \mu_A(x) \leq \mu_B(x) \end{aligned} \quad (2.3)$$

Soporte de un conjunto difuso: El soporte de un conjunto difuso  $A$  definido sobre un conjunto universo  $\Omega$  es un subconjunto que satisface la ecu. (2.4):

$$\begin{aligned} &\text{Ecuación 2.4 Soporte de un conjunto difuso.} \\ &Supp(A) = \{x \in \Omega | \mu_A(x) > 0\} \end{aligned} \quad (2.4)$$

Si el soporte resulta en un conjunto finito, entonces es llamado soporte compacto.

Núcleo de un conjunto difuso: El núcleo de un conjunto difuso  $A$  definido sobre un conjunto universo  $\Omega$  es un subconjunto de dicho universo que satisface la ecu. (2.5):

$$\begin{aligned} &\text{Ecuación 2.5 Núcleo de un conjunto difuso.} \\ &Core(A) = \{x \in \Omega | \mu_A(x) = 1\} \end{aligned} \quad (2.5)$$

Altura de un conjunto difuso: La altura de un conjunto difuso  $A$  definido sobre un conjunto universo  $\Omega$  se define con la ecu. (2.6) como:

$$\begin{aligned} &\text{Ecuación 2.6 Altura de un conjunto difuso.} \\ &Hgt(A) = Supp \mu_A(x) = 1 \end{aligned} \quad (2.6)$$

Esta definición implica que  $Hgt(A) = 1$

### 2.4.6 Números e intervalos difusos

El miembro principal y básico de la lógica difusa es el número difuso, introducido con el propósito de analizar y manipular valores numéricos aproximados. Este concepto ha sido refinado a través del tiempo. Aquí un número difuso es definido simplemente como un número ordinario cuyo valor preciso es un poco incierto, y consiste de un rango de valores que se aproximan o se alejan del valor entero de este número.

Sin embargo, es posible definir más formalmente a un número difuso como un tipo especial de un conjunto difuso. Para que un conjunto difuso  $F$  sea un número difuso debe de reunir las siguientes características:

1. El conjunto difuso es convexo.
2. El conjunto difuso está normalizado.
3. La función de membresía del conjunto difuso es continua en algunas partes.
4. El núcleo del conjunto difuso consiste de un solo valor.

Las operaciones matemáticas tales como la adición, sustracción, etc. pueden ser ampliadas para usar números difusos por medio del principio de extensión, el cual será explicado en la siguiente sección. Por último, además de los números difusos se pueden considerar también los intervalos difusos. Un intervalo difuso es un conjunto difuso con las mismas restricciones definidas para los números difusos, con la excepción de que el núcleo no está restringido a ser solamente un punto.

### 2.4.7 Principio de extensión

Este principio, es uno de los elementos más importantes de la teoría de conjuntos difusos; y proporciona un método general que permite extender conceptos matemáticos no difusos para el tratamiento de cantidades difusas. Este principio se define como sigue:

Sea  $f: x \rightarrow y$  (con universos arbitrarios) y sea  $A$  un subconjunto difuso de  $x$  entonces la imagen de  $A$  a través de  $f$  es un conjunto difuso de  $y$  cuya función de membresía está dada por:  $B(y) = \sup\{A_x y | y = f(x)\}$ . Gracias al principio de extensión es posible

extender las operaciones aritméticas clásicas para que puedan tratar con números difusos. Así, las cuatro operaciones fundamentales quedan extendidas como sigue:

Adición extendida: Dadas dos cantidades difusas  $A_1$  y  $A_2$ , la función de pertenencia de la suma viene dada por la ecu. (2.7):

$$\begin{aligned} & \text{Ecuación 2.7 Adición extendida.} \\ \mu_{A_1} + \mu_{A_2}(y) &= \sup\{\min(\mu_{A_1}(y - x), \mu_{A_2}(x)) / x \in R\} \end{aligned} \quad (2.7)$$

Sustracción extendida: Dadas dos cantidades difusas  $A_1$  y  $A_2$ , la función de pertenencia de la resta viene dada por la ecu. (2.8):

$$\begin{aligned} & \text{Ecuación 2.8 Sustracción extendida.} \\ \mu_{A_1} - \mu_{A_2}(y) &= \sup\{\min(\mu_{A_1}(y + x), \mu_{A_2}(x)) / x \in R\} \end{aligned} \quad (2.8)$$

Producto extendido: El producto de dos cantidades difusas  $A_1$  y  $A_2$ , se obtiene por la ecu. (2.9):

$$\begin{aligned} & \text{Ecuación 2.9 Producto extendido.} \\ \mu_{A_1} * \mu_{A_2}(z) & \begin{cases} \sup\{\min(\mu_{A_1}(z/y), \mu_{A_2}(y)) / y \in R - \{0\}\} & \text{si } z \neq 0 \\ \max(\mu_{A_1}(0), \mu_{A_2}(0)) & \text{si } z = 0 \end{cases} \end{aligned} \quad (2.9)$$

Cociente extendido: La división de dos cantidades difusas se define mediante la siguiente ecu. (2.10):

$$\begin{aligned} & \text{Ecuación 2.10 Cociente extendido.} \\ \mu_{A_1} \div \mu_{A_2}(y) &= \sup\{\min(\mu_{A_1}(y * z), \mu_{A_2}(z)) / z \in R\} \end{aligned} \quad (2.10)$$

#### 2.4.8 Representaciones de conjuntos difusos

En la teoría de conjuntos difusos la mayoría de las operaciones están definidas para universos continuos. Las definiciones incluyen operaciones sobre conjuntos discretos como casos especiales. En la práctica los conjuntos difusos son almacenados en la memoria de computadoras por estructuras de datos y las operaciones sobre conjuntos difusos están implementados por algoritmos de computadoras. Ya que la mayoría de las aplicaciones de la teoría de conjuntos difusos están basadas en computadoras, es necesario considerar las diversas representaciones de conjuntos difusos. Se pueden distinguir diversos tipos de representaciones de conjuntos difusos [134].

Representación funcional: este tipo de representación de conjuntos usa descripciones funcionales para representar conjuntos difusos, ecu. (2.11):

Ecuación 2.11 Representación conjunto difuso.

$$\mu_A(x) = f(x) \quad (2.11)$$

El uso de funciones para representar conjuntos difusos plantea varias dificultades en la práctica, cuando se realizan combinaciones con otros conjuntos difusos. El uso de símbolos de cálculo solamente está limitado a casos simples debido a la complejidad de las operaciones. Aunque es posible almacenar operaciones en forma simbólica, los resultados de la operación no pueden ser derivados simbólicamente y una aproximación del resultado de una operación tiene que ser hecha. Por lo anterior es necesaria la representación discreta de conjuntos difusos.

#### **2.4.9 Funciones de membresía**

El problema de construir una función de membresía que adecuadamente capture los significados de los términos lingüísticos empleados en una aplicación en particular (así como, el problema de determinar los significados de las operaciones asociadas) no pertenece a la teoría de conjuntos difusos, sino en general al área de la adquisición del conocimiento. Sin embargo, se mencionara en forma general las diversas formas en que pueden ser obtenidas. Una función de membresía caracteriza la incertidumbre en los conjuntos difusos, y son necesarias para poder definir y operar los conjuntos difusos [134]. Para construir la función de membresía de un conjunto difuso involucra:

1. El dominio del conocimiento específico de interés.
2. Uno o varios especialistas en este campo.
3. Un ingeniero de conocimiento que obtiene el conocimiento de interés del especialista y expresa el conocimiento en términos de proposiciones involucrando variables lingüísticas.

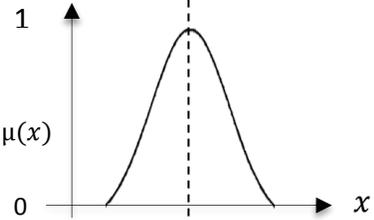
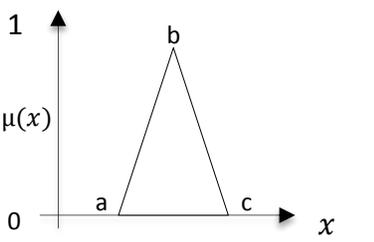
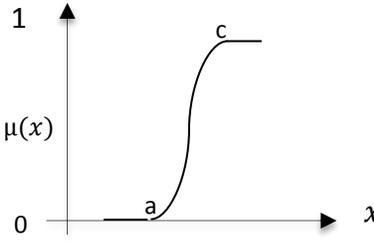
Esto es, el conocimiento que representa a una función de membresía es obtenido a través de la interacción entre el ingeniero de conocimiento y los especialistas:

- El ingeniero intenta obtener el conocimiento en términos de proposiciones expresadas en lenguaje natural.
- Intenta determinar el significado de cada término lingüístico usado. (Es en esta práctica donde las funciones de membresía son construidas). Existen en la literatura numerosos métodos para construir funciones de membresía que están basados en el juicio del especialista. Estos, pueden ser clasificados en:
  - Directos: Los especialistas proveen respuestas para preguntas de varias especies que explícitamente pertenecen a la construcción de la función de membresía.
  - Indirectos: Los especialistas dan respuestas a preguntas más simples y más fáciles de responder y menos sensibles en diversas direcciones del juicio subjetivo, que pertenecen a la construcción de la función de membresía. Sin embargo, no solamente a través del conocimiento de un especialista es que se pueden construir funciones de membresía, existen métodos más formales y automatizados para llevar a cabo esta tarea, a continuación mencionaremos algunos de ellos:
    - Intuición: simplemente se derivan las funciones de membresía a través de la inteligencia y entendimiento innatos. La intuición involucra conocimiento semántico y contextual sobre los problemas; así como valores de verdad de tipo lingüístico.
    - Inferencia: usamos conocimiento para la realización del razonamiento deductivo, esto es; deseamos deducir o inferir una conclusión, dado un cuerpo de hechos y conocimientos.
    - Orden de clasificación: asociamos preferencias hechas por un individuo, un comité u otros métodos de opinión que pueden ser usados para atribuir valores de membresía para una variable difusa.
    - Redes neuronales: es una técnica que procura construir un programa inteligente usando modelos que simulan las neuronas del cerebro. Aquí se genera un proceso de aprendizaje para obtener la función de membresía a través de datos de muestra.

- Algoritmos genéticos: aquí las funciones de membresía y sus formas son codificadas y existe una función de evaluación que es usada para adaptar cada función de membresía a nuevas situaciones.
- Razonamiento inductivo: se realiza con el objetivo de agrupar más óptimamente los parámetros correspondientes para la salida de clases. Se basa en el esquema ideal que describe una relación de entrada y salida para una base de datos bien definida. El objetivo de la inducción es descubrir una ley que tenga validez objetiva y aplicación universal.

Por lo anteriormente expuesto, las funciones de membresía pueden tomar diversas formas, sin embargo, existen algunas funciones que son más usadas en las aplicaciones, en el presente trabajo de investigación se hace uso de las funciones Gaussianas, triangulares y sigmoideas. En la Tabla 2.1, se muestran las funciones mencionadas.

Tabla 2.1 Funciones de pertenencia.

Función de Pertenencia	Gráfica
$\mu(x; \sigma, c) = e^{-\frac{1}{2}\left(\frac{x-c}{\sigma}\right)^2}$ <p>Una función Gaussiana es determinada por <math>c</math> y <math>\sigma</math>; <math>c</math> representa el centro de la función y <math>\sigma</math> determina la amplitud de la función.</p>	
$\mu(x; a, b, c) = \text{Max}\left(\text{Min}\left(\frac{x-a}{b-a}, \frac{c-x}{c-b}\right), 0\right)$ <p>Los parámetros <math>\{a, b, c\}</math> con <math>(a &lt; b &lt; c)</math> determinar las coordenadas de <math>x</math> en las tres esquinas de la función triangular.</p>	
$\mu(x; a, c) = \frac{1}{1 + e^{-a(x-c)}}$ <p>Función de pertenencia sigmoidea: se define mediante dos parámetros <math>\{a, c\}</math> donde <math>a</math> controla la pendiente en el punto de cruce <math>x = c</math>. Dependiendo del signo del parámetro <math>a</math>, la función sigmoidea es abierta a la derecha o izquierda.</p>	

#### **2.4.10 Variables lingüísticas**

La importancia de la teoría de conjuntos difusos es que proporciona instrumentos teóricos de gran poder para representar y manipular conceptos expresados en lenguaje natural, los cuales son predominantemente vagos y además dependen del contexto. Por ejemplo, los conceptos tales como barato y caro dependen tanto del contexto como de la opinión del comprador. La función de membresía asignada a tales conjuntos difusos, describiría el comportamiento de tales conceptos y las operaciones sobre dichos conjuntos difusos describirían las relaciones entre dichos conceptos [135].

#### **2.4.11 Modificadores lingüísticos**

Los modificadores lingüísticos pueden ser usados para modificar el significado de un conjunto difuso. Por ejemplo, el modificador lingüístico muy puede ser usado para cambiar el significado de grande a muy grande. Varios autores han estudiado los modificadores lingüísticos para los conjuntos difusos, también conocidos como cercos o separadores [135]. Ejemplos de separadores son: muy, ligeramente, más o menos, etc. Generalmente, el estudio de los separadores toma dos enfoques principales que son:

- Separadores de poder
- Separadores de cambio

#### **2.4.12 Operaciones con conjuntos difusos**

Ya que la lógica difusa es un subconjunto de la lógica predicativa, entonces los operadores para los conjuntos difusos y para los conjuntos no difusos son en mucho los mismos. Cuando se aplican operadores difusos a conjuntos no difusos, se obtienen las mismas respuestas que si se hubiera usado los correspondientes operadores de la lógica predicativa.

Los operadores lógicos están basados en valores de verdad que van de 0 (falso) a 1 (verdadero). Cuando estos operadores lógicos son aplicados a valores no difusos, dan los mismos resultados como con los operadores familiares "o", "y" y "no". Un

paralelismo más directo con la lógica convencional es el uso de tres operaciones de conjuntos básicas: la intersección, unión y complemento [136].

La unión de conjuntos difusos. La función de membresía de la Unión de dos conjuntos difusos  $A$  y  $B$  con funciones de membresía  $\mu_A$  y  $\mu_B$  respectivamente es definida como el máximo de las dos funciones de membresía individuales. Esto es llamado el criterio máximo. La operación Unión en la teoría de conjuntos difusos es el equivalente de la operación "o" en el álgebra Booleana.

La Intersección de conjuntos difusos. La función de membresía de la Intersección de dos conjuntos difusos  $A$  y  $B$  con funciones de membresía  $\mu_A$  y  $\mu_B$  respectivamente es definida como el mínimo de las dos funciones de membresía individuales. Esto es llamado el criterio mínimo. La operación de Intersección en la teoría de conjuntos difusos es el equivalente de la operación "y" en el álgebra Booleana.

El complemento de un conjunto difuso. La función de membresía del Complemento de un conjunto difuso  $A$  con una función de membresía  $\mu_A$  es definida como la negación de la función de membresía especificada. Esto es llamado el criterio de negación. La operación Complemento en la teoría de conjuntos difusos es el equivalente de la operación "no" en el álgebra Booleana.

#### **2.4.13 Relaciones difusas**

Los conjuntos difusos pueden ser extendidos para manejar funciones de membresía de una dimensión más alta. A estos conjuntos difusos multidimensionales se les conoce como relaciones difusas. Las relaciones difusas representan un grado de presencia, ausencia, interacción o falta de conexión entre los elementos de dos o más conjuntos difusos [137]. Algunos ejemplos de las relaciones difusas son:  $z$  es más grande que  $x$ ,  $z$  está cerca de  $x$ ,  $z$  es mucho más grande que  $x$ , etc. Las relaciones difusas resultan útiles debido a que gracias a ellas se pueden representar declaraciones lingüísticas del tipo: aproximadamente iguales, ligeramente mayor, casi el doble que, etc. Es decir, sirven para modelar asociaciones, relaciones o correspondencias lingüísticas. Además, las propiedades y operaciones sobre

conjuntos difusos pueden ser extendidas para manejar las propiedades y operaciones de las relaciones difusas [138].

#### **2.4.14 Razonamiento con lógica difusa**

Así como la teoría de conjuntos clásica sirve de base a la lógica clásica, así también, la teoría de conjuntos difusos sirve de base para la lógica difusa. Esto significa que las operaciones teóricas definidas para los conjuntos como la unión, intersección y complemento, tienen un correspondiente significado lógico; como las operaciones "o", "y" y "no" respectivamente [138].

#### **2.4.15 Defusificación**

Algunas veces resultan útiles los subconjuntos difusos producidos por el proceso de composición, pero con frecuencia, este valor difuso necesita ser convertido a un solo número, un valor discreto. Esto es lo que hace el subproceso de la defusificación. Existen diversos métodos de defusificación. Las técnicas más comunes son los métodos del centroide y el máximo. En el método del centroide, el valor discreto de la variable de salida se calcula al encontrar el centro de gravedad del subconjunto difuso de salida. En el método máximo, uso de los valores del subconjunto difuso donde la variable de salida tenga su valor de verdad máximo, es elegido como el valor discreto de salida [138]. Existen diversas variaciones del método máximo que difieren solamente en lo que hacen cuando existe más de un valor máximo para la variable de salida. Uno de estos, el método promedio de máximos, regresa el promedio de los valores máximo. Algunas veces los procesos de composición y defusificación son combinados, tomando ventaja de las relaciones matemáticas que simplifican el proceso de calcular los valores finales de las variables de salida [138].

### **2.5 REDES NEURONALES ARTIFICIALES**

#### **2.5.1 Definición de neurona artificial**

Cuando hablamos de sistemas neuronales es importante definir el concepto de neurona artificial, elemento básico de este tipo de sistemas, cuya descripción se

hereda de los principios neuro-biológicos que describen el comportamiento de las neuronas en la corteza cerebral. La neurona artificial consta de elementos de entrada y salida que se procesan en la unidad central, así como de los elementos de procesamiento que permitirán a la neurona generalizar y aprender conceptos. La arquitectura básica de la neurona se muestra a continuación [139]. Ver Fig. (2.7).

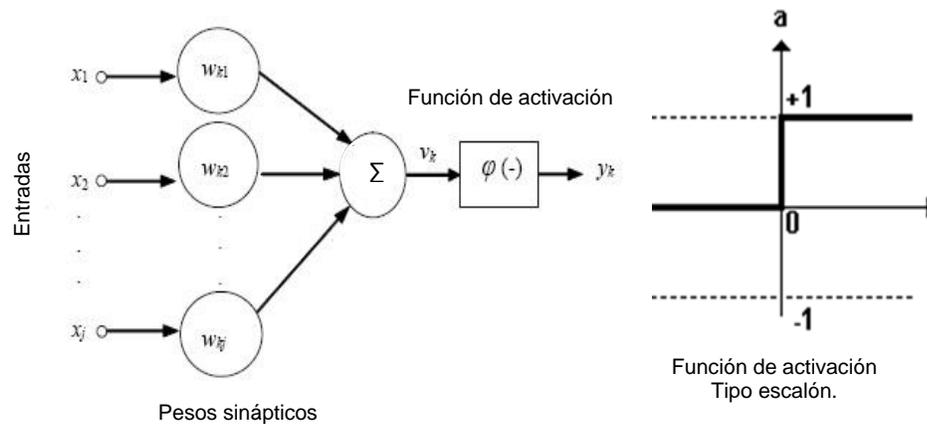


Figura 2.7 Arquitectura de la neurona y función de activación.

Donde  $X_p$  es el vector de entrada de la neurona,  $\omega_{k0...kp}$  es el vector de pesos correspondientes a la neurona  $k$  por los que se multiplica cada entrada, a  $\theta_k$  lo llamaremos el umbral que se multiplica por una entrada  $X_0 = -1$ ,  $v_k$  es el producto punto del vector de entrada  $X^k$  y el vector de pesos  $\omega^k$ ,  $\varphi()$  es la función de activación y finalmente  $y_k$  es la salida de la neurona  $k$ . La Fig. (2.7), también muestra la función de activación  $\varphi()$  correspondiente a la neurona y que en este caso es la función de umbral la cual propone que a todos los valores de  $v_k$  menores a cero les corresponda una salida de  $0$  y a todos los valores de  $v_k$  mayores o iguales a cero les corresponda una salida de  $+1$ . A partir de esta estructura básica la neurona puede mapear las entradas para obtener a la salida, una respuesta deseada que pudiera pertenecer a alguna función determinada y que, debido a la función de activación  $\varphi()$  que la genera, puede caer en dos categorías. Esta respuesta depende en primer lugar de las entradas de la neurona y en segundo lugar de las operaciones que se realicen al interior de la neurona.

El objeto de este esquema es plantear la posibilidad de que las operaciones internas, que están determinadas por los parámetros libres de la red, como es el vector de pesos  $\omega$  y el umbral  $\theta = \omega_0$ , puedan representar una variedad de salidas con solo modificar dichos parámetros. De manera tal que cuando se pretenda entrenar a la neurona, para que con unas entradas nos entregue determinadas salidas, únicamente sea necesario modificar el valor de los parámetros libres para que la diferencia entre el valor esperado y el valor obtenido a la salida sea mínima. Este procedimiento básico sienta las bases de entrenamiento para los sistemas basados en la neurona como unidad básica [139].

### **2.5.2 Procesos de aprendizaje en sistemas neuronales**

En general cualquier sistema neuronal puede utilizar distintos paradigmas para el aprendizaje de la red, al igual que distintos algoritmos de entrenamiento. Cuando se habla de aprendizaje supervisado (supervised learning), se refiere al tipo de entrenamiento en el cual, se provee al sistema con información de las entradas al igual que se proveen las salidas esperadas o destinos correspondientes a dichas entradas a modo de que el sistema tenga los destinos como punto de referencia para evaluar su desempeño en base a la diferencia de estos valores y modificar los parámetros libres en base a esta diferencia.

En un aprendizaje no supervisado los parámetros libres del sistema son modificados únicamente en base a las entradas del sistema de manera que aprenden a categorizar las entradas y clasificarlas sin necesidad de una referencia [139].

### **2.5.3 El perceptrón**

A partir del modelo de la neurona artificial se desarrolló el modelo del perceptrón el cuál básicamente consiste en una capa de neuronas con pesos y umbral ajustables como se muestra en la Fig. (2.8), este sistema neuronal puede ser llamado una red neuronal debido a las conexiones existentes en sus elementos.

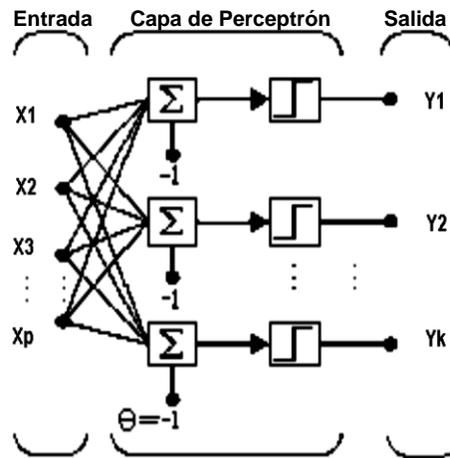


Figura 2.8 Arquitectura del perceptrón.

En un inicio en base al modelo de aprendizaje de la regla delta, se determinó el algoritmo de entrenamiento del perceptrón que, siguiendo los principios de la regla, consiste en determinar el ajuste que se debe realizar a cada peso  $\omega$  en la neurona para que el error a la salida sea cero. El algoritmo de entrenamiento del perceptrón comienza por inicializar los parámetros libres (pesos y umbrales) en cero y posteriormente se estimula la red con algún vector de entrada obteniendo el error a cada salida calculado mediante ecu. (2.12):

Ecuación 2.12 Aprendizaje de la regla delta.

$$e_k(n) = d_k(n) - y_k(n) \quad (2.12)$$

Donde  $e_k(n)$  corresponde al error a la salida para la muestra  $n$  de la neurona  $k$ ,  $d_k(n)$  es el valor destino esperado a la salida para la muestra  $n$  y  $y_k(n)$  es la salida obtenida en la neurona  $k$  para la muestra  $n$ . El siguiente paso es calcular la delta o diferencia a agregar a los pesos para que el error sea cero. La delta está dada por la ecu (2.13) y ecu. (2.14).

Ecuación 2.13 Calculo de delta.

$$\Delta\omega = e(n)x(n) \quad (2.13)$$

Ecuación 2.14 Calculo de delta.

$$\Delta\theta = e(n) \quad (2.14)$$

Donde  $\Delta\theta$  es la modificación que se debe realizar al umbral y  $\Delta\omega$  es la modificación que se debe realizar a los pesos. La regla de aprendizaje del Perceptrón puede ser expresa a través de la ecu. (2.15) y ecu. (2.16) como sigue:

Ecuación 2.15 Regla de aprendizaje del perceptrón.

$$\omega^{nueva} = \omega^{vieja} + e(n)x(n) \quad (2.15)$$

Ecuación 2.16 Regla de aprendizaje del perceptrón.

$$\theta^{nueva} = \theta^{vieja} + e(n) \quad (2.16)$$

Si se aplica la regla a una perceptrón con distintas muestras, hasta que el error sea cero, se obtendrá una red que pueda generar exactamente las salidas deseadas logrando así que el perceptrón aprenda una función [139]. Como se puede observar la regla delta para el perceptrón consiste en agregar a cada peso el producto del error generado por la neurona con las entradas correspondientes de manera que se dan 3 casos posibles.

1. El error es cero y los pesos no se modifican.
2. El error es 1 y a cada peso se le agrega exactamente la entrada correspondiente.
3. El error es -1 y a cada peso se le subtrae exactamente la entrada correspondiente.

#### 2.5.4 Limitaciones del perceptrón

Se debe tener en cuenta que no siempre el algoritmo de entrenamiento del perceptrón podrá converger hacia un error nulo. De hecho el perceptrón es incapaz de converger en aquellas funciones que no son linealmente separables, es decir, aquellas cuyos elementos pueden ser separados por una línea recta [140]. Esto se debe a las propiedades inherentes de las unidades básicas del perceptrón que son las neuronas artificiales, cuya limitación reside principalmente en la función de activación que como se puede observar separa las entradas en dos salidas de manera que con todas las entradas posibles se forma un hiperplano cuyos elementos de salida son separados en dos partes dentro del hiperplano [141].

Visto de otra forma, se podría decir que el perceptrón divide en dos grupos las entradas por medio de una línea divisoria de manera que no es posible separar elementos que no se encuentren claramente separados de otros elementos. Es decir que no se puede caracterizar elementos no lineales. Esto se puede observar

claramente en la Fig. (2.9), donde se muestra el caso en el que el perceptrón es un buen clasificador, y otro caso donde el perceptrón no puede separar los elementos en dos categorías. En la figura, los puntos  $(X_1, X_2)$  corresponden a la intersección de dos entradas  $X_1$  y  $X_2$ . Enfocándonos al problema de la detección de intrusos, se infiere que el uso del perceptrón sería inadecuado debido a las limitaciones lineales que su estructura posee. Sin embargo, a partir de estos principios se comenzará a vislumbrar las características necesarias para que nuestro sistema neuronal pueda clasificar patrones no lineales [142].

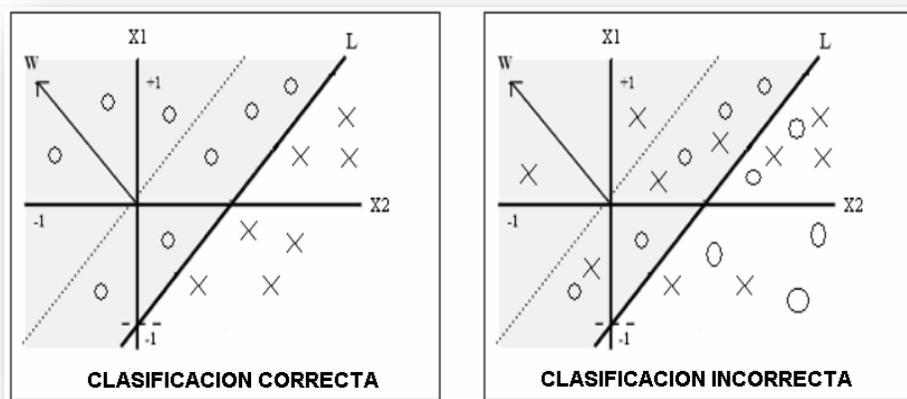


Figura 2.9 Margen de Caracterización del perceptrón.

### 2.5.5 Evolución al perceptrón multicapa

Como se mencionó anteriormente los modelos que se desprenden del perceptrón se basan en los principios de corrección de error planteados por el algoritmo de la regla delta para entrenar a estos sistemas. En un principio el desarrollo del perceptrón llevó a la generación de un nuevo tipo de red cuya modificación principal respecto a la estructura del perceptrón se basa en el uso de varias capas de neuronas artificiales, en vez de usar una sola capa [143].

Este hecho significativo no hubiera servido de nada sin el cambio de la función de activación de las neuronas artificiales pasando de una función no diferenciable como

era la activación logística a una función diferenciable y no lineal como lo es la sigmoide que se muestra en la Fig. (2.10).

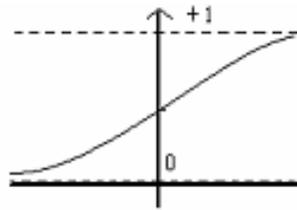


Figura 2.10 Función de activación sigmoide.

El recurso de este tipo de función de activación introdujo un nuevo paradigma en el procesamiento de los sistemas neuronales permitiendo a las redes neuronales aprender las variaciones no lineales de los distintos tipos de ambientes, que en su mayoría, presentan variaciones del tipo no lineal. Este sistema neuronal es considerado también una red neuronal se conoce en la literatura como perceptrón multicapa debido a que parte del principio del perceptrón simple [143]. A continuación se muestra la arquitectura de esta red neuronal. Ver Fig. (2.11).

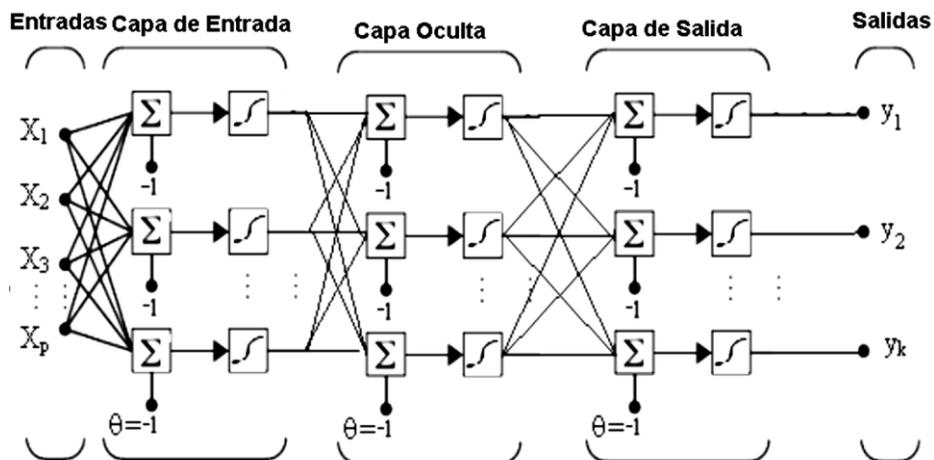


Figura 2.11 Arquitectura del perceptrón multicapa.

Al observar la arquitectura del perceptrón multicapa se puede observar que las múltiples entradas conectadas en la primera capa son mapeadas en las salidas en función de las distintas capas de neuronas intermedias y de los parámetros libres de la red. Se puede ver como una caja negra que realiza una operación sobre las entradas, produciendo un rango de salidas en función de los parámetros libres. Se infiere de la arquitectura que el algoritmo de entrenamiento de una red con tales

características deberá ser planeado para que los cambios en los parámetros libres sean tales que el error en las unidades básicas de la estructura sea mínimo de manera que el conjunto de los cambios produzca un error global que tienda al mínimo. Se buscará entonces el límite en el cual la configuración de los parámetros libres produzca un error mínimo. Tomando en cuenta este razonamiento, la evolución al perceptrón multicapa tuvo que basar su éxito en el diseño del algoritmo de entrenamiento que lograra minimizar el error al modificar adecuadamente los pesos y umbrales. La historia marco como primer paso, estudiar la forma de minimizar el error en una capa de neuronas lineales, que se conoce también como filtro lineal. El análisis de este tipo de red neuronal que posee elementos lineales, nos permite deducir un algoritmo más complejo para entrenar a una red como la perceptrón multicapa que posee elementos no lineales. El perceptrón multicapa propone una estructura de capas ocultas que realizan procesamiento complejo sobre las entradas. Además de esto, el uso de neuronas con función de activación no lineal, como lo es la sigmoide, permite a la red aprender las discontinuidades de los entornos.

Toda esta evolución en la arquitectura lleva a plantear un nuevo y complejo algoritmo de entrenamiento que permita a una red de este tipo llevar al mínimo una función global de error que es dependiente, no solo de los parámetros libres de la red, sino también de las diversas interconexiones entre los elementos del sistema que desempeñan una labor de conceptualización global y compleja. La visión que ahora se tiene de los algoritmos de entrenamiento de redes de una sola capa permite introducir a este nuevo algoritmo que permite entrenar a redes de muchas capas. El algoritmo Back Propagation o propagación hacia atrás, está basado en el algoritmo de la regla de corrección de error o también llamado regla delta. En el back propagation se calcula el error instantáneo de la suma de los errores cuadrados para derivar la función de costo y depende únicamente de los elementos de la última capa visible. El error instantáneo está dado por la siguiente ecu. (2.17):

Ecuación 2.17 Error instantáneo.

$$\varepsilon(n) = \frac{1}{2} \sum_{j \in c} e_j^2(n) \quad (2.17)$$

Donde  $c$  incluye a todas las neuronas de la capa de salida. Si ahora  $N$  denota el número total de muestras contenidas en un conjunto de entrenamiento, entonces se puede calcular el valor promedio del error cuadrado con la ecu. (2.18):

Ecuación 2.18 Valor promedio del error cuadrado.

$$\varepsilon_{av} = \frac{1}{N} \sum_{n=1}^N \varepsilon(n) \quad (2.18)$$

Así pues la función de costo a minimizar será la denotada por la ecu. (2.18). Para minimizar esta función se usará una aproximación similar a la usada para derivar el algoritmo de mínimos cuadrados y nuevamente usando el concepto de gradiente. Para esto se calcula el valor del gradiente instantáneo de la función de costo con respecto a los pesos sinápticos como muestra la siguiente ecuación aplicando la regla de la cadena donde la derivada parcial se descompone en las funciones de las que depende la función inicial.

Ecuación 2.19 Regla de la cadena.

$$\frac{\partial \varepsilon(n)}{\partial \omega_{kj}(n)} = \frac{\partial \varepsilon(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial \omega_{kj}(n)} \quad (2.19)$$

Donde  $k, j$  son los índices que indican la posición de cada neurona dentro del perceptrón multicapa. Posteriormente la delta de cada peso se calcula mediante la ecu. (2.20) como sigue:

Ecuación 2.20 Peso de cada delta.

$$\Delta \omega_{kj}(n) = -n \frac{\partial \varepsilon(n)}{\partial \omega_{kj}(n)} \quad (2.20)$$

Y resolviendo la derivada parcial se obtiene que la delta quede de la siguiente manera:

Ecuación 2.21 Derivada parcial.

$$\Delta \omega_{kj}(n) = -n \delta_j n X(n) \quad (2.21)$$

Donde  $X(n)$  representa el vector de entrada para la muestra  $n$  y  $\delta$  representa el gradiente local que depende de la ubicación de la neurona en la red y queda como sigue:

Ecuación 2.22 Ubicación de la neurona en la red.

$$\delta_j = e_j(n) \varphi'(v_j(n)) \quad (2.22)$$

De acuerdo a la ecu. (2.22), el gradiente local para una neurona es igual al producto del error que esta neurona genera y la derivada de la función de activación asociada. Para este tipo de red con varias capas se afrontaran cálculos para dos tipos de neuronas. En el primer caso la Neurona  $j$  es un nodo de salida. En este caso se puede aplicar simplemente la ecu. (2.20), tomando en cuenta que el gradiente local está determinado por los valores del error y la derivada de la función de activación datos que son conocidos debido a que el error a la salida de cada neurona es conocido y está determinado por la ecu. (2.17). De aquí se infiere que para las neuronas ocultas el error que se genera es desconocido y por lo tanto se debe emplear otro tipo de análisis que permita al algoritmo determinar el valor adecuado de delta en cada peso para que el error a la salida sea mínimo. Se dice entonces que el error se debe propagar de la capa de salida hacia la capa de entrada, razón por la cual, este algoritmo se conoce como de Propagación hacia atrás o Back Propagation (BP). El gradiente local se calcula mediante ecu. (2.23) de la siguiente forma:

$$\begin{aligned} &\text{Ecuación 2.23 Gradiente local.} \\ \delta_j(n) &= e_j(n)\varphi'(v_j(n)) \sum_k \delta_k(n) \omega_{kj}(n) \end{aligned} \quad (2.23)$$

En este caso el gradiente es igual al producto de la derivada de la función de activación asociada y la sumatoria, amplificada por los pesos, de los gradientes locales calculados para las neuronas de las siguientes capas conectadas a la neurona  $j$ . Se puede decir finalmente que para calcular el error de las neuronas ocultas es necesario determinarlas recursivamente usando el error de todas sus neuronas conectadas [144].

El método estándar para calcular los gradientes locales se conoce como el método del gradiente descendiente ya que los pesos se mueven en dirección del negativo del gradiente sobre la superficie de error. El cálculo del gradiente local implica obtener la derivada de la función de activación por lo que es importante que la función de activación sea diferenciable. Esta propiedad hace que el perceptrón multicapa sea adecuado para este tipo de entrenamiento debido a que las neuronas de su arquitectura utilizan funciones de activación diferenciables como lo es la función Sigmoide [144].

Como se puede observar en la ecu. (2.21), la delta de los pesos depende también de un factor conocido como coeficiente de velocidad de aprendizaje  $\eta$  el cuál se mantiene fijo para todas las deltas de manera que se puede controlar la velocidad con que el algoritmo debe converger al punto mínimo. En este momento es importante resaltar que la superficie de error que se genera por la combinación de pesos, en una red del tipo multicapa, es completamente distinta a la generada por una red lineal. En este caso la superficie de error tiende a tener más de un mínimo.

Si se tiene esto en consideración es importante que el algoritmo no sea muy acelerado al ir en busca del mínimo ya que podría hacer que el sistema se volviera inestable o se perdiera en un mínimo local [144]. Es decir, que un valor muy grande de  $\eta$  haría que el algoritmo oscile indefinidamente en busca del mínimo global. Teniendo en cuenta lo anterior mencionado, es importante que el valor de  $\eta$  no sea muy alto para evitar este problema, en la práctica  $\eta$  debería ser dependiente de la conexión con cada neurona ya que algunos pesos se deben ajustar más rápido que otros.

### 2.5.6 Propiedades del perceptrón multicapa.

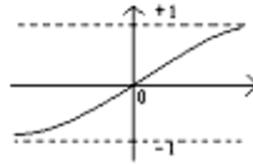
La arquitectura del perceptrón multicapa mostrada en la Fig. (2.11) presenta un modelo de capas de neuronas cuya función de activación es una función que trabaja en zonas no lineales. Como ya se ha visto con anterioridad es importante que esta función de activación sea diferenciable para poder aplicar el algoritmo de propagación hacia atrás. Hasta este momento sólo se conoce la función sigmoide la cual viene representada en la Fig. (2.10) y cuya expresión queda expresada con la ecu. (2.24):

Ecuación 2.24 Función sigmoide.

$$\varphi(v) = \frac{1}{1+\exp(-v)} \quad (2.24)$$

Las neuronas sigmoideas presentan la mayor pendiente cuando las neuronas trabajan más cerca de su rango medio. Por el contrario, cuando las neuronas trabajan cerca de sus límites la pendiente es mínima y tiende a cero. Esta es la razón por la cual se debe buscar que las neuronas sigmoideas se entrenen con salidas destino entre .1 y .9 y no en 0 y 1 ya que en los límites de la sigmoide, la derivada se aproxima a cero y

entonces el cambio de los pesos del algoritmo de propagación hacia atrás será mínimo haciendo más lento el aprendizaje [145]. Ver Fig. (2.12).



$$\varphi(v) = \frac{1 - \exp(-v)}{1 + \exp(-v)}$$

Figura 2.12 Función de activación tangente hiperbólica.

La función tangente hiperbólica presenta ciertas ventajas en relación a la sigmoidea debido a que su rango de salida va de -1 a 1, esto permite que la función se considere simétrica ya que cumple con  $\phi(-v) = -\phi(v)$  y entonces el perceptrón multicapa entrenado con Back Propagation aprende más rápido en términos del número de iteraciones requerido.

En el caso de que se intente obtener modelos de funciones por medio de la red neuronal, es decir, una aproximación de funciones lineales o no lineales es importante tener en la capa de salida neuronas lineales y usar funciones de activación de tangente hiperbólica en las demás capas. Esto es debido a que las neuronas de salida lineal permiten acceder a rangos de salida distintos a cero y uno y de esta manera la aproximación a la salida será más cercana al destino deseado. Las neuronas no lineales en las capas ocultas permitirán a la red aprender las no linealidades que posiblemente se encuentren en la función a aproximar. Para el problema de la detección de intrusos no se está haciendo un modelado de función sino más bien una clasificación de patrones por lo que probablemente sea conveniente que todas las neuronas sean no lineales [145].

Por otro lado siempre se puede topar con el problema de la saturación incorrecta de las neuronas, esto sucede cuando el algoritmo de entrenamiento se estanca en un mínimo local o superficial de manera que las neuronas se saturan antes de tiempo provocando que trabajen cerca de los límites de la función que es justo donde la pendiente se aproxima a cero por lo que los cambios en los pesos ocurrirán mínimos.

Para evitar este problema se recomienda que los pesos se inicialicen uniformemente distribuidos dentro de un rango pequeño para evitar que la función de activación se dispare a zonas de saturación. Además, será importante mantener bajo el número de neuronas ocultas debido a que el uso de neuronas extras puede acarrear consecuencias graves como que la red aprenda idiosincrasias en los patrones evitando un conocimiento acertado y se debe procurar trabajar a las neuronas en la zona media donde se considera que la región es lineal [145]. Se recuerda que un buen ajuste es logrado con el modelo de red más simple adecuado al problema.

A continuación se hablará de dos formas en las que se puede entrenar una red neuronal en cuanto a la presentación de los datos a la red y los ajustes que se llevan a cabo, en el primer caso se tiene al entrenamiento de patrón por patrón, en el cuál a la red se le presenta un patrón e inmediatamente después se realiza la propagación hacia atrás ajustando los pesos. Este modo de entrenamiento es útil debido a que el ajuste de los pesos sucede aleatorio debido a que con cada patrón surge un nuevo ajuste de pesos, de esta manera se evita al algoritmo de caer en un mínimo local y ocupa menos memoria, ya que no almacena los cambios. En cambio el otro caso de entrenamiento corresponde al modo de conjunto de datos o Batch, en el cual los datos se presentan a la red y el cálculo de la modificación en los pesos se almacenan hasta que todas las muestras han sido presentadas a la red, en este momento se modifican los pesos con la suma de las modificaciones almacenadas. Este algoritmo es bueno debido a que estima de manera más precisa el vector gradiente y es más eficiente computacionalmente. En general se maneja que el método de Batch es el más adecuado para los problemas de clasificación y detección de patrones como lo es el problema en cuestión. A la presentación de todo el conjunto de muestras a la red neuronal se le llama epoch, se recomienda para cualquiera de los casos mencionados anteriormente que el orden de las muestras sea aleatorizado de epoch en epoch para aumentar la velocidad de convergencia. Y en este momento se destaca la verdadera importancia que tiene el hecho de que se le permita al algoritmo converger rápidamente hacia un mínimo. La cuestión de la velocidad de convergencia es importante debido a que representa una menor pérdida de tiempo al entrenar la red, y por otro lado asegurará de que la red trabaje correctamente con el conjunto de datos

de entrenamiento mostrado. Sin embargo se debe aclarar que el hecho de que el algoritmo converja a un valor pequeño no implica una buena generalización.

Las redes del tipo perceptrón multicapa que se entrenan apropiadamente tienden a ofrecer razonables respuestas cuando son puestas a prueba con entradas que nunca han visto. Esta propiedad de generalización hace posible entrenar a la red con un paquete representativo de pares de entradas y destinos esperados y obtener buenos resultados sin necesidad de entrenar a la red con todos los pares posibles de entradas y salidas. Se puede ver a la red neuronal como un elemento para hacer mapeo no lineal de entradas y salidas en un problema de ajuste de curva, en un supuesto de contar con un número infinito de muestras, el error al evaluar la red, es mínimo, sin embargo la idea es que con pocas muestras se pueda lograr la generalización. No obstante, la generalización no siempre se logra aunque la reducción del error siempre se puede lograr. Debido a que la idea es que la red tenga una buena generalización, se determinarán los factores que influyen en esta tarea y que son el tamaño y eficiencia del conjunto de datos de entrenamiento, la arquitectura de la red y la complejidad física del problema. El último punto no se puede controlar, sin embargo, los dos primeros sí. Una vez que la arquitectura de la red ha sido fijada de acuerdo a la complejidad física del problema se puede utilizar la ecu. (2.25), que propone [146], para determinar el tamaño del conjunto de datos está determinado por:

Ecuación 2.25 Conjunto de datos.

$$N \geq \frac{W}{\varepsilon} \quad (2.25)$$

Donde  $W$  es el número de pesos de la red y  $\varepsilon$  es la fracción de error permitido que generalmente se puede establecer en .01, de manera que se puede asegurar que el número de muestras permitirá a nuestra red generalizar correctamente.

### **CAPÍTULO 3. PROCEDIMIENTO DE INVESTIGACIÓN**

El presente capítulo explica de forma detallada la arquitectura del sistema inteligente propuesto para el reconocimiento-clasificación de patrones a través de una RNA así como la estimación del deterioro de forma cuantitativa a partir de lógica difusa, la arquitectura del sistema y diagrama de flujo de la información en el mismo se muestra en la Fig. (3.1). En la investigación se proponen dos técnicas para generar una señal de entrada a la RNA, la primera es a partir de un histograma y la segunda es por medio de estadísticos de primero, segundo y tercer orden. Es importante marcar la diferencia entre el histograma utilizado como señal de entrada a la RNA y un histograma que representa los niveles de intensidad. El primero se construye a partir de la suma de las columnas de la matriz que compone la imagen procesada digitalmente y el segundo representa el número de píxeles que tienen colores en cada una de las listas fijas de rangos de colores, que se extienden sobre el espacio de color de la imagen, es decir, el conjunto de todos los posibles colores.

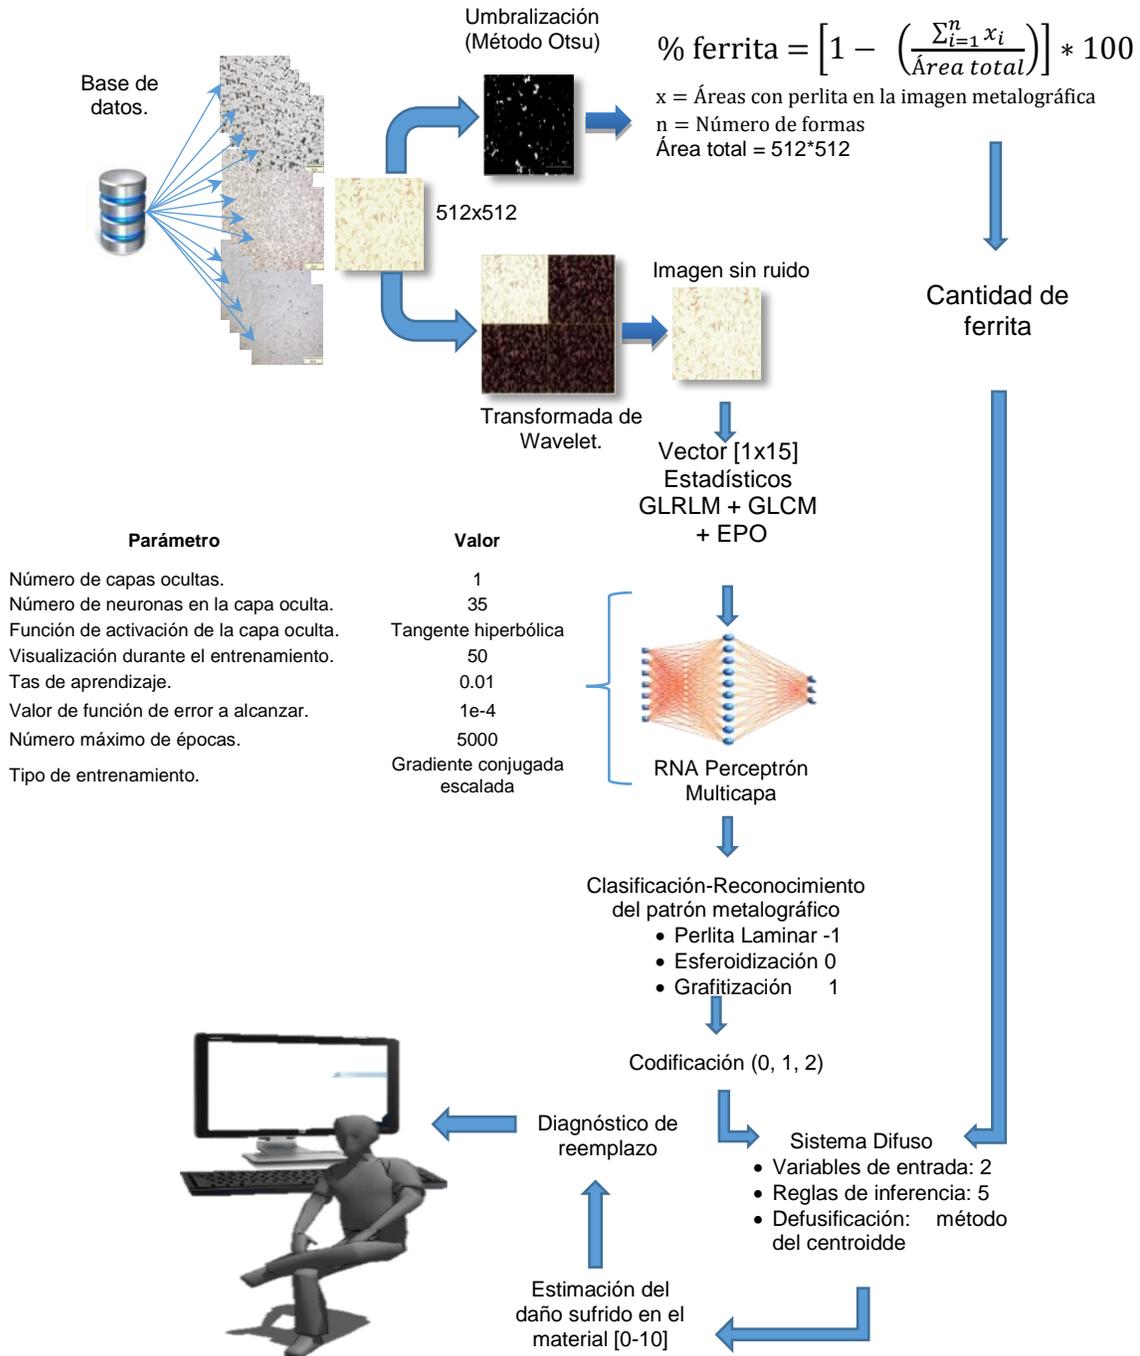


Figura 3.1 Metodología propuesta para el desarrollo del sistema inteligente.

### 3.1 PROCESAMIENTO DIGITAL DE LA IMAGEN

El procesamiento digital de la imagen inicia con la obtención de la imagen metalográfica, que consta de operaciones consecutivas. De acuerdo con [147], la primera operación es cortar el material afectado, así se analizan pequeñas secciones

que permitan revelar información sobre las causas que propiciaron el daño en el material. El segundo paso es la fabricación de una probeta con resina epóxica, lijada y pulida con una solución de carburo de silicio hasta obtener un acabado espejo posteriormente se aplica una solución Nital sobre la probeta con una concentración de 4% durante cinco segundos para revelar la microestructura. Finalmente, la muestra es observada por un experto usando un microscopio invertido metalográfico (Olympus - GX71) y un analizador de imágenes (Analysis Five). Una vez tomada la imagen puede ser almacenada o distribuida para su futuro procesamiento.

### 3.1.1 Caracterización de la imagen metalográfica por medio de un histograma

El procesamiento digital de imágenes tiene que ver con la adquisición, transmisión, procesamiento y representación de las imágenes. Las técnicas de procesamiento digital de imágenes se utilizan con el propósito de mejorar la apariencia visual para un observador y preparar convenientemente el contenido fotográfico de cara a la percepción por parte de máquinas y en éste caso la red neuronal artificial. Se presenta un diagrama de flujo indicando las operaciones en el proceso de extracción y limpieza de ruido en la imagen metalográfica obtenida de los materiales para generar un histograma que caracterice de forma correcta la imagen metalográfica y sirva como señal de entrada a la red neuronal artificial para una eficiente clasificación-reconocimiento. Ver Fig. (3.2).

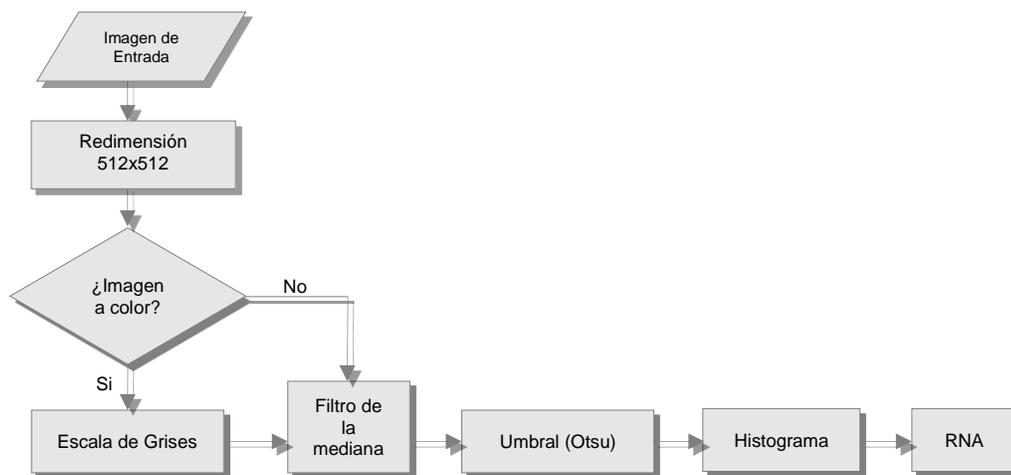


Figura 3.2 Diagrama de proceso para el procesamiento de la imagen metalográfica.

**Redimensión de la imagen:** La redimensión es una parte del pre-procesamiento de las imágenes que persigue la homogenización del tamaño en las imágenes de entrada, después de probar diferentes tamaños como: [1024 x 1024]; [512 x 512] y [256 x 256], se concluye que la mejor opción es [512 x 512] ya que la dimensión de la imagen define la longitud del histograma, el histograma es la entrada a la red neuronal y de ser muy grande como una imagen de [1024 x 1024] se reduce la eficiencia de computo de la red neuronal, por otro lado al tener una dimensión de la imagen de [256 x 256] se reduce la resolución de la imagen ocasionada por la eliminación de pixeles al reducir la imagen, lo que resulta en un reconocimiento y clasificación de la red neuronal incorrecto. En la Fig. (3.3), se muestra la redimensión de la imagen del patrón metalográfico grafitización y perlita laminar.

(a)	(b)
(c)	(d)

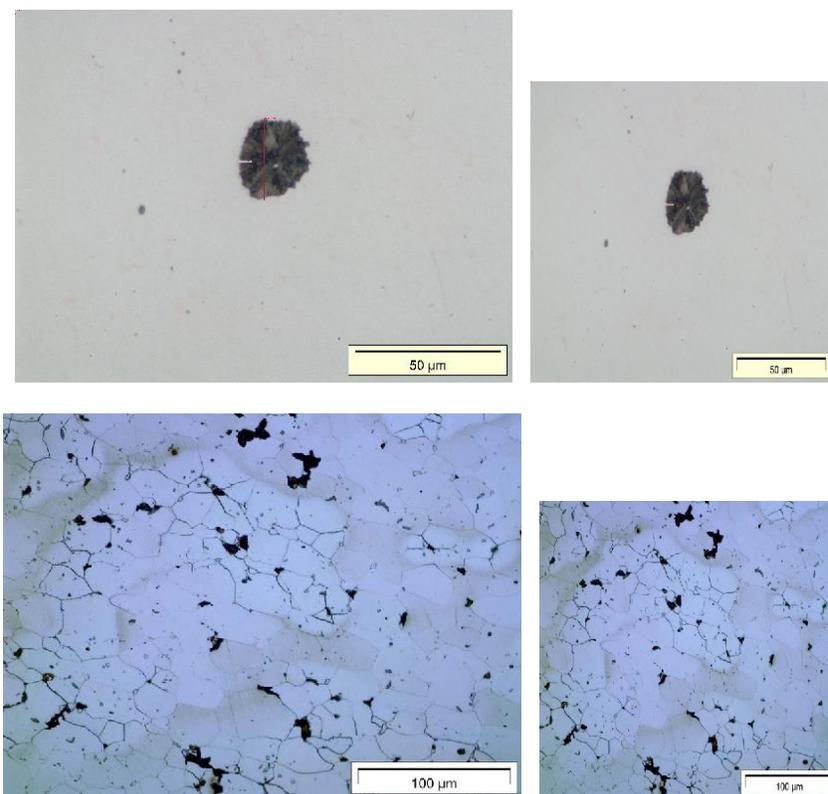


Figura 3.3 Redimensión de la imagen. (a) Imagen original del patrón grafitización [3072 x 4080]. (b) Redimensión de (a) [512 x 512]. (c) Imagen original del patrón perlita laminar [602 x 800]. (d) Redimensión de (c) [512 x 512].

**Filtrado de la imagen:** El filtrado se aplica para resaltar o atenuar detalles espaciales con el fin de mejorar la interpretación visual o facilitar un procesamiento posterior, y constituye una de las técnicas comprendidas dentro del realce de imágenes. El filtro utilizado en el pre-procesamiento de la imagen metalográfica es un *filtro de mediana*, el cual está clasificado como un filtro pasa bajas cuya respuesta está basada en reemplazar el pixel central por la mediana de los pixeles contenidos en una máscara de [3x3]. En la Fig. (3.4) y (3.5), se muestra el resultado del filtro de la mediana en las imágenes metalográficas con su respectivo histograma, calculado a partir de la suma de las columnas de la imagen.

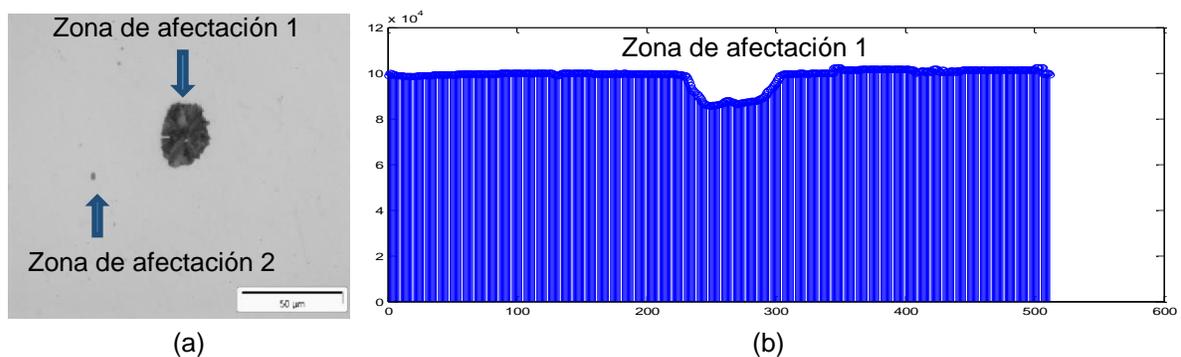


Figura 3.4 Filtro de la imagen grafitización e histograma (a) Filtro de la imagen (b) Histograma.

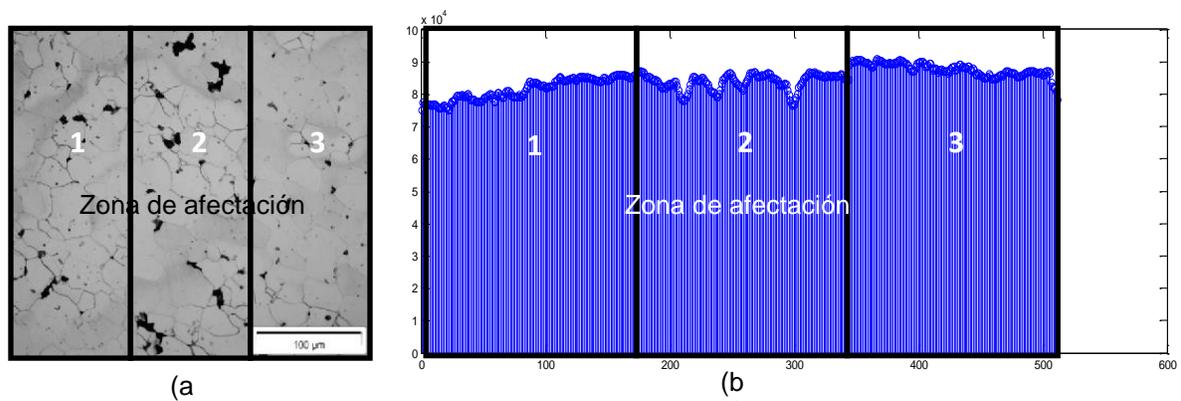


Figura 3.5 Filtro de la imagen perlita laminar e histograma (a) Filtro de la imagen (b) Histograma.

El histograma después de aplicar el filtro de la mediana para el patrón metalográfico grafitización no muestra con detalle las zonas de afectación, queda demostrado al observar que la zona de afectación 2 no figura en dicho histograma. Ver Fig. 3.4 (a) y 3.4 (b). En el patrón metalográfico perlita laminar la zona de afectación 1 no se refleja

de forma clara dentro del histograma generado a partir de la imagen metalográfica. Ver Fig. 3.5 (a) y 3.5 (b). Al no tener detalle en el histograma que muestre las zonas de afectación dentro de la imagen no es posible proporcionar una adecuada señal de entrada a la red neuronal artificial para la clasificación-reconocimiento del patrón metalográfico presente en la imagen. Por lo cual se recomienda una segmentación de la imagen.

**Segmentación de la imagen:** La segmentación es una etapa del procesamiento digital de imágenes que ubica y destaca elementos de una imagen. Uno de los métodos que se emplean para generar la segmentación de una imagen es el umbralizado. Si bien hay diferentes métodos para hallar un umbral, la mayoría de ellos no dan buenos resultados cuando se trabaja con imágenes del mundo real debido a la presencia de ruido, histogramas planos o una iluminación inadecuada. Por el contrario, el método de Otsu es uno de los mejores métodos de selección de umbral para imágenes del mundo real, por lo tanto fue el método seleccionado para realizar la segmentación por umbralización dentro de las imágenes.

El método de Otsu considera que el histograma es bimodal. Por otro lado, este itera a lo largo del histograma calculando para cada valor estimado posible de  $T$  [0 hasta 255] la varianza de pesos dentro de cada clase. El umbral óptimo se logra cuando la varianza entre clases entregue un valor mínimo. La varianza entre clases se calcula mediante la ecu. (3.1). En la Fig. (3.6) se muestra un ejemplo para el cálculo del umbral de acuerdo al método Otsu.

Ecuación 3.1 Varianza entre clases.

$$\sigma_w^2(t) = P_1(t)\sigma_1^2(t) + P_2(t)\sigma_2^2(t) \quad (3.1)$$

Donde las probabilidades de cada clase se determinan con la ecu. (3.2) y ecu. (3.3)

Ecuación 3.2 Probabilidad de cada clase.

$$P_1(t) = \sum_{i=0}^t p(i) \quad (3.2)$$

Ecuación 3.3 Probabilidad de cada clase.

$$P_2(t) = \sum_{i=t+1}^{255} p(i) \quad (3.3)$$

Y los promedios de clase a través de las ecuaciones en la ecu. (3.4) y ecu. (3.5)

Ecuación 3.4 Promedios de clases.

$$\mu_1(t) = \frac{\sum_{i=0}^t p(i)}{P_1(t)} \quad (3.4)$$

Ecuación 3.5 Promedio de clase.

$$\mu_2(t) = \frac{\sum_{i=t+1}^{G-1} i * p(i)}{P_2(t)} \quad (3.5)$$

Con las varianzas de cada clase presentadas mediante la ecu. (3.6) y ecu. (3.7)

Ecuación 3.6 Varianza de cada clase.

$$\sigma_1^2(t) = \sum_{i=0}^t [i - \mu_1(t)]^2 \frac{p(i)}{p_1(t)} \quad (3.6)$$

Ecuación 3.7 Varianza de cada clase.

$$\sigma_2^2(t) = \sum_{i=t+1}^{255} [i - \mu_2(t)]^2 \frac{p(i)}{p_2(t)} \quad (3.7)$$

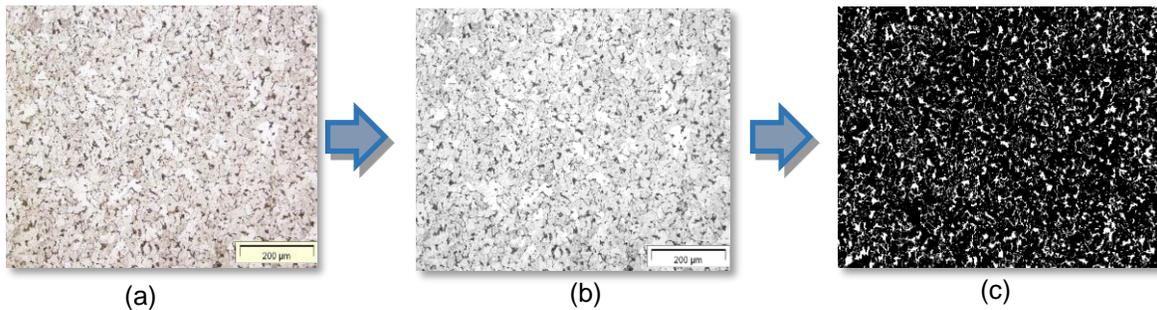


Figura 3.6 Segmentación del patrón metalográfico perlita laminar mediante el Método Otsu.

El umbral óptimo según el metodo Otsu para este caso se obtiene cuando  $t = 171$ , resultando la imagen umbralizada con este valor. La mayor varianza ( $1.4426e+03$ ) entre clases se obtiene con dicho umbral.

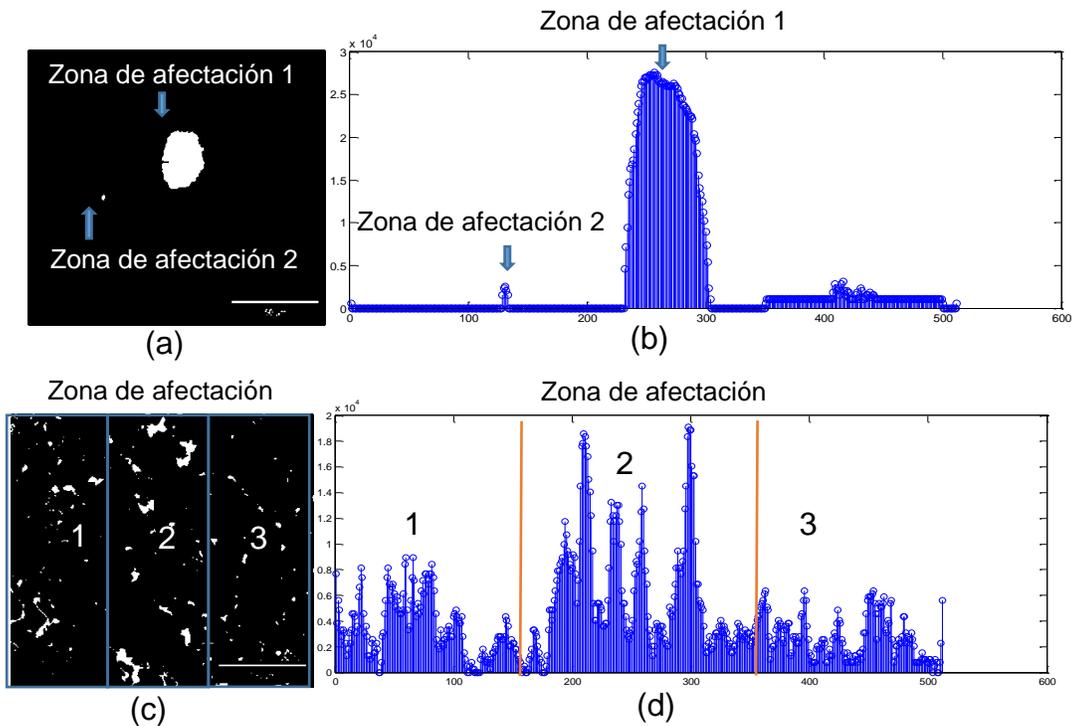


Figura 3.7 Segmentación de la imagen. (a) Patrón grafitización. (b) Histograma. (c) Patrón perlita laminar. (d) Histograma.

**Histograma:** El histograma es generado por medio de la suma de las columnas de la matriz que representa a la imagen, mediante el histograma se genera la señal de entrada a la red neuronal artificial, por ello la importancia en la fase de umbralización ya que al producir una señal de entrada detallada sobre la zona afectada en la imagen metalográfica se incrementa la eficiencia de la red neuronal artificial en la clasificación-reconocimiento del patrón de metalográfico presente en el material.

En la Fig. 3.7 (a) y 3.7 (b), se demuestra la importancia de la fase de umbralizado obteniendo los beneficios de una correcta localización y separación de la zona afectada en la imagen metalográfica con el patrón grafitización, a diferencia del histograma calculado en la Fig. 3.4 (b), ya que después de la operación de umbralización es posible detectar la zona de afectación 2. En la Fig. 3.7 (c) y 3.7 (d), se manifiesta con más detalle la zona afectada dentro de la imagen metalográfica con el patrón metalográfico perlita laminar.

En la Fig. (3.8) y (3.9), se muestra la fase de pre-procesamiento (a, b) y procesamiento (c, d) de las imágenes que presentan los patrones metalográficos grafitización y perlita laminar, generando el histograma correspondiente que funcionará como señal de entrada a la RNA permitiendo la clasificación-reconocimiento de patrones metalográficos.

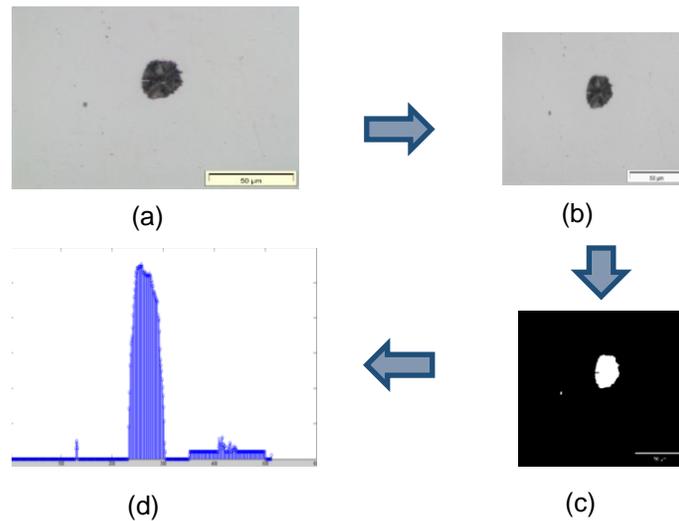


Figura 3.8 Grafitización procesamiento digital. (a) Imagen original. (b) Redimensión y escala de gris. (c) Cálculo de umbral. (d) Cálculo de Histograma.

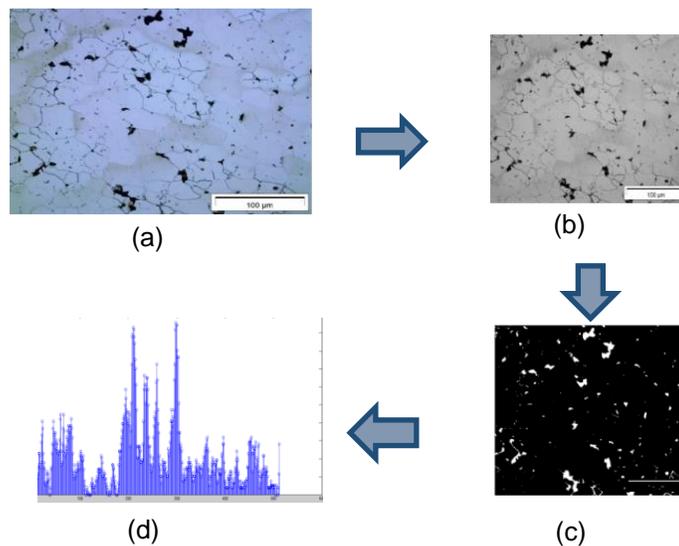


Figura 3.9 Perlita laminar procesamiento digital. (a) Imagen original. (b) Redimensión y escala de gris. (c) Cálculo de umbral. (d) Cálculo de Histograma.

### 3.1.2 Caracterización de la imagen metalográfica por medio de estadísticos

La caracterización por medio de estadísticos hace uso de la transformada Wavelet sobre la imagen metalográfica, la transformada es utilizada con el fin de obtener de las señales un conjunto de características en el plano Tiempo-Frecuencia. Lo cual resuelve el problema en caso de que una imagen presente características aperiódicas importantes [148]. Existen diversas formas de generalizar las transformadas wavelet 1D a 2D para poder ser empleadas en imágenes. Se necesita una función de escalado 2D  $\varphi(x, y)$  y tres de wavelets 2D:  $\Psi^H(x, y)$ ,  $\Psi^V(x, y)$  y  $\Psi^D(x, y)$ , que son separables ecu. (3.8):

Ecuación 3.8 Transformada Wavelet.

$$\varphi(x, y) = \varphi(x)\varphi(y), \psi^H(x, y) = \psi(x)\varphi(y), \psi^V(x, y) = \varphi(x)\psi(y), \psi^D(x, y) = \psi(x)\psi(y) \quad (3.8)$$

Ahora las funciones de base 2D son:

Ecuación 3.9 Función de base 2D.

$$\varphi_{j,m,n}(x, y) = 2^{j/2} \varphi(2^j x - m, 2^j y - n) \quad (3.9)$$

Ecuación 3.10 Función de base 2D.

$$\psi^i_{j,m,n}(x, y) = 2^{j/2} \psi^i(2^j x - m, 2^j y - n) \quad (3.10)$$

Dónde:

$\varphi_{m,n}(x, y)$  = Funciones de escalonado

$\psi_{m,n}^i(x, y)$  = Función wavelet madre obtenida mediante escalado ( $m$ ) y traslación ( $n$ )

Siendo:  $i = \{H (Horizontal), V (Vertical), D (Diagonal)\}$

Dada una imagen y aplicando la ecu. (3.9) y ecu. (3.10), la transformada Wavelet la descompone en una sub-imagen de baja frecuencia y un conjunto de detalles de alta frecuencia. Ver Fig. (3.10); 3.10 (a) imagen original, 3.10 (b), 3.10 (c) y 3.10 (d) descomposición horizontal, vertical y diagonal respectivamente. 3.10 (e) Imagen reconstruida.

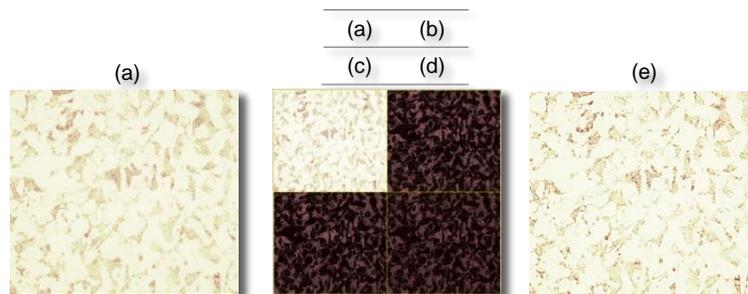


Figura 3.10 Aplicación de la transformada de Wavelet.

Una vez aplicada la descomposición wavelet, es necesario extraer un vector de características que permita caracterizar la textura.

### 3.1.3 Extracción de estadísticos

Los estadísticos de primero, segundo y tercer orden generados a partir de la imagen metalográfica, son calculados a través de las operaciones entre píxeles mediante las fórmulas matemáticas presentadas en la Tabla 3.1, [83]. El total de estadísticos descriptores calculados de la textura en la imagen metalográfica son convertidos en la señal de entrada a la red neuronal artificial, de aquí que la red neuronal es entrenada y probada mediante vectores de tamaño [1x15]. El procedimiento general para obtener cada uno de los estadísticos se muestra en la Fig. (3.11).



Figura 3.11 Proceso para la obtención de estadísticos.

Los estadísticos de primer orden (EPO) son descriptores que solo consideran la intensidad,  $p(i, j)$  de cada pixel en la región. La matriz de coocurrencia de niveles de gris GLCM genera los estadísticos de segundo orden, parten de histogramas bidimensionales que representan la dependencia espacial entre dos niveles de gris separados una cierta distancia  $d$  a lo largo de una dirección  $\theta$  [83].

Los estadísticos de tercer orden son calculados a partir de la matriz de longitud de secuencia de nivel de gris, más conocida por sus siglas en inglés como GLRLM, es un histograma bidimensional donde el elemento  $(i, j)$  representa el número de veces que aparece una secuencia de nivel de gris  $i$  con longitud  $j$  Ec.(3.11). Se consideran las cuatro direcciones principales para la búsqueda de secuencias ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$ ), obteniendo cuatro matrices GLRLM. Ver Fig. (3.12). Por lo cual, es necesario aplicar un conjunto de estadísticos sobre cada una de estas matrices, énfasis en secuencias cortas o SRE (Short Run Emphasis), énfasis en secuencias largas o LRE (Long Run Emphasis), no uniformidad en el nivel de gris o GLN (Grey Level Nonuniformity), no

uniformidad en la longitud de secuencia o RLN (Run Length Nonuniformity) y porcentaje de secuencia o RP (Run Percentage), énfasis en secuencias de nivel de gris bajo o LGRE (Low Grey Level Run Emphasis) y énfasis en secuencias de nivel de gris alto o HGRE (High Grey Level Run Emphasis).

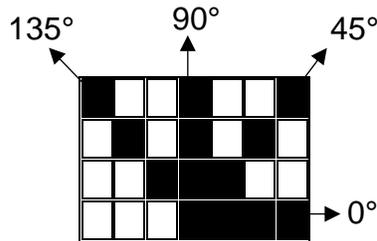


Figura 3.12 Dirección de búsqueda de secuencias.

Ecuación 3.11 Dirección de búsqueda de secuencia.

$$(R(\theta) = (g(i, j)|\theta), 0 \leq i \leq N_g, 0 \leq j \leq R_{max} \quad (3.11)$$

Tabla 3.1 Características estadísticas.

Primer orden		Segundo orden	Tercer orden	
<b>Desviación estándar</b>	$\sqrt{\frac{\sum_{i=1}^N (i-\mu)^2 h(i)}{N}}$	<b>Contraste</b>	<b>SRE</b>	<b>RP</b>
		$\sum_{n=0}^{N_g-1} i^2 \left\{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j),  i-j =n \right\}$	$\frac{1}{n} \sum_{i,j} \frac{P(i,j)}{j^2}$	$\sum_{i,j} \frac{n}{P(i,j)}$
<b>Kurtosis</b>	$\sum_{i=1}^N [(i-\mu)^4 h(i)] - 3$	<b>Correlación</b>	<b>LRE</b>	<b>LGRE</b>
		$\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{(i-\mu_x)(j-\mu_y)p(i,j)}{\sigma_x \sigma_y}$	$\frac{1}{n} \sum_{i,j} j^2 P(i,j)$	$\frac{1}{n} \sum_{i,j} \frac{P(i,j)}{i^2}$
<b>Entropía</b>	$-\sum_{g=0}^{L-1} P(g) \text{Log}_2[P(g)]$	<b>Energía</b>	<b>GLN</b>	<b>HGRE</b>
		$\sqrt{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (p(i,j))^2}$	$\frac{1}{n} \sum_i (\sum_j P(i,j))^2$	$\frac{1}{n} \sum_{i,j} i^2 P(i,j)$
<b>Oblicuidad</b>	$\sum_{i=1}^N (i-\mu)^3 h(i)$	<b>Homogeneidad</b>	<b>RLN</b>	
		$\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{1}{1+(i-j)} p(i,j)$	$\frac{1}{n} \sum_i (\sum_i P(i,j))^2$	

### 3.1.4 Porcentaje de fases

El cálculo del porcentaje de fases en una imagen metalográfica es un mecanismo que permite medir la cantidad de ferrita en el material de acero al carbón, un material sin afectación inicia con un porcentaje alrededor del 80% de ferrita la cual se incrementa conforme es utilizado el acero en condiciones específicas de acuerdo con el diagrama de fases hierro-carbono ( $Fe - C$ ). El procesamiento para determinar la cantidad de ferrita presente en cualquier imagen metalográfica se describe en las Fig. (3.13) y (3.14). En 3.14 (a) imagen con tamaño [1024 x 1024], 3.14 (b) redimensión [512 x 512] y escala de gris 3.14 (c) fase de umbralización mediante el método Otsu, como

consecuencia de la umbralización únicamente quedan activados los píxeles ligados a la presencia de perlita. En 3.14 (d) se localizan las áreas de perlita, la operación devuelve un escalar que especifica el número real de píxeles en cada región. Por diferencia se obtiene la cantidad de ferrita empleando la ecu. (3.12).

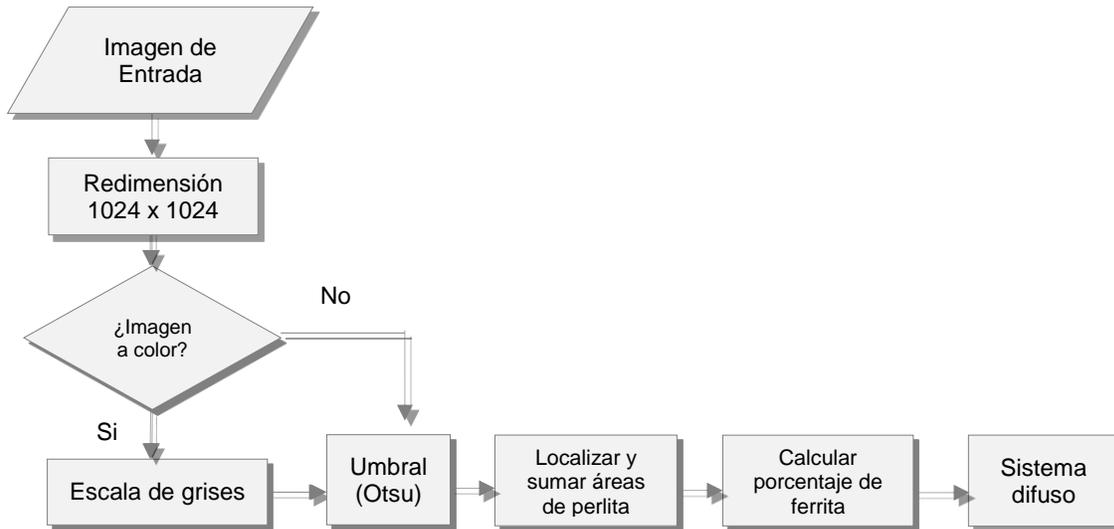


Figura 3.13 Diagrama de proceso para calcular el porcentaje de ferrita.

Ecuación 3.12 Cálculo de porcentaje de ferrita.

$$\% \text{ ferrita} = \left[ 1 - \left( \frac{\sum_{i=1}^n x_i}{\text{Área total}} \right) \right] * 100 \quad (3.12)$$

Dónde:

x = Total de píxeles presentes en las regiones detectadas con presencia de perlita en la imagen metalográfica

n = Regiones con presencia de perlita en la imagen metalográfica

Área total = 512 \* 512

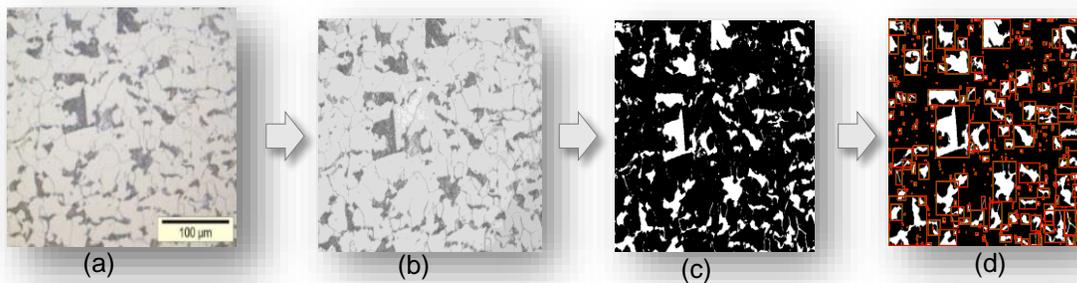


Figura 3.14 Etapas para el cálculo del porcentaje de ferrita.

### 3.2 Clasificación-reconocimiento de patrones metalográficos

El conjunto de patrones empleados para entrenar y probar a la RNA se llevó a cabo por medio de una base de datos de 194 imágenes metalográficas afectadas por patrones previamente reconocidos e identificados por expertos de LAPEM. La composición de la matriz se muestra en la Tabla 3.2. El procedimiento para entrenar y probar a la RNA a partir de los estadísticos calculados y llevar a cabo la tarea de clasificación-reconocimiento se muestra en la Fig. (3.15).

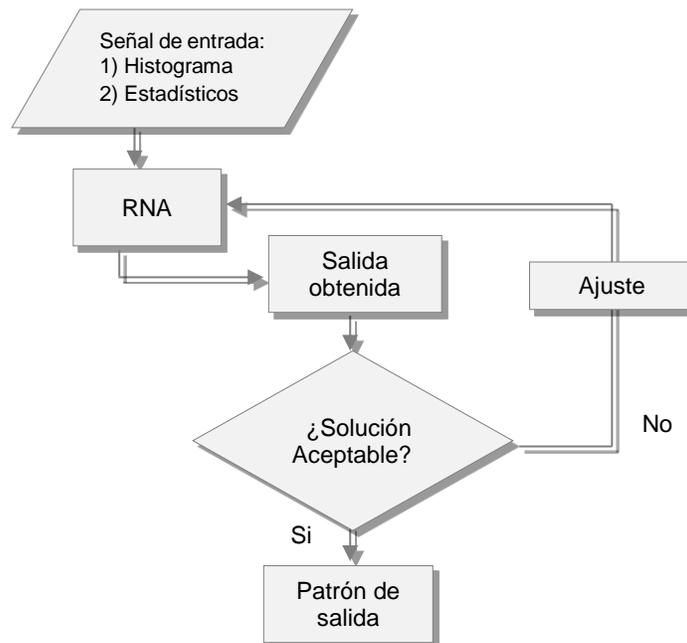


Figura 3.15 Procedimiento de clasificación-reconocimiento.

El ajuste corresponde a la acción de modificar parámetros que integran la topología de la red neuronal artificial hasta obtener una combinación de parámetros que arroje una solución aceptable de la clasificación presentada a la red neuronal desarrollada.

Tabla 3.2 Dimensión de la matriz de entrenamiento y prueba.

	Histograma		Estadísticos	
	Entrenamiento	Prueba	Entrenamiento	Prueba
Total de Imágenes	84	110	84	110
Patrón Metalográfico	Dimensión	Dimensión	Dimensión	Dimensión
Perlita Laminar	28x512	31x512	28x15	31x15
Esferoidización	34x512	47x512	34x15	47x15
Grafitización	22x512	32x512	22x15	32x15

La función de activación en la arquitectura de la RNA es una tangente hiperbólica. Se asigna el valor de (-1) al patrón perlita laminar, (0) esferoidización y (1) grafitización. Las topologías de redes neuronales artificiales propuestas en la Tabla 3.3, son topologías entrenadas mediante la técnica del histograma, las presentadas en la Tabla 3.4, son entrenadas mediante la técnica de estadísticos. Dichas topologías son las que mejor se ajustan a los 84 valores objetivos del patrón metalográfico correspondiente en la fase de entrenamiento es por ello que se recurre a un parámetro estadístico como el error cuadrático medio (MSE) para determinar que arquitectura será seleccionada y posteriormente usada en la fase de prueba con las 110 imágenes restantes.

Tabla 3.3 Topologías entrenadas por histograma.

Topología	No. de Neuronas en la capa oculta	Tasa de aprendizaje	Error permitido	Épocas	Coefficiente de Correlación. R	Error Cuadrático Medio. MSE
1	22	0.01	1e-5	3000	0.99992	7.40742E-05
2	22	0.01	1e-5	5000	0.99999	0.000139443
3	22	0.01	1e-3	5000	0.99924	0.002763031
4	22	0.005	1e-5	5000	0.99995	0.000298984
5	23	0.01	1e-5	3000	0.99989	0.000498906
6	21	0.01	1e-5	3000	0.99956	0.001839077
7	22	0.005	1e-5	3000	0.99839	0.014691897

Tabla 3.4 Topologías entrenadas mediante estadísticos.

Topología	No. de Neuronas en la capa oculta	Tasa de aprendizaje	Error permitido	Épocas	Coefficiente de Correlación. R	Error Cuadrático Medio. MSE
1	35	0.01	1e-4	5000	0.99978	0.00012423
2	35	0.01	1e-4	3000	0.99912	0.00023656
3	37	0.01	1e-5	5000	0.99964	0.00345781
4	37	0.005	1e-4	5000	0.99923	0.00032188
5	34	0.01	1e-5	5000	0.99687	0.00124365

Las topologías detalladas de las redes neuronales artificiales numero 1 presentan un menor MSE, por lo tanto serán utilizadas en la fase de prueba. Ver Tabla 3.5.

Tabla 3.5 Topologías de RNA's seleccionas.

Parámetro	Histograma	Estadísticos
	Valor	Valor
Número de capas ocultas.	1	1
Número de neuronas en la capa oculta.	22	35

Función de activación de la capa oculta.	Tangente Hiperbólica	Tangente Hiperbólica
Visualización durante el entrenamiento.	50	50
Tasa de aprendizaje.	0.01	0.01
Valor de función de error a alcanzar.	1e-5	1e-4
Número máximo de épocas.	3000	5000
Tipo de entrenamiento.	Gradiente conjugada escalada	Gradiente conjugada escalada

### 3.3 Desarrollo del sistema de lógica difusa

Actualmente dentro del Laboratorio de Pruebas de Equipos y Materiales (LAPEM) de la Comisión Federal de Electricidad (CFE), la estimación del deterioro del material de acero al carbón SA 210 Grado A-1 se realiza mediante la experiencia del analista al observar el patrón de comportamiento presente en la imagen metalográfica y determinar el porcentaje de fases del material, después de este proceso el experto arroja un resultado cualitativo y lingüístico.

#### 3.3.1 Fusificación

La fusificación para la cuantificación de ferrita en la imagen metalográfica, se desarrolló generando tres funciones de pertenencia. La primera función se cataloga como *Normal* con un valor de pertenencia mayor en 80% de ferrita, este es el estado inicial comúnmente de un acero al carbón SA 210 y conforme es sujeto a condiciones de trabajo aumenta el porcentaje de ferrita. La segunda función presenta su valor máximo en 86% y se define como *Incremento Moderado* ambas funciones de pertenencia son del tipo *Gaussianas*. La última función de pertenencia es del tipo *Sigmoidea* y etiquetada como *Incremento Considerable*, esta función presenta un incremento positivo y posteriormente constante a partir de registrar un 89.5%, ya que a partir de este valor de acuerdo con los expertos el incremento en la ferrita es importante. La amplitud de las funciones de pertenencia se definió tomando como base un intervalo de confianza del 95% para la media, comprobando el supuesto de normalidad mediante el estadístico Anderson Darling respectivamente obteniendo  $p = 0.104$ ,  $p = 0.088$  y  $p = 0.94 > 0.05$ . El universo del discurso tiene un rango de [75, 95] ya que son los extremos de presencia de ferrita en un acero al carbón del tipo SA 210. Ver Fig. (3.16).

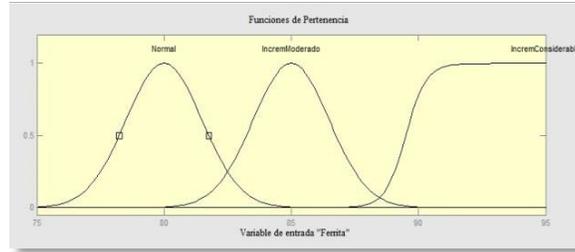


Figura 3.16 Fusificación del porcentaje de ferrita.

La fusificación de la entrada que analiza el patrón metalográfico clasificado y reconocido por la RNA es codificada añadiendo valores de salida para cada patrón metalográfico. El sistema difuso asigna a las salidas de la RNA un valor de (1) *perlita laminar*, (2) *esferoidización* y (3) *grafitización*, debido a que el sistema de lógica difusa realizado en *Matlab®2012<sup>a</sup>* no acepta valores negativos y es una opción de salida de la RNA. Las tres funciones de pertenencia son del tipo *Gaussianas* solo por la forma no debido a que sigan la distribución normal, cada función es etiquetada de acuerdo al patrón que representan y logrando su mayor grado de pertenencia en 1, 2 y 3 respectivamente, de esta forma queda definido el universo del discurso con valores entre [0, 4]. Ver Fig. (3.17).

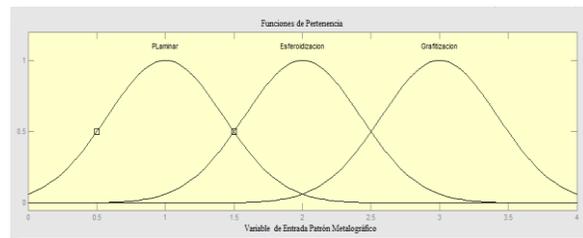


Figura 3.17 Fusificación patrón metalográfico.

La fusificación de la variable de salida está dada por la cantidad de diferentes variables lingüísticas que se manejan actualmente en la estimación del deterioro en el material de acero al carbón por expertos de LAPEM que son: *Sin afectación*, *incipiente*, *inicial*, *parcial* y *avanzada afectación*. Dado que son cinco etiquetas lingüísticas, se generan cinco funciones de pertenencia del tipo triangular, el universo del discurso es definido de [0, 10] ya que requiere emitir una estimación del deterioro del material de forma puntual en una escala de 0 a 10. El grado de pertenencia más alto para cada función es de 0 para la función *sin afectación* y va incrementando en 2.5 unidades hasta llegar

a 10 con la función *avanzada afectación*, de este modo será posible asignarle un valor cuantitativo posterior a la defusificación a cada una de las variables lingüísticas utilizadas hasta el momento. Ver Fig. (3.18).

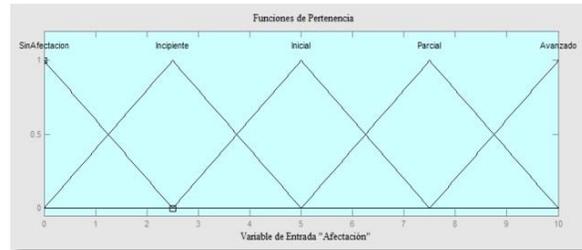


Figura 3.18 Fusificación estimación del daño.

### 3.3.2 Inferencia

El método utilizado para realizar la inferencia es el denominado método Mamdani el cual utiliza reglas tipo *si-entonces* (if-else). Una regla que pertenece a la base de conocimiento tiene dos partes, el antecedente y la conclusión como se observa en la Tabla 3.6. La inferencia está basada en dos entradas que son el porcentaje de fases y el patrón de comportamiento presente en el material y a partir del análisis de las dos variables se concluye en base a la única salida que es la estimación del deterioro del material de acero al carbón del tipo SA 210 grado A-1.

Tabla 3.6 Reglas de inferencia utilizadas en el sistema de lógica difusa.

Reglas de Inferencia
<i>If Ferrita is Normal and Patrón is PLaminar then Afectación is SinAfectacion</i>
<i>If Ferrita is IncremModerado and Patrón is PLaminar then Afectación is Incipiente</i>
<i>If Ferrita is IncremModerado and Patrón is Esferoidizacion then Afectación is Inicial</i>
<i>If Ferrita is IncremConsiderable and Patrón is Esferoidizacion then Afectación is Parcial</i>
<i>If Ferrita is IncremConsiderable and Patrón is Grafitizacion then Afectación is Avanzado</i>

El sistema difuso presentado no cuenta con 9 reglas de inferencia como dicta en [2], debido a que 5 reglas son las mínimas necesarias para explicar el deterioro del acero al carbón a partir del estudio del patrón metalográfico y el porcentaje de fases. Esto es debido a que existen reglas que no tendrían un fin práctico y una nula posibilidad de que ocurra tal como: un acero que contenga un nivel considerable de ferrita y una microestructura con un patrón de perlita laminar. Si el acero presenta niveles altos de

ferrita el acero ha sufrido afectaciones por temperatura y por lo tanto su microestructura no podría estar en una fase de perlita laminar.

### 3.3.3 Defusificación

La defusificación es un proceso matemático usado para convertir un conjunto difuso en un número real. Se empleó el algoritmo de Centro de Gravedad (CoG) para defusificar el valor de salida y obtener el escalar ecu. (3.13) [138].

Ecuación 3.13 Cálculo de la defusificación.

$$y_d = \frac{\int_s y \mu_y(y) dy}{\int_s \mu_y(y) dy} \quad (3.13)$$

Dónde:

$\mu_y$  = Función de pertenencia del conjunto de salida  $y$

$y$  = Variable de salida

S = Rango de integración

Después de la defusificación se obtiene un escalar dentro del intervalo [0, 10].

## CAPÍTULO 4. RESULTADOS

Para verificar el funcionamiento de la RNA en la tarea de clasificación-reconocimiento de los patrones metalográficos, se desarrolló una fase de validación en la que se introducen 110 nuevas imágenes con patrones de perlita laminar, esferoidización y grafitización para su clasificación y reconocimiento, ver Tabla 3. Las imágenes metalográficas fueron previamente reconocidas e identificadas por expertos. Antes de validar la técnica de clasificación-reconocimiento es necesario comprobar que la caracterización de la imagen metalográfica es correcta y brinda una señal de entrada detallada a la RNA. Se estudió una caracterización mediante el histograma, estadísticos de primer orden (EPO), matriz de coocurrencia GLCM y la matriz de longitud de secuencia de nivel de gris GLRLM además de sus combinaciones para poder definir la mejor técnica para caracterización de la imagen metalográfica que permita una correcta clasificación-reconocimiento por medio de la RNA. Los indicadores son: sensibilidad ecu. (4.1), especificidad ecu. (4.2) y exactitud ecu. (4.3). Ver Tabla 4.1, 4.2, 4.3 y 4.4.

$$\begin{aligned} &\text{Ecuación 4.1 Sensibilidad.} \\ &\text{Sensibilidad (S)} = \frac{VP}{VP+FN} \end{aligned} \quad (4.1)$$

$$\begin{aligned} &\text{Ecuación 4.2 Especificidad.} \\ &\text{Especificidad (Es)} = \frac{VN}{VN+FP} \end{aligned} \quad (4.2)$$

$$\begin{aligned} &\text{Ecuación 4.3 Exactitud.} \\ &\text{Exactitud (Ex)} = \frac{VP+VN}{VN+FP+VP+FN} \end{aligned} \quad (4.3)$$

Dónde:

VP – Verdadero Positivo

FN – Falso Negativo

VN – Verdadero Negativo

FP – Falso Positivo

Tabla 4.1 Caracterización del patrón metalográfico mediante el histograma.

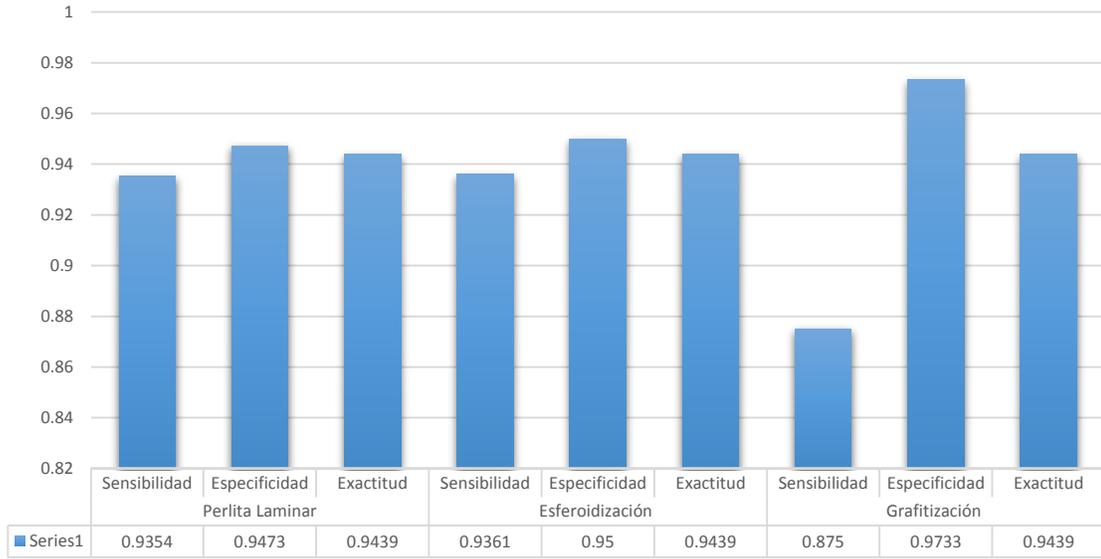


Tabla 4.2 Comparación de técnicas para caracterización del patrón perlita laminar.

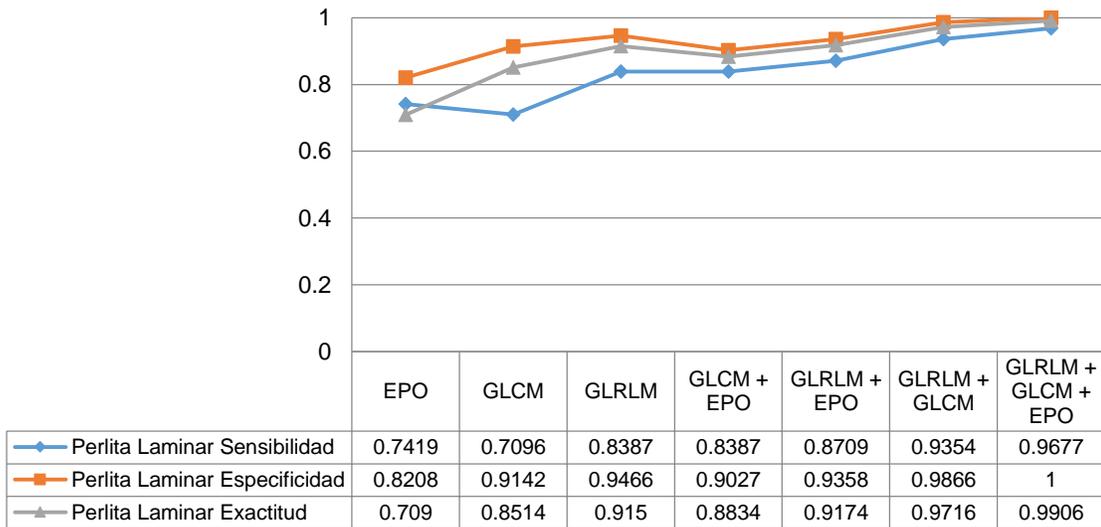


Tabla 4.3 Comparación de técnicas para caracterización del patrón esferoidización.

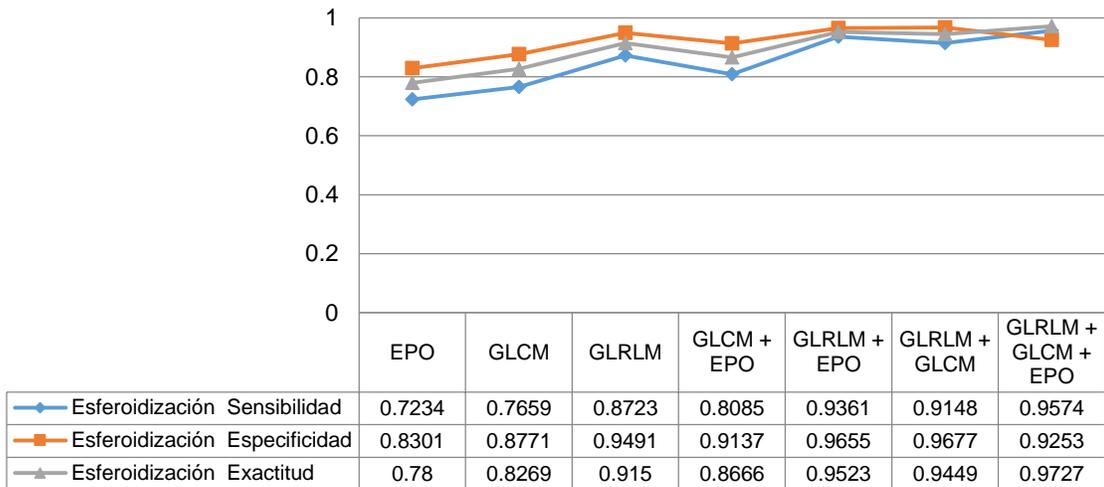
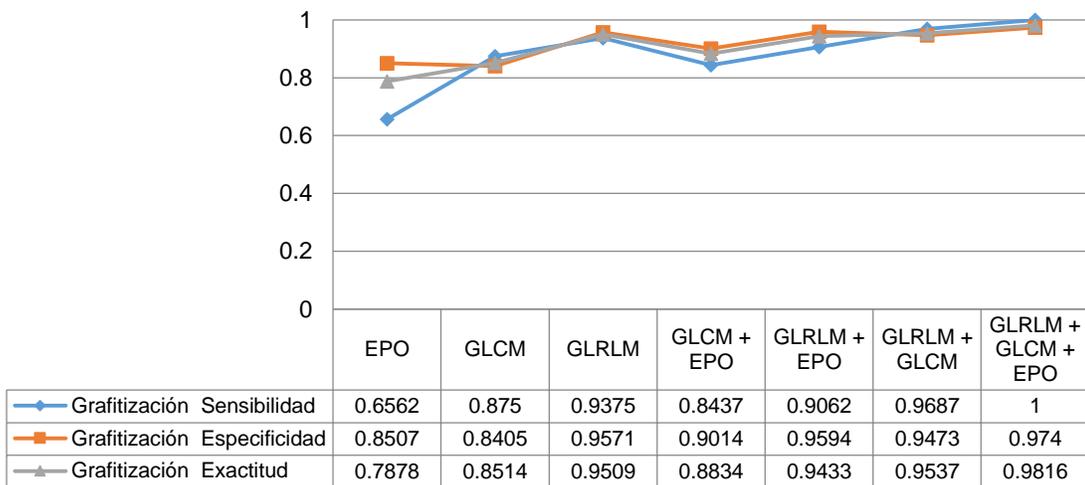


Tabla 4.4 Comparación de técnicas para caracterización del patrón grafitización.



A partir de los indicadores de sensibilidad, especificidad y exactitud se demuestra que la combinación de EPO+GLCM+GLRM generan una señal de entrada eficiente para la RNA y así poder realizar la tarea de clasificación-reconocimiento a través de la arquitectura presentada en la Tabla 3.5.

Para validar la estimación del deterioro en el material a partir del sistema de lógica difusa se compararon los resultados obtenidos del sistema contra los resultados emitidos por un experto en la materia en un total de 110 imágenes. La comparación consistió en realizar una prueba de hipótesis estadística sobre la igualdad de dos

poblaciones, para ello se toma en cuenta la media (Medida de tendencia central) y la varianza (medida de dispersión), se comprobó si para cada uno de los patrones de comportamiento es posible demostrar que no existe diferencia significativa en la estimación del deterioro hecha por el sistema propuesto y el experto humano con una confianza del 99%. Ver Tabla 4.5.

$H_0: \mu_1 = \mu_2$ . La estimación del sistema experto y el experto humano son iguales

$H_1: \mu_1 \neq \mu_2$ . La estimación del sistema experto y el experto humano no son iguales.

El error tipo I queda definido como:  $\alpha = 0.01$

Estadístico de prueba ecu. (4.4).

Ecuación 4.4 Estadístico de prueba.

$$z_0 = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \quad (4.4)$$

Rechazar  $H_0: \mu_1 = \mu_2$  si  $z_0 > 2.58$  ó  $z_0 < -2.58$

Tabla 4.5 Prueba de hipótesis.

Perlita Laminar		Esferoidización		Grafitización	
Sistema Propuesto	Experto Humano	Sistema Propuesto	Experto Humano	Sistema Propuesto	Experto Humano
$\bar{x}_1 = 2.2$	$\bar{x}_2 = 2.4$	$\bar{x}_1 = 6$	$\bar{x}_2 = 6.1$	$\bar{x}_1 = 9.1$	$\bar{x}_2 = 9$
$\sigma_1^2 = 0.7895$	$\sigma_2^2 = 1.0037$	$\sigma_1^2 = 0.870$	$\sigma_2^2 = 0.942$	$\sigma_1^2 = 0.1205$	$\sigma_2^2 = 0.1382$
P=0.878	P=0.809	P=0.078	P=0.166	P=0.1	P=0.099

Perlita Laminar	Esferoidización	Grafitización
$z_0 = \frac{2.2 - 2.4}{\sqrt{\frac{0.7895}{31} + \frac{1.0037}{31}}}$	$z_0 = \frac{6 - 6.1}{\sqrt{\frac{0.8707}{47} + \frac{0.9423}{47}}}$	$z_0 = \frac{9.1 - 9}{\sqrt{\frac{0.1205}{32} + \frac{0.1382}{32}}}$
$z_0 = -0.83211$ Se acepta $H_0$	$z_0 = -0.5092$ Se acepta $H_0$	$z_0 = 1.118$ Se acepta $H_0$

De acuerdo a la prueba de hipótesis empleada, se verifica con un 99% de confianza que no existe diferencia significativa entre las estimaciones del deterioro realizadas por el sistema propuesto y el experto humano. El supuesto para la aplicación de la prueba de hipótesis es el comportamiento normal de los datos, dicho supuesto es probado mediante el estadístico Anderson Darling donde cada uno de los conjuntos de datos presenta un valor mayor a 0.05. El sistema de lógica difusa podrá otorgar

una calificación en donde el valor de cero es el estado sano del material. En la Fig. (4.1), se muestra la superficie de afectación generada en base al porcentaje de ferrita y el patrón de comportamiento.

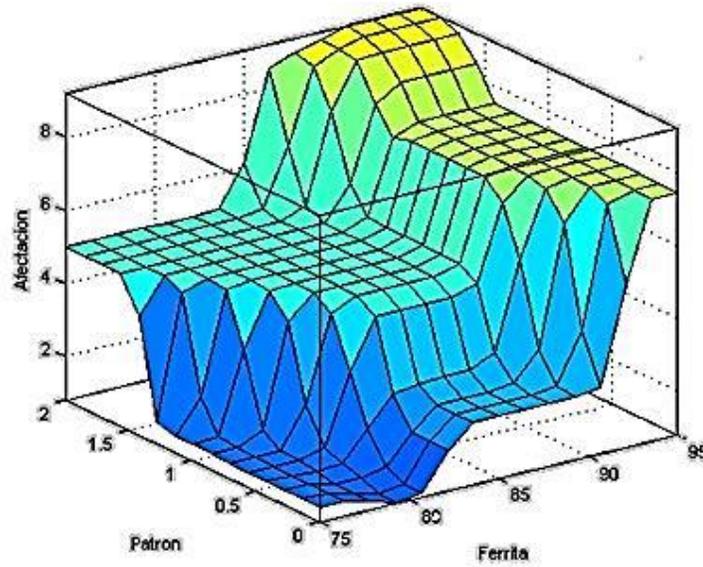


Figura 4.1 Superficie de afectación.

## CONCLUSIONES

Los resultados obtenidos en la presente investigación enfatizan la viabilidad de uso de un sistema inteligente aplicado sobre el procesamiento digital de imágenes metalográficas y apoyado en estadística descriptiva, donde el sistema contribuye como elemento de diagnóstico para la clasificación-reconocimiento de patrones metalográficos del acero al carbón del tipo SA 210 grado A-1 además de la estimación cuantitativa de su deterioro sufrido en planta a partir de una imagen micro estructural del acero, cubriendo la necesidad que se presenta actualmente, ya que los procedimientos de reconocimiento y estimación son realizados a partir de la experiencia de un experto en el área de materiales lo cual es subjetivo.

Un aspecto importante para lograr una clasificación-reconocimiento eficiente de la imagen metalográfica bajo la premisa de textura fue la caracterización por medio de la combinación de EPO+GLCM+GLRLM generando una señal de entrada detallada. Cabe destacar que los estadísticos GLRLM por si solos presentan mejores resultados que la combinación EPO+GLCM. En la fase de estimación se demuestra con una confianza del 99% que es posible establecer una estimación cuantitativa de [0,10] sobre el deterioro en el acero al carbón SA 210 igual a la de un experto en la materia, tomando en cuenta solo dos variables de entrada. Bajo lo antes mencionado es posible pensar en establecer este procedimiento en empresas que requieran análisis de sus materiales en uso y no cuenten con un experto de forma inmediata.

La metodología propuesta integra teorías tales como: el procesamiento digital de imágenes, redes neuronales artificiales y lógica difusa, lo cual conduce a la construcción de un sistema experto capaz de reconocer y clasificar patrones metalográficos además de estimar el daño presente en el acero SA 210 a consecuencia de la temperatura sufrida al conducir agua y vapor a altas temperaturas.

Es conveniente resaltar que de acuerdo a los resultados obtenidos durante la investigación es dejar ver la posibilidad de procesar información tanto cuantitativa como cualitativa, lo que conduce a analizar tanto una variable (% de fases) como un

atributo (reconocimiento del patrón metalográfico) para controlar el diagnóstico de continuidad en los conductores fabricados de acero SA 210.

## **RECOMENDACIONES**

La metodología propuesta a lo largo del presente trabajo fue desarrollada únicamente para dar solución a situaciones de reconocimiento de patrones en el acero al carbón, así como la estimación del daño en dicho acero de forma cuantitativa. Por otro lado, es importante destacar que la metodología propuesta puede extenderse a otro tipo de aceros que sufren daños debido a la temperatura del agua o vapor u otra sustancia que conducen, por ejemplo: los aceros de baja aleación.

Con el desarrollo del sistema experto presentado a partir de la metodología propuesta, es importante destacar la etapa del procesamiento digital de las imágenes metalográficas ya que el sistema trabaja de forma integral al generar las señales de entrada tanto para el sistema difuso y la RNA por medio del procesamiento digital de la imagen. Un ejemplo claro de la importancia y relevancia de los procesos desarrollados en el área de procesamiento digital de imágenes metalográficas es el cálculo del porcentaje de fases, ya que dicho cálculo hasta el momento había sido realizado de forma aislada por procedimientos químicos y técnicas de ultrasonido y no mediante un procesamiento digital de la imagen, lo que lleva a reducir tiempo y recursos en la generación de dicha información.

El aporte realizado a la ciencia mediante el presente trabajo de investigación, es la generación de procedimientos y algoritmos basados en modelos matemáticos como el cálculo del porcentaje de fases, la estimación del daño presente en los aceros al carbón mediante la lógica difusa y el reconocimiento de patrones presentes en las imágenes metalográficas a partir de la RNA. El aporte tecnológico es el desarrollo de un sistema experto que integra todos los procedimientos de forma estructurada para resolver tareas de reconocimiento y estimación de deterioro sufrido en aceros al carbón al mismo nivel que un experto humano.

## REFERENCIAS BIBLIOGRÁFICAS

- [1]. Apraiz-Barreiro, J. Tratamiento térmico de los Aceros. 10ª edición. España, S.I. Cie Inversiones Editoriales Dossat, 2002. 739 p. ISBN: 9788495312563.
- [2]. Zadeh, Lotfi A. "Fuzzy Sets." *Information & Control*, Vol. 8,1965, pp338-353.
- [3]. Bishop C. M. (1996), "Neural network for pattern recognition", Clarendon Press, Oxford, pp. 482.
- [4]. Garcia-Martín, J., Martinez-Martinez, V., Gomez-Gil, J. (2014). "Heat-Treatment Classification of Steels with Nondestructive Eddy Current Testing using Neural Networks". *DYNA*, 89(5). 526-532. DOI: <http://dx.doi.org/10.6036/7083>
- [5]. Garcia-Bringas, P., Pastor-Lopez, I., Santos-Grueiro, I.. (2014). "Machine Vision for Surface Defects Categorisation In Foundries Based on Machine Learning". *DYNA*, 89(3). 325-332. DOI: <http://dx.doi.org/10.6036/6940>
- [6]. Liu, C., Wang Zhigang., Li, Y., (2012) "Damage Pattern Recognition of Refractory Materials Based on BP Neural Network" *Neural Information Processing*. Vol. 7666, 2012, pp 431-440. DOI: 10.1007/978-3-642-34478-7\_53
- [7]. Subashini,L.,Vasudevan,M.,(2012) "Adaptive Neuro-Fuzzy Inference System (ANFIS)-Based Models for Predicting the Weld Bead Width and Depth of Penetration from the Infrared Thermal Image of the Weld Pool". *Metallurgical and Materials Transactions B*. Vol 43 p 145-154. DOI: 10.1007/s11663-011-9570-x
- [8]. Campos, I. Islas, M. Gonzalez, E. Ponce, P. Ramirez, G. (2006) "Use of fuzzy logic for modeling the growth of Fe<sub>2</sub>B boride layers during boronizing". *Surface and Coatings Technology* Vol.201 p.2717–2723 DOI:10.1016/j.surfcoat.2006.05.016
- [9]. Han, Y. Zeng, W. Zhao, Y. Qi, Y. Sun, Y. (2011) "An ANFIS model for the prediction of flow stress of Ti600 alloy during hot deformation process" *Computational Materials Science*. Vol. 50 p. 2273-2279. DOI:10.1016/j.commatsci.2011.03.004
- [10]. Thinh Nguyen, T. Soo Yang, Y. Woong Kim, J. (2013). An artificial neural network system for predicting the deformation of steel plate in triangle

- induction heating process. *International Journal of Precision Engineering and Manufacturing*. Volume 14, pp 551-557. DOI 10.1007/s12541-013-0075-1.
- [11]. Hassani, M. Hajian, A. (2015). Investigation of material removal rate and surface roughness in wire electrical discharge machining process for cementation alloy steel using artificial neural network. *The International Journal of Advanced Manufacturing Technology*. pp 1-9 DOI 10.1007/s00170-015-7349-y.
- [12]. Pontes, F. Ferreira, J. Silva, M. (2010). Artificial neural networks for machining processes surface roughness modeling. *The International Journal of Advanced Manufacturing Technology*. Volume 49, pp 879-902. DOI 10.1007/s00170-009-2456-2
- [13]. Azadeh, A. Neshat, N. Mardan, E. (2013). Optimization of steel demand forecasting with complex and uncertain economic inputs by an integrated neural network–fuzzy mathematical programming approach. *The International Journal of Advanced Manufacturing Technology*. Volume 65, pp 833-841. DOI 10.1007/s00170-012-4221-1.
- [14]. Hasan, B. (2014). Experimental Determination of Cutting Forces and Surface Roughness when Turning 50CrV4 Steel (SAE 6150) and Modelling with the Artificial Neural Network Approach. *Transactions of the Indian Institute of Metals*. Volume 67, pp 869-879. DOI 10.1007/s12666-014-0410-y
- [15]. Median, R. Gayubo, F. Gonzalez, L. (2011). Automated visual classification of frequent defects in flat steel coils. *The International Journal of Advanced Manufacturing Technology*. Volume 57, pp 1087-1097. DOI 10.1007/s00170-011-3352-0
- [16]. Yazdi , M. Bagheri, G. Tahmasebi. (2012). Finite Volume Analysis and Neural Network Modeling of Wear During Hot Forging of a Steel Splined Hub. *Arabian Journal for Science and Engineering*. Volume 37, pp 821-829. DOI 10.1007/s13369-012-0210-9
- [17]. Çaydaş, U. Ekici, S. (2012). Support vector machines models for surface roughness prediction in CNC turning of AISI 304 austenitic stainless steel.

- Journal of Intelligent Manufacturing. Volume 23, pp 639-650. DOI 10.1007/s10845-010-0415-2
- [18]. Khalaj, G. Yoozbashizadeh, H. Khodabandeh, A. (2013). Artificial neural network to predict the effect of heat treatments on Vickers microhardness of low-carbon Nb microalloyed steels. Volume 22, pp 879-888. DOI 10.1007/s00521-011-0779-z
- [19]. Moia, D. Thomazella, I. Aguiar, P. (2015). Tool condition monitoring of aluminum oxide grinding wheel in dressing operation using acoustic emission and neural networks. Journal of the Brazilian Society of Mechanical Sciences and Engineering. Volume 37, pp 627-640. DOI 10.1007/s40430-014-0191-6
- [20]. Khalaj, G. (2013). Artificial neural network to predict the effects of coating parameters on layer thickness of chromium carbonitride coating on pre-nitrided steels. Neural Computing and Applications. Volume 23, pp 779-786. DOI 10.1007/s00521-012-0994-2
- [21]. Moura, E. Normando, P. Gonçalves, L. (2012). Characterization of Cast Iron Microstructure Through Fluctuation and Fractal Analyses of Ultrasonic Backscattered Signals Combined with Classification Techniques. Volume 31, pp 90-98. DOI 10.1007/s10921-011-0124-6
- [22]. Vafaenezhad, H. Ghanei, S. Seyedein, S. (2014). Process Control Strategies for Dual-Phase Steel Manufacturing Using ANN and ANFIS. Journal of Materials Engineering and Performance. Volume 23, pp 3975-3983. DOI 10.1007/s11665-014-1174-6
- [23]. Samtaş, G. (2014). Measurement and evaluation of surface roughness based on optic system using image processing and artificial neural network. The International Journal of Advanced Manufacturing Technology. Volume 7, pp 353-364. DOI 10.1007/s00170-014-5828-1.
- [24]. Medina, R. Gayubo, F. Olmedo, D. Automated visual classification of frequent defects in flat steel coils. The International Journal of Advanced Manufacturing Technology. Volume 57, pp 1087-1097. DOI 10.1007/s00170-011-3352-0

- [25]. Palani, S. Natarajan, U. Prediction of surface roughness in CNC end milling by machine vision system using artificial neural network based on 2D Fourier transform. *The International Journal of Advanced Manufacturing Technology*. Volume 54, pp 1033-1042. DOI 10.1007/s00170-010-3018-3
- [26]. Chandrashekhar, M. Ganguli R. (2009). Damage assessment of structures with uncertainty by using mode-shape curvatures and fuzzy logic. *Journal of Sound and Vibration*. Volume 326, pp 939–957. doi:10.1016/j.jsv.2009.05.030
- [27]. Ren, Q. Balazinski, M. Baron, L. (2014). Type-2 fuzzy tool condition monitoring system based on acoustic emission in micromilling. *Information Sciences*. Volume 255, pp 121–134. doi:10.1016/j.ins.2013.06.010
- [28]. Hassan, M. El-Sharie, M. Aboul-Kasem, A. (2012). A fuzzy model for evaluation and prediction of slurry erosion of 5127 steels. *Materials & Design*. Volume 39, pp 186–191. doi:10.1016/j.matdes.2012.02.012
- [29]. Masoumi, M. Masoumi, M. Jamshidi, E. (2015). Damage diagnosis in steel structures with different noise levels via optimization algorithms. *International Journal of Steel Structures*. Volume 15, pp 557-565. DOI 10.1007/s13296-015-9004-8
- [30]. Jiang Y. Xu F. Xu B. (2015). Acoustic Emission tomography based on simultaneous algebraic reconstruction technique to visualize the damage source location in Q235B steel plate. *Mechanical Systems and Signal Processing*. Volumes 64–65, pp 452–464. doi:10.1016/j.ymsp.2015.04.013
- [31]. Deng, Y. Liu, Y. (2014) Monitoring damage evolution of steel strand using acoustic emission technique and rate process theory. Volume 21, pp 3692-3697. DOI 10.1007/s11771-014-2352-2
- [32]. Kirby, R. L. and Rosenfeld, A. (1979). A note on the use of gray level, local average (gray level) space as an aid in threshold selection. *IEEE Trans. Syst. Man Cybern.* SMC-9:860-864.
- [33]. Cheng, H. D. and Chen, Y. H. (1999). Fuzzy partition of two-dimensional histogram and its application to thresholding. *Pattern Recogn.* 32: 825-84.
- [34]. Martin-H, J.A.; Santos, M.; Farias, G.; Duro, N.; Sanchez, J.; Dormido, R.; Dormido-Canto, S.; Vega, J.; Vargas, H. (2009). Dynamic clustering and

- modeling approaches for fusion plasma signals. *IEEE Trans. Instrum. Meas.* 58: 2969-2978.
- [35]. Macedo-Cruz, Antonia; Pajares-Martinsanz, Gonzalo; Santos-Peñas, Matilde. (2010). Unsupervised classification of images in RGB color model and cluster validation techniques. In: *WORLDCOMP2010, Proceedings of the International Conference on Image Processing, Computer Vision, & Pattern Recognition, (IPCV 2010)*. Hamid R. Arabnia, Leonidas Deligiannidis, Gerald Schaefer, Ashu M. G. Solo (eds.), Las Vegas, Nevada, USA, July 12-15. CSREA Press 2010 (Eds) 2:526-532. ISBN 1-60132-154-6.
- [36]. Gonzales-Barron, U.; Butler, F. (2006). A comparison of seven thresholding techniques with the k-means clustering algorithm for measurement of breadcrumb features by digital image analysis. *J. Food Eng.* 74:268-278.
- [37]. Sezgin, Mehmet; and Sankur, B. (2004). Survey over Image Thresholding Techniques and Quantitative Performance Evaluation. *Journal of Electronic Imaging*, 13(1):146-165.
- [38]. Kurugollu F; Sankur, B.; Harmanci, A.E. (2001). Color image segmentation using histogram multithresholding and fusion. *Image and Visión Computing* 19:915-928
- [39]. Otsu, N. (1979). A threshold selection method from gray level histogram. *IEEE Trans. Systems Man and Cybernetics.* 9(1):62-66.
- [40]. Kittler, J.; Illingworth, J. (1986). Minimum error thresholding. *Patt. Recog.* 19: 41-47.
- [41]. Ridler, T. W. and Calvard, S. (1978). Picture thresholding using an iterative selection method. *IEEE Transactions on Systems, Man and Cybernetics*, 8(8): 630-632.
- [42]. Lloyd, D.E. (1985). Automatic target classification using moment invariant of image shapes. Technical Report, RAE IDN AW126, Farnborough, UK.
- [43]. Jawahar, C. V.; Biswas, P. K. and Ray, A. K. (1997). Investigations on fuzzy thresholding based on fuzzy clustering. *Pattern Recog.* 30(10):1605-1613.

- [44]. Chang, C.C., Lin, C.Y., and Fan, Y.H. (2008). Lossless Data Hiding for Color Images Based on Block Truncation Coding. *Pattern Recognition*. 41: 2347-2357.
- [45]. Burgos-Artizzu, X.; Ribeiro, A.; Guijarro, M.; Pajares, G. (2011). Real-time image processing for crop/weed discrimination in maize fields. *Computers and Electronics in Agriculture*, 75:337-346.
- [46]. Kapur, J. N.; Sahoo, P. K.; and Wong, A. K. C. (1985). A new method for graylevel picture thresholding using the entropy of the histogram. *Graph. Models Image Process*. 29:273-285.
- [47]. Sahoo, P., Wilkins, C.; and Yeager, J. (1997). Threshold selection using Renyi's entropy. *Pattern Recognition*, 30:71-84.
- [48]. Chang, C.I.; Du, Y; Wang, J.; and Guo, S.M. (2006). Survey and Comparative Analysis of Entropy and Relative Entropy Thresholding Techniques. *Vision, Image and*, 153(6): 837-850.
- [49]. Stathis P., Kavallieratou E., Papamarkos .N. (2008). An Evaluation Technique for Binarization Algorithms. *Journal of Universal Computer Science*, 14(18): 3011-3030.
- [50]. Silveira, G.F.; Carvalho, J.R.H.; Madrid, M.K.; Rives, P.; Bueno, S.S. (2001). A fast vision-based road following strategy applied to the control of aerial robots. *Proceedings of XIV Brazilian Symposium, Computer Graphics and Image Processing*, pp. 226-231.
- [51]. Ribeiro, A.; Fernández-Quintanilla, C.; Barroso, J.; García-Alegre, M.C. (2005). Development of an image analysis system for estimation of weed. In: *Proceedings of the 5th European Conf. On Precision Agriculture (5ECPA)*, pp. 169-174.
- [52]. Yan, Guangjian; Li, Chaoyang; Zhou, Guoqing; Zhang, Wuming; Li, Xiaowen. (2007). Automatic Extraction of Power Lines From Aerial Images. *IEEE Geoscience and Remote Sensing Letters*, 4(3):387-391.
- [53]. Cao, Guo; Yang, Xin; Mao, Zhihong. (2005). A two-stage level set evolution scheme for man-made objects detection in aerial images. In: *IEEE Computer*

- Society Conference on Computer Vision and Pattern Recognition. CVPR, 1: 474- 479.
- [54]. Bicego, M.; Dalfini, S.; Vernazza, G.; Murino, V. (2003). Automatic Road Extraction from Aerial Images by Probabilistic Contour Tracking. Image Processing, vol. 3. (ICIP 14-17 sep 2003). pp. III- 585-588.
- [55]. Tuo, Hongya and Zhang, L; and Liu, Y. (2004), Multisensor Aerial Image Registration Using Direct Histogram Specification. Networking, Sensing and Control. 2:807-812
- [56]. Burgos-Artizzu, X.; Ribeiro, A.; Guijarro, M.; Pajares, G. (2011). Real-time image processing for crop/weed discrimination in maize fields. Computers and Electronics in Agriculture, 75:337-346.
- [57]. Tellaeche, A., Pajares, G., Burgos-Artizzu, X.P., Ribeiro, A. (2011). A computer vision approach for weeds identification through Support Vector Machines. Applied Soft Computing, 11:908-915.
- [58]. Montiel, E.; Aguado, A.S.; and Nixon, M.S. (2005). Texture classification via conditional histograms. Pattern Recognition Letters, 26:1740-1751.
- [59]. Vazquez, E.; Baldrich, R.; Vazquez, J.; and Vanrell, M. (2007). Topological Histogram Reduction towards colour segmentation. (J. Martí, J.M. Benedí. A.M. Mendoça and J. Serrat (Eds.)). Pattern Recognition and Image Analysis. Lecture Notes in Computer Science, Springer-Verlag, Berlin, 4477, Part I, 55-62.
- [60]. Tkalcic, J.T.M. (2003). Colour spaces-perceptual, historical and applicational background. IEEE region 8 EUROCOM, pp. 304-308.
- [61]. Raof, A.; Zaleha, S.; Sahidan, S.I.; Mashor, N. Noor, S.S, Idris, M and Hasan, H (2008), Color Thresholding Method for Image Segmentation Algorithm of Ziehl-Neelsen Sputum Slide Images. Library, (Cce): 212-217.
- [62]. Sirmacek, B.; Unsalan, C. (2008). Building Detection from Aerial Images Using Invariant Color Features and Shadow Information. In 23rd International Symposium, Computer and Information Sciences, Istanbul, Turkey (Oct. 27-29), pp. 1-5.

- [63]. Lim, Y.W; Lee, S.U. (1990). On the color image segmentation algorithm based on the thresholding and fuzzy c-means techniques. *Pattern Recognition*, 23:935-952.
- [64]. Janssen Lucas L. F.; Van der Wel F. J. M. (1994). Accuracy Assessment of Satellite Derived Land-Cover Data: A Review. *Photogrammetric Engineering & Remote Sensing*. Vol. 60(4):419-426.
- [65]. Chen, W. and Fang, K. (2008). Multilevel thresholding algorithm based on particle swarm optimization for image segmentation. In: *Control Conference, 27th Chinese*, Kunming, Yunnan, China, pp:348-351.
- [66]. Guijarro, M. Pajares, G. (2009a). On combining classifiers through a fuzzy multicriteria decision making approach: Applied to natural textured images. *Expert Systems with Applications*, 36:7262-7269.
- [67]. Herrera, Pedro Javier; Pajares, Gonzalo; Guijarro, M.; Ruz, José J.; Cruz, Jesús M.; and Montes, Fernando. (2009b). A Featured-based Strategy for Stereovision Matching in Sensors with Fish-eye Lenses for Forest Environments. *Sensors*, 9(12):9468-92.
- [68]. Honeycombe R W K *Steels Microstructure and Properties* Editorial: Edward Arnold. London, 1988, 1988 ISBN 10: 0713127937 / ISBN 13: 9780713127935
- [69]. A.K. Jain and F. Farrokhnia. Unsupervised texture segmentation using gabor filters. *Pattern Recognition*, 24(12):1167–1186, 1991.
- [70]. S. Arivazhagan, L. Ganesan, and S.P. Priyal. Texture classification using gabor wavelets based rotation invariant features. *Pattern Recognition Letters*, 27(16):1976–1982, 2006.
- [71]. A. Abdesselam. Texture image retrieval using local binary edge patterns. In *Digital Information and Communication Technology and Its Applications*, volume 166 of *Communications in Computer and Information Science*, pages 219–230. Springer Berlin Heidelberg, 2011.
- [72]. J.S. De Bonet. Multiresolution sampling procedure for analysis and synthesis of texture images. In *Proc. 24th annual conference on Computer graphics and interactive techniques, SIGGRAPH '97*, pages 361–368, 1997.

- [73]. M. Amadasun and R. King. Textural features corresponding to textural properties. *IEEE Transactions on Systems, Man and Cybernetics*, 19(5):1264–1274, 1989.
- [74]. H. Aboulmagd, N. El-Gayar, and H. Onsi. A new approach in content-based image retrieval using fuzzy. *Telecommunication Systems*, 40(1):55–66, 2008.
- [75]. R.M. Haralick. Statistical and structural approaches to texture. *Proceedings of the IEEE*, 67(5):786–804, 1979.
- [76]. L.J. Van Gool, P. Dewaele, and A. Oosterlinck. Texture analysis anno 1983. *Computer Vision, Graphics, and Image Processing*, 29(3):336–357, 1985.
- [77]. T.R. Reed and J.M.H. du Buf. A review of recent texture segmentation and feature extraction techniques. *CVGIP: Image Understanding*, 57(3):359–372, 1993.
- [78]. M. Tuceryan and A.K. Jain. Texture analysis. In *The Handbook of Pattern Recognition and Computer Vision*, pages 207–248. World Scientific Publishing Co., 2 edition, 1998.
- [79]. C.W. Kim and A.J. Koivo. Hierarchical classification of surface defects on dusty wood boards. In *Proc. 10th International Conference on Pattern Recognition*, volume 1, pages 775–779, June 1990.
- [80]. C. Boukouvalas, J. Kittler, R. Marik, and M. Petrou. Color grading of randomly textured ceramic tiles using color histograms. *IEEE Transactions on Industrial Electronics*, 46(1):219–226, February 1999.
- [81]. B. Julesz. Visual pattern discrimination. *IEEE Transactions on Information Theory*, 8(2):84–92, 1962.
- [82]. B. Julesz, E.N. Gilbert, L.A. Shepp, and H.L. Frisch. Inability of humans to discriminate between visual textures that agree in secondorder statistics - revisited. *Perception*, 2:391–405, 1973.
- [83]. M.K. Tsatsanis and G.B. Giannakis. Object and texture classification using higher order statistics. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 14(7):733–750, July 1992.

- [84]. R.M. Haralick, K. Shanmugam, and I. Dinstein. Textures features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, 3:610–621, 1973.
- [85]. R. Cossu. Segmentation by means of textural analysis. *Pixel*, 1(2):21–24, 1988.
- [86]. A. Baraldi and F. Parmiggiani. An investigation of the textural characteristics associated with gray level cooccurrence matrix statistical parameters. *IEEE Transactions on Geoscience and Remote Sensing*, 33(2):293–304, March 1995.
- [87]. V. Atlamazoglou, D. Yova, N. Kavantzias, and S. Loukas. Texture analysis of fluorescence microscopic images of colonic tissue sections. *Medical and biological engineering and computing*, 39(2):145–151, 2001.
- [88]. D.G. Morrison. On the interpretation of discriminant analysis. *Journal of Marketing Research*, 6(2):156–163, 1969.
- [89]. M. Partio, B. Cramariuc, M. Gabbouj, and A. Visa. Rock texture retrieval using gray level co-occurrence matrix. *Entropy*, 75:8–14, 2002.
- [90]. X. Song, Y. Li, and W. Chen. A textural feature-based image retrieval algorithm. In *Proc. 4th International Conference on Natural Computation*, volume 4 of ICNC'08, pages 71–75. IEEE Computer Society, 2008.
- [91]. F. Pacifici, M. Chini, and W.J. Emery. A neural network approach using multi-scale textural metrics from very high-resolution panchromatic imagery for urban land-use classification. *Remote Sensing of Environment*, 113(6):1276–1292, 2009.
- [92]. R.W. Connors and C.A. Harlow. A theoretical comparison of texture algorithms. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-2(3):204–222, 1980.
- [93]. J. Wan, J. Mao, and C.D. Wang. Multiresolution rotation invariant simultaneous autoregressive model for texture analysis. In *Proc. 9<sup>th</sup> International Conference on Pattern Recognition*, volume 2, pages 845–847, November 1988.
- [94]. J.S. Weszka, C.R. Dyer, and A. Rosenfeld. A comparative study of texture measures for terrain classification. *IEEE Transactions on Systems, Man and Cybernetics*, 6:269–285, 1976.

- [95]. M.M. Galloway. Texture analysis using gray level run lengths. *Computer Graphics and Image Processing*, 4:172–179, 1975.
- [96]. E.J. Carton, J.S.Weszka, and A. Rosenfeld. Some basic texture analysis techniques. University of Maryland, Computer Science Center, 1974.
- [97]. A. Chu, C.M. Sehgal, and J.F. Greenleaf. Use of gray value distribution of run lengths for texture analysis. *Pattern Recognition Letters*, 11:415– 420, June 1990.
- [98]. B.V. Dasarathy and E.B. Holder. Image characterizations based on joint gray level-run length distributions. *Pattern Recognition Letters*, 12:497–502, August 1991.
- [99]. B. Julesz, E.N. Gilbert, and J.D. Victor. Visual discrimination of textures with identical third-order statistics. *Biological Cybernetics*, 31(3):137–140, 1978.
- [100]. T.M. Caelli. *Visual perception*. Pergamon international library of science, technology, engineering, and social studies. Pergamon, 1981.
- [101]. S.S. Liu and M.E. Jernigan. Texture analysis and discrimination in additive noise. *Computer Vision, Graphics, and Image Processing*, 49:52–67, January 1990.
- [102]. F. D’Astous and M.E.Jernigan. Texture discrimination based on detailed measures of the power spectrum. *Proc. International Conference on Pattern Recognition*, pages 83–86, 1984.
- [103]. D.C. He, L. Wang, and J. Guibert. Texture discrimination based on an optimal utilization of texture features. *Pattern Recognition*, 21(2):141– 146, 1988.
- [104]. J. Han and K.K. Ma. Rotation-invariant and scale-invariant gabor features for texture image retrieval. *Image and Vision Computing*, 25(9):1474–1481, 2007.
- [105]. D. Gabor. Theory of communication. part 1: The analysis of information. *Journal of the Institution of Electrical Engineers - Part III: Radio and Communication Engineering*, 93(26):429 –441, November 1946.
- [106]. J.G. Daugman. Uncertainty relation for resolution in space, spatial frequency, and orientation optimized by two-dimensional visual cortical filters. *Journal of the Optical Society of America A Optics and image science*, 2(7):1160–1169, 1985.

- [107]. J.G. Daugman. Two-dimensional spectral analysis of cortical receptive field profiles. *Vision Research*, 20(10):847–856, 1980.
- [108]. B.S. Manjunath and W.Y. Ma. Texture features for browsing and retrieval of image data. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 18(8):837–842, 1996.
- [109]. M.R. Turner. Texture discrimination by gabor functions. *Biological Cybernetics*, 55:71–82, 1986.
- [110]. A.K. Jain and F. Farrokhnia. Unsupervised texture segmentation using gabor filters. *Pattern Recognition*, 24(12):1167–1186, 1991.
- [111]. D.A. Clausi and H. Deng. Design-based texture feature fusion using gabor filters and co-occurrence probabilities. *IEEE Transactions on Image Processing*, 14(7):925–936, July 2005.
- [112]. S. Li and J. Shawe-Taylor. Comparison and fusion of multiresolution features for texture classification. *Pattern Recognition Letters*, 26(5):633–638, 2005.
- [113]. F. Bianconi and A. Fernández. Evaluation of the effects of gabor filter parameters on texture classification. *Pattern Recognition*, 40(12):3325– 3335, 2007.
- [114]. A. Haar. Zur theorie der orthogonalen funktionensysteme. *Mathematische Annalen*, 71:38–53, 1911.
- [115]. S.G. Mallat. A theory for multiresolution signal decomposition: the wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11(7):674–693, 1989.
- [116]. I. Daubechies. Ten lectures on wavelets. Society for Industrial and Applied Mathematics, Philadelphia, PA, USA, 1992.
- [117]. H.B. Kekre, S.D.Thepade, and A. Maloo. Query by image content using color-texture features extracted from haar wavelet pyramid. *International Journal of Computer Applications (IJCA) for the special edition on CASCT*, (2):52–60, 2010.
- [118]. M. Kokare, P.K. Biswas, and B.N. Chatterji. Texture image retrieval using rotated wavelet filters. *Pattern Recognition Letters*, 28(10):1240– 1249, 2007.

- [119]. L. Nanni, S. Brahmam, and A. Lumini. Texture descriptors for generic pattern classification problems. *Expert Systems with Applications*, 38(8):9340–9345, 2011.
- [120]. P. Jackman, D.W. Sun, C.J. Du, P. Allen, and G. Downey. Prediction of beef eating quality from colour, marbling and wavelet texture features. *Meat Science*, 80(4):1273–1281, 2008.
- [121]. S. Arivazhagan and L. Ganesan. Texture segmentation using wavelet transform. *Pattern Recognition Letters*, 24(16):3197–3203, 2003.
- [122]. M. Unser. Texture classification and segmentation using wavelet frames. *IEEE Transactions on Image Processing*, 4(11):1549 –1560, November 1995.
- [123]. T. Chang and C.C.J. Kuo. Texture analysis and classification with treestructured wavelet transform. *IEEE Transactions on Image Processing*, 2(4):429–441, October 1993.
- [124]. A. Laine and J. Fan. Texture classification by wavelet packet signatures. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 15(11):1186–1191, 1993.
- [125]. W.Y. Ma and B.S. Manjunath. Texture features and learning similarity. In *Proc. Conference on Computer Vision and Pattern Recognition, CVPR '96*, pages 425–430, 1996.
- [126]. Duda, R. O.; Hard, P.E.; and Stork, D.G. (2001). *Pattern Classification*. 2nd ed. John Wiley. New York, NY, USA. 654 p.
- [127]. Gonzalez, R. and Woods, R. E. (2008). *Digital Image processing*, third ed. Prentice Hall, New Jersey, EE.UU. 954 p.
- [128]. Bow, S. T. (2002). *Pattern Recognition and Image Preprocessing*. 2nd ed. Marcel Dekker. New York, NY, USA. 698 p.
- [129]. Theodoridis, S. and Koutroumbas, K. (2009). *Pattern Recognition*. Fourth ed. Academic Press, ELSEVIER, California, USA.
- [130]. Pajares, G. and Cruz, J.M. (2007). *Visión por Computador: Imágenes Digitales y Aplicaciones*, 2ª ed. RA-MA, Madrid. 768 p.

- [131]. Grabot, B. and L. Geneste. Dispatching Rules in Scheduling: A Fuzzy Approach. International Journal of Production Research. Vol. 32, No. 4,1994, pp903-915.
- [132]. Isik, Can and Farrukh Zia. "Fuzzy Logic Control Using a Self-Organizing Map." Proceedings of the 1993 International Neural Network Society, July, Vol. 2, pp56-65.
- [133]. Lee, Chuen Chien. "Fuzzy Logic in Control Systems: Fuzzy Logic Controller Part I." IEEE Transactions on Systems, Man, and Cybernetics. Vol. 20, No. 2, March 1990, pp404-418.
- [134]. Murakami, S. "Application of fuzzy controller to automobile speed control system," in Industrial Applications of Fuzzy Control, M. Sugeno, Ed. Amsterdam: North-Holland, 1985, pp105-124.
- [135]. Watanabe, H. and W. Dettloff "Reconfigurable fuzzy logic processor A full custom digital VLSI," in Int Workshop on Fuzzy System Applications, Iizuka, Japan, Aug. 1988, pp49-50.
- [136]. Yamakawa, T. and T. Miki "The current mode fuzzy logic integrated circuits fabricated by the standard CMOS process," IEEE Trans. Computer, Vol. C-35, No. 2, pp161-167, 1986.
- [137]. Yamakawa, T. "Fuzzy Microprocessors-Rule chip and defuzzifier chip," in Int. Workshop on Fuzzy Systems Applications, Iizuka, Japan, Aug. 1988, pp51-52.
- [138]. Zadeh, Lotfi A. "Fuzzy Sets." Information & Control, Vol. 8, 1965, pp338-353.
- [139]. Bishop C. M. (1996), "Neural network for pattern recognition", Clarendon Press, Oxford, pp. 482.
- [140]. Brío B. y Sanz A. (2002), "Redes neuronales y sistemas difusos", segunda edición, Alfaomega.
- [141]. Fiesler, E. (1994), "Neural network classification and formalization", Computer Standards and
- [142]. Interfaces, Vol. 16, special issue on Neural Networks Standards, J. Fulcher (edt), Elsevier.
- [143]. Chen, A. M., H. Lu y R. Hecht-Nielsen (1993). On the geometry of feedforward neural network error surfaces. Neural Computation 5 (6), 910-967.

- [144]. P. Isasi, I. Galván, *Redes Neuronales Artificiales: Un enfoque práctico*, Pearson. Prencice Hall, 2004.
- [145]. Luo, Zhi-Quan (1991). On the convergence of the LMS algorithm with adaptive learning rate for linear feedforward networks. *Neural Computation* 3 (2), 226-245.
- [146]. Haykin, Simon (1998). *Neural Networks: A Comprehensive Foundation*, Prentice Hall, 2nd edition
- [147]. ASTM E3-01, *Standard Practice for Preparation of Metallographic Specimens*, ASTM International, West Conshohocken, PA, 2001, [www.astm.org](http://www.astm.org)
- [148]. Mallat, S., (1989) "A theory for multiresolution signal decomposition: the wavelet representation". *IEEE Transactions on Pattern Analysis and Machine Intelligence*. Vol 11(7) p. 674–693.

# Condition Estimation of Carbon Steel using a Neuro-Fuzzy System and Image Processing

E.A. Ruelas-Santoyo<sup>1</sup>, J.A. Vázquez López<sup>2</sup>, J. Yañez Mendiola<sup>1</sup>, I. López Juárez<sup>3</sup>, C. Bravo Barrera<sup>4</sup>

**Abstract**— This paper describes the development of an intelligent integrated system comprised of a fuzzy logic architecture developed from descriptive statistics and an artificial neural network multilayer perceptron applied in pattern recognition with digital image processing. The studied patterns are from the microstructure of carbon steel SA 210 Grade A-1. The purpose is to estimate the damage present in the material from the determination of the physical state of the material. Steel samples were tested in actual conditions, such as the steam and water at high temperature suffering deterioration not easily detectable by standard metallographic means. Studied patterns in the microstructure of the material were: pearlite lamellar, spheroidization and graphitization. The microstructure was revealed from images obtained by an inverted metallographic microscope (Olympus - GX71) in the Testing Laboratory Equipment and Materials of the Federal Electricity Commission in Mexico. (LAPEM - CFE). The results showed that the damage estimation and pattern recognition in the material were correctly predicted with the developed system compared to the human expert. Furthermore, the analysis can be performed in less time and cost.

**Keywords**— Artificial neural network (ANN), digital image processing, fuzzy logic and material defects.

## I. INTRODUCCIÓN

LA metalografía es la disciplina que estudia microscópicamente las características estructurales de un metal o de una aleación [2]. La microestructura revela el tratamiento mecánico y térmico del metal y, bajo un conjunto de condiciones dadas, se pueden predecir los comportamientos del metal. El comportamiento del acero al carbón SA 210 Grado A-1 presenta patrones metalográficos que deben ser diagnosticados por expertos en la disciplina a partir de una imagen de la microestructura del material. El experto valora en base a su experiencia y al patrón de comportamiento del material el grado de afectación de dicho material. La calidad del diagnóstico depende en gran medida de la experiencia del experto. Cabe mencionar que los diagnósticos para el grado de afectación realizados actualmente en el Laboratorio de Pruebas de Equipos y Materiales (LAPEM), son del tipo

lingüísticos, es decir, se emiten resultados como: incipiente, inicial, parcial, importante y avanzada afectación. El programa de mantenimiento en una planta de energía incluye la vigilancia sobre la salud en las estructuras metálicas, rutinariamente, se toman muestras de metal de diferentes conductores y se almacenan en una base de datos con el fin de ser analizadas por un experto en el área a partir de una imagen generando altos costos asociados. La representación del proceso actual se muestra en la Fig. 1.

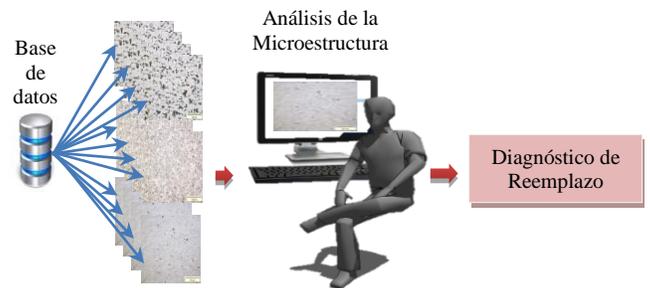


Figura 1. Esquema actual para el análisis metalográfico del acero al carbón.

En este artículo se muestra que es posible realizar una estimación del daño y reconocimiento del patrón presente en el material por medio de un sistema basado en la clasificación-reconocimiento de patrones a través de la integración de lógica difusa con una red neuronal artificial (RNA) perceptrón multicapa aplicada al procesamiento digital de imágenes. Esto se hace en dos etapas. La primera es de reconocimiento y clasificación mientras que la segunda, etapa es de estimación, por lo que el sistema presentado es del tipo reconocedor-clasificador-predicador. La RNA se emplea para realizar la primera etapa y el sistema de lógica difusa para la segunda.

### A. Trabajo Relacionado

Dentro de la aplicación de redes neuronales y la ciencia de los materiales, se demuestra el funcionamiento de las redes neuronales artificiales para estimar el espesor de imágenes radiográficas de materiales obtenidas por rayos X [9]. Otra aplicación de rayos X propone la detección de defectos internos en piezas fundidas derivadas de un sistema de inspección de rayos-X. El método propuesto aprovecha la teoría de conjuntos difusos e histograma. El umbral ideal se obtiene mediante la maximización de la entropía difusa exponencial asociada con la distribución de las clases de objetos y el fondo en el histograma [8].

Otra técnica que relaciona las redes neuronales con el estudio de materiales se presenta en [4], donde se desarrolla

<sup>1</sup>E. A. Ruelas, Centro de Innovación en Tecnologías Competitivas (CIATEC), Guanajuato, México, edruelas@itesi.edu.mx

<sup>2</sup>J. A. Vázquez, Instituto Tecnológico de Celaya, Guanajuato, México, antonio.vazquez@itcelaya.edu.mx

<sup>3</sup>J. Yañez, Centro de Innovación en Tecnologías Competitivas (CIATEC), Guanajuato, México, jyanez@ciatec.mx

<sup>4</sup>I. López, Centro de Investigación y de Estudios Avanzados del IPN (CINVESTAV), México, ismael.lopez@cinvestav.edu.mx

<sup>5</sup>C. F. Bravo, Laboratorio de Pruebas de Equipos y Materiales (LAPEM), Guanajuato, México, fernando.bravo01@cfe.gob.mx

un método para determinar el tipo de daño en el material y la magnitud del daño a partir de una emisión acústica (AE) en materiales refractarios. El uso de redes neuronales en materiales se ha visto abordado para resolver tareas de estimación, en el estudio de [1] y [7], se utilizan redes neuronales capaces de predecir características específicas de los materiales tales como fallo por fatiga y calidad de soldadura respectivamente, una de las principales características físicas de los materiales es la micro dureza y para poder determinar dicha característica es viable el uso de redes neuronales artificiales utilizando catorce parámetros de entrada a la RNA que afectan a la microdureza [6]. Otra aplicación para poder predecir la microestructura de los materiales es utilizando técnicas de elemento finito y redes neuronales artificiales [8].

De acuerdo a la revisión realizada de la literatura se deduce que el uso de las redes neuronales en el área de materiales es llevado a cabo en conjunto con técnicas que utilizan rayos X, análisis de elemento finito, emisiones acústicas y procesamiento digital de imágenes. De tal forma que la incorporación simultánea de técnicas como: redes neuronales, lógica difusa y procesamiento digital de imágenes enfocadas al desarrollo de un método para la clasificación-reconocimiento y estimación del deterioro del material en una escala establecida, es un enfoque no abordado para establecer diagnósticos en el área de materiales.

Se han realizado investigaciones previas donde se comprueba la viabilidad y beneficios de la integración entre redes neuronales artificiales y procesamiento digital de imágenes enfocados principalmente a la clasificación-reconocimiento y estimación de características importantes en el campo de los materiales, dentro de los avances de esta integración son el desarrollo de procedimientos donde se caracterizan los diferentes objetos en una escena por medio del cálculo de un histograma [6] o segmentación de una imagen [5], ambos métodos son utilizados para el entrenamiento de una red neuronal perceptrón multicapa y la Fuzzy ARTMAP respectivamente, posterior al entrenamiento las redes neuronales son empleadas en la clasificación-reconocimiento de patrones metalográficos de forma eficiente.

### B. Aportación

Los autores refieren como la contribución de esta investigación el desarrollo del sistema inteligente aplicado sobre el procesamiento digital del tipo de imágenes metalográficas que al mejor entendimiento de los mismos, contribuye como elemento de apoyo en la elaboración de diagnósticos predictivos en el área referida, cubriendo un espacio actual ya que, como se mencionó, estos diagnósticos se realizan por expertos humanos. Por otra parte, se menciona que la RNA es entrenada a partir de un histograma generado de la imagen metalográfica siguiendo el procedimiento desarrollado por [6]. Este procedimiento proporciona resultados eficaces en la clasificación y reconocimiento de estados del acero al carbón, lo cual da pie a la emisión de un

diagnóstico de reemplazo del material de forma automática. Aun identificando los estados del acero al carbón, solo es posible emitir un diagnóstico cualitativo es decir se podrá recomendar el reemplazo argumentando una parcial o avanzada afectación en el material u otra opción es recomendar la continuidad de uso del material argumentando una incipiente o inicial afectación.

Esta situación es corregida por un sistema difuso el cual toma como variables de entrada el estado del acero al carbón previamente clasificado y reconocido por la RNA y además la cantidad de ferrita presente, el sistema difuso después de procesar las entradas brinda un diagnóstico automático y eficiente del estado presente en el acero al carbón junto a la recomendación de reemplazo validado en la estimación del deterioro en una escala cuantitativa de 0-10 (siendo 10 un acero SA 210 Grado A-1 totalmente dañado) este enfoque de estimación en el daño presente en el material de acuerdo a los autores no se ha abordado desde la perspectiva de la lógica difusa. La arquitectura del sistema propuesto se presenta en la Fig. 2.

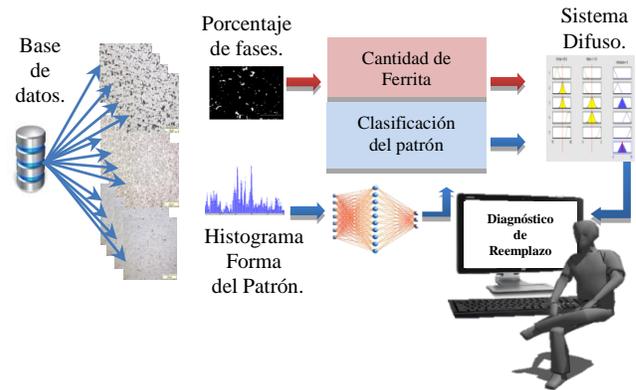


Figura 2. Arquitectura del sistema para la estimación del deterioro en el material

El desarrollo de un sistema que estime el deterioro presente en el material surge de la necesidad de corroborar el diagnóstico hecho por un experto metalográfico además de automatizar el proceso ya que el experto humano puede no estar disponible o puede haber una escasez de tales especialistas altamente cualificados. El impacto de un sistema que estime el deterioro a partir del reconocimiento de un patrón metalográfico está directamente relacionado con la recomendación de reemplazo o continuidad del material o equipo, en ambos casos si se emite un dictamen desacertado la organización de la cual proviene el material dañado tendrá costos inapropiados, ya que en el caso de emitir un reemplazo errado se perderá tiempo de vida útil, por lo contrario al recomendar la continuidad de uso de forma incorrecta el material sufrirá una falla en operación pasando así a un mantenimiento correctivo inesperado además de que la falla podría repercutir en otros equipos generando costos elevados.

## II. METODOLOGÍA EXPERIMENTAL

El caso de aplicación para esta investigación se desarrolló en el Laboratorio de Pruebas de Equipos y Materiales (LAPEM) de la Comisión Federal de Electricidad (CFE). Los patrones perlita laminar, esferoidización y grafitización se presentan en la Fig. 3; (a), (b) y (c) respectivamente.

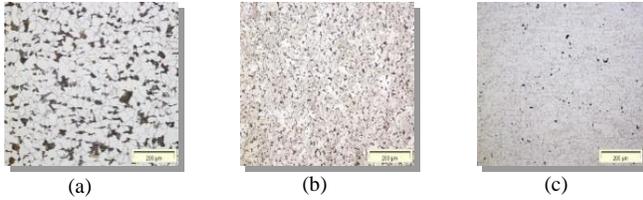


Figura 3. Patrones de comportamiento estudiados

### A. Procesamiento Digital de la Imagen

El procesamiento digital de la imagen inicia con la obtención de la imagen metalográfica, la cual consta de operaciones consecutivas. La primera operación es cortar el material afectado, de esta forma se analizan pequeñas secciones que permitan revelar información acerca de la causa o causas que propiciaron el daño en el material. El segundo paso es la fabricación de un probeta con resina epóxica, lijada y pulida con una solución de carburo de silicio hasta obtener un acabado espejo. Por último se aplica una solución Nital sobre la probeta con una concentración de 4% durante cinco segundos para revelar la microestructura. Finalmente, la muestra es observada por un experto usando un microscopio invertido metalográfico (Olympus - GX71) y un analizador de imágenes (Analysis Five). Una vez tomada la imagen puede ser almacenada o distribuida para su futuro procesamiento.

De acuerdo con los autores [6], una forma eficiente para la clasificación- reconocimiento de patrones metalográficos por medio de una RNA, es mediante el entrenamiento de la red neuronal a partir de un histograma calculado como se muestra en la Fig. 4.

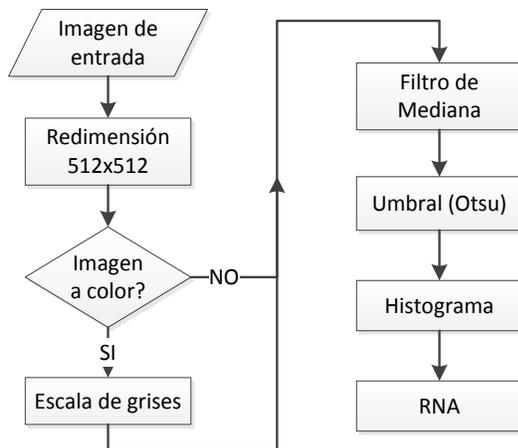


Figura 4. Diagrama de proceso para la imagen metalográfica

Dentro de la fase de procesamiento se agrega el cálculo del histograma generado por medio de la suma de las columnas de la matriz que representa a la imagen. De dicho histograma se genera la señal de entrada de la imagen a la RNA. En la Fig. 5, se muestra la fase de pre-procesamiento (a, b) y procesamiento (c, d) de las imágenes que son introducidas a la RNA y así permitir la clasificación-reconocimiento de patrones metalográficos, la imagen presentada pertenece al patrón de comportamiento grafitización.

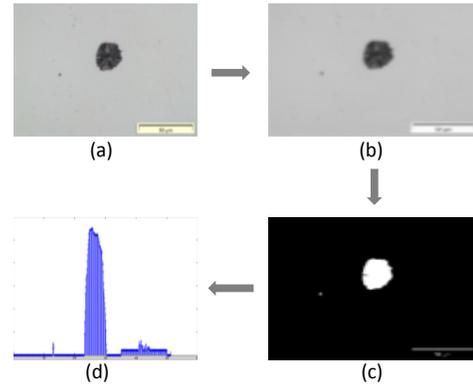


Figura 5. Grafitización. Procesamiento y asociación del patrón a la imagen. (a) Imagen original. (b) Redimensión y escala de gris. (c) Cálculo de umbral. (d) Cálculo de Histograma

Se realiza un ajuste en los parámetros que integran la topología de la RNA hasta obtener una combinación que arroje una solución aceptable en la clasificación presentada a la red neuronal. El cálculo del porcentaje de fases en una imagen metalográfica es un mecanismo que permite medir la cantidad de ferrita y de perlita en el material de acero al carbón, un material sin afectación inicia con un porcentaje de 80% de ferrita y 20% de perlita. Un fenómeno que se manifiesta en el acero al carbón SA 210 Grado A-1 es el incremento del porcentaje de ferrita conforme el material se va deteriorando a lo largo del tiempo en uso.

El porcentaje de ferrita puede determinarse empleando la ecuación 1.

$$\% \text{ ferrita} = \left[ 1 - \left( \frac{\sum_{i=1}^n x_i}{\text{Área total}} \right) \right] * 100 \quad (1)$$

Dónde:  $x$  = Formas con perlita en la imagen metalográfica  
 $n$  = Numero de formas

Tomando como base la relación de la ferrita con respecto al daño presente en el material, es importante determinar la cantidad de ferrita presente en la muestra de material y de esta forma poder establecer otro indicador que contribuya a fundamentar una estimación del deterioro en material de forma eficiente. El procesamiento de la imagen que se llevó a cabo para determinar la cantidad de ferrita presente en la imagen metalográfica se ilustra en la Fig. 6. En 6(a) se obtienen la imagen en estado original de tamaño [1024 x 1024], en 6(b) se pasa a escala de gris y se indexa a un tamaño de [455 x 512], en 6(c) se realiza la fase de umbralización mediante el método Otsu y por último en 6(d) se localizan áreas de perlita y por diferencia se obtiene la cantidad de ferrita empleando la ecuación 1.

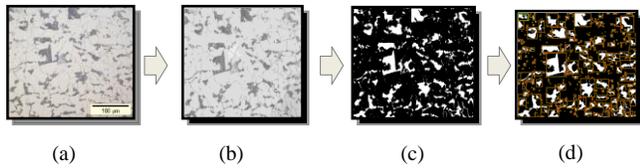


Figura 6. Etapas para el cálculo del porcentaje de ferrita en la imagen metalográfica

### B. Reconocimiento – Clasificación del Patrón Metalográfico

El conjunto de patrones empleados para entrenar y probar a la RNA se llevó a cabo por medio de una base de datos de dieciséis imágenes metalográficas afectadas por patrones previamente reconocidos e identificados por expertos de LAPEM. La matriz de entrenamiento se generó a partir de dieciséis vectores con tamaño igual a quinientos doce elementos [1 x 512] desarrollados a partir del proceso mostrado en la Fig. 7, así queda definida una matriz de [16 x 512] incorporada a la red neuronal perceptrón multicapa. La composición de la matriz para el entrenamiento se muestra en la tabla 1. La fase de validación en el proceso de clasificación-reconocimiento se realizó empleando una matriz de [6 x 512].

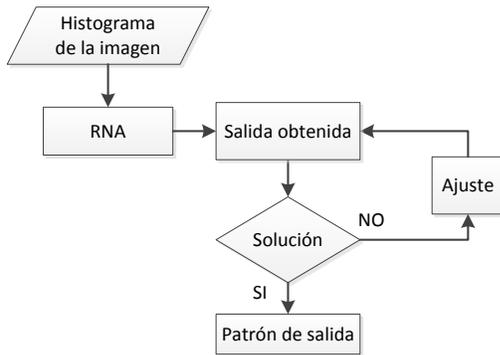


Figura 7. Proceso de Clasificación-Reconocimiento de patrones metalográficos.

TABLA 1. MATRIZ DE ENTRENAMIENTO

Patrón Metalográfico	Dimensión
Perlita Laminar	6 x 512
Esferoidización	5 x 512
Grafitización	5 x 512

La topología utilizada en la red neuronal está descrita en la tabla 2. El código fue desarrollado dentro del programa *Matlab*® 2012. El criterio de selección para los parámetros de la topología está basado en el error cuadrático medio (MSE) que tienen los valores estimados de la RNA con respecto a los objetivos tanto en la fase de aprendizaje como de validación.

TABLA 2. PARÁMETROS Y TOPOLOGÍA DE LA RED NEURONAL PERCEPTRÓN MULTICAPA

Parámetro	Valor
Número de capas ocultas.	1
Número de neuronas en la capa oculta.	22
Función de activación de la capa oculta.	Tangente Hiperbólica
Visualización durante el entrenamiento.	50
Tasa de aprendizaje.	0.01
Valor de función de error a alcanzar.	1e-5
Número máximo de épocas.	3000
Tipo de entrenamiento.	Gradiente conjugada escalada

La RNA seleccionada fue probada para verificar el aprendizaje de la matriz introducida y así poder pasar a una fase de validación. El valor de (-1) es el patrón perlita laminar, (0) esferoidización y (1) grafitización. Los valores obtenidos de la RNA fueron redondeados a su entero más cercano para así después compararlos contra los valores objetivos, la topología presenta un error cuadrático medio (MSE) de 0.0034 y un coeficiente de correlación de 0.99979. Ver tabla 3.

TABLA 3: VALORES CALCULADOS POR LA RNA VS OBJETIVOS

Salida de la RNA	Aproximación	Objetivo
-0.943613908	-1	-1
-0.925075354	-1	-1
-0.940437794	-1	-1
-0.927135461	-1	-1
-0.930951598	-1	-1
-0.945067194	-1	-1
-0.000334693	0	0
0.002325878	0	0
0.000862719	0	0
-0.002749532	0	0
-0.00059213	0	0
0.937526449	1	1
0.877807218	1	1
0.918653839	1	1
0.953097102	1	1
0.96176845	1	1

### C. Estimación de la condición del deterioro

En el LAPEM la estimación del deterioro se realiza mediante la experiencia del analista al observar el patrón de comportamiento presente en la imagen metalográfica y determinar el porcentaje de fases del material, después de este proceso el experto arroja un resultado cualitativo y lingüístico.

La Fusificación realizada para la entrada correspondiente a la cuantificación de la ferrita presente en la imagen metalográfica se desarrolló generando tres niveles de pertenencia los cuales se muestran en la Fig. 8. La primera función de pertenencia se cataloga como *Normal* con un valor de pertenencia superior en 80% de ferrita, este es el estado inicial comúnmente de un acero al carbón SA 210 Grado A-1 y conforme es sujeto a condiciones de trabajo aumenta el porcentaje de ferrita y solo en pocos casos decrece. La segunda función de pertenencia presenta su valor máximo en 86% y se define como un *Incremento Moderado* ambas funciones de pertenencia son del tipo Gaussianas. La última función de pertenencia es del tipo *sigmoidal* y etiquetada

como *Incremento Considerable*, esta función presenta un incremento positivo y posteriormente constante a partir de registrar un 89.5%, ya que a partir de este valor de acuerdo con los expertos el incremento en la ferrita ya es importante.

La amplitud de cada función de pertenencia se definió tomando como base un intervalo de confianza para la media, para la construcción del intervalo se consideró la relación del patrón de comportamiento y la cantidad de ferrita presentes en el material, es decir, se analizaron los históricos del porcentaje de ferrita presente en cada patrón de comportamiento previamente definidos por expertos humanos. Los datos fueron analizados estadísticamente por cuartiles para eliminar puntos atípicos y se comprobó el comportamiento de normalidad mediante la prueba Anderson Darling con resultados de  $p > 0.05$ , la probabilidad del error tipo I en el intervalo fue de 5%. Aun así se realizaron ajustes en la amplitud de la función tomando en cuenta la opinión de expertos, en esta etapa se consideró el valor de salida (estimación del deterioro en el material) como el parámetro de ajuste, las modificaciones mínimas se llevaron a cabo para desarrollar una arquitectura de lógica difusa que arroje un resultado coherente y ajustado a la realidad. El universo del discurso tiene un rango de [75, 95] ya que son los extremos de presencia de ferrita en un acero al carbón del tipo SA 210 Grado A-1.

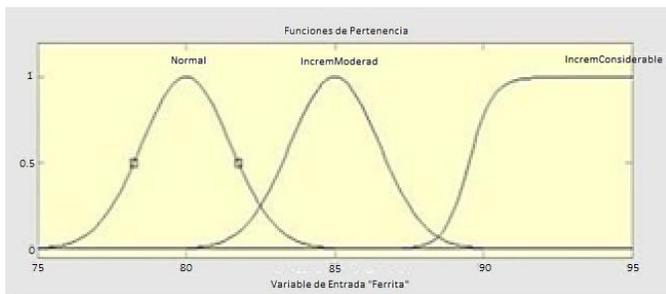


Figura 8. Funciones de pertenencia para la variable porcentaje de ferrita

La fusificación de la entrada que analiza el patrón de comportamiento previamente clasificado y reconocido por la RNA es codificada añadiendo valores de salida para cada patrón de comportamiento. El sistema de lógica difusa identifica las salidas de la RNA con un valor numérico (0) *perlita laminar*, (1) *esferoidización* y (2) *grafitización*. De tal forma que se genera una función de pertenencia para cada salida de la RNA posible, las tres funciones de pertenencia son del tipo sigmoide etiquetadas con el respectivo nombre del patrón que representan y logrando su mayor grado de pertenencia en 0, 1 y 2 respectivamente para cada patrón de comportamiento, y de esta forma queda definido también el universo del discurso con valores entre [0, 2]. Ver Fig. 9.



Figura 9. Funciones de pertenencia para la variable patrón metalográfico

La fusificación de la variable de salida está dada por la cantidad de diferentes variables lingüísticas que se manejan en la estimación del deterioro en el material de acero al carbón que son: *Sin afectación*, *incipiente*, *inicial*, *parcial* y *avanzada afectación*. Dado que son cinco variables lingüísticas se generan cinco funciones de pertenencia del tipo triangular, el universo del discurso es definido de [0, 10] ya que requiere emitir una estimación del deterioro del material de forma puntual en una escala de 0 a 10. El grado de pertenencia más alto para cada función es de 0 para la función *sin afectación* y va incrementando en 2.5 unidades hasta llegar a 10 con la función *avanzada afectación*. Ver Fig. 10.

El método utilizado para realizar la inferencia es el denominado método Mamdani el cual utiliza reglas tipo *si-entonces* (if-else). Una regla que pertenece a la base de conocimiento tiene dos partes, el antecedente y la conclusión como se observa en la tabla 4. La inferencia está basada en dos entradas que son el porcentaje de fases y el patrón de comportamiento presente en el material y a partir del análisis de las dos variables se concluye en base a la única salida que es la estimación de la condición del material de acero al carbón del tipo SA 210 Grado A-1.

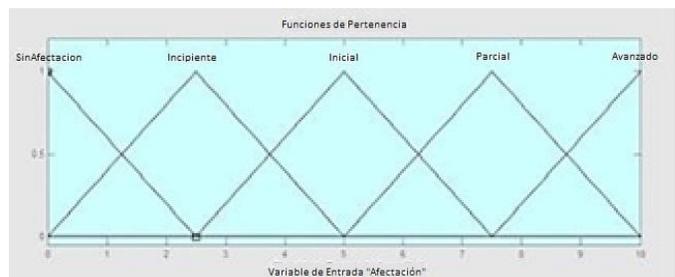


Figura 10. Funciones de pertenencia para la variable de salida

TABLA 4. REGLAS DE INFERENCIA UTILIZADAS EN EL SISTEMA DE LÓGICA DIFUSA

### Reglas de Inferencia

- If Ferrita is Normal and Patrón is PLaminar then Afectación is SinAfectacion
- If Ferrita is IncrémModerado and Patrón is PLaminar then Afectación is Incipiente
- If Ferrita is IncrémModerado and Patrón is Esferoidizacion then Afectación is Inicial
- If Ferrita is IncrémConsiderable and Patrón is Esferoidizacion then Afectación is Parcial
- If Ferrita is IncrémConsiderable and Patrón is Grafitizacion then Afectación is Avanzado

Se empleó el algoritmo de Centro de Gravedad (CoG) para defusificar el valor de salida y obtener un número real.

$$y_d = \frac{\int_s y \mu_y(y) dy}{\int_s \mu_y(y) dy} \quad (2)$$

Donde  $\mu_y$  es la función de pertenencia del conjunto de salida  $Y$ , cuya variable de salida es  $y$ .  $S$  es el dominio o rango de integración. Después de la defusificación se obtiene un escalar dentro del intervalo  $[0, 10]$ . El sistema de lógica difusa podrá otorgar una calificación en donde el valor de cero es el estado sano del material. En la Fig. 11, se muestra la superficie de afectación generada en base al porcentaje de ferrita y el patrón de comportamiento.

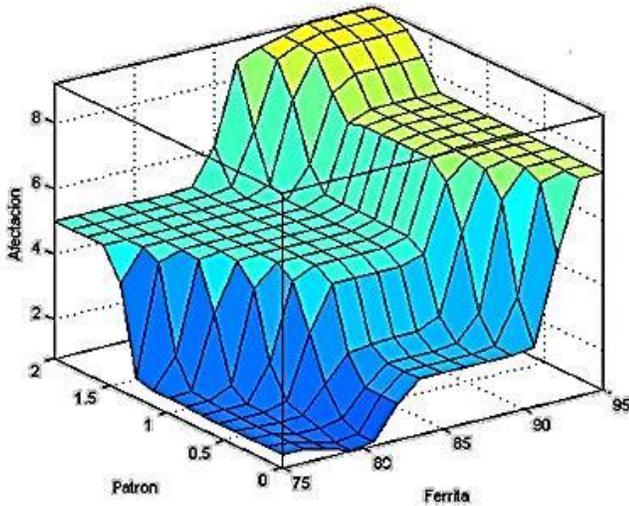


Figura 11. Superficie de afectación

### III. RESULTADOS

Para verificar el buen funcionamiento de la red neuronal artificial (RNA) y la capacidad de solución de la tarea de clasificación y reconocimiento de los patrones metalográficos, se desarrolló una fase de validación en la que se introducen 6 nuevas imágenes con patrones de perlita laminar, esferoidización y grafitización para su clasificación y reconocimiento. Las imágenes metalográficas fueron previamente reconocidas e identificadas por expertos. Los resultados de la fase de validación para la topología desarrollada se muestran en la tabla 5, con un MSE de 0.039.

TABLA 5. VALORES CALCULADOS POR LA RNA VS OBJETIVOS

Imagen	Salida de la RNA	Objetivo	Reconocimiento del Patrón
1	-0.65822119	-1	Correcto Perlita Laminar
2	-0.932801352	-1	Correcto Perlita Laminar
3	0.098983452	0	Correcto Esferoidización
4	0.036884246	0	Correcto Esferoidización
5	0.676775168	1	Correcto Grafitización
6	0.962338658	1	Correcto Grafitización

Para validar la estimación del deterioro en el material a partir del sistema de lógica difusa se compararon los resultados obtenidos del sistema contra los resultados emitidos por un experto en la materia en un total de 6 imágenes. Ver tabla 6.

TABLA 6. RESULTADOS DE CLASIFICACIÓN-RECONOCIMIENTO Y ESTIMACIÓN DE DETERIORO

Imagen	Indicadores	Sistema Experto	Experto Humano	Comparación
1	Patrón	Perlita Laminar	Perlita Laminar	Correcto
	Deterioro	2.5%	3%	0.5%
2	Patrón	Perlita Laminar	Perlita Laminar	Correcto
	Deterioro	0.8%	0%	0.8%
3	Patrón	Esferoidización	Esferoidización	Correcto
	Deterioro	3.92%	5%	1.08%
4	Patrón	Esferoidización	Esferoidización	Correcto
	Deterioro	5%	5%	0%
5	Patrón	Grafitización	Grafitización	Correcto
	Deterioro	91.6%	90%	1.6%
6	Patrón	Grafitización	Grafitización	Correcto
	Deterioro	92%	95%	3%

### IV. CONCLUSIONES

Los resultados obtenidos en esta investigación demuestran la viabilidad de un sistema neuro-difuso de procesamiento digital de imágenes para el diagnóstico de diversos estados físicos del acero a partir de una imagen microestructural. El caso de estudio se realizó para acero al carbón SA 210 Grado A-1. El método se presenta como alternativa de estimación cuantitativa de deterioro del acero sufrido en planta en sustitución del uso de un experto humano.

El artículo presenta una alternativa novedosa, eficiente y con bajo costo computacional en comparación a técnicas reportadas hasta ahora para la estimación del deterioro ya que solo recurre a la información de dos parámetros como son: el patrón metalográfico y el porcentaje de fases presentes en la imagen de la microestructura. Este procedimiento ha demostrado brindar resultados equivalentes a los de un experto, por lo que su empleo sería útil cuando no se cuenta con un experto.

### AGRADECIMIENTOS

Los autores agradecen a CONACYT-MEXICO y al Posgrado Interinstitucional en Ciencia y Tecnología por las facilidades brindadas a Edgar Augusto Ruelas Santoyo durante sus estudios doctorales.

### REFERENCIAS

- [1] Al-Assadi, et al., "Predicting the Fatigue Life of Different Composite Materials Using Artificial Neural Networks", Applied Composite Materials, Volume 17, Issue 1, pp 1-14, 2010.
- [2] Federación de Enseñanza de C.C.O.O. de Andalucía, "Temas para la Educación", Metalografía, Revista digital para profesores de la enseñanza [En Línea], Recuperado el 13 de febrero de 2013, de <http://www2.fe.ccoo.es/andalucia/docu/p5sd8732.pdf>, 2011.
- [3] G. Khalaj, et al., "Artificial neural network to predict the effect of heat treatments on Vickers microhardness of low-carbon Nb microalloyed

- steels”, *Neural Computing and Applications*, Volume 22, Issue 5, pp 879-888, 2013.
- [4] C. Liu, et al., “Damage Pattern Recognition of Refractory Materials Based on BP Neural Network”, *Neural Information Processing*, Volume 7666, pp 431-440, 2012.
- [5] E. Ruelas, J. Vázquez, J. Yáñez, I. López, C. Bravo, “Integración de métodos para la clasificación-reconocimiento de patrones a base de inteligencia artificial y procesamiento digital de imágenes”, *Special issue: Advances in Intelligent and Information Technologies, Research in Computing Science*, ISSN: 18770-4069, Indexado en Latindex y Periodica, 2012.
- [6] E. Ruelas, J. Vázquez, J. Yáñez, I. López, C. Bravo, “Wear Pattern Recognition System for Metal Microstructure using a Multilayer Perceptron”, *International Journal of Computers Communications & Control (IJCCC)*, ISSN: 1841-9844 Online, ISSN-L: 1841- 9836, En revision.
- [7] L. Subashini, et al., “Adaptive Neuro-Fuzzy Inference System (ANFIS)-Based Models for Predicting the Weld Bead Width and Depth of Penetration from the Infrared Thermal Image of the Weld Pool”, *Metallurgical and Materials Transactions B.*, Volume 43, Issue 1, pp 145-154, 2012.
- [8] Y. Tang, et al., “Application of a new image segmentation method to detection of defects in castings”, *The International Journal of Advanced Manufacturing Technology*, Volume 43, Issue 5-6, pp 431-439, 2009.
- [9] I. Tansel, et al., “Neural Network Based Thickness Estimation from Multiple Radiographic Images”, *Journal of Nondestructive Evaluation*, Volume 25, Issue 2, pp 53-66, 2006.



**Edgar Augusto Ruelas Santoyo.** Earned a BEng and MSc in Industrial Engineering from the Instituto Tecnológico de Celaya in 2008 and 2011, respectively. Currently, he is pursuing his PhD studies in the Posgrado Interinstitucional en Ciencia y Tecnología (PICYT), Mexico. He is also lecturing at the Instituto Tecnológico Superior de Irapuato. His main research interests are in Industrial Engineering, Image processing, Fuzzy Logic and Neural Networks.



**José Antonio Vázquez López** graduated with Engineering and Master degree from Instituto Tecnológico de Celaya, in 1998 and 2001. He obtained PhD in Posgrado Interinstitucional en Ciencia y Tecnología (PICYT) from CIATEC in 2009. His main research interest is in industrial engineering and statistics, where he has served as an industrial consultant for several companies. His research interests are design and improvement of processes and products: advanced process control and pattern recognition using neural networks. He is currently a Full Professor in the Instituto Tecnológico of Celaya.



**Javier Yáñez Mendiola.** He obtained a BEng in Electronics from the Instituto Tecnológico de Celaya, México. He also holds an MSc and a PhD degree in optics from the Centro de Investigación en Optica in the area of image processing. He is a researcher at the Centro de Innovación en Tecnologías Competitivas (CIATEC), México.



**Ismael López Juárez** obtained a BEng in Mechanical-Electrical Engineering from UNAM in 1991. He received an MSc in Instrument Design and Application from University of Manchester in 1996, and the PhD in Intelligence Robotics from Nottingham Trent University in 2000. He was founder and leader of *Grupo de Investigación en Mecatrónica y Sistemas Inteligentes de Manufactura* in CIATEQ, A.C (2000-2006). Currently, he is a principal researcher in CINVESTAV.



**Carlos Fernando Bravo Barrera.** Obtained a BEng in Electrical and Mechanical Engineering from the Tecnológico de Monterrey in 1990. He is currently the Head of Department of Materials at the Laboratorio de Pruebas de Equipo y Materiales from the Comisión Federal de Electricidad de México (LAPEM - CFE). His main research areas are within the area of material characterization and failure analysis.

**Result of paper submission #2439 for RevistaIEEE-AL**  
editor-in-chief-r9@ieee.org [editor-in-chief-r9@ieee.org]

Ha reenviado este mensaje el 18/08/2015 05:47 p.m..

**Enviado el:** martes, 18 de agosto de 2015 01:04 p.m.

**Para:** Edgar Augusto Ruelas Santoyo; editor-in-chief-r9@ieee.org

Estimado autor,  
THIS IS AN AUTOMATIC MESSAGE. PLEASE, DON'T REPLY.

Su artículo ha sido aceptado y pronto será publicado en IEEE Latin America Transactions y el IEEE Xplore.

Publicación de los enlaces:

IEEE Xplore: <http://ieeexplore.ieee.org/xpl/mostRecentIssue.jsp?punumber=9907>

Revista IEEE Latin America Transactions : <http://www.ewh.ieee.org/reg/9/etrans/esp/>

Agradecemos su colaboración.  
Editor IEEE-R9  
July de 2015 - Accept.  
Regular Edition Vol 13 Issue 7 July 2015.

THIS IS AN AUTOMATIC MESSAGE. PLEASE, DON'T REPLY.

===

**Published in:**

Latin America Transactions, IEEE (Revista IEEE America Latina) (Volume:13 , Issue: 7 )

**Page(s):**  
2322 - 2328

**ISSN :**  
1548-0992

**INSPEC Accession Number:**  
15475088

**DOI:**  
[10.1109/TLA.2015.7273794](https://doi.org/10.1109/TLA.2015.7273794)

**Date of Publication :**  
July 2015

**Date of Current Version :**  
22 septiembre 2015

**Issue Date :**  
July 2015

**Sponsored by :**  
[IEEE Region 9](#)

**Publisher:**  
IEEE

Ruelas, E.A.; Vazquez, J.A.; Yanez, J.; Lopez, I.; Bravo, C.F., "Condition Estimation Of Carbon Steel Using A Neuro-Fuzzy System And Image Processing," in *Latin America Transactions, IEEE (Revista IEEE America Latina)* , vol.13, no.7, pp.2322-2328, July 2015  
doi: 10.1109/TLA.2015.7273794

URL: <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=7273794&isnumber=7273753>

# Sistema neuronal-difuso aplicado al reconocimiento y evaluación del daño en aceros al carbono apoyado en estadística descriptiva



## Neuronal-fuzzy system applied to recognize and assessing of damage in carbon steel supported by descriptive statistics



Edgar Augusto Ruelas Santoyo<sup>1</sup>, José Antonio Vázquez López<sup>2</sup>, Javier Yáñez Mendiola<sup>1</sup>, Ismael López Juárez<sup>3</sup>, Carlos Fernando Bravo Barrera<sup>4</sup>

<sup>1</sup> Centro de Innovación Aplicada en Tecnologías Competitivas (CIATEC). Omega 201. León, Guanajuato (Méjico).

<sup>2</sup> Instituto Tecnológico de Celaya. Departamento de Ingeniería Industrial. Avenida Tecnológico. Celaya, Guanajuato (Méjico).

<sup>3</sup> Centro de Investigación y de Estudios Avanzados del IPN. Departamento de Robótica y Manufactura Avanzada. Av. Ind. Metalúrgica 1062, P. Ind. Ramos Arizpe, Ramos Arizpe, Coahuila (Méjico).

<sup>4</sup> Laboratorio de Pruebas de Equipos y Materiales, Departamento de Mecánica y Materiales. Av. Apaseo Ote. s/n Cd. Industrial. Irapuato, Guanajuato (Méjico).

DOI: <http://dx.doi.org/10.6036/7777> | Recibido: 27/01/2015 • Aceptado: 17/10/2015

### ABSTRACT

- This paper describes the development of an intelligent integrated system able to estimate the damage to carbon steel; the system is integrated by a fuzzy logic architecture developed from descriptive statistics and an artificial neural network multilayer perceptron applied to the recognition of metallographic patterns. The images obtained were characterized from the analysis of textures images using first, second and third order statistical. The patterns studied were associated to the microstructure of carbon steel (SA 210 Grade A-1). The proposal allowed estimating the damage present in the material from the determination of the physical states of the material. Steel samples were tested in real conditions of operation, such as high temperatures and humidity, suffering deterioration that it was difficulty detected by standard metallographic methods. The patterns studied in the microstructure of the material were: laminate perlite, spheronization and graphitization. The microstructure was revealed from images obtained by an inverted metallographic microscope (Olympus - GX71) in the Testing Equipment and Materials Laboratory of the Federal Electricity Commission in Mexico. (LAPEM - CFE). The results showed that the damage estimation and pattern recognition in the material were correctly predicted with the developed system compared to the human expert.
- Key Words:** Artificial neural network, image processing, fuzzy logic and metallography.

### RESUMEN

Este artículo describe el desarrollo de un sistema integral inteligente capaz de reconocer patrones metalográficos y estimar el daño en el acero al carbono SA 210 Grado A-1. El sistema está compuesto por una arquitectura de lógica difusa desarrollada tomando como base estadística descriptiva y la red neuronal artificial perceptrón multicapa aplicado en el reconocimiento de patrones metalográficos. El procesamiento digital de las imágenes metalográficas es llevado a cabo caracterizando las texturas de las imágenes mediante estadísticos de primero, segundo y tercer orden.

Los patrones estudiados se encuentran en la microestructura de los materiales de acero al carbono SA 210 Grado A-1. La pro-

puesta permite estimar el daño presente en el material a partir de la determinación de los estados físicos del material; las muestras de acero estuvieron sometidas a condiciones de trabajo reales, tales como la conducción de vapor y agua a altas temperaturas, sufriendo en consecuencia deterioro que no es fácilmente detectable por medios estándar metalográficos. Los patrones estudiados en la microestructura del material fueron: perlita laminar, esferoidización y grafitización. La microestructura se revela a partir de imágenes obtenidas por un microscopio invertido metalográfico (Olympus-GX71) en el Laboratorio de Pruebas de Equipos y Materiales de la Comisión Federal de Electricidad México. (LAPEM-CFE). Los resultados mostraron que la estimación de daños y de reconocimiento de patrones en el material se predijo correctamente con el sistema desarrollado en comparación con el experto humano.

**Palabras Clave:** Redes Neuronales artificiales, procesamiento de imágenes, lógica difusa y metalografía.

### INTRODUCCIÓN

La metalografía es la disciplina que estudia microscópicamente y a partir de imágenes las características estructurales de un metal o de una aleación [1]. Dichas imágenes revelan el tratamiento mecánico y térmico del metal y, bajo un conjunto de condiciones dadas, pueden predecir los comportamientos del metal. El comportamiento del acero al carbono SA 210 Grado A-1 presenta patrones metalográficos desde el inicio y al final de su vida útil, ver Fig. (1): 1(a) perlita laminar, 1(b) esferoidización y 1(c) grafitización.

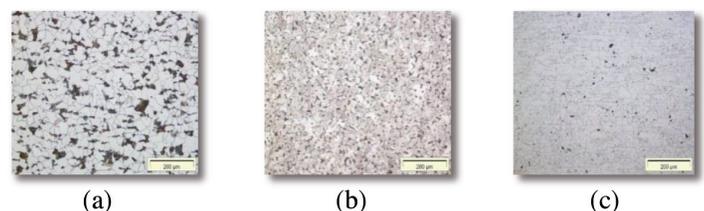


Fig. 1: Patrones metalográficos estudiados

De acuerdo con [1] cada grano de perlita está formado por láminas de cementita y ferrita, de ahí el nombre de perlita laminar

y, micro estructuralmente hablando, es el estado más estable del acero al carbono. Sin embargo, cuando se somete durante tiempos prolongados el material a altas temperaturas cercanas al A1 (723°C) [1], se puede producir la transformación de esa cementita, apareciendo en una forma globular en el grano de ferrita: es la esferoidización.

Posteriormente, la descomposición de esa cementita metaestable en ferrita y grafito, conocida como grafitización, puede ocasionar fallas o agrietamiento en los aceros al carbono. El origen de la fase de grafitización comienza con la formación de grafitos en la interface ferrita-cementita y presencia de carburos pequeños en las fronteras de grano a temperaturas por encima del A1 [1]. Durante el proceso de grafitización la dureza y resistencia decrece progresivamente.

En los tubos de aceros al carbono se encuentra una capa fina de magnetita. La formación de esta capa de óxido es esencial para la protección del acero. Pero una capa gruesa de magnetita tiene el inconveniente que impide la transferencia de calor entre el metal del tubo y el vapor, debido a que el óxido de hierro tiene una conductividad térmica mucho menor que el acero del tubo (conductividad del acero esta entre 170 y 310 BTU × in/h × ft<sup>2</sup> × °F la magnetita tiene una conductividad de 20 BTU × in/h × ft<sup>2</sup> × °F) esto da como resultado un aumento de la temperatura del metal y por lo tanto una reducción de la vida útil del tubo. El problema se intensifica cuando el tubo de acero opera por largos periodos de tiempo sin una limpieza química de remoción de la magnetita pudiendo alcanzar espesores no recomendables cercanos a un 1 mm [1].

En plantas termoeléctricas de México el material más utilizado como conductor de agua y vapor a temperaturas entre [600-780 °C] es el acero al carbono SA 210, para vigilar el daño sufrido en los conductores es necesario extraer muestras y así evaluar el estado del resto de los elementos. Solo así es posible establecer un mantenimiento preventivo y no incurrir en mantenimientos correctivos que generarían costos inesperados.

Debido a que el acero al carbono SA 210 es sometido a condiciones de altas temperaturas genera diferentes estados en su microestructura de forma repetitiva y bajo condiciones similares, pudiendo así denominar patrones metalográficos a las fases de perlita laminar, esferoidización y grafitización. Los patrones metalográficos actualmente como primera instancia deben ser diagnosticados por expertos en la disciplina a partir de una imagen micro estructural del material. Como segunda instancia el experto valora en base al patrón metalográfico el grado de afectación del material, ver Fig. (2). La calidad del diagnóstico depende en gran medida de la experiencia del experto. Cabe mencionar que los diagnósticos para el grado de afectación realizados actualmente en el Laboratorio de Pruebas de Equipos y Materiales (LAPEM), son únicamente del tipo lingüísticos, es decir, se emiten resultados como: sin afectación, incipiente, inicial, parcial, y avanzada afectación, lo cual es subjetivo al no tener una escala establecida.

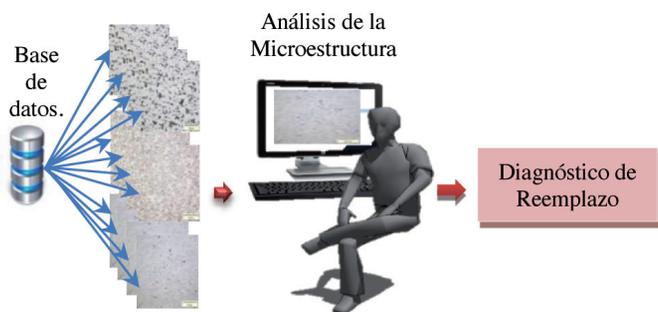


Fig. 2: Esquema actual para el análisis metalográfico

El artículo muestra que es posible realizar una estimación cuantitativa del daño en aceros al carbono en una escala establecida de [0,10] siendo el cero el estado sano del material. Además el sistema es capaz de realizar una clasificación-reconocimiento del patrón metalográfico presente en el material por medio de un sistema integral neuronal-difuso aplicado al procesamiento digital de imágenes metalográficas y soportado mediante estadística descriptiva, logrando el desarrollo de un sistema inteligente orientado a corroborar el diagnóstico hecho por un experto e incluso a sustituir la aportación del experto.

El sistema neuronal-difuso trabaja en dos etapas al igual que el experto humano. La primera es de reconocimiento y clasificación mientras que la segunda etapa es de estimación. La red neuronal artificial (RNA) se emplea para realizar la primera etapa. De este modo, los materiales, o propiamente dicho, sus imágenes son procesadas digitalmente para reconocer y clasificar los patrones metalográficos ubicados en la microestructura del material. La clasificación-reconocimiento del patrón metalográfico es información que no tiene un límite claro para estimar un deterioro cuantitativo en el material es por ello que el experto emite diagnósticos lingüísticos.

La lógica difusa permite trabajar con información no exacta ligada a variables lingüísticas y obtener información definida [2], para mejorar la estimación del deterioro en el material adicionalmente se procesa información como el nivel de capa magnetita y la cantidad de ferrita presente en la imagen metalográfica y pasar de un diagnóstico cualitativo a uno cuantitativo.

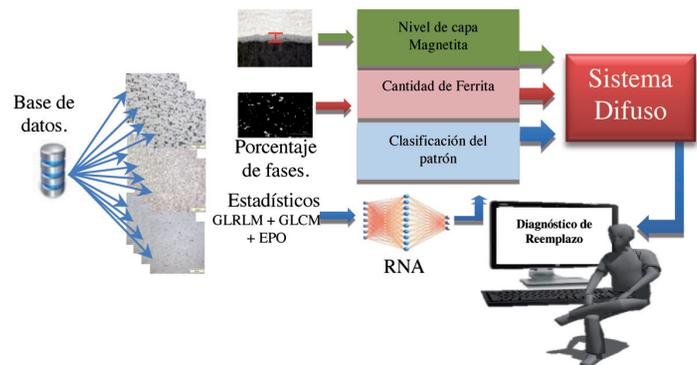


Fig. 3: Arquitectura del sistema propuesto

De acuerdo con [3], la RNA perceptron multicapa presenta cualidades por encima de las redes de una capa simple. Las redes feedforward son eficientes en aplicaciones de clasificación-reconocimiento de patrones. Para dar paso a la etapa de clasificación-reconocimiento de los patrones metalográficos es indispensable generar una señal de entrada para la RNA, para ello las imágenes metalográficas son analizadas como texturas, hoy en día los métodos estadísticos son un referente en la caracterización de texturas, se basan en el análisis de la distribución espacial de los niveles de gris en la imagen. Dependiendo del número de píxeles usados para definir los rasgos locales, los métodos estadísticos pueden ser clasificados a su vez en estadísticos de primer orden (EPO; toman los píxeles individualmente), de segundo orden (Gray Level Co-occurrence Matrices; GLCM; toman parejas de píxeles) o de tercer orden (Gray Level Run Length Matrix; GLRLM; se involucran tres o más píxeles) [4]. La arquitectura del sistema propuesto se presenta en la Fig. (3). Los códigos del sistema propuesto fueron desarrollados en el entorno del programa *Matlab*® 2012 incluyendo la interface de usuario.

Se han realizado investigaciones donde comprobaron los beneficios de la integración entre RNA's, sistemas difusos y procesa-

miento digital de imágenes en el campo de los materiales. En [5] se compararon RNA's monofrecuencia y una multifrecuencia en la clasificación de piezas de acero obteniendo mejores resultados con una RNA multifrecuencia incluso en el costo computacional.

$$\varphi(x, y) = \varphi(x)\varphi(y), \psi^H(x, y) = \psi(x)\varphi(y), \psi^V(x, y) = \varphi(x)\psi(y), \psi^D(x, y) = \psi(x)\psi(y) \quad (1)$$

El procesamiento de imágenes en los materiales fue estudiado por [6] donde a partir de un algoritmo de segmentación se llevó a cabo el control de calidad de piezas fabricadas por fundición. Otro uso de las RNA's en materiales se ha visto abordado para resolver tareas de estimación, en el estudio de [7] y [8], se utilizaron redes neuronales capaces de predecir características específicas de los materiales tales como fallo por fatiga y calidad de soldadura respectivamente. En cuanto a la integración de lógica difusa en el área de los materiales se propuso que la lógica difusa es una herramienta eficiente para modelar el crecimiento de fases boruradas de aceros [9], en [10] se demostró que un sistema de inferencia difusa cuenta con mayor precisión que un método de regresión tradicional para la estimación del esfuerzo durante la deformación en aleaciones de titanio. De acuerdo a la revisión realizada se concluye que la incorporación del procesamiento de imágenes como señal de entrada a un sistema proporciona una señal automática y con información importante, el uso de una RNA como método de clasificación y la lógica difusa como mecanismo de estimación de estados físicos en los materiales brinda buenos resultados

Después de una breve introducción del tema a tratar en la sección 1, el artículo se organiza de la siguiente forma: la sección 2 se compone por una descripción de los materiales y métodos utilizados como la RNA, el procesamiento digital de la imagen y el sistema difuso. Los resultados de las experimentaciones y validación son mostrados en la sección 3. Por último las conclusiones sobre el desarrollo del sistema propuesto conforman la sección 4.

## 2. MATERIALES Y METODOS

### 2.1. PROCESAMIENTO DIGITAL DE LA IMAGEN

El procesamiento digital de la imagen inicia con la obtención de la imagen metalográfica, que consta de operaciones consecutivas. De acuerdo con [11], la primera operación es cortar el material afectado, así se analizan pequeñas secciones que permitan revelar información sobre las causas que propiciaron el daño en el material. El segundo paso es la fabricación de una probeta con resina epóxica, lijada y pulida con una solución de carburo de silicio hasta obtener un acabado espejo posteriormente se aplica una solución Nital sobre la probeta con una concentración de 4% durante cinco segundos para revelar la microestructura. Finalmente, la muestra es observada por un experto usando un microscopio invertido metalográfico (Olympus-GX71) y un analizador de imágenes (Analysis-Five). Una vez tomada la imagen puede ser almacenada o distribuida para su futuro procesamiento.

El sistema integral propuesto, en la parte de procesamiento digital de la imagen aplica la transformada Wavelet sobre la imagen metalográfica, la transformada es utilizada con el fin de obtener de las señales un conjunto de características en el plano Tiempo-Frecuencia. Lo cual resuelve el problema en caso de que una imagen presente características aperiódicas



Fig.5: Procedimiento para la obtención de estadísticos

importantes [12]. Existen diversas formas de generalizar las *transformadas wavelet* 1D a 2D para poder ser empleadas en imágenes. Se necesita una función de escalado 2D  $\varphi(x, y)$  y tres de *wavelets* 2D:  $\psi^H(x, y)$ ,  $\psi^V(x, y)$  y  $\psi^D(x, y)$  que son separables Ec. (1).

Ahora las funciones de base 2D son:

$$\varphi_{j,m,n}(x, y) = 2^{j/2}\varphi(2^jx - m, 2^jy - n) \quad (2)$$

$$\psi^i_{j,m,n}(x, y) = 2^{j/2}\psi^i(2^jx - m, 2^jy - n) \quad (3)$$

Dónde:

$\varphi_{m,n}(x, y)$  = Funciones de escalonado

$\psi^i_{m,n}(x, y)$  = Función wavelet madre obtenida mediante escalado(m) y traslación(n)

Siendo:  $i = \{H \text{ (Horizontal)}, V \text{ (Vertical)}, D \text{ (Diagonal)}\}$

Dada una imagen y aplicando la Ec. (2) y Ec. (3), la transformada Wavelet la descompone en una sub-imagen de baja frecuencia y un conjunto de detalles de alta frecuencia. Ver Fig. (4). 4(a) imagen original, 4(b) 4(c) y 4(d) descomposición horizontal, vertical y diagonal respectivamente. 4(e) Imagen reconstruida.

Una vez aplicada la descomposición wavelet, es necesario extraer un vector de características que permita caracterizar la textura.

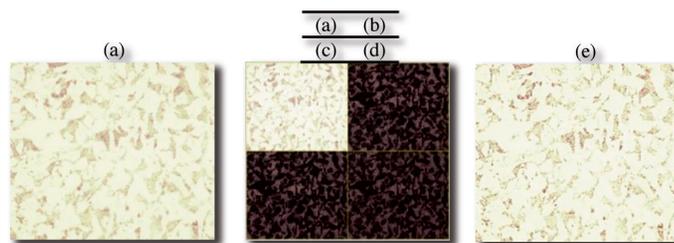


Fig. 4: Aplicación de la transformada Wavelet

#### 2.1.1. Extracción de características

Los estadísticos de primero, segundo y tercer orden generados a partir de la imagen metalográfica, fueron calculados a través de las operaciones entre píxeles mediante las fórmulas matemáticas presentadas en la Tabla 1, [4]. El total de estadísticos descriptores calculados de la textura en la imagen metalográfica fueron convertidos en la señal de entrada a la red neuronal artificial, así que la red neuronal fue entrenada y probada mediante vectores de tamaño [1x15]. El procedimiento general para obtener cada uno de los estadísticos se muestra en la Fig. (5).

Los estadísticos de primer orden (EPO) son descriptores que solo consideran la intensidad  $p(i, j)$  de cada pixel en la región. La matriz de co-ocurrencia de niveles de gris GLCM genera los estadísticos de segundo orden, parten de histogramas bidimensionales que representan la dependencia espacial entre dos niveles de gris separados una cierta distancia a lo largo de una dirección  $\theta$ [4].

Los estadísticos de tercer orden son calculados a partir de la matriz de longitud de secuencia de nivel de gris, más conocida por sus siglas en inglés como GLRLM, es un histograma bidimensional

donde el elemento  $(i,j)$  representa el número de veces que aparece una secuencia de nivel de gris  $i$  con longitud  $j$  Ec.(4). Se consideran las cuatro direcciones principales para la búsqueda de secuencias ( $0^\circ, 45^\circ, 90^\circ, 135^\circ$ ), obteniendo cuatro matrices GLRLM [4]. Ver Fig. (6). Por lo cual, es necesario aplicar un conjunto de estadísticos sobre cada una de estas matrices, énfasis en secuencias cortas o SRE (*Short-Run-Emphasis*), énfasis en secuencias largas o LRE (*Long-Run-Emphasis*), no uniformidad en el nivel de gris o GLN (*Grey-Level-Nonuniformity*), no uniformidad en la longitud de secuencia o RLN (*Run-Length Nonuniformity*) y porcentaje de secuencia o RP (*Run-Percentage*), énfasis en secuencias de nivel de gris bajo o LGRE (*Low-Grey-Level-Run-Emphasis*) y énfasis en secuencias de nivel de gris alto o HGRE (*High-Grey-Level-Run Emphasis*) [3].

$$(R(\theta) = (g(i, j)|\theta), 0 \leq i \leq N_g, 0 \leq j \leq R_{max} \quad (4)$$

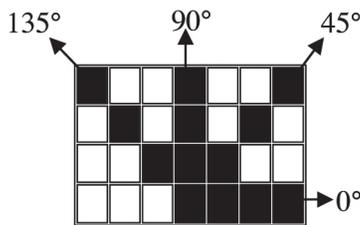


Fig. 6: Dirección de búsqueda de secuencias

### 2.1.2. Porcentaje de Fases

El cálculo del porcentaje de fases en una imagen metalográfica es un mecanismo que permite medir la cantidad de ferrita en el material de acero al carbón, un material sin afectación inicia con un porcentaje alrededor de 20% perlita y 80% de ferrita la cual se incrementa conforme es utilizado el acero en condiciones específicas de acuerdo con el diagrama de fases hierro-carbono (Fe-C). El procesamiento para determinar la cantidad de ferrita presente en cualquier imagen metalográfica se describe en las Fig. (7) y (8). En 8(a) imagen con tamaño [1024 x 1024], 8(b) escala de gris e indexación a [512 x 512], 8(c) fase de umbralización mediante el método *Otsu*, como consecuencia de la umbralización únicamente quedan activados los píxeles ligados a la presencia de perlita. 8(d) localizar y cuantificar áreas de perlita, la operación devuelve un escalas que especifica el número real de píxeles en cada región. Por diferencia se obtiene la cantidad de ferrita empleando la Ec. (5).

$$\%ferrita = \left[ 1 - \left( \frac{\sum_{i=1}^n x_i}{\text{Área total}} \right) \right] * 100 \quad (5)$$

Dónde:

$x$  = Total de píxeles presentes en las regiones detectadas con presencia de perlita en la imagen metalográfica

$n$  = Regiones con presencia de perlita en la imagen metalográfica

Área total = 512\*512 píxeles

Primer orden	Segundo orden	Tercer orden	
<b>Desviación estándar</b> $\sqrt{\frac{\sum_{i=1}^N (i-\mu)^2 h(i)}{N}}$	<b>Contraste</b> $\sum_{n=0}^{N_g-1} i^2 \left\{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j),  i-j =n \right\}$	<b>SRE</b> $\frac{1}{n} \sum_{i,j} \frac{P(i,j)}{j^2}$	<b>RP</b> $\sum_{i,j} \frac{n}{P(i,j)j}$
<b>Kurtosis</b> $\sum_{i=1}^N [(i-\mu)^4 h(i)] - 3$	<b>Correlación</b> $\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{(i-\mu_x)(j-\mu_y)p(i,j)}{\sigma_x \sigma_y}$	<b>LRE</b> $\frac{1}{n} \sum_{i,j} j^2 P(i, j)$	<b>LGRE</b> $\frac{1}{n} \sum_{i,j} \frac{P(i,j)}{i^2}$
<b>Entropía</b> $-\sum_{g=0}^{L-1} P(g) \text{Log}_2[P(g)]$	<b>Energía</b> $\sqrt{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (p(i, j))^2}$	<b>GLN</b> $\frac{1}{n} \sum_i (\sum_j P(i, j))^2$	<b>HGRE</b> $\frac{1}{n} \sum_{i,j} i^2 P(i, j)$
<b>Oblicuidad</b> $\sum_{i=1}^N (i-\mu)^3 h(i)$	<b>Homogeneidad</b> $\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{1}{1+(i-j)} p(i, j)$	<b>RLN</b> $\frac{1}{n} \sum_i (\sum_j P(i, j))^2$	

Tabla 1: Características estadísticas

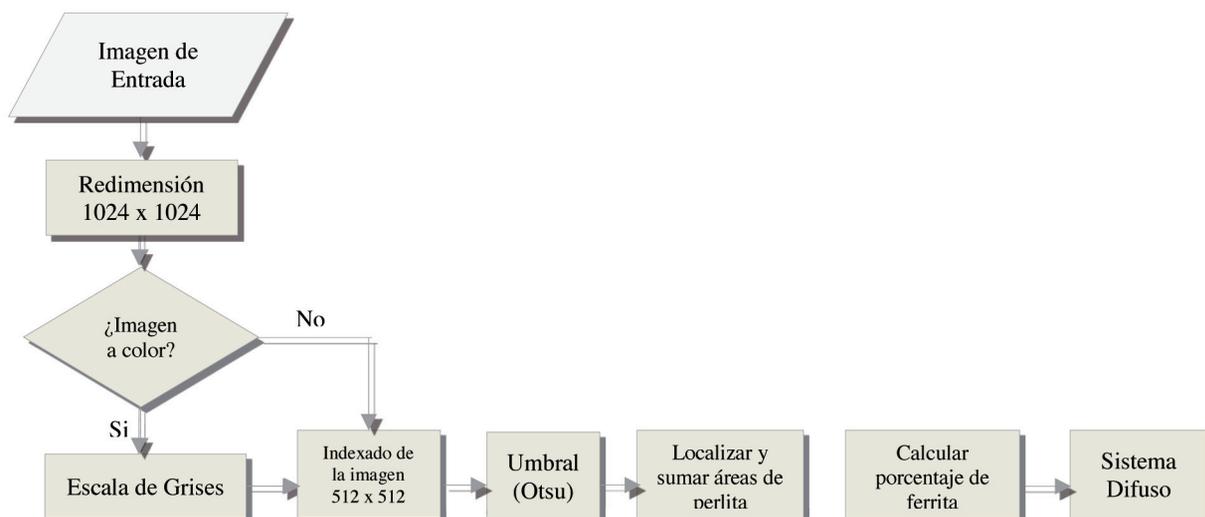


Fig. 7: Procedimiento para calcular el porcentaje de ferrita

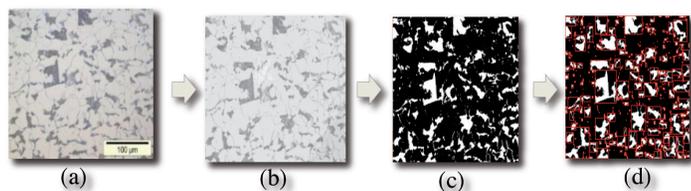


Fig. 8: Etapas para el cálculo del porcentaje de ferrita

## 2.2. RED NEURONAL ARTIFICIAL

El conjunto de patrones empleados para entrenar y probar la RNA fueron obtenidos de una base de datos de 194 imágenes metalográficas afectadas por patrones previamente reconocidos e identificados por expertos de LAPEM. La composición de la matriz se muestra en la Tabla 2. El procedimiento para entrenar y probar a la RNA a partir de los estadísticos calculados y llevar a cabo la tarea de clasificación-reconocimiento se muestra en la Fig. (9).

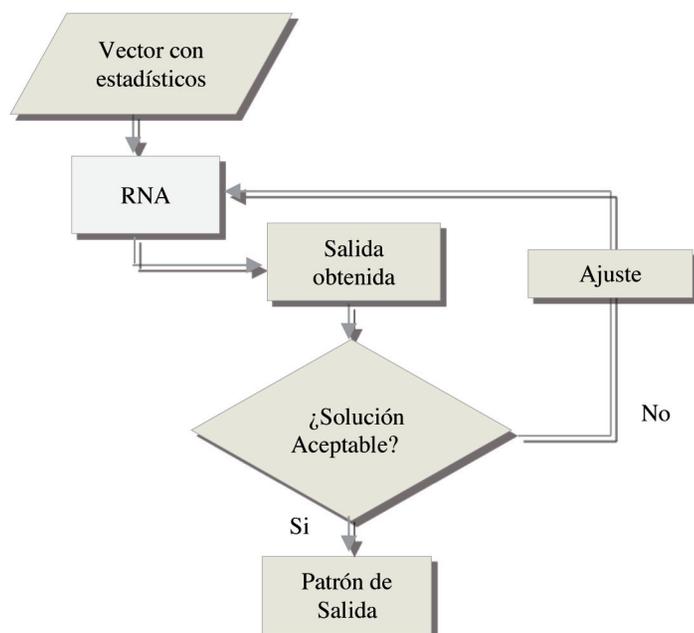


Fig. 9: Procedimiento de clasificación-reconocimiento.

Entrenamiento		Prueba
Total de Imágenes 84		110
Patrón Metalográfico	Dimensión	Dimensión
Perlita Laminar	28x15	31x15
Esferoidización	34x15	47x15
Grafitización	22x15	32x15

Tabla 2: Dimensión de la matriz de entrenamiento y prueba

El ajuste corresponde a la acción de modificar parámetros que integran la topología de la red neuronal artificial hasta obtener

Topología	No. de Neuronas en la capa oculta	Tasa de aprendizaje	Error permitido	Épocas	Coefficiente de Correlación. R	Error Cuadrático Medio. MSE
1	35	0.01	1e-4	5000	0.99978	0.00012423
2	35	0.01	1e-4	3000	0.99912	0.00023656
3	37	0.01	1e-5	5000	0.99964	0.00345781
4	37	0.005	1e-4	5000	0.99923	0.00032188
5	34	0.01	1e-5	5000	0.99687	0.00124365

Tabla 3: Topologías desarrolladas

una combinación de parámetros que arroje una solución aceptable de la clasificación presentada a la red neuronal desarrollada.

La función de activación en la arquitectura de la RNA es una tangente hiperbólica, se asigna el valor de (-1) al patrón perlita laminar, (0) esferoidización y (1) grafitización. Las topologías de RNA's propuestas en la Tabla 3, son topologías que se ajustan adecuadamente a los 84 valores objetivos del patrón metalográfico correspondiente en la fase de entrenamiento es por ello que se recurrió a un parámetro estadístico como el error cuadrático medio (MSE) para determinar que topología debería ser seleccionada y posteriormente usada en la fase de prueba con las 110 imágenes restantes.

La topología detallada de la RNA 1 utilizada está descrita en la Tabla 4.

Parámetro	Valor
Número de capas ocultas.	1
Número de neuronas en la capa oculta.	35
Función de activación de la capa oculta.	Tangente Hiperbólica
Visualización durante el entrenamiento.	50
Tasa de aprendizaje.	0.01
Valor de función de error a alcanzar.	1e-4
Número máximo de épocas.	5000
Tipo de entrenamiento.	Gradiente conjugada escalada

Tabla 4: Topología de la RNA seleccionada

## 2.3. LÓGICA DIFUSA

### 2.3.1. Fusificación

La fusificación para la cuantificación de ferrita en la imagen metalográfica, se desarrolló generando tres funciones de pertenencia. La primera función se catalogó como *Normal* con un valor de pertenencia mayor en 80% de ferrita, este es el estado inicial comúnmente de un acero al carbono SA 210 y conforme es sujeto a condiciones de trabajo aumenta el porcentaje de ferrita. La segunda función presenta su valor máximo en 86% y se definió como *Incremento Moderado* ambas funciones de pertenencia son del tipo *Gaussianas*. La última función de pertenencia es del tipo *Sigmoidea* y fue etiquetada como *Incremento Considerable*, esta función describe un incremento positivo y posteriormente constante a partir de registrar un 89.5%, ya que a partir de este valor de acuerdo con los expertos el incremento en la ferrita es importante. La amplitud de las funciones de pertenencia se definió tomando como base un intervalo de confianza del 95% para la media, comprobando el supuesto de normalidad mediante el estadístico Anderson Darling obteniendo  $p = 0.104, 0.094$  y  $0.062 > 0.05$  respectivamente. El universo del discurso tiene un rango de [75, 95] ya que son los extremos de presencia de ferrita en un acero al carbono SA 210. Ver Fig. (10).

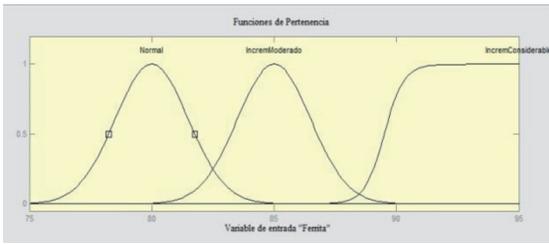


Fig. 10: Porcentaje de ferrita

La fusificación de la entrada que analiza el patrón metalográfico clasificado y reconocido por la RNA fue codificada añadiendo valores de salida para cada patrón metalográfico. El sistema difuso asigna a las salidas de la RNA un valor de (1) *perlita laminar*, (2) *esferoidización* y (3) *grafitización* debido a que el sistema de lógica difusa realizado en *Matlab® 2012'* no acepta valores negativos y es una opción de salida de la RNA. Las tres funciones de pertenencia son del tipo *Gaussianas* solo por la forma no debido a que sigan la distribución normal, cada función fue etiquetada de acuerdo al patrón que representan y logrando su mayor grado de pertenencia en 1, 2 y 3 respectivamente, de esta forma quedó definido el universo del discurso con valores entre [0, 4]. Ver Fig. (11).

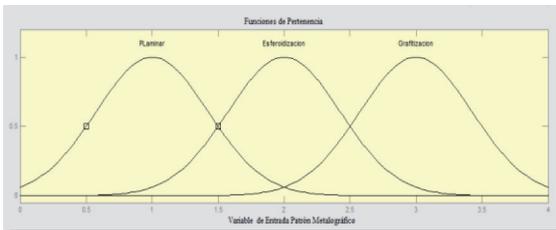


Fig. 11: Patrón metalográfico

Para la variable de entrada nivel de capa magnetita, la fusificación quedó definida a partir de 4 funciones de pertenencia: *mínimo*, *moderado*, *importante* y *crítica*. Las primeras tres funciones son del tipo *normal*, tienen su mayor grado de pertenencia en 0, 0.3 y 0.6 respectivamente. La última es del tipo *Sigmoidea* con su mayor grado de pertenencia y constante a partir de 0.85. La capa se considera con un nivel crítico al llegar a un nivel de 1 mm, por lo que su universo del discurso es analizado entre [0,1]. La medición de la capa magnetita se llevó a cabo a través del software *Análisis-Five* el cual se encuentra certificado para realizar mediciones. Ver Fig. (12).

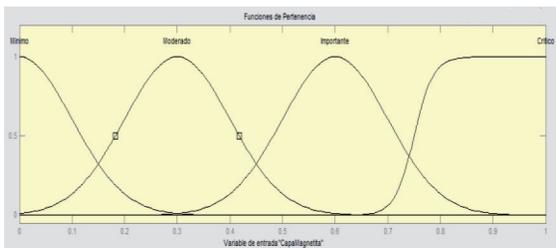


Fig. 12: Capa magnetita

La fusificación de la variable de salida está dada por la cantidad de diferentes variables lingüísticas que se manejan actualmente en la estimación del deterioro en el material de acero al carbono por expertos de LAPEM que son: *Sin afectación*, *incipiente*, *inicial*, *parcial* y *avanzada afectación*. Dado que son cinco variables lingüísticas se generaron cinco funciones de pertenencia del tipo triangular, el universo del discurso fue definido de [0, 10] ya que

fue requerido emitir una estimación del deterioro del material de forma puntual en una escala de 0 a 10. El grado de pertenencia más alto para cada función va de 0 para la función *sin afectación* y se incrementa en 2.5 unidades hasta llegar a 10 con la función *avanzada afectación*, de este modo fue posible asignarle un valor cuantitativo posterior a la defusificación a cada una de las variables lingüísticas utilizadas hasta el momento. Ver Fig. (13).

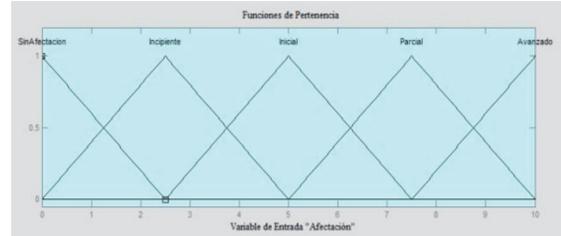


Fig. 13: Estimación del daño

### 2.3.2 Inferencia

El método utilizado para realizar la inferencia es el método *Mamdani* que utiliza reglas tipo *si-entonces* [2]. La inferencia está basada en tres entradas: porcentaje de fases, nivel de capa magnetita y el patrón de metalográfico presente en el material y a partir del análisis de las tres variables se concluye en base a la única salida que es la estimación del deterioro del material de acero al carbono del tipo SA 210. Ver Tabla 5. El sistema difuso presentado no cuenta con 36 reglas de inferencia como dicta en [2], debido a que 9 reglas son las mínimas necesarias para explicar el deterioro del acero al carbono a partir del estudio del patrón metalográfico, % de fases y el nivel de la capa magnetita. Esto es debido a que existen reglas que no tendrían un fin práctico y una nula posibilidad de que ocurra tal como: un acero que contenga un nivel considerable de ferrita, una microestructura con un patrón de perlita laminar además de una capa magnetita importante. Si el acero presenta niveles altos de ferrita y capa magnetita el acero ha sufrido afectaciones por temperatura y por lo tanto su microestructura no podría estar en una fase de perlita laminar.

Reglas de Inferencia
$If(Ferrita \text{ is Normal}) \text{ and } (Patron \text{ is PLaminar}) \text{ and } (CapaMagnetita \text{ is Minimo}) \text{ then } (Afectacion \text{ is SinAfectacion})$
$If(Ferrita \text{ is IncremModerado}) \text{ and } (Patron \text{ is PLaminar}) \text{ and } (CapaMagnetita \text{ is Minimo}) \text{ then } (Afectacion \text{ is SinAfectacion})$
$If(Ferrita \text{ is IncremModerado}) \text{ and } (Patron \text{ is PLaminar}) \text{ and } (CapaMagnetita \text{ is Moderado}) \text{ then } (Afectacion \text{ is Incipiente})$
$If(Ferrita \text{ is IncremModerado}) \text{ and } (Patron \text{ is Esferoidizacion}) \text{ and } (CapaMagnetita \text{ is Moderado}) \text{ then } (Afectacion \text{ is Inicial})$
$If(Ferrita \text{ is Normal}) \text{ and } (Patron \text{ is Esferoidizacion}) \text{ and } (CapaMagnetita \text{ is Minimo}) \text{ then } (Afectacion \text{ is Inicial})$
$If(Ferrita \text{ is IncremConsiderable}) \text{ and } (Patron \text{ is Esferoidizacion}) \text{ and } (CapaMagnetita \text{ is Importante}) \text{ then } (Afectacion \text{ is Parcial})$
$If(Ferrita \text{ is IncremConsiderable}) \text{ and } (Patron \text{ is Grafitizacion}) \text{ and } (CapaMagnetita \text{ is Moderado}) \text{ then } (Afectacion \text{ is Avanzado})$
$If(Ferrita \text{ is IncremConsiderable}) \text{ and } (Patron \text{ is Grafitizacion}) \text{ and } (CapaMagnetita \text{ is Critico}) \text{ then } (Afectacion \text{ is Avanzado})$
$If(Ferrita \text{ is IncremConsiderable}) \text{ and } (Patron \text{ is Grafitizacion}) \text{ and } (CapaMagnetita \text{ is Importante}) \text{ then } (Afectacion \text{ is Avanzado})$

Tabla 5: Reglas de inferencia

### 2.3.3 Defusificación

La defusificación es un proceso matemático usado para convertir un conjunto difuso en un número real. Se empleó el algoritmo

mo de Centro de Gravedad (CoG) para defusificar el valor de salida y obtener el escalar Ec. (6). [2]

$$Y_d = \frac{\int_S y \mu_y(y) dy}{\int_S \mu_y(y) dy} \quad (6)$$

Dónde:

$\mu_y$  = Función de pertenencia del conjunto de salida  $\mu$

$y$  = Variable de salida

$S$  = Rango de integración

Después de la defusificación se obtiene un escalar dentro del intervalo [0, 10].

### 3. RESULTADOS

Para verificar el funcionamiento de la RNA en la tarea de clasificación-reconocimiento de los patrones metalográficos, se desarrolló una fase de validación en la que se introdujeron 110 nuevas imágenes con patrones de perlita laminar, esferoidización y grafitización para su clasificación y reconocimiento, ver Tabla 2. Las imágenes metalográficas fueron previamente reconocidas e identificadas por expertos. Antes de validar la técnica de clasificación-reconocimiento fue necesario comprobar que la caracterización de la imagen metalográfica era correcta y brindaba una señal de entrada detallada a la RNA. Se estudió una caracterización me-

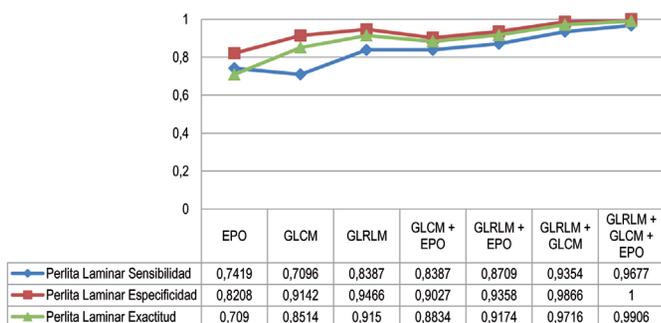


Tabla 6: Comparación de técnicas para caracterización del patrón perlita laminar

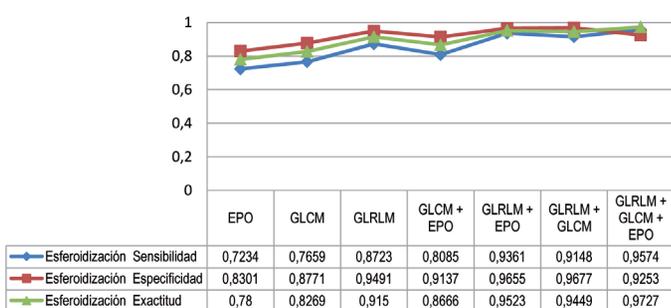


Tabla 7: Comparación de técnicas para caracterización del patrón esferoidización

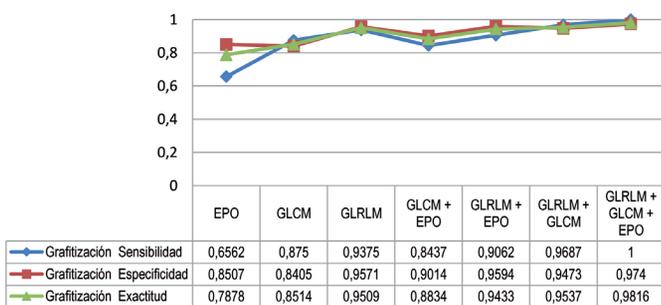


Tabla 8: Comparación de técnicas para caracterización del patrón grafitización

dante estadísticos de primer orden (EPO), matriz de co-ocurrencia GLCM y la matriz de longitud de secuencia de nivel de gris GLRLM además de sus combinaciones para poder definir la mejor técnica para caracterización de la imagen metalográfica que permitiera una correcta clasificación-reconocimiento por medio de la RNA. De acuerdo con [4], es posible validar una correcta clasificación-reconocimiento mediante los siguientes indicadores: sensibilidad Ec. (7), especificidad Ec. (8) y exactitud Ec. (9). Ver Tabla 6,7 y 8.

$$\text{Sensibilidad (S)} = \frac{VP}{VP+FN} \quad (7)$$

$$\text{Especificidad (Es)} = \frac{VN}{VN+FP} \quad (8)$$

$$\text{Exactitud (Ex)} = \frac{VP+VN}{VN+FP+VP+FN} \quad (9)$$

Dónde:

VP – Verdadero-Positivo

FN – Falso-Negativo

VN – Verdadero-Negativo

FP – Falso-Positivo

A partir de los indicadores de sensibilidad, especificidad y exactitud se demostró que la combinación de EPO+GLCM+GLRLM generan una señal de entrada eficiente para la RNA y así poder realizar la tarea de clasificación-reconocimiento a través de la arquitectura presentada en la Tabla 4.

Para validar la estimación del deterioro en el material a partir del sistema de lógica difusa se compararon los resultados obtenidos del sistema contra los resultados emitidos por un experto en la materia en un total de 110 imágenes. La comparación consistió en realizar una prueba de hipótesis estadística sobre la igualdad de dos poblaciones, para ello se toma en cuenta la media (Medida de tendencia central) y la varianza (medida de dispersión), se comprobó si para cada uno de los patrones de comportamiento es posible demostrar que no existe diferencia significativa en la estimación del deterioro hecha por el sistema propuesto y el experto humano con una confianza del 99%. Ver Tabla 9.

$H_0: \mu_1 = \mu_2$ . La estimación del sistema experto y el experto humano son iguales

$H_1: \mu_1 \neq \mu_2$ . La estimación del sistema experto y el experto humano no son iguales.

El error tipo I queda definido como:  $\alpha = 0.01$

Estadístico de Prueba.

De acuerdo a la prueba de hipótesis empleada, se verificó con un 99% de confianza que no existe diferencia significativa entre las estimaciones del deterioro realizadas por el sistema propuesto y el experto humano. El supuesto para la aplicación de la prueba de hipótesis es el comportamiento normal de los datos, dicho supuesto es probado mediante el estadístico Anderson Darling donde cada uno de los conjuntos de datos presenta un valor mayor a 0.05. Ver Tabla 9.

### 4. DISCUSIÓN

Los resultados obtenidos muestran la viabilidad de uso del sistema inteligente propuesto aplicado sobre el procesamiento digital de imágenes metalográficas apoyado en estadística descriptiva. El sistema contribuye como elemento de diagnóstico para la clasificación-reconocimiento de patrones metalográficos del acero al carbono del tipo SA 210 Grado A-1. Además el sistema

$$z_0 = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}}$$

Rechazar  $H_0: \mu_1 = \mu_2$  si  $z_0 > 2.58$  ó  $z_0 < -2.58$

Perlita Laminar		Esferoidización		Grafitización	
Sistema-Propuesto	Experto-Humano	Sistema-Propuesto	Experto-Humano	Sistema-Propuesto	Experto-Humano
$\bar{x}_1 = 2.2$	$\bar{x}_2 = 2.4$	$\bar{x}_1 = 6$	$\bar{x}_2 = 6.1$	$\bar{x}_1 = 9.1$	$\bar{x}_2 = 9$
$\sigma_1^2 = 0.7895$	$\sigma_2^2 = 1.0037$	$\sigma_1^2 = 0.870$	$\sigma_2^2 = 0.942$	$\sigma_1^2 = 0.1205$	$\sigma_2^2 = 0.1382$
P=0.878	P=0.809	P=0.078	P=0.166	P=0.1	P=0.099

$z_0 = \frac{2.2 - 2.4}{\sqrt{\frac{0.7895}{31} + \frac{1.0037}{31}}}$ <p><math>z_0 = -0.83211</math> Se acepta <math>H_0</math></p>		$z_0 = \frac{6 - 6.1}{\sqrt{\frac{0.8707}{47} + \frac{0.9423}{47}}}$ <p><math>z_0 = -0.5092</math> Se acepta <math>H_0</math></p>		$z_0 = \frac{9.1 - 9}{\sqrt{\frac{0.1205}{32} + \frac{0.1382}{32}}}$ <p><math>z_0 = 1.118</math> Se acepta <math>H_0</math></p>	
--	--	---	--	---	--

Tabla 9: Prueba de hipótesis

estima cuantitativamente el deterioro presente en el acero sufrido en planta a partir de una imagen micro estructural del acero contrario a lo que se realiza actualmente un experto humano.

La topología de la RNA presentada en la Tabla 4, resultado de la experimentación efectuada como se muestra en la Tabla 3, logra una clasificación-reconocimiento eficiente de la imagen metalográfica debido a una correcta caracterización por medio de la combinación de EPO+GLCM+GLRLM generando una señal detallada de acuerdo a los indicadores de sensibilidad, especificidad y exactitud. Los resultados cumplen con los principios de reproducibilidad y repetibilidad únicamente bajo las condiciones descritas a lo largo del artículo. Cabe destacar que los estadísticos GLRLM por si solos presentan mejores resultados en la clasificación-reconocimiento que la combinación EPO+GLCM.

En la fase de estimación se demuestra con una confianza del 99% que es posible establecer una estimación cuantitativa de [0,10] sobre el deterioro en el acero al carbono SA 210 igual a la de un experto en la materia, tomando en cuenta solo tres variables de entrada. Bajo lo antes mencionado es posible pensar en establecer este procedimiento en empresas que requieran análisis de sus materiales en uso y no cuenten con un experto de forma inmediata.

## BIBLIOGRAFÍA

[1] Apraiz-Barreiro, J. Tratamiento térmico de los Aceros. 10ª edición. España, S.I. Cie Inversiones Editoriales Dossat, 2002. 739 p. ISBN: 9788495312563.  
 [2] Pedrycz, W. Fuzzy Control and Fuzzy Systems. Research Studies Press. Ltd, John Wiley & Sons Inc., 1989. 225 p. ISBN:0471923117  
 [3] Hagan, M., Demuth H., Beale H. Neural Network Design. Campus Pub. Service, University of Colorado Bookstore, 2002. 1012 p e ISBN: 0971732108  
 [4] Radhakrishnan, M., Kuttiannan, T., (2012) "Comparative Analysis of Feature Extraction Methods for the Classification of Prostate Cancer from TRUS Medical Images". International Journal of Computer Science Issues, Vol. 9 p. 171-179.  
 [5] Garcia-Martín, J., Martínez-Martínez, V., Gómez-Gil, J. (2014). "Heat-Treatment Classification of Steels with Nondestructive Eddy Current Testing using Neural Networks". DYNA, 89(5). 526-532. DOI: <http://dx.doi.org/10.6036/7083>  
 [6] Garcia-Bringas, P., Pastor-Lopez, I., Santos-Grueiro, I.. (2014). "Machine Vision for Surface Defects Categorisation In Foundries Based on Machine Learning". DYNA, 89(3). 325-332. DOI: <http://dx.doi.org/10.6036/6940>  
 [7] Liu, C., Wang Zhigang., Li, Y., (2012) "Damage Pattern Recognition of

Refractory Materials Based on BP Neural Network" Neural Information Processing. Vol. 7666, 2012, pp 431-440. DOI: [http://dx.doi.org/10.1007/978-3-642-34478-7\\_53](http://dx.doi.org/10.1007/978-3-642-34478-7_53)

[8] Subashini,L.,Vasudevan,M.,(2012) "Adaptive Neuro-Fuzzy Inference System (ANFIS)-Based Models for Predicting the Weld Bead Width and Depth of Penetration from the Infrared Thermal Image of the Weld Pool". Metallurgical and Materials Transactions B. Vol 43 p 145-154. DOI: <http://dx.doi.org/10.1007/s11663-011-9570-x>  
 [9] Campos, I. Islas, M. Gonzalez, E. Ponce, P. Ramirez, G. (2006) "Use of fuzzy logic for modeling the growth of Fe<sub>2</sub>B boride layers during boronizing". Surface and Coatings Technology Vol.201 p.2717-2723 DOI: <http://dx.doi.org/10.1016/j.surfcoat.2006.05.016>  
 [10] Han, Y. Zeng, W. Zhao, Y. Qi, Y. Sun, Y. (2011) "An ANFIS model for the prediction of flow stress of Ti600 alloy during hot deformation process" Computational Materials Science. Vol. 50 p. 2273-2279. DOI: <http://dx.doi.org/10.1016/j.commatsci.2011.03.004>  
 [11] ASTM E3-01, Standard Practice for Preparation of Metallographic Specimens, ASTM International, West Conshohocken, PA, 2001, [www.astm.org](http://www.astm.org)  
 [12] Mallat, S., (1989) "A theory for multiresolution signal decomposition: the wavelet representation". IEEE Transactions on Pattern Analysis and Machine Intelligence. Vol 11(7) p. 674-693.

**<http://www.revistadyna.com> - Comunicacion de aprobacion de articulo 7777**

Jose Maria Hernandez [jmhernandez@revistadyna.com]

Respondió el 08/12/2015 02:28 p.m..

**Enviado el:** martes, 10 de noviembre de 2015 06:31 a.m.

**Para:** Edgar Augusto Ruelas Santoyo

ARTICULO:  
SISTEMA NEURONAL-DIFUSO APLICADO AL RECONOCIMIENTO Y EVALUACIÓN DEL DAÑO EN  
ACEROS AL CARBÓN APOYADO EN ESTADÍSTICA DESCRIPTIVA

Estimad@ autor@,  
Nos complace comunicarle que su artículo ha sido validado por nuestro  
proceso de revisión entre pares. Para agilizar al máximo la publicación de  
su trabajo le recomendamos que lea atentamente el párrafo siguiente:

=====

 **SISTEMA NEURONAL-DIFUSO APLICADO AL RECONOCIMIENTO Y EVALUACIÓN DEL DAÑO  
EN ACEROS AL CARBÓN APOYADO EN ESTADÍSTICA DESCRIPTIVA**

0 (DYNA ACELERADO)  [Ver ejemplar](#) - Volumen: DYNA-ACELERADO - Páginas: 0

DOI: <http://dx.doi.org/10.6036/7777>

AUTORES: EDGAR AUGUSTO RUELAS SANTOYO - JOSE ANTONIO VAZQUEZ LOPEZ - JAVIER YÁÑEZ MENDIOLA - ISMAEL  
LOPEZ JUAREZ - CARLOS FERNANDO BRAVO BARRERA

MATERIAS: INDUSTRIAS DE LA INFORMACION Y DEL CONOCIMIENTO (INTELIGENCIA ARTIFICIAL Y SIMULACION )

Ruelas-Santoyo, E., Vazquez-Lopez, J., Yáñez-Mendiola, J., Lopez-Juarez, I., Bravo-Barrera, C.. (0).  
NEURO-FUZZY SYSTEM APPLIED TO RECOGNIZE AND ASSESSING THE DAMAGE IN CARBON STEEL  
SUPPORTED BY DESCRIPTIVE STATISTICS .DYNA, DYNA-ACELERADO(0). 0. DOI:  
<http://dx.doi.org/10.6036/7777>

URL: [http://www.revistadyna.com/Articulos/Ficha.aspx?Cod=7777&CodArt=96D8E6B2-  
CF46-4A16-8814-DAE7E4D62CA2](http://www.revistadyna.com/Articulos/Ficha.aspx?Cod=7777&CodArt=96D8E6B2-CF46-4A16-8814-DAE7E4D62CA2)