

Integración de métodos para la clasificación-reconocimiento de patrones metalográficos a base de inteligencia artificial y procesamiento digital de imágenes

E. A. Ruelas¹, J. A. Vázquez-López², J. Yañez-Mendiola¹, I. López-Juárez³,
C. F Bravo-Barrera⁴

¹ CIATEC, León, Gto. Mexico
edruelas@itesi.edu.mx
jyaney@ciatec.mx

² Instituto Tecnológico de Celaya, Celaya, Guanajuato., México
antonio.vazquez@itcelaya.edu.mx

³ Centro de Investigación y de Estudios Avanzados del IPN – Unidad Saltillo, Ramos Arizpe,
Coahuila., Mexico
ismael.lopez@cinvestav.edu.mx

⁴ Laboratorio de Pruebas Equipos y Materiales. Irapuato, Guanajuato., Mexico
fernando.bravo01@cfe.gob.mx

Paper received on 24/07/12, Accepted on 11/09/12.

Resumen. Este artículo propone un método para el reconocimiento de patrones en materiales de acero al carbón mediante la red neuronal artificial Fuzzy ArtMap y procesamiento digital de Imagen. Un aspecto importante que se aborda es dejar ver la viabilidad para la integración de estos dos métodos para desarrollar un sistema de reconocimiento de diversos estados de aceros al carbón en base a imágenes obtenidas de microscopio usando la red neuronal fuzzy ArtMap.

Palabras clave: Red neuronal artificial (RNA), procesamiento digital de imágenes.

1 Introducción

La metalografía es la disciplina que estudia microscópicamente las características estructurales de un metal o de una aleación. Sin duda, el microscopio es la herramienta más importante del metalurgista tanto desde el punto de vista científico como desde el técnico. Es posible 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 revelará el tratamiento mecánico y térmico del metal y, bajo un conjunto de condiciones dadas, podrá predecirse su comportamiento esperado.

El comportamiento esperado del material y la falla de mismo presentan patrones de comportamiento que pueden ser analizadas por un sistema basado en la clasifica-

ción-reconocimiento de patrones por medio de redes neuronales y procesamiento digital de imágenes. La red neuronal artificial (RNA) clasificara el patrón de comportamiento que arroje el análisis de la microestructura del material, eliminando la subjetividad del operador en el sistema a través del entrenamiento exhaustivo de la RNA.

Las herramientas que se utilizaran serán: RNA, Lógica difusa y procesamiento digital de imágenes. La primera se emplea para reconocer y clasificar patrones de comportamiento dentro de la microestructura del material, la lógica difusa se incorpora en la arquitectura de la RNA para obtener una decisión más robusta en cuestión al reconocimiento y clasificación de los patrones observados en la microestructura, el procesamiento digital de imágenes es un punto clave, ya que por medio de este se alimenta al sistema enfocado a la clasificación-reconocimiento de patrones. Una parte importante del problema es la complejidad un sistema que integre los métodos y que además sirva como método de diagnóstico basado en la clasificación-reconocimiento de patrones y procesamiento de imágenes. La otra parte del planteamiento del problema se refiere a la necesaria optimización de uso del sistema, de tal forma que se mantengan bajas las probabilidades de los errores tipo I.

Se han realizado investigaciones donde comprueban la viabilidad y beneficios de la integración entre RNA y procesamiento digital de imágenes enfocados al reconocimiento de patrones. Se propone un sistema para la resolución de píxeles basados en múltiples problemas de clasificación de imágenes espectrales [8]. El tema de integración de ambos métodos se ha probado en el campo de la medicina, la técnica de procesamiento de imágenes y redes neuronales artificiales para detectar y clasificar la tuberculosis en imágenes de las diapositivas de tejidos [7]. Otra aplicación exitosa fue desarrollada por [10], sistema mediante el cual una red neuronal de propagación hacia atrás con un enfoque para clasificar defectos a partir de imágenes por sus convexos y brillo. En la ref. [9], se presenta el uso de redes neuronales art empleadas para el reconocimiento de imágenes en cuanto al color y textura. La arquitectura presentada logra una buena segmentación y reconocimiento, en comparación con otros métodos. Siguiendo con la aplicación de la RNA's en la ref. [3], se estudian diversas aplicaciones de la red neuronal Fuzzy ARTMAP, en reconocimiento de patrones dentro del procesamiento de señales de diferentes fuentes, imágenes, voz y texto.

La colaboración entre las redes neuronales artificiales y lógica difusa puede ser utilizado para mejorar o resolver algunas de las limitaciones que presentan cada una de ellas; estos nuevos sistemas híbridos, llamados sistemas neuro-difusos, desarrollan las propiedades y ventajas propias de cada tecnología en beneficio de la otra tecnología complementaria, obteniendo una mejora importante en el comportamiento global del sistema [2].

Dentro del ambiente de sistemas que combinan redes neuronales y lógica difusa se encuentran trabajos enfocados al ramo alimenticio. En la ref. [1], presenta una herramienta visual desarrollada sobre el entorno Matlab dedicada al control de calidad del proceso. En la ref. [6], propone una metodología de integración entre redes neuronales y Lógica difusa para hacer evaluaciones y predicciones que conllevan a la optimización de fabricación de arrabio. Otra aplicación se desarrolla en la implementación y evaluación de filtros tanto para el pre-proceso como para la detección de bordes en imágenes digitales, los cuales se basan en lógica difusa [4]. Un sistema

de procesamiento de imagen se compone de una serie de subsistemas que operan sobre una escena con el objetivo de interpretar alguna característica notable. La materia prima del procesamiento de imágenes y la visión son las imágenes, las cuales se consideran como una representación del mundo físico que tiene información importante, la cual es captada mediante un proceso de muestreo, generalmente por medios electrónicos.

De acuerdo con [5], una imagen puede estar definida con una función de dos dimensiones denotada $f(x, y)$, donde x y y denotan la posición de una muestra en donde se mide la intensidad de la luz. Cuando se muestrea tanto espacialmente como en amplitud una señal bidimensional, hablamos de una imagen digital, al tratamiento que se le da a la imagen digital a través de la información que se obtiene por el par ordenado, se le denomina procesamiento digital de imágenes. Las imágenes son representadas por medio de matrices con M renglones y N columnas. Donde la coordenada $f(0,0)$ de la imagen corresponde a $f(1,1)$ de la matriz y así sucesivamente. Se ha demostrado la efectividad del software MATLAB para el procesamiento de imágenes, mediante la herramienta de simulink [5].

2 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. 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 (F^{ab}) que liga las clases de entrada con las de salida. Ver figura 1.

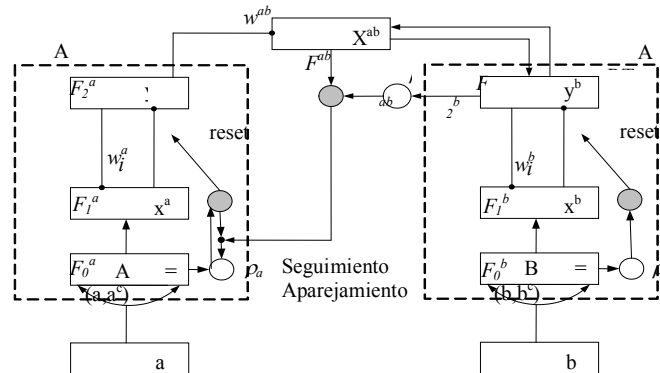


Figura 1. Estructura de la RNA Fuzzy ARTMAP.

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 sub-

sistemas, 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 entrará 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.

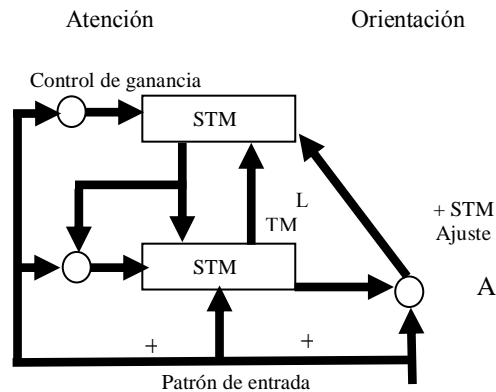


Figura 2. Funcionamiento de la RNA Fuzzy ARTMAP.

El parámetro de vigilancia de la red (ρ) 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) (ρ_a), vigilancia de salida (ρ_b) y vigilancia de mapeo (ρ_{ab}).

3 Metodología Experimental

El caso de aplicación para esta investigación está siendo desarrollado dentro del Laboratorio de Pruebas de Equipos y Materiales (LAPEM) de la comisión federal de electricidad (CFE).

Específicamente enfocado en el área de materiales. Para los intereses de la empresa y la investigación se pretende desarrollar un sistema experto con las siguientes características:

- Reconocer y clasificar patrones de comportamiento en el deterioro del material (aceros al carbón) afectado por temperatura.
- Identificar el tipo de material y predecir el tiempo de vida de dicho material después del uso en campo en una escala de 1 a 10.

Los patrones detectados presentes en la microestructura para el deterioro del material, con afectación por temperatura son los siguientes:

- Crecimiento de grano.
- Crecimiento de espesor magnetita.
- Afectaciones Cristalográficas.
- Granos de Perlita en proceso de Esferoidización.
- Grafitización.
- Descarborización.

Cabe mencionar que los datos obtenidos acerca de patrones de comportamiento, tipo de material y afectaciones son a partir de imágenes. Por lo cual el procesamiento digital de imágenes es una base teórica primordial dentro de esta investigación.

Las pruebas realizadas se limitan solo a los patrones de granos dispersos, granos de perlita en proceso de esferoidización y granos finos de Perlita Laminar. Cada uno de ellos con características propias generados a partir de que el material sufrió afectaciones por temperatura en campo.

A continuación se muestran ejemplos de materiales afectados por temperatura en pruebas de campo y su microestructura:

i. Granos dispersos

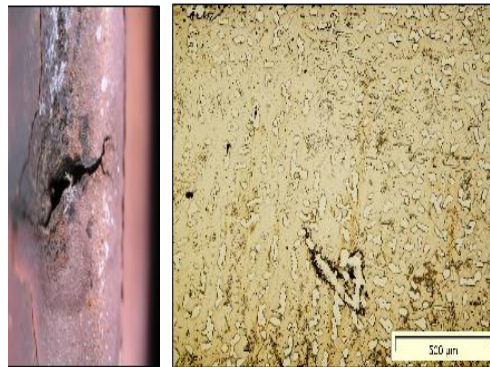


Figura 3. Material afectado por temperatura (Granos dispersos).

Tabla 1. Características generales del patrón granos dispersos (Fig 3).

Nombre	Tamaño	Bytes	Clase
F	235x290x3	211344	uint 8

Tabla 2. Características generales del patrón esferoidización (Fig 4).

Nombre	Tamaño	Bytes	Clase
A	235x247x3	174876	uint8

ii. Granos de Perlita en proceso de Esferoidización



Figura 4. Material afectado por temperatura (Esferoidización).

iii. Granos finos de Perlita Laminar



Figura 5. Material afectado por temperatura (Perlita Laminar).

Tabla 3. Características generales del patrón perlita laminar (Fig 5).

Nombre	Tamaño	Bytes	Clase
B	171x212x3	108756	uint8

3.1 Procesamiento de la imagen

Se presenta un diagrama de flujo indicando las operaciones de manera detallada en el proceso de extracción y limpieza de ruido de la imagen metalográfica obtenida de los materiales a partir de microscopio.

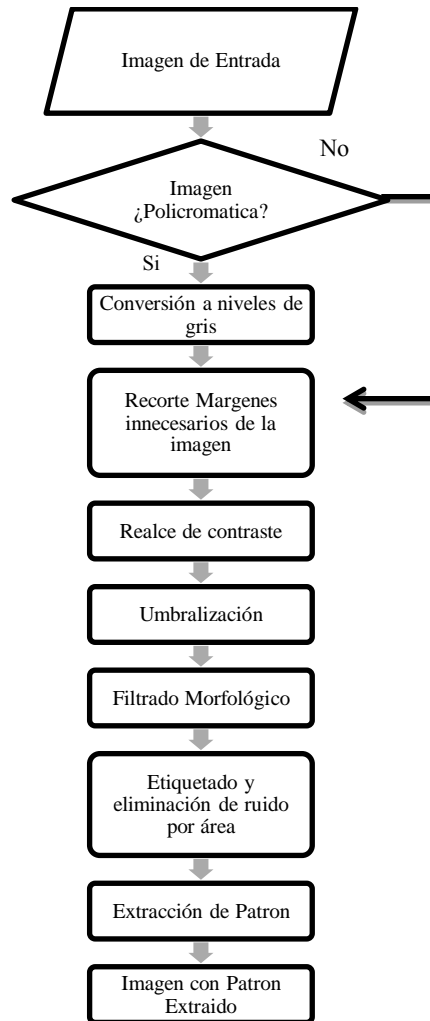


Figura 6. Diagrama de proceso para la extracción del patrón presente en la Imagen.

El procesamiento digital de la imagen es un paso necesario llevado acabo en este trabajo mediante técnicas ya conocidas dentro de esta disciplina. El procesamiento se muestra en la Fig. 7. Este Proceso surge de la necesidad de hacer más evidente el patrón de comportamiento y de esta forma esperar una mejor eficiencia en la RNA en el reconocimiento del patrón.

3.2 Fase de Entrenamiento

En la presente investigación se plantean dos técnicas de entrenamiento para la red neuronal Fuzzy ArtMap que son: Matriz desacoplada y por familia. Y de esta forma medir la eficiencia de cada una en cuanto a la clasificación-reconocimiento de patrones que para este caso es en el área de metalografía.

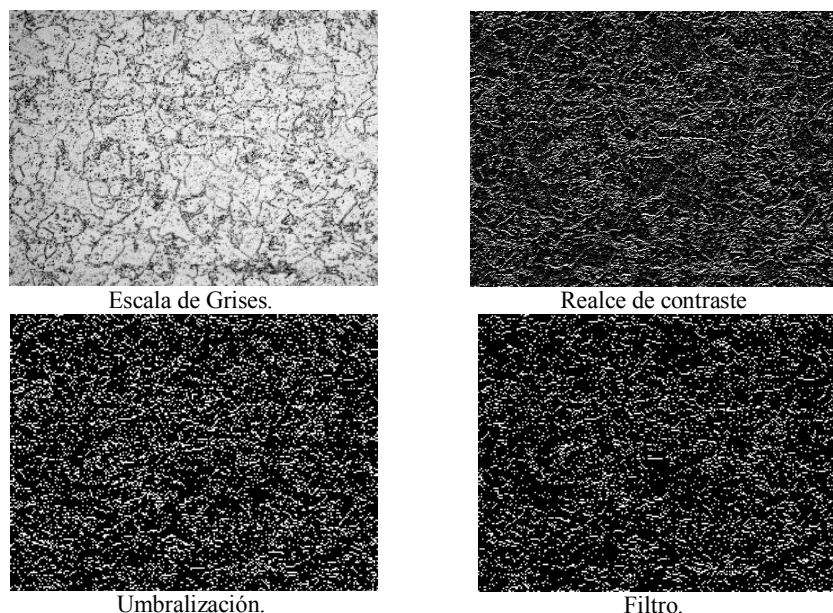


Figura 7. Procesamiento digital de la Imagen.

Cabe mencionar que una de las limitantes que presenta la RNA Fuzzy ArtMap es que para la fase de entrenamiento solo acepta a lo más matrices de $n \times 50$. De aquí surgen las dos alternativas para el entrenamiento de la RNA que cumplan con la restricción de su arquitectura.

- Matriz desacoplada.

El término surge por la idea de convertir la matriz de entrenamiento de 5×10 . A un vector de entrenamiento de 1×50 . Que cumple con la restricción de tamaño que presenta la RNA.

- Familia de Vectores.

Otra alternativa de entrenamiento evaluada es la de tomar familias de vectores de 1×10 . Que al darles un mismo vector de salida la RNA tomará como el mismo elemento o patrón. Las familias se realizaron de cinco vectores para formar una matriz de 5×10 . Con esta forma de entrenamiento también se desea probar que el vector de entrenamiento no debe ser del mismo tamaño que el vector de prueba. Los parámetros de funcionamiento para esta fase de entrenamiento son los que se muestran en la tabla 4.

Tabla 4. Entrenamiento de la RNA.

Parámetros de entrenamiento	
Art A	50,10
Base Vigilance	0.2
Rho Map	0.7
Learn Rate	1
Lower Weight Bound	0.5
Art B	3
Vigilance	0.9

3.3 Fase de Prueba

Para realizar esta actividad es necesario establecer la región de prueba en la imagen, dentro de esta región se analizara si el comportamiento descrito en la fase de entrenamiento esta presente por medio de la RNA.

Se seleccionaron dos regiones de prueba al azar dentro de toda la imagen en cada una de las microestructuras analizadas en la investigación. El tamaño de cada una de las regiones es de $n \times 50$.

Tabla 5. Entrenamiento de la RNA.

Parámetros de Prueba	
Art A	50,10
Base Vigilance	0.2
Rho Map	0.7
Learn Rate	1
Lower Weight Bound	0.5

4 Resultados

En la tabla 6 y 7 se muestra la eficiencia de la red neuronal para detectar el patrones de comportamiento granos dispersos, esferoidización y perlita laminar presentado en las regiones de prueba de su respectiva microestructura.

Tabla 6. Entrenamiento Matriz desacoplada.

	Prueba 1	Prueba 2
Granos dispersos	89.0%	91.5%
Esferoidización	95.4%	97.4%
Perlita Laminar	92.5%	94.3%

Tabla 7. Entrenamiento Familia de Vectores.

	Prueba 1	Prueba 2
Granos dispersos	93.9%	92.7%
Esferoidización	91.9%	90.2%
Perlita Laminar	85.7%	84.8%

5 Conclusión

El modulo de la RNA Fuzzy ArtMap tiene una eficiencia aceptable en la clasificación-reconocimiento de patrones explorados en este artículo a pesar de realizar la fase entrenamiento con vectores cortos. Con lo que se puede concluir que es posible establecer protocolos de clasificación-reconocimiento de patrones metalográficos por medio de redes neuronales artificiales que posibilite un análisis predictivo a partir de un procesamiento digital de imágenes. Es imprescindible desarrollar mejores técnicas de operación y dimensionalidad de la RNA para poder ofrecer un mejor diagnóstico de la imagen y de esta forma lograr su implementación en campo.

Referencias

- 1 Al-Hadithi, B., Rueda., M., Muro, J. (2006). Interfaz visual para el prototipado rápido de clasificadores de gajos de mandarina basados en redes neuronales.
- 2 Basogain O. X., (2004). Redes neuronales artificiales y sus aplicaciones. Escuela superior de ingeniería de Bilbao.
- 3 Boaz L. and Guterman H. (2008). Advanced Developments and Applications of the Fuzzy ARTMAP Neural Network in Pattern Classification. Volume 137/2008, 77-107.
- 4 Cardona., C., (2004). Evaluación de algoritmos basados en lógica difusa aplicados al pre-proceso y detección de bordes en imágenes digitales. Universidad Nacional de Colombia.
- 5 Gonzalez R. C; Woods R. E y Eddins S. L. (2009). Procesamiento digital de imagen utilizando MATLAB. Editorial Pearson.
- 6 Hussien, Ghidan (2008). Aplicación de las redes neuronales y la lógica difusa a la optimización del proceso de la fabricación del arrabio en un horno alto. Universidad Alcala.
- 7 Osman M. K., Mashor M. Y. and Jaafar H. (2011). Hybrid Multilayered Perceptron Network Trained by Modified Recursive Prediction Error-Extreme Learning Machine for Tuberculosis Bacilli Detection. Volume 35, Part 15.
- 8 Reid. P., Neal H., Simon P., James T., Steven B., Jeffrey B., Maya G and Jonh S., (2003). Optimizing Digital Hardware Perceptrons for Multi-Spectral Image Classification. Volume 19, Number 2.
- 9 Rodríguez M., González D., Díaz-Pernas F. J., Martínez-Zarzuela M. and J. F. Díez-Higuera. (2012). Color-texture image segmentation and recognition through a biologically-inspired architecture. Volume 22, Number 1.
- 10 Shih-Wei L., Shuo-Yan C., and Shih-Chieh. (2007). Irregular shapes classification by back-propagation neural networks. Volume 34, Numbers 11-12.