

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-Santoyo¹, José Antonio Vázquez-López², Javier Yáñez-Mendiola¹, Ismael López-Juárez³, Carlos Fernando Bravo-Barrera⁴

¹ CENTRO DE INNOVACIÓN APLICADA EN TECNOLOGÍAS COMPETITIVAS (CIATEC). Omega 201, Industrial Delta - 37545 León, Guanajuato (Méjico).

² INSTITUTO TECNOLÓGICO DE CELAYA. Dpto. de Ingeniería Industrial. Avenida Tecnológico - 38010 Celaya, Guanajuato (Méjico).

³ CENTRO DE INVESTIGACIÓN Y DE ESTUDIOS AVANZADOS DEL IPN. Dpto. Robótica y Manufactura Avanzada. P.I. Ramos Arizpe. Avenida Industria Metalúrgica, 1062 - 25900 Ramon Arizpe, Coahuila (Méjico).

⁴ LABORATORIO DE PRUEBAS EQUIPOS Y MATERIALES (LAPEM). Dpto. de Mecánica y Materiales. Ciudad Industrial. Av. Apaseo Ote, s/n - 36541 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.

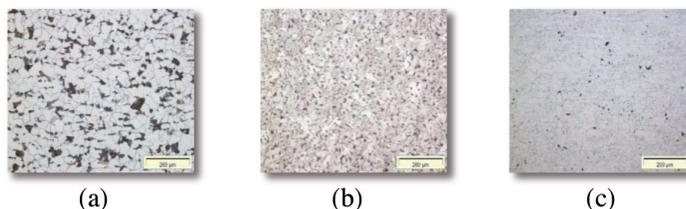


Fig. 1: Patrones metalográficos estudiados

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 $310 \text{ BTU} \times \text{in/h} \times \text{ft}^2 \times ^\circ\text{F}$ la magnetita tiene una conductividad de $20 \text{ BTU} \times \text{in/h} \times \text{ft}^2 \times ^\circ\text{F}$) 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 $[600-780 \text{ } ^\circ\text{C}]$ 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.

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.

De acuerdo con [3], la RNA perceptron multicapa presenta

calidades 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

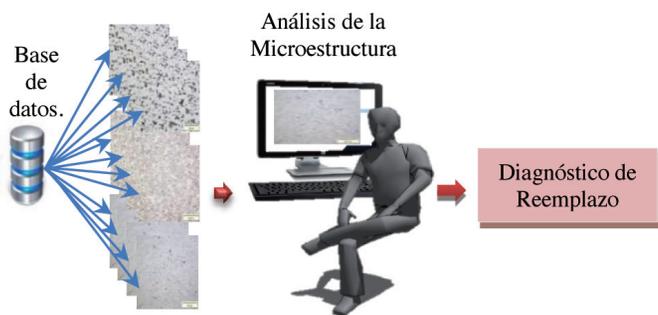


Fig. 2: Esquema actual para el análisis metalográfico

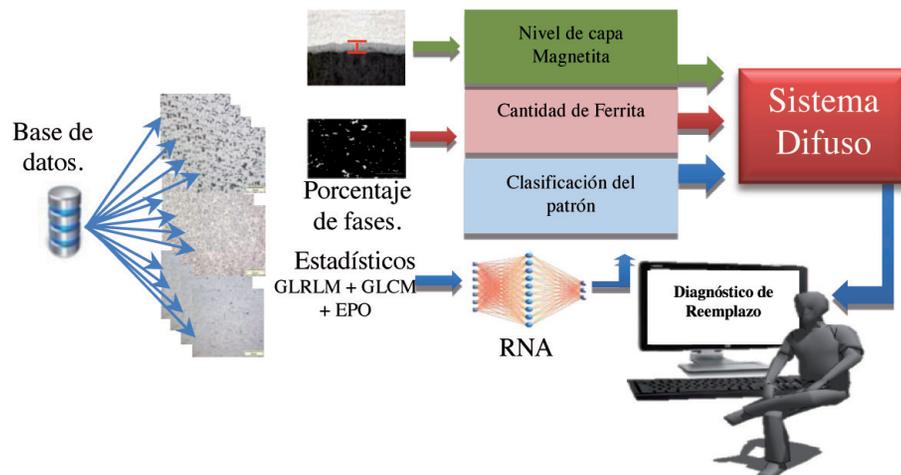


Fig. 3: Arquitectura del sistema propuesto

pueden ser clasificados a su vez en estadísticos de primer orden (EPO; toman los píxeles individualmente), de segundo orden (Gray Level Co-ocurrence 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 procesamiento 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. El procesamiento de imágenes en los materiales fue estudiado por

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

[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




Fig.5: Procedimiento para la obtención de estadísticos

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 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.

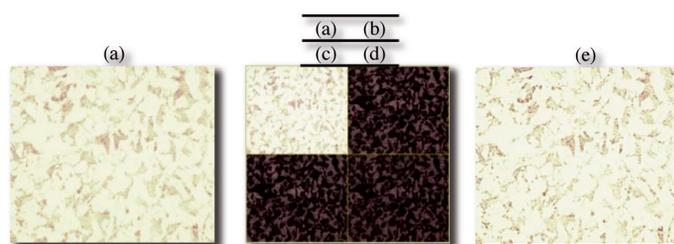


Fig. 4: Aplicación de la transformada Wavelet

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 θ [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].

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

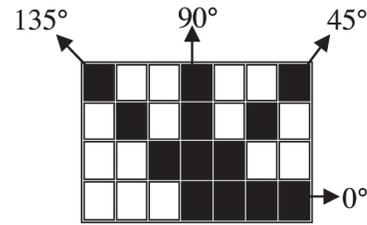


Fig. 6: Dirección de búsqueda de secuencias

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

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

Tabla 1: Características estadísticas

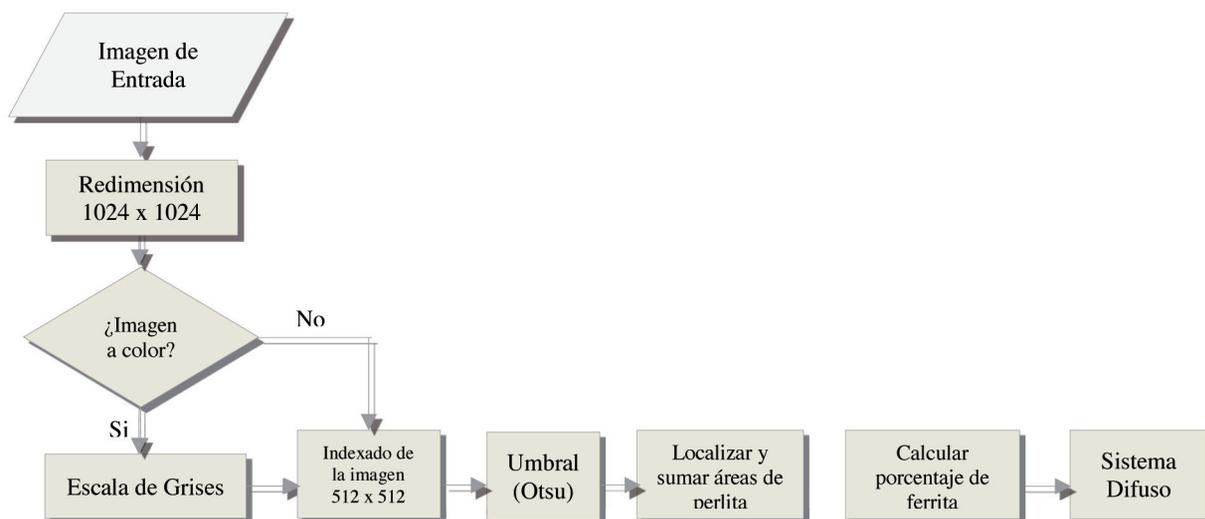


Fig. 7: Procedimiento para calcular el porcentaje de ferrita

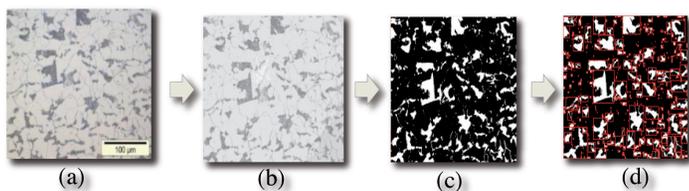


Fig. 8: Etapas para el cálculo del porcentaje de ferrita

quedan activados los píxeles ligados a la presencia de perlita. 8(d) localizar y cuantificar 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 Ec. (5).

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

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

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).

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.

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 me-

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

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

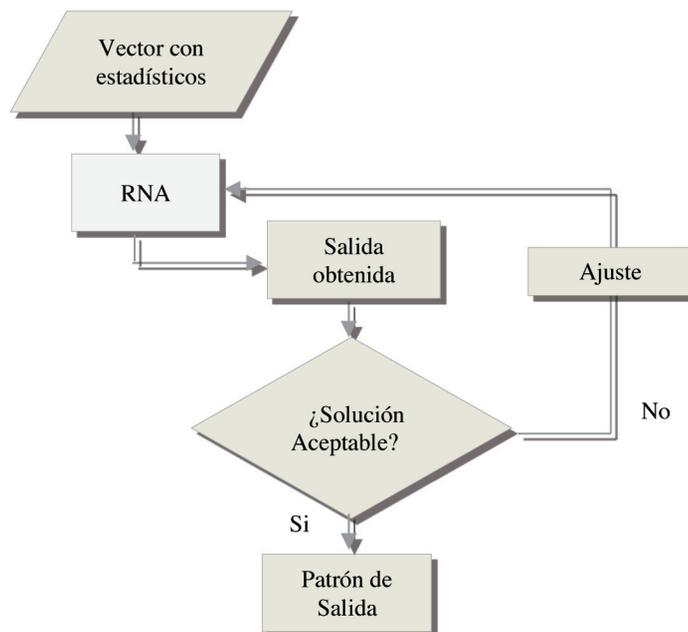


Fig. 9: Procedimiento de clasificación-reconocimiento.

dio (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).

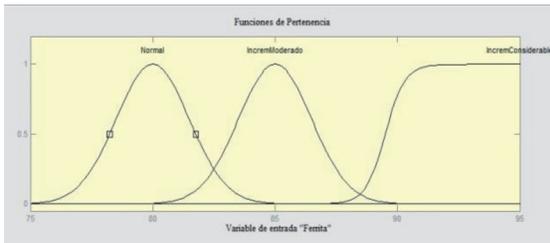


Fig. 10: Porcentaje de ferrita

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).

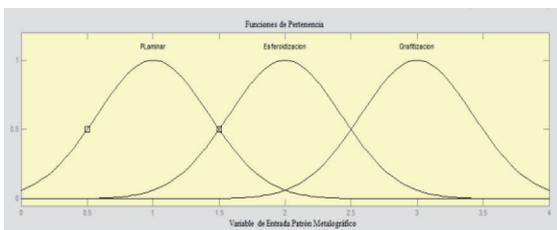


Fig. 11: Patrón metalográfico

Para la variable de entrada nivel de capa magnetita, la fusificación quedó definida a partir de 4 funciones de pertenencia: *mínimo*, *moderado*, *importante* y *crítico*. 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).

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

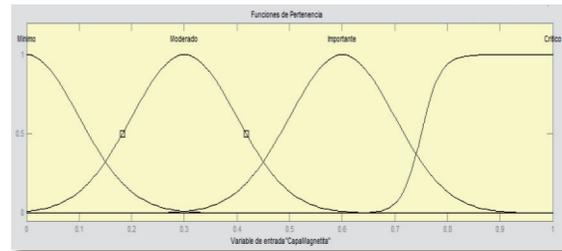


Fig. 12: Capa magnetita

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).

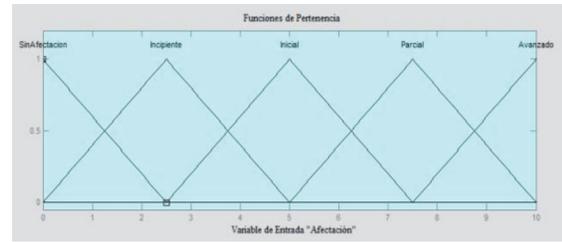


Fig. 13: Estimación del daño

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

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

Tabla 5: Reglas de inferencia

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.

2.3.3 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 Ec. (6). [2]

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

Dónde:

μ_y = Función de pertenencia del conjunto de salida μ

y = Variable de salida

S = Rango de integración

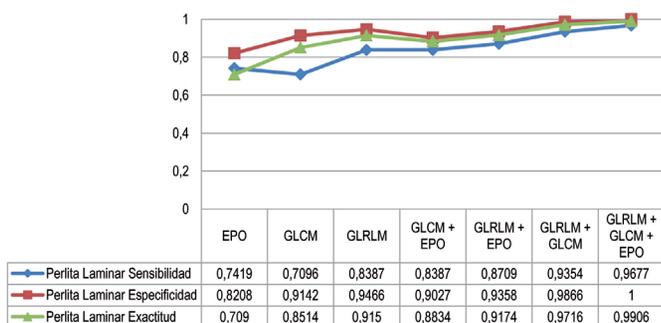


Tabla 6: Comparación de técnicas para caracterización del patrón perlita laminar

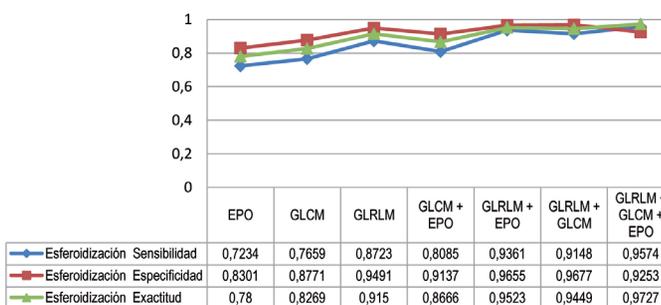


Tabla 7: Comparación de técnicas para caracterización del patrón esferoidización

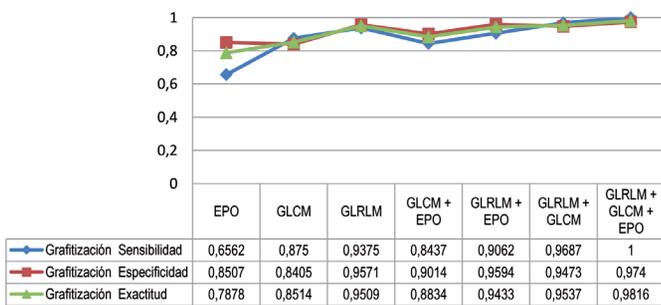


Tabla 8: Comparación de técnicas para caracterización del patrón grafitización

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 mediante 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

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

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

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

Tabla 9: Prueba de hipótesis

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 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 sí 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
- [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 Fe₂B 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
- [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.