

# Reconocimiento de patrones de corrosión en acero inoxidable mediante el método congruencia de fases

Ruelas Santoyo, Edgar Augusto; Figueroa Fernández, Vicente; Hernández González, Salvador  
Tecnológico Nacional de México en Celaya  
*edgar.ruelas@itcelaya.edu.mx; vicente.figueroa@itcelaya.edu.mx; salvador.hernandez@itcelaya.edu.mx*

## Resumen

Para asegurar el desempeño óptimo de los componentes empleados en las plantas termoeléctricas, la evaluación de su estado operativo resulta fundamental. Entre los elementos sometidos al monitoreo se encuentran piezas fabricadas en acero inoxidable, cuya función principal es conducir agua a altas temperaturas. Las condiciones severas de operación provocan un desgaste gradual que requiere ser controlado mediante el análisis del material. El acero inoxidable tipo AISI 304, cuando se expone a temperaturas comprendidas entre 450 y 850 °C, presenta desgaste, el cual disminuye su resistencia y altera su

microestructura. El trabajo presenta un algoritmo que clasifica automáticamente las microestructuras de corrosión en el material. Este algoritmo se fundamenta en el procesamiento digital de imágenes e inteligencia artificial. En primera instancia, se expone el contexto teórico además de particularidades del algoritmo propuesto; posteriormente, se detallan las experimentaciones realizadas y la arquitectura de la red neuronal artificial. Los hallazgos manifiestan que el algoritmo es competente para identificar la corrosión en el acero inoxidable con una eficiencia del 90%.

**Palabras Clave:** Corrosión, acero inoxidable, red neuronal artificial.  
**JEL:** C45, L63, O31

## Corrosion pattern recognition in stainless steel using the phase congruency method

To ensure optimal performance of the components used in thermoelectric plants, evaluating their operating condition is essential. Among the elements subject to monitoring are parts made of stainless steel, whose main function is to conduct water at high temperatures. Severe operating conditions cause gradual wear that needs to be controlled through material analysis. When exposed to temperatures between 450 and 850 °C, AISI 304 stainless steel undergoes wear, which reduces its strength and

alters its microstructure. This paper presents an algorithm that automatically classifies corrosion microstructures in the material. This algorithm is based on digital image processing and artificial intelligence. First, the theoretical context and particularities of the proposed algorithm are presented; then, the experiments carried out, and the architecture of the artificial neural network are detailed. The findings show that the algorithm can identify corrosion in stainless steel with 90% efficiency.


**Keywords:** Corrosion, stainless steel, artificial neural network.  
**JEL:** M14

## 1. Introducción

El acero inoxidable AISI 304 se utiliza para fabricar conductores de calderas en plantas termoeléctricas, lo que se traduce en condiciones de trabajo a altas temperaturas y en el ataque de agentes oxidantes externos como la humedad sobre dichos conductores. La permanencia del acero en la zona de temperaturas entre 450 y 850 °C, ocasiona la precipitación de carbono mediante la generación de carburos abundantes en cromo del tipo M<sub>23</sub>C<sub>6</sub> (Tsuge, 2020). El principal cambio que ocurre después de la exposición del acero inoxidable es la aparición de susceptibilidad a la corrosión intergranular, vinculada a la modificación de la estructura del material y, en consecuencia, se estaría propiciando la generación de fallas inesperadas en los conductores y equipos que se encuentran en servicio (Sedriks & Zaroog, 2017).

De acuerdo con Amuda et al. (2016), en el acero inoxidable AISI 304 se presentan diferentes estados que están relacionados con el tiempo y la temperatura a los que el material ha sido sometido, a temperaturas próximas a los 500 °C, los carburos se manifiestan en el límite de grano como una lámina delgada y continua, es decir, en ese momento no existe corrosión intergranular, (Ver figura. 1).

**Figura 1 Microestructuras de acero inoxidable AISI 304. Sin corrosión intergranular.**



*Fuente: elaboración propia.*

Cuando el acero se encuentra en condiciones de funcionamiento con temperaturas cercanas a los 700 °C, los carburos toman formas dendríticas desarrolladas en la intersección de los límites del grano, desde donde comienzan su aglomeración; bajo esta morfología inicia la corrosión intergranular, (Ver Figura 2).


**Figura 2 Microestructuras de acero inoxidable AISI 304. Presencia de corrosión intergranular.**



*Fuente: elaboración propia.*

Con incrementos en el tiempo de trabajo y temperaturas cercanas a los 850 °C, la forma dendrítica fina del carburo de cromo se transforma gradualmente en una nucleación de tamaño considerable que se precipita hacia el límite del grano, dando paso a una condición comprometida para que el material continúe su operación, (Ver Figura. 3).

**Figura 3 Microestructuras de acero inoxidable AISI 304. Precipitación de carburos de cromo.**



*Fuente: elaboración propia.*

Se han realizado investigaciones donde se han demostrado las ventajas de sistemas inteligentes dentro del área metalográfica (Ferreira & Giraldi, 2017). Las redes neuronales artificiales han estado presentes en el área de los aceros inoxidables con la intención de resolver tareas de clasificación, reconocimiento y estimación. En la investigación desarrollada por Desu et al. (2015), se analizan los aceros inoxidables austeníticos 304L y 326L sometidos a altas temperaturas mediante el uso de RNA's entrenadas para

predecir diferentes propiedades mecánicas, como el alargamiento y el coeficiente de resistencia. El trabajo de Lakshmi et al. (2018), manifiesta la eficiencia de una red neuronal para estimar la tensión de flujo del acero inoxidable austenítico 304 durante su deformación por calor a partir de las variables: voltaje y temperatura. Mohamed et al. (2019) muestra el desarrollo de un sistema basado en una red neuronal artificial para detectar grietas en el acero y estimar su profundidad a partir de imágenes 2D. La localización de aberturas es necesaria para optimizar la calidad y minimizar gastos de inspección en superficies, impactando directamente el mantenimiento de infraestructuras.

De acuerdo con la revisión literaria realizada, la principal diferencia y contribución del artículo que se propone radica en el estudio de la corrosión intergranular bajo el enfoque de reconocimiento de patrones. La investigación muestra la construcción de un algoritmo enfocado en reconocer modelos de corrosión generados en el acero inoxidable a través de una red neuronal artificial (RNA) y el método de congruencia de fases encargado de ejecutar el procesamiento de la imagen. La metodología presentada posibilita tener al alcance un análisis relacionado directamente con la sugerencia de sustitución u operación de los dispositivos empleados en las plantas termoeléctricas que han sido fabricados de acero inoxidable AISI 304. Los resultados obtenidos demuestran la viabilidad para obtener la recomendación de uso para cada uno de los dispositivos, lo que trae como consecuencia, no incurrir en pérdidas de disponibilidad en equipos y demoras al proceso de generación de energía, lo que se traduce en mayor productividad.

Tras la sección de introducción, el artículo se estructura de esta forma: la sección 2 incluye una explicación de los procedimientos empleados para el tratamiento digital de imágenes, además de los datos producidos para entrenar y examinar la RNA. La sección 3 presenta los hallazgos de los experimentos. Las secciones 4 y 5, respectivamente, abordan la discusión y las conclusiones en relación con el método sugerido.

### 3. Método

La corrosión intergranular generada en el acero inoxidable tipo AISI 304 como secuela del trabajo en medios de alta temperatura se exterioriza en la microestructura del material de forma iterativa desde la iniciación hasta la finalización de su servicio operativo, de esta forma, se pueden identificar tres modelos distintos en la microestructura del material, (Ver Figura 1) sin corrosión intergranular (SCI), (Ver Figura 2) presencia de corrosión intergranular (PCI) y (Ver Figura 3) precipitación de carburos de cromo (PCC). La imagen metalográfica que contiene la microestructura del acero inoxidable es obtenida a partir de técnicas de microscopía óptica para su posterior procesamiento (Matyas et al., 2013). La reproducción de una microestructura se realiza a través de una sucesión de pasos normalizados (McArthur & Spalding, 2004). Se inicia con el corte del acero inoxidable para examinar una sección del material, la sección del acero inoxidable es colocada en una probeta que será lijada, y a la cual se aplicará una solución de Nital con una concentración de 4%. Como último paso, la probeta es colocada en un microscopio invertido para que un usuario logre visualizar la microestructura del material (Diamond, 2015).

El método para ejecutar la investigación planteada consta de dos etapas, la primera corresponde al tratamiento de la imagen y la segunda etapa corresponde al desarrollo de una RNA enfocada a la clasificación de las diferentes fases de corrosión presentes en la microestructura del acero inoxidable. Para llevar a cabo la primera etapa, se aplicó el método congruencia de fases.

El procesamiento digital de imágenes es la implementación de algoritmos informáticos con el fin de procesar, visualizar y optimizar la calidad de imágenes digitales. A partir del procesamiento, es posible extraer características importantes que describan la textura de una imagen (Burger & Burge, 2022). De acuerdo con Liu et al. (2014), la congruencia de fases en términos de la serie de Fourier efectúa una eficiente caracterización de las imágenes digitales por medio de la aplicación de diferentes filtros y se formula como en la ecuación 1.

$$PC(x) = \max_{\bar{\phi}(x) \in [0, 2\pi]} \frac{\sum_n A_n \cos(\phi_n(x) - \bar{\phi}(x))}{\sum_n A_n} \quad (1)$$

Donde:

- $A_n$  representa la amplitud.
- $n$  componente de Fourier.
- $\phi_n(x)$  es la fase local del componente de Fourier en una posición  $x$ .
- $\bar{\phi}(x)$  representa la amplitud promedio ponderada del ángulo de la fase local de todos los términos de Fourier.

Por otra parte, la función de energía local está definida en la ecuación 2:

$$E(x) = \sqrt{F(x)^2 + H(x)^2} \quad (2)$$

Se ha demostrado que emplear filtros logarítmicos de Gabor son sumamente útiles para la representación de imágenes. En el presente estudio, las funciones de filtros logarítmicos son empleadas utilizando una función de transferencia Gaussiana. Por lo tanto, el vector de respuesta para cada una de las parejas de filtros se determina a través de la ecuación 3.

$$[e_n(x), o_n(x)] = [I(x) * M_n^e, I(x) * M_n^o] \quad (3)$$

La transformada de la amplitud de onda a una escala dada para cada componente  $n$  se define a partir de la ecuación 4.

$$A_n(x) = \sqrt{e_n(x)^2 + o_n(x)^2} \quad (4)$$

Es de vital importancia considerar que la congruencia de fases se puede comprometer debido al ruido presente en la señal de entrada. Con la intención de disminuir los efectos se considera un factor de ruido  $T$ , expresado como se muestra en la ecuación (5).

$$T = \mu_R + k\sigma_R \quad (5)$$

Donde


- a.  $k$  es el número de desviaciones estándar en un rango de 2 a 3.
- b.  $\mu_R$  media de la distribución
- c.  $\sigma_R^2$  varianza de la distribución

Finalmente, la congruencia de fases se obtiene a partir de la ecuación (6).

$$PC(x) = \frac{|E(x) - T|}{\sum_n A_n(x) + \varepsilon} \quad (6)$$

El patrón metalográfico original, que subsiguientemente se establecerá en función de escala de grises y le será aplicado el filtro de la mediana se muestra en (Ver Figura 4(a)). Finalmente, es necesario un umbral para realizar la binarización del patrón metalográfico que se encuentra presente en la microestructura del acero inoxidable, (Ver Figura 4(b)).

Figura 4. Aplicación del método congruencia de fases. (a) Imagen original y (b) Umbralización.



Fuente: elaboración propia.

La congruencia de fases se aplica en cinco escalas a cada una de las seis orientaciones establecidas para el banco de filtros, lo que genera un vector de caracterización que contiene 30 componentes (Ver Tabla 1). Es necesario procesar digitalmente cada una de las imágenes metalográficas del acero inoxidable que contengan algún patrón representativo del daño generado en el material, con el propósito de almacenar los vectores y se conviertan en información de entrada a la red neuronal artificial.

**Tabla 1. Vectores generados a partir del método congruencia de fases.**

Componente	Patrón metalográfico presente en el acero inoxidable AISI 304.		
	SCI	PCI	PCC
1	6.0300	5.5823	1.7211
2	8.8148	9.8251	1.7571
3	8.6776	14.5955	3.2660
4	7.6662	14.0988	4.8691
5	6.3951	9.3328	7.3934
6	5.7221	5.7381	1.4638
7	8.3490	10.4227	2.2225
8	9.7173	15.0286	2.9717
9	8.2731	14.2035	5.4536
10	5.4300	9.1656	8.3809
11	6.7947	5.3662	1.5650
12	9.2929	10.3671	1.8682
13	9.2679	14.7681	3.5037
14	8.5413	14.1553	5.7727
15	6.0860	8.9967	7.8168
16	6.6713	5.2175	1.3221
17	9.2497	10.4453	2.1292
18	10.4381	14.3778	3.5200
19	8.2007	14.2971	5.9348
20	5.7418	9.8507	7.8561
21	6.3851	5.6280	0.9103
22	9.6704	10.3227	2.3300
23	10.1019	14.6871	2.8774
24	8.3516	14.3190	5.8238
25	6.0661	9.7006	7.5346
26	6.1350	5.4951	1.3761
27	9.0344	10.3248	2.1281
28	8.9569	14.8131	3.0669
29	7.6759	14.5777	5.5631
30	5.9755	10.0006	8.2290

*Fuente: elaboración propia.*

El cerebro humano tiene la capacidad de pensar e interpretar información para dar una solución eficiente a los problemas planteados. Los científicos han intentado modelar computacionalmente algunas cualidades relacionadas al funcionamiento del cerebro humano, el resultado han sido las RNA's. Las redes neuronales artificiales tienen en la actualidad una serie de rasgos propios del cerebro como, por ejemplo, que pueden generalizar, extraen características relevantes de series de datos y aprenden a partir de la experiencia (Thomas et al., 2019). Una red neuronal artificial se conforma por un conjunto de unidades denominadas neuronas, dichas neuronas se encuentran interconectadas y organizadas en grupos a los que se les refiere como capas. Al inicio se

Reconocimiento de patrones de corrosión en acero inoxidable mediante el método congruencia de fases

encuentra la capa de ingreso, consecutivamente se ubican las capas intermedias denominadas capas ocultas y finalmente se presenta a la capa de salida (Hassanien et al., 2022).

El algoritmo perceptrón multicapa, emplea un entrenamiento supervisado a partir de los vectores generados por los métodos de caracterización. Las muestras de imágenes con los aceros dañados se utilizan para adiestrar y validar la RNA con un total de 538 imágenes anticipadamente clasificadas, (Ver Tabla 2).

**Tabla 2. Matriz de adiestramiento y validación.**

	Adiestramiento.	Validación
Imágenes	240	90
Patrón metalográfico	Dimensión	
SCI	145 x 30	30 x 30
PCI	60 x 30	30 x 30
PCC	35 x 30	30 x 30

*Fuente: elaboración propia.*

Las arquitecturas de RNA construidas (Ver Tabla 3) se adaptan eficazmente a los 411 valores meta proporcionado durante la fase de adiestramiento. Es por ello, que se manejó el error cuadrático medio (MSE) para distinguir la RNA que será utilizada en la etapa de validación.

**Tabla 3. Topologías desarrolladas para la fase de adiestramiento.**

Topología	1	2	3	4
Conjunto de neuronas en la capa oculta	30	32	30	32
Proporción de aprendizaje	0.01	0.005	0.01	0.005
Error autorizado	1e-5	1e-5	1e-4	1e-5
Cantidad de iteraciones	1478	1897	1343	1526
MSE	0.091	0.106	0.095	0.088

*Fuente: elaboración propia.*

La topología de la RNA 4, presentó un mejor ajuste en la fase adiestramiento y por lo tanto es empleada en la fase de validación.

#### 4. Análisis y discusión de los resultados

Con la finalidad de comprobar el desempeño de la RNA, se evalúan 90 imágenes metalográficas no incluidas en el proceso de entrenamiento, (Ver Tabla 4). De acuerdo con (Woldaregay et al., 2019), la proporción de predicciones verdaderas y falsas propias de cada método de caracterización se determina mediante las medidas de desempeño: sensibilidad, especificidad y exactitud, ecuaciones 7 – 9 respectivamente.

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

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

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

Donde:

- *VP Verdadero positivo*
- *FP Falso positivo*
- *VN Verdadero Negativo*
- *FN Falso Negativo*

Los resultados relacionados al desempeño del método congruencia de fases aplicado para la caracterización de los tres tipos de modelos metalográficos generados en el acero inoxidable AISI 304, (Ver Tabla 4).

**Tabla 4. Indicadores de desempeño empleando el método Congruencia de Fases.**

	Sensibilidad	Especificidad	Exactitud
Sin corrosión intergranular (SCI)	0.82	0.83	0.92
Corrosión intergranular (PCI)	0.95	0.94	0.89
Precipitación de carburos de Cromo (PCC)	0.93	0.91	0.91

*Fuente: elaboración propia.*

El indicador de interés a maximizar es la exactitud, bajo la arquitectura de red neuronal artificial desarrollada el método congruencia de fases proporciona una media de 90% de exactitud en la tarea de clasificación de modelos de corrosión generados en los aceros inoxidables afectados.

El método de congruencia de fases empleado para caracterizar las imágenes metalográficas logra una precisión adecuada para la tarea de reconocimiento en un tiempo razonable, esto se debe a que proporciona un buen grado de detalle en la descripción de la microestructura del acero inoxidable, facilitando el trabajo de la RNA y dando paso al reconocimiento de la corrosión intergranular presente en el acero inoxidable AISI 304 mediante la integración de la RNA perceptrón multicapa y el procesamiento digital de imágenes metalográficas. En otros trabajos han empleado distintos métodos para la caracterización de la imagen, como estadísticos de la textura o momentos invariantes en conjunto con diferentes arquitecturas de algoritmos inteligentes (Thankachan et al., 2018) y (Filho et al., 2017), respectivamente; esto marca la pauta para continuar con el desarrollo de sistemas que permitan el análisis de materiales donde se alcanzan eficiencias similares al propuesto.

## 5. Conclusiones

Después del estudio de los resultados se determina que la topología de red neuronal artificial efectúa de forma eficientemente la clasificación de modelos de corrosión generados en el material AISI 304, tales como: sin corrosión intergranular, presencia de corrosión intergranular y precipitación de carburos de Cromo. Además, es posible afirmar que el método congruencia de fases caracteriza de forma eficiente las imágenes microestructurales del acero inoxidable. La metodología podría emplearse para el análisis de materiales que deban ser examinadas para verificar su estado sin la necesidad de expertos en el área, lo que permitirá una supervisión más cercana del material en operación. Como trabajo futuro se planea explorar el uso de redes neuronales probabilísticas y diferentes procesamientos de imágenes, tales como: momentos invariantes y texturas.

## 6. Referencias

- Amuda, M., Akinlabi, E., & Mridha, S. (2016). Ferritic Stainless Steels: Metallurgy, Application and Weldability. En Elsevier eBooks. <https://doi.org/10.1016/b978-0-12-803581-8.04010-8>
- Burger, W., & Burge, M. J. (2022c). Digital Image Processing. En Texts in computer science. <https://doi.org/10.1007/978-3-031-05744-1>
- Desu, R. K., Krishnamurthy, H. N., Balu, A., Gupta, A. K., & Singh, S. K. (2015). Mechanical properties of Austenitic Stainless Steel 304L and 316L at elevated temperatures. *Journal Of Materials Research and Technology*, 5(1), 13-20. <https://doi.org/10.1016/j.jmrt.2015.04.001>
- Diamond, D. (2015). Fundamental Materials Science. En *Elsevier eBooks*. <https://doi.org/10.1016/b978-0-12-803581-8.04105-9>
- Ferreira, A., & Giraldi, G. (2017). Convolutional Neural Network approaches to granite tiles classification. *Expert Systems with Applications*, 84, 1-11. <https://doi.org/10.1016/j.eswa.2017.04.053>
- Filho, P. P. R., Santos, J. C. D., Freitas, F. N. C., De Araújo Rodrigues, D., Ivo, R. F., Herculano, L. F. G., & De Abreu, H. F. G. (2017). New approach to evaluate a non-grain oriented electrical steel electromagnetic performance using photomicrographic analysis via digital image processing. *Journal Of Materials Research And Technology*, 8(1), 112-126. <https://doi.org/10.1016/j.jmrt.2017.09.007>
- Hassanien, A. E., Chatterjee, J. M., & Jain, V. (2022). Artificial Intelligence and Industry 4.0. Elsevier.
- Lakshmi, A. A., Rao, C. S., Srikanth, M., Faisal, K., Fayaz, K., Puspalatha, N., & Singh, S. K. (2018). Prediction of mechanical properties of ASS 304 in superplastic region using artificial neural networks. *Materials Today Proceedings*, 5(2), 3704-3712. <https://doi.org/10.1016/j.matpr.2017.11.622>

- Liu, D., Xu, Y., Quan, Y., & Callet, P. L. (2014). Reduced reference image quality assessment using regularity of phase congruency. *Signal Processing. Image Communication*, 29(8), 844-855. <https://doi.org/10.1016/j.image.2014.06.007>
- Matyas, J., Ohji, T., Liu, X., Paranthaman, M. P., Devanathan, R., Fox, K. M., Singh, M., & Wong-Ng, W. (2013). *Advances in Materials Science for Environmental and Energy Technologies II*. John Wiley & Sons.
- McArthur, H., & Spalding, D. (2004). *Engineering Materials Science: Properties, Uses, Degradation, Remediation*. ISBS.
- Mohamed, Y. S., Shehata, H. M., Abdellatif, M., & Awad, T. H. (2019). Steel crack depth estimation based on 2D images using artificial neural networks. *Alexandria Engineering Journal*, 58(4), 1167-1174. <https://doi.org/10.1016/j.aej.2019.10.001>
- Sedriks, A., & Zaroog, O. (2017). *Corrosion of Stainless Steels*. En Elsevier eBooks. <https://doi.org/10.1016/b978-0-12-803581-8.02893-9>
- Thankachan, T., Prakash, K. S., Malini, R., Ramu, S., Sundararaj, P., Rajandran, S., Rammasamy, D., & Jothi, S. (2018). Prediction of surface roughness and material removal rate in wire electrical discharge machining on aluminum-based alloys/composites using Taguchi coupled Grey Relational Analysis and Artificial Neural Networks. *Applied Surface Science*, 472, 22-35. <https://doi.org/10.1016/j.apsusc.2018.06.117>
- Thomas, J. J., Karagoz, P., Ahamed, B. B., & Vasant, P. (2019). *Deep Learning Techniques and Optimization Strategies in Big Data Analytics*. IGI Global.
- Tsuge, S. (2022). *Recent Advances in Stainless Steel*. En Elsevier eBooks (pp. 200-207). <https://doi.org/10.1016/b978-0-12-819726-4.00023-5>
- Woldaregay, A. Z., Årsand, E., Walderhaug, S., Albers, D., Mamykina, L., Botsis, T., & Hartvigsen, G. (2019). Data-driven modeling and prediction of blood glucose dynamics: Machine learning applications in type 1 diabetes. *Artificial Intelligence in Medicine*, 98, 109-134. <https://doi.org/10.1016/j.artmed.2019.07.007>