



Industrial Data

ISSN: 1560-9146

iifi@unmsm.edu.pe

Universidad Nacional Mayor de San

Marcos

Perú

Ruelas Santoyo, Edgar Augusto; Vargas Rodríguez, Bertha Laura; Sánchez Márquez, Juan Antonio

Evaluación del deterioro presente en conductores de acero al carbón mediante un sistema inteligente

Industrial Data, vol. 18, núm. 2, julio-diciembre, 2015, pp. 113-120

Universidad Nacional Mayor de San Marcos

Lima, Perú

Disponible en: <http://www.redalyc.org/articulo.oa?id=81643819014>

- Cómo citar el artículo
- Número completo
- Más información del artículo
- Página de la revista en redalyc.org

redalyc.org

Sistema de Información Científica

Red de Revistas Científicas de América Latina, el Caribe, España y Portugal  
Proyecto académico sin fines de lucro, desarrollado bajo la iniciativa de acceso abierto

# Evaluación del deterioro presente en conductores de acero al carbón mediante un sistema inteligente

RECIBIDO: 10/10/15 ACEPTADO: 04/11/15

EDGAR AUGUSTO RUELAS SANTOYO\*  
 BERTHA LAURA VARGAS RODRÍGUEZ\*\*  
 JUAN ANTONIO SÁNCHEZ MÁRQUEZ \*\*\*

## RESUMEN

Este artículo describe la aplicación de la integración entre un sistema de lógica difusa y una red neuronal artificial Fuzzy ArtMap además del procesamiento digital de imágenes, con el objetivo de reconocer patrones en la microestructura de los materiales de acero al carbón SA 210 Grado A-1, además de estimar el daño presente en el material a partir de imágenes que presentan diversos estados físicos del mismo material. Los patrones estudiados en la microestructura del material SA 210 Grado A-1 son: perlita laminar, esferoidización y grafitización. Los resultados obtenidos muestran que la estimación del daño y el reconocimiento del patrón en el material fueron realizados de mejor forma por el sistema en comparación con expertos del área.

**Palabras clave:** lógica difusa y materiales, procesamiento digital de imágenes, red neuronal artificial (RNA)

THIS ASSESSMENT OF IMPAIRMENT IN DRIVERS OF CARBON STEEL THROUGH INTELLIGENT SYSTEM

## 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 Fuzzy ArtMap 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. Studied patterns in the microstructure of the material were: pearlite lamellar, spheroidization and graphitization. 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.

**Keywords:** artificial neural network (ANN), digital image processing, fuzzy logic and materials

## 1. INTRODUCCIÓN

La metalografía es la disciplina que estudia microscópicamente las características estructurales de un metal o de una aleación. Permite determinar el tamaño de grano, forma y distribución de varias fases e inclusiones que tienen gran efecto sobre las propiedades mecánicas del metal. 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 como primera instancia deben de ser diagnosticados por expertos en la disciplina a partir de una imagen de la microestructura del material. Como segunda instancia 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. La subjetividad e incertidumbre está presente al emitir un diagnóstico para evaluar el daño presente en el material de esta manera, ya que no se ha encontrado el mecanismo para cuantificar la afectación. En éste 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 una red neuronal artificial (RNA) Fuzzy ArtMap y un sistema de lógica difusa en conjunto con el procesamiento digital de imágenes. La red neuronal artificial se emplea para reconocer y clasificar patrones de comportamiento en la imagen de la microestructura del material. El sistema de lógica difusa es empleado para estimar de forma cuantitativa el grado de afectación presente en el material tomando como entradas el patrón de comportamiento y la cantidad de ferrita encontrados en el material.

Se han realizado investigaciones donde comprueban la viabilidad y beneficios de la integración entre redes neuronales artificiales y procesamiento digital de imágenes enfocados

\* Docente del Departamento de Ingeniería Industrial en el Instituto Tecnológico Superior de Irapuato, Guanajuato, México. E-mail: edruelas@itesi.edu.mx

\*\* Docente del Departamento de Ingeniería Industrial en el Instituto Tecnológico Superior de Irapuato, Guanajuato, México. E-mail: bevargas@itesi.edu.mx

\*\*\* Docente de la División de Ciencias Naturales y Exactas, Universidad de Guanajuato, Guanajuato, México. E-mail: samj02@hotmail.com

principalmente a la clasificación-reconocimiento y estimación de características importantes en el campo de los materiales. Una aplicación de la integración entre ambas disciplinas es mostrar la caracterización llevada a cabo por propiedades morfológicas presentes en imágenes obtenidas a partir de muestras de hierro fundido dúctil, con el fin de proporcionar una evaluación cuantitativa sobre la forma de los nódulos de grafito, para éste fin, las imágenes de las muestras de material se presentan de forma binaria. Tal proceso de binarización se puede formular como un problema de segmentación óptima. La búsqueda de la solución óptima se resuelve de manera eficiente mediante la formación de una red neuronal artificial [3]. 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 [11].

En [10], se llevan a cabo procedimientos de clasificación-reconocimiento de patrones a partir de imágenes y redes neuronales artificiales, las aplicaciones se llevaron a cabo dentro de procesos de separación de materia orgánica y microestructuras de materiales, respectivamente, esta última utiliza únicamente seis parámetros de entrada a la red neuronal artificial. Otra técnica que relaciona las redes neuronales con el estudio de materiales se presenta en [7], donde se desarrolla 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, dicho reconocimiento y predicción se hace mediante una red neuronal artificial que tiene como entrada los siguientes parámetros cuantitativos: amplitud, tiempo de subida, la duración y frecuencia. El uso de redes neuronales en materiales se ha visto abordado para resolver tareas de estimación, en el estudio de [1] y [9], 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 red neuronal artificial que afectan a la microdureza como: la temperatura de austenización, velocidad de enfriamiento, el tamaño inicial de grano de austenita, diferentes composiciones químicas y Niobio (Nb) en solución [6]. 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. Finalmente, los autores refieren como la contribución de esta investigación el desarrollo del sistema inteligente aplicado sobre el procesamiento digital del tipo de imágenes metalografías 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 (Ver Figura 1).

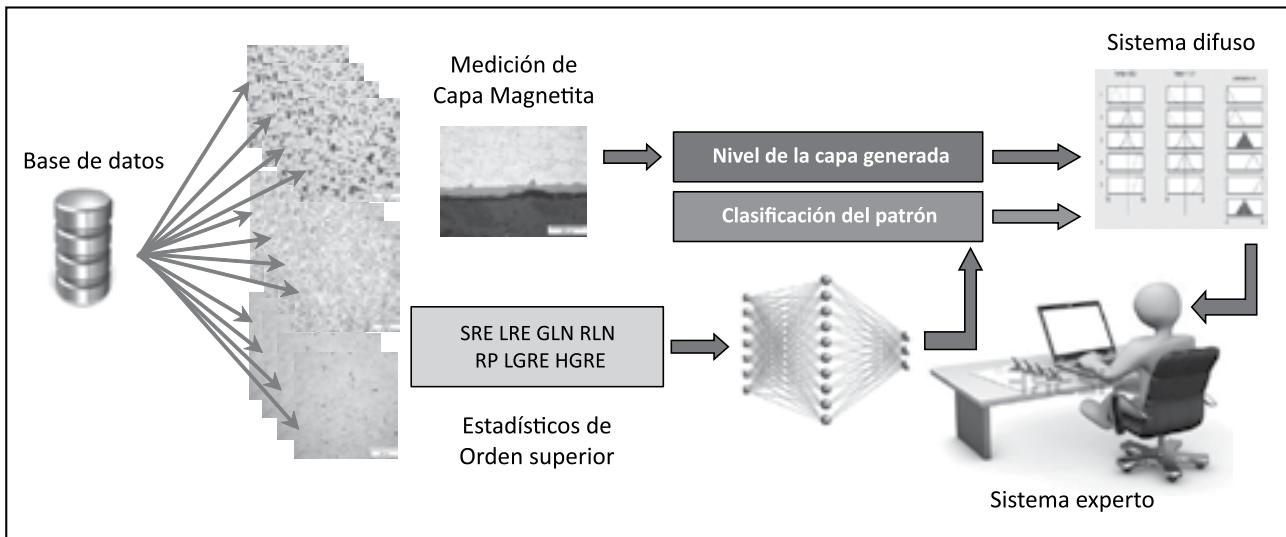
El desarrollo de un sistema que estime el deterioro presente en el material surge de la necesidad de corroborar el diagnóstico hecho por un experto metalográfico además de automatizar el proceso ya que el experto humano puede no estar disponible o puede haber una escasez de tales especialistas altamente cualificados.

### 1.1. Estadísticos basados en las matrices de longitud de secuencia

El uso de matrices de longitud de secuencia para el modelado de textura fue propuesto inicialmente por Galloway en [4]. Se trata de estadísticos de orden superior, pues en su cálculo 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.

$$(R(\theta) = (g(i,j) \mid \theta), 0 \leq i \leq N_g, 0 \leq j \leq R_{\max}) \quad (1)$$

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, por lo cual, es necesario aplicar un conjunto de estadísticos sobre cada una de estas

**Figura 1.** Arquitectura del sistema básica del sistema inteligente.

matrices para obtener los vectores de características correspondientes. Tradicionalmente, de acuerdo al trabajo de Galloway [4], 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). La matriz de longitud de secuencia de nivel de gris queda definida mediante:

$$SRE = \frac{1}{n} \sum_{i,j} \frac{P(i,j)}{j^2} \quad (2)$$

$$LRE = \frac{1}{n} \sum_{i,j} j^2 P(i,j) \quad (3)$$

$$GLN = \frac{1}{n} \sum_i \left( \sum_j P(i,j) \right)^2 \quad (4)$$

$$RLN = \frac{1}{n} \sum_i \left( \sum_j P(i,j) \right)^2 \quad (5)$$

$$RP = \sum_{i,j} \frac{n}{P(i,j)j} \quad (6)$$

$$LGRE = \frac{1}{n} \sum_{i,j} \frac{P(i,j)}{i^2} \quad (7)$$

$$HGRE = \frac{1}{n} \sum_{i,j} i^2 P(i,j) \quad (8)$$

A raíz de este trabajo, han surgido nuevos modelos en los que se propone la incorporación de otros estadísticos para mejorar diversas carencias del original. Así, por ejemplo, en [2] 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).

## 1.2. Red Neuronal Artificial

Una red neuronal artificial es un procesador masivo paralelo formado por unidades simples de procesamiento que tienen una propensión natural para almacenar conocimiento experimental, haciéndolo viable para su uso. La red neuronal se asemeja al cerebro en dos aspectos:

- El conocimiento es adquirido por la red desde su entorno a través de un proceso de aprendizaje.
- Las fuerzas de las conexiones entre neuronas, conocidas como pesos sinápticos, son usadas para almacenar el conocimiento [5].

La arquitectura de una red neuronal consiste en la organización y disposición de las neuronas en la red formando capas o agrupaciones de neuronas. Los parámetros fundamentales son: número de capas, número de neuronas por capa, grado de conectividad y tipo de conexión entre neuronas.

## Fuzzy ArtMap

La red neuronal artificial utilizada para la investigación es la Fuzzy ARTMAP la cual cuenta con una arquitectura perteneciente a la familia de ART (Adaptive Resonance Theory). Esta teoría fue desarrollada por Grossberg y Carpenter en la Universidad de Boston. Fuzzy ARTMAP puede efectuar aprendizaje supervisado. Esta red neuronal crea varias neuronas de acuerdo al número de patrones presentados en su entrenamiento y a las diferencias entre ellos. Está basada en las siguientes características (Ver Figura 2). Esta red tiene dos módulos Fuzzy ART, uno para manejar las entradas y el segundo para las salidas (ARTa y ARTb). También tiene un campo de correspondencia Fab que liga las clases de entrada con las de salida.

La forma de operación de un módulo básico (ARTa ó ARTb) opera como un módulo básico ART como se ilustra en la Figura 3. Dicho modulo

consta de 2 subsistemas, atención y orientación. El primer subsistema consta de dos capas de nodos hacia arriba, F1 y F2 que representan la memoria de corto plazo (STM), que a su vez están unidas por los pesos ajustables de largo plazo (LTM). Así, la información de salida del elemento de procesamiento reverbera hacia atrás y hacia delante entre las dos capas. Si una resonancia estable toma lugar entonces puede ocurrir aprendizaje o adaptación. El subsistema de orientación reinicia el subsistema de atención cuando ocurre un evento no común. Si el patrón de entrada no es reconocido inmediatamente entonces la red entrara a un estado de resonancia, después de lo cual un nuevo patrón es almacenado por primera vez. De este modo la red responde rápidamente a datos aprendidos previamente.

El parámetro de vigilancia de la red ( $\rho$ ) mide la diferencia permitida entre los datos de entrada y los patrones almacenados. Por tanto este parámetro es el determinante para afectar a la selectividad o granularidad de la predicción de la red. Este parámetro tiene 3 factores: vigilancia a la entrada (vigilancia base) ( $\rho_a$ ), vigilancia de salida ( $\rho_b$ ) y vigilancia de mapeo ( $\rho_{ab}$ ).

### 1.3 Lógica difusa

Los sistemas expertos son programas computacionales diseñados para tener disponibles las habilidades de los expertos a los no expertos. Estos programas tratan de emular los patrones de razonamiento del experto. Existen varias formas para crear programas que actúen como sistemas expertos, los primeros y más utilizados son los sistemas basados en reglas, los cuales usan reglas si-entonces para representar el proceso de razonamiento del experto (si la información coincide con ciertas condiciones especificadas, entonces se toman las acciones apropiadas). Algunos expertos en conocimiento, opinan que una parte significativa del razonamiento humano puede expresarse en forma de reglas, lo que le da un interés adicional a los sistemas basados en reglas. Algunas otras maneras de diseñar sistemas expertos son: redes semánticas o asociativas y redes neuronales [8]. La arquitectura típica de un sistema de lógica difusa se muestra en la Figura 4. El cual se compone principalmente de cuatro módulos: un fusificador, una base de conocimiento, un módulo de inferencia y por ultimo un defusificador. En la fusificación se asignan grados de pertenencia a cada una de las variables de entrada con relación a los conjuntos difusos previamente definidos utilizando las funciones de pertenencia asociadas a los conjuntos difusos [8].

Figura 2. Estructura de la RNA Fuzzy ARTMAP.

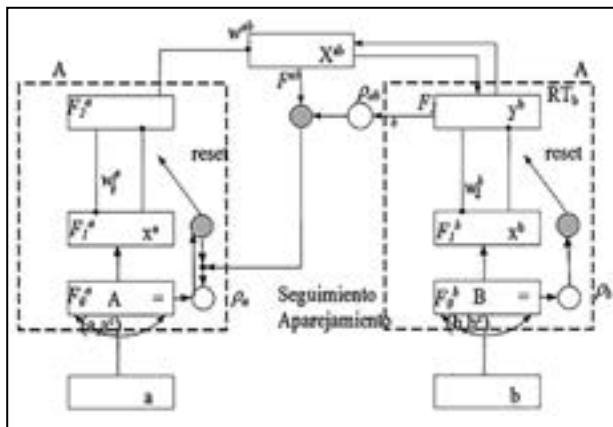
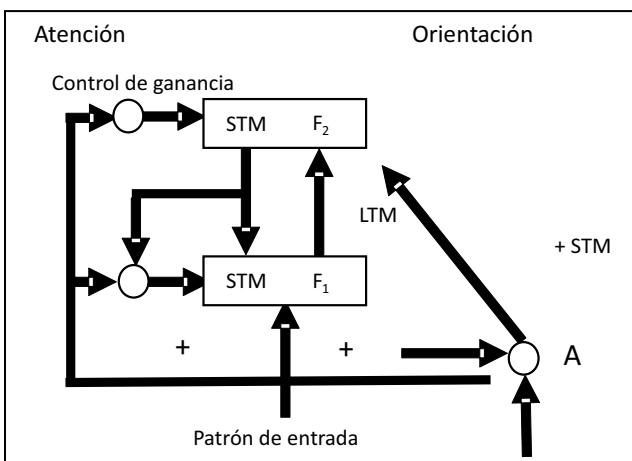
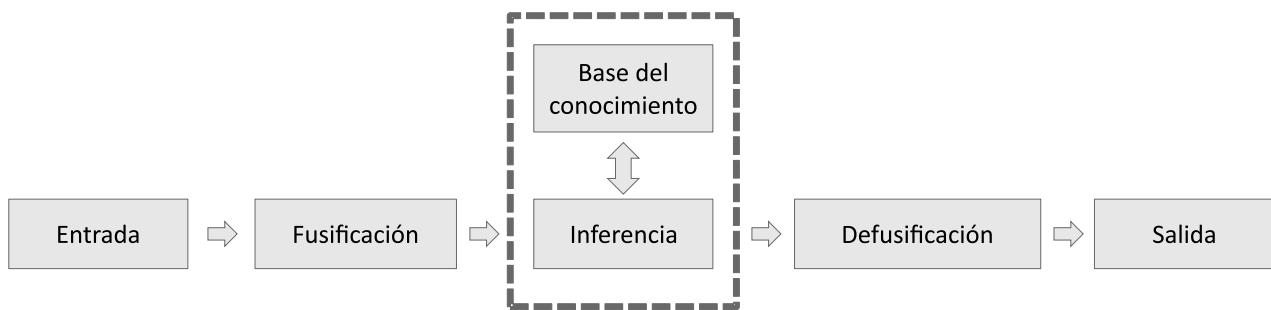
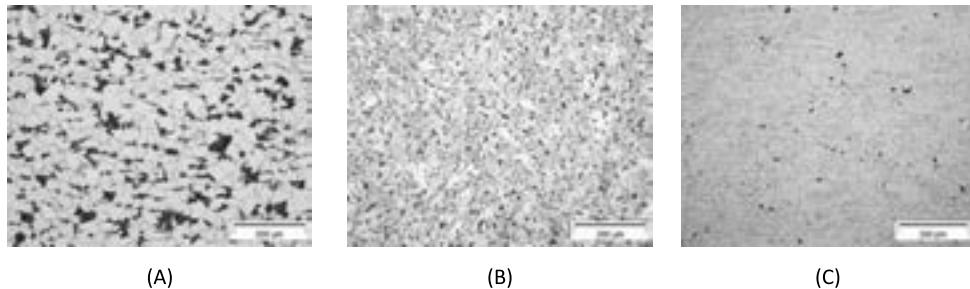
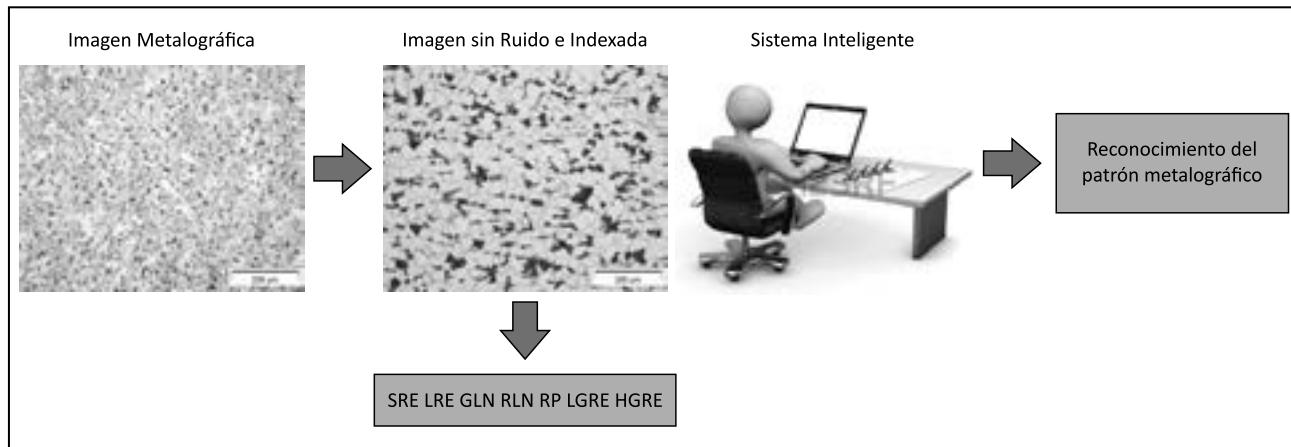


Figura 3. Funcionamiento de la RNA Fuzzy ARTMAP.



**Figura 4.** Estructura de un sistema de lógica difusa.**Figura 5.** Patrones de comportamiento estudiados.**Figura 6.** Esquema básico de funcionamiento del sistema para reconocimiento de patrones metalográficos.

## 2. 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 Figura 5; (a), (b) y (c) respectivamente.

El conjunto de patrones empleados para entrenar y probar a la red neuronal artificial se llevó a cabo por medio de una base de datos de sesenta y dos imágenes metalográficas afectadas por patrones previamente reconocidos e identificados por

expertos de LAPEM. La matriz de entrenamiento se generó a partir del proceso mostrado de aplicación de un filtro (Filtro de la mediana) además de la indexación de la imagen para obtener medidas uniformes (512 x 512) en cada una de las imágenes, para que posteriormente se calculen los estadísticos de orden superior y así poder caracterizar cada una de las imágenes como se muestra en la figura 6.

De acuerdo a la serie de pasos descrita se define la matriz de entrenamiento de [62 x 7] incorporada a la red neuronal Fuzzy ArtMap. La composición de la matriz para el entrenamiento se muestra en la Tabla 1.

**Tabla 1.** Matriz de entrenamiento de la RNA

Patrón Metalográfico	Dimensión
Perlite Laminar	23 x 7
Esferoidización	21 x 7
Grafitización	18 x 7

Los parámetros de funcionamiento de la red neuronal artificial Fuzzy ArtMap tanto para la fase entrenamiento y prueba se muestran en la Tabla 2.

### 2.1 Sistema Difuso

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 medir el tamaño de la capa magnetita generada en el material, después de este proceso el experto arroja un resultado cualitativo y lingüístico como: Incipiente hasta avanzada afectación lo cual es subjetivo.

### Fusificación

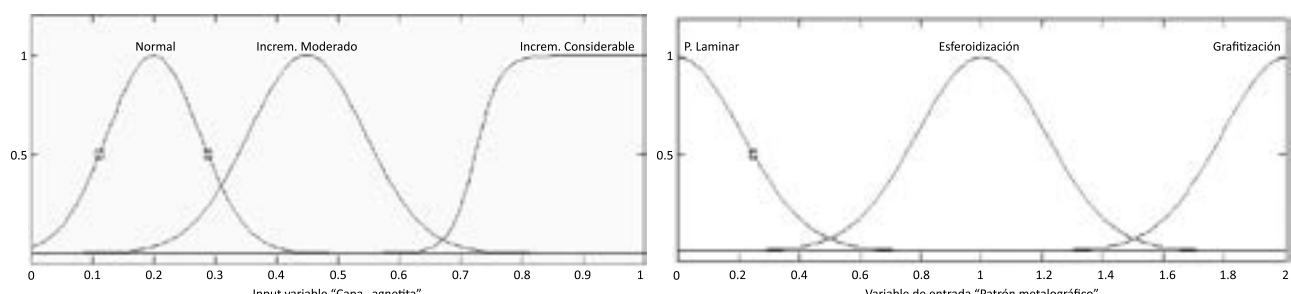
En la fusificación se asignan grados de pertenencia a cada una de las variables de entrada con relación a los conjuntos difusos previamente definidos utilizando las funciones de pertenencia asociadas a los conjuntos difusos [8]. La variable de entrada: Patrón de comportamiento, es el resultado del proceso realizado por la RNA después reconocer y clasificar la señal de entrada generada a partir de los estadísticos. La segunda variable, nivel de capa magnetita, es generada a partir de un proceso de medición de dicha capa, la cual mantiene en un rango de [0, 1] milímetros mm. Tomando en cuenta que un milímetro es una capa considerablemente gruesa formada en el material, lo cual puede producir fallos en el proceso de conducción y disminuir eficiencia en el sistema de generación de energía eléctrica.

### Inferencia

La base de conocimiento contiene el conocimiento asociado con el dominio de la aplicación. En esta etapa se deben definir las reglas lingüísticas de control que realizarán la toma de decisiones que a su vez decidirán la forma en la que debe actuar

**Tabla 2.** Parámetros de operación de la RNA

Parámetros de entrenamiento		Parámetros de Prueba	
Art A	7	Art A	7
Base Vigilance	0.2	Base Vigilance	0.2
Rho Map	0.7	Rho Map	0.7
Learn Rate	1	Learn Rate	1
Lower Weight Bound	0.5	Lower Weight Bound	0.5
Art B	3		
Vigilance	0.9		

**Figura 7.** Fusificación de la variable de entrada patrón de comportamiento y nivel de capa magnetita.

el sistema. El proceso de inferencia provee las bases para la toma de decisiones del sistema. Este proceso involucra la utilización de funciones de pertenencia y las reglas generadas en la base de conocimiento.

### Defusificación

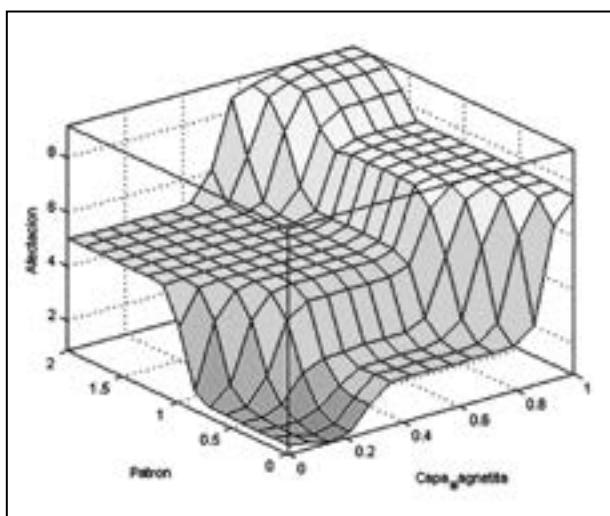
Después de la inferencia, tendremos una conclusión difusa, una variable lingüística cuyos valores han sido asignados por grados de pertenencia, sin embargo usualmente necesitamos un escalar que corresponda a estos grados de pertenencia, a este proceso se le llama defusificación [8]. En la figura 8, se muestra la superficie de respuesta generada al combinar las dos diferentes variables de entrada, arrojando así, en nivel de afectación presente en el material en una escala numérica con un rango de [0, 10].

### 3. RESULTADOS

Para verificar el buen funcionamiento de la red neuronal artificial 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 seis nuevas imágenes con patrones de perlita laminar, esferoidización y grafitización para su clasificación y reconocimiento.

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 seis imágenes. El sistema de lógica difusa toma como base la clasificación-reconocimiento del patrón metalográfico presente

**Figura 8.** Superficie de respuesta del nivel de afectación.



en la imagen además de la cantidad de ferrita. Ver tabla 3.

### 4. CONCLUSIÓN

Los resultados obtenidos en esta investigación enfatizan principalmente en dejar ver la viabilidad de uso de un sistema neuro-difuso y procesamiento digital de imágenes para el diagnóstico de diversos estados físicos del acero al carbón del tipo SA 210 Grado A-1 y la estimación cuantitativa de su deterioro sufrido en planta a partir de una imagen microestructural del acero, actualmente estos procedimientos de reconocimiento y diagnóstico son realizados a partir de la experiencia de un experto en el área de materiales. Este artículo

**Tabla 3.** Resultados de clasificación-reconocimiento y estimación de deterioro

Imagen	Indicadores	Sistema Experto	Experto Humano	Comparación
1	Patrón metalográfico Deterioro	Perlita Laminar 5%	Perlita Laminar 7%	Correcto Diferencia de 2%
2	Patrón metalográfico Deterioro	Perlita Laminar 0.2%	Perlita Laminar 0%	Correcto Diferencia de 0.2%
3	Patrón metalográfico Deterioro	Esferoidización 4%	Esferoidización 6.6%	Correcto Diferencia de 2.6%
4	Patrón metalográfico Deterioro	Esferoidización 7%	Esferoidización 5%	Correcto Diferencia de 2%
5	Patrón metalográfico Deterioro	Grafitización 95%	Grafitización 90%	Correcto Diferencia de 5%
6	Patrón metalográfico Deterioro	Grafitización 89%	Grafitización 95%	Correcto Diferencia de 6%

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.

## 5 BIBLIOGRAFÍA

- [1] Al-Assadi, et al. (2010) *Predicting the Fatigue Life of Different Composite Materials Using Artificial Neural Networks*. *Applied Composite Materials*. Volume 17, Issue 1, pp 1-14.
- [2] Chu A., 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.
- [3] Federación de Enseñanza de C.C.O.O. de Andalucía (2011) 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>
- [4] Galloway M.M.. Texture analysis using gray level run lengths. *Computer Graphics and Image Processing*, 4:172–179, 1975.
- [5] Haykin, S. (2009) *Neural Networks and Learning Machines*. New Jersey; Editorial Pearson Prentice Hall.
- [6] Khalaj, G., et al. (2013) 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
- [7] Liu, C., et al. (2012) Damage Pattern Recognition of Refractory Materials Based on BP Neural Network. *Neural Information Processing*. Volume 7666, pp 431-440.
- [8] Pedrycz, W. (1989) *Fuzzy Control and Fuzzy Systems*. Research Studies Press. Ltd, John Wiley & Sons Inc.,
- [9] Rauch, L. et al. (2010) Optimization of Parameters of Feed-Back Pulse Coupled Neural Network Applied to the Segmentation of Material Microstructure Images. *Artifical Intelligence and Soft Computing*. Lecture Notes in Computer Science Volume 6114, pp 80-87.
- [10] Subashini, L. et al. (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*. Volume 43, Issue 1, pp 145-15.