

Optimización Estructural y Proyección de Vida Útil a la Fatiga en Puentes de Celosía Soldados para Apilamiento de Mineral: Una Aproximación Integrando Redes Neuronales de Grafos y Mecánica Fractal

Structural Optimization and Fatigue Life Projection of Welded Truss Stacker Bridges for Mineral Stockpiling: An Integrated Approach Using Graph Neural Networks and Fractal Mechanics

Luis Rojas^{✉,1}, José García¹, Vanesa Bazan², Fabian León² and Yuniel Martínez¹

(1) Doctorado en Industria Inteligente, Facultad de Ingeniería, Pontificia Universidad Católica de Valparaíso, Valparaíso 2362804, Chile

(2) CONICET-IIM, Facultad de Ingeniería, Universidad Nacional de San Juan, San Juan, Argentina

*autor de correspondencia (luis.rojas.v@mail.pucv.cl)

Recibido 14/09/2025

Evaluado 28/01/2026

Aceptado 03/03/2026

<https://doi.org/10.65093/aci.v17.n1.2026.50>

RESUMEN

Se propone una metodología integrada de tres etapas para la evaluación predictiva y el mantenimiento proactivo de celosía soldados de tipo apilador (*stacker bridges*). Se ejecuta un análisis por elementos finitos (FEA) tridimensional que caracteriza los campos de desplazamiento y tensión de von Mises, identificando nodos críticos mediante un factor de escala cinemático de deformación de 908.2x. Se desarrolla un mapeo fractal de fisuras en el plano crítico, estimando la dimensión fractal D_f de las trayectorias de grieta mediante el método de *box-counting*, lo que permite cuantificar el potencial de propagación no lineal más allá de la mecánica de fractura elástica lineal (LEFM). Finalmente, se diseña y entrena una Red Neuronal de Grafos (GNN) que asimila la malla estructural como grafo $G = (V, E, \Phi)$, donde los nodos representan las uniones físicas y las aristas las vigas estructurales, permitiendo la predicción iterativa de probabilidades de falla nodal y la proyección de vida útil remanente (RUL). Los resultados revelan un Índice de Salud Estructural (SHI) del 52.9%, identifican el nodo 253 como el de mayor probabilidad de falla (57.7%) y proyectan un riesgo inminente de falla sistémica en el horizonte de 3 a 6 meses. Se formula un plan de intervención de 60 días que incluye reemplazo de riostras, tratamiento térmico post-soldadura (PWHT) controlado de 30 minutos, y ensayos no destructivos (END) con 100% de líquidos penetrantes, alcanzando un factor de mejora de vida a la fatiga de 4x respecto a la condición *as-welded*.

Palabras clave: red neuronal de grafos, mecánica fractal, fatiga estructural, puente móvil

ABSTRACT

An integrated three-stage methodology is proposed for the predictive assessment and proactive maintenance of stacker bridges. A three-dimensional finite element analysis (FEA) is performed to characterize the displacement and von Mises stress fields, identifying critical nodes using a kinematic deformation scale factor of 908.2x. A fractal mapping of cracks in the critical plane is developed, estimating the fractal dimension D_f of the crack trajectories using the box-counting method, which allows for the quantification of nonlinear propagation potential beyond linear elastic fracture mechanics (LEFM). Finally, a Graph Neural Network (GNN) is designed and trained that models the structural mesh as a graph $G = (V, E, \Phi)$, where the nodes represent the physical connections and the edges represent the structural beams, enabling the iterative prediction of nodal failure probabilities and the projection of remaining useful life (RUL). Results reveal a Structural Health Index (SHI) of 52.9%, identify node 253 as having the highest failure probability (57.7%), and project imminent systemic failure risk within a 3-6 month horizon. A 60-day intervention plan is formulated, including brace replacement, controlled 30-minute post-weld heat treatment (PWHT), and 100% liquid penetrant non-destructive examination (NDE), achieving a fatigue life improvement factor of 4x relative to the as-welded condition.

Keywords: graph neural network, fractal mechanics, structural fatigue, mobile bridge

INTRODUCCIÓN

La infraestructura de gran escala en minería comprende un conjunto de activos estructurales cuya operación continua bajo cargas cíclicas severas define el rendimiento productivo y la seguridad operacional de las faenas. Entre estos activos, los puentes de celosía soldados de tipo apilador (stacker bridges) —estructuras móviles de acero que soportan un tripper de distribución de mineral sobre su parte superior— constituyen componentes críticos en los circuitos de manejo de materiales (Rusiński *et al.*, 2010; Bošnjak *et al.*, 2011). Estas estructuras deben resistir simultáneamente cargas gravitacionales, dinámicas de traslación, esfuerzos de torsión generados por el desplazamiento del tripper, y solicitaciones cíclicas de fatiga derivadas de miles de ciclos operativos anuales (Arsić *et al.*, 2011; Bošnjak *et al.*, 2013).

La fatiga estructural en uniones soldadas representa la causa predominante de falla en estos equipos. La concentración de tensiones en el pie de soldadura (weld toe), combinada con tensiones residuales producto del proceso térmico de soldeo, genera condiciones favorables para la nucleación y propagación de fisuras (Fuštar *et al.*, 2018; Hobbacher, 2016). Los enfoques tradicionales de evaluación de fatiga, basados en la curva S-N y la ley de Paris (Paris & Erdogan, 1963; Basquin, 1910), proporcionan estimaciones útiles bajo hipótesis de mecánica de fractura elástica lineal (LEFM); sin embargo, la complejidad geométrica de las trayectorias de grieta en aceros sometidos a estrés minero exhibe un comportamiento intrínsecamente no lineal y autosimilar que excede las capacidades de estos modelos clásicos (Mandelbrot *et al.*, 1984; Carpinteri & Paggi, 2009).

En este contexto, la mecánica fractal ofrece un marco teórico para la descripción cuantitativa de la rugosidad superficial y la geometría irregular de las superficies de fractura. El concepto de dimensión fractal D_f , introducido en el análisis de fractura por Mandelbrot y otros (Mandelbrot *et al.*, 1984) y posteriormente formalizado por Bouchaud (Bouchaud, 1997) y Ponson y otros (Ponson *et al.*, 2006), permite caracterizar el potencial de propagación de grietas sin restringirse a la simplificación de la mecánica lineal elástica clásica. Trabajos recientes han demostrado la correlación entre la dimensión fractal y la tasa de crecimiento de grietas por fatiga (Hashmi *et al.*, 2022a; Hashmi *et al.*, 2022b), estableciendo un puente entre la geometría fractal y la ingeniería de confiabilidad.

Paralelamente, el advenimiento de las Redes Neuronales de Grafos (GNN, Graph Neural Networks) ha generado un cambio paradigmático en el modelado de sistemas estructurales complejos. A diferencia de las redes neuronales convencionales, las GNN operan nativamente sobre datos con topología de grafo $G = (V, E, \Phi)$, lo que las convierte en una arquitectura natural para representar mallas de elementos finitos donde los vértices corresponden a las uniones físicas de la estructura y las aristas a los elementos estructurales (Scarselli *et al.*, 2009; Kipf & Welling, 2017; Wu *et al.*, 2021). Desarrollos recientes han demostrado la eficacia de las GNN en la predicción de campos de deformación y tensión en estructuras de barras y marcos (Pfaff *et al.*, 2021; Li *et al.*, 2023a), en la reconstrucción de campos de tensión de alta fidelidad a partir de datos dispersos de sensores (Jiang *et al.*, 2025), y en la detección de daño estructural en puentes (Liu *et al.*, 2025; Wang *et al.*, 2026). La revisión exhaustiva de Chen y otros (Chen *et al.*, 2024; Rojas *et al.*, 2026) confirma el crecimiento exponencial de aplicaciones de GNN en dominios mecánicos, abarcando desde la simulación de dinámica de fluidos hasta la predicción de modos de falla dominante.

El monitoreo de salud estructural (SHM, Structural Health Monitoring) ha evolucionado significativamente con la integración de técnicas de aprendizaje profundo (Farrar & Worden, 2007; Li *et al.*, 2023b; Bao *et al.*, 2019). Las revisiones sistemáticas de Flah y otros (Flah *et al.*, 2021) y Serradilla y otros (Serradilla *et al.*, 2022) han documentado la transición del mantenimiento predictivo (PdM) desde enfoques reactivos hacia paradigmas proactivos e inteligentes, donde las arquitecturas de deep learning permiten la estimación de la vida útil remanente (RUL, Remaining Useful Life) y la optimización de estrategias de intervención (Carvalho *et al.*, 2019; Lei *et al.*, 2018; Theissler *et al.*, 2021; Garcia *et al.*, 2025).

No obstante, la literatura presenta una brecha significativa: la integración sistemática de simulación por elementos finitos, análisis fractal de fisuras y predicción basada en GNN para la evaluación de puentes de celosía soldados en minería. Los estudios existentes abordan estos enfoques de manera aislada, sin capitalizar la

sinergia entre la información topológica del grafo estructural, la caracterización fractal del daño y la capacidad predictiva de las arquitecturas de *message passing* (Gilmer *et al.*, 2017; Rojas *et al.*, 2025a; Tapia *et al.*, 2025).

El presente trabajo propone una metodología integrada de tres etapas —FEA tridimensional, mapeo fractal de fisuras y modelo predictivo GNN— para la evaluación de la confiabilidad y la proyección de vida útil a la fatiga de un puente de celosía soldado, móvil, de acero, que cumple la función de apilar mineral, sobre cuya parte superior se desplaza un tripper. Los resultados alimentan un panel de inteligencia de negocios (BI) que traduce las predicciones en un plan de intervención de ingeniería de turno de 60 días corridos, cuyo impacto se cuantifica en términos de mejora del Índice de Salud Estructural (SHI) y del factor multiplicador de vida a la fatiga. La contribución original radica en la convergencia de tres disciplinas —inteligencia artificial estructural, mecánica fractal y confiabilidad aplicada— bajo un marco unificado orientado a la infraestructura minera pesada.

MARCO TEÓRICO

Análisis de Elementos Finitos y Cinemática Estructural

El modelado numérico de la estructura se fundamenta en la teoría de elementos finitos (FEA), que discretiza el dominio continuo en un conjunto de elementos interconectados por nodos. Para una estructura de celosía, el campo de desplazamientos $\mathbf{u}$ se obtiene de la resolución del sistema matricial (Zienkiewicz *et al.*, 2013; Bathe, 2014):

$$\mathbf{K} \mathbf{u} = \mathbf{F} \quad (1)$$

donde $\mathbf{K} \in \mathbb{R}^{n \times n}$ es la matriz de rigidez global ensamblada, $\mathbf{u} \in \mathbb{R}^n$ es el vector de desplazamientos nodales y $\mathbf{F} \in \mathbb{R}^n$ es el vector de fuerzas externas. La transición del estado indeformado al deformado se visualiza mediante un factor de escala cinemático α_s , que permite amplificar los desplazamientos para su inspección visual:

$$\mathbf{x}_{\text{def}} = \mathbf{x}_0 + \alpha_s \mathbf{u} \quad (2)$$

donde $\mathbf{x}_0$ son las coordenadas nodales originales y $\alpha_s = 908.2$ es el factor de escala empleado en el presente estudio. El tensor de tensiones de Cauchy se evalúa en cada punto de Gauss, obteniéndose la tensión equivalente de von Mises como:

$$\sigma_{\text{VM}} = \sqrt{\frac{1}{2} [(\sigma_1 - \sigma_2)^2 + (\sigma_2 - \sigma_3)^2 + (\sigma_3 - \sigma_1)^2]} \quad (3)$$

donde $\sigma_1, \sigma_2, \sigma_3$ son las tensiones principales.

Mecánica de Fractura y Modelado Fractal de Fisuras

La propagación de fisuras por fatiga se describe clásicamente mediante la ley de Paris-Erdogan (Paris & Erdogan, 1963; Anderson, 2017):

$$\frac{da}{dN} = C (\Delta K)^m \quad (4)$$

donde a es la longitud de la grieta, N es el número de ciclos, $\Delta K = K_{\text{max}} - K_{\text{min}}$ es el rango del factor de intensidad de tensiones (SIF), y C, m son constantes del material. El SIF para una grieta de longitud a en un campo de tensión σ se expresa como (Irwin, 1957):

$$K = Y(a) \sigma \sqrt{\pi a} \quad (5)$$

donde $Y(a)$ es el factor de corrección geométrica.

Sin embargo, las trayectorias reales de las grietas en estructuras soldadas exhiben rugosidad y ramificación que no son capturadas por la LEFM. La geometría fractal proporciona un marco adecuado para su descripción. La longitud efectiva de una grieta fractal se escala como (Mandelbrot, 1982; Mandelbrot *et al.*, 1984):

$$L(\epsilon) = L_0 \epsilon^{1-D_f} \quad (6)$$

donde ϵ es la escala de medición, L_0 es una constante prefactor y $D_f \in [1, 2]$ es la dimensión fractal de la trayectoria de la grieta. El método de *box-counting* estima D_f mediante la relación (Hashmi *et al.*, 2022b):

$$D_f = - \lim_{\epsilon \rightarrow 0} \frac{\ln N(\epsilon)}{\ln \epsilon} \quad (7)$$

donde $N(\epsilon)$ es el número de cajas de tamaño ϵ necesarias para cubrir la trayectoria de la grieta. Carpinteri y Paggi (Carpinteri & Paggi, 2009), demostraron que la dimensión fractal permite formular una ley de fatiga fractal unificada que incorpora la anomalía del escalamiento en los umbrales de propagación.

La integral J de Rice (Rice, 1968) proporciona un parámetro energético independiente del camino para la caracterización de la propagación:

$$J = \int_{\Gamma} \left(W dy - \mathbf{T} \cdot \frac{\partial \mathbf{u}}{\partial x} ds \right) \quad (8)$$

donde W es la densidad de energía de deformación, $\mathbf{T}$ es el vector de tracción, Γ es un contorno arbitrario alrededor de la punta de la grieta y ds es el diferencial de arco.

Redes Neuronales de Grafos (GNN)

Una GNN opera sobre un grafo $G = (V, E, \Phi)$, donde V es el conjunto de nodos, E es el conjunto de aristas y Φ define los mapeos de atributos asociados (Scarselli *et al.*, 2009). El mecanismo fundamental de las GNN es el paradigma de **paso de mensajes** (*message passing*), el cual refina iterativamente las *representaciones latentes* de los nodos mediante la *agregación de estados de su vecindad local* (Gilmer *et al.*, 2017):

$$\mathbf{h}_v^{(t+1)} = \phi \left(\mathbf{h}_v^{(t)}, \bigoplus_{u \in \mathcal{N}(v)} \psi \left(\mathbf{h}_v^{(t)}, \mathbf{h}_u^{(t)}, \mathbf{e}_{vu} \right) \right) \quad (9)$$

donde $\mathbf{h}_v^{(t)}$ es el *embedding* del nodo v en la iteración t , $\mathcal{N}(v)$ es el vecindario de v , $\mathbf{e}_{vu}$ son los atributos de la arista (v, u) , ϕ es la función de mensaje, L es un operador de agregación permutación-invariante (suma, media o máximo) y ϕ es la función de actualización (Veličković *et al.*, 2018; Rojas *et al.*, 2026).

En la formulación de convolución espectral de grafos (GCN), la actualización se expresa como (Kipf & Welling, 2017):

$$\mathbf{H}^{(l+1)} = \sigma \left(\tilde{\mathbf{D}}^{-1/2} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-1/2} \mathbf{H}^{(l)} \mathbf{W}^{(l)} \right) \quad (10)$$

donde $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}_N$ es la matriz de adyacencia con auto-conexiones, $\tilde{\mathbf{D}}$ es la matriz de grado correspondiente, $\mathbf{W}^{(l)}$ es la matriz de pesos aprendible de la capa l y σ es una función de activación no lineal.

Para la estructura del puente apilador, la malla de FEA se mapea naturalmente al grafo: cada nodo estructural se convierte en un vértice con atributos $x_v = [\sigma_{VM}, \epsilon_v, T, D_{f,v}]$ (tensión de von Mises, deformación, temperatura,

dimensión fractal local), y cada elemento barra se convierte en una arista con atributos $evu = [d_{vu}, K_{vu}, \theta_{vu}]$ (distancia, rigidez relativa, ángulo).

Ingeniería de Confiabilidad y Fatiga Termomecánica

La confiabilidad estructural se cuantifica mediante el *Índice de Salud Estructural* (SHI), definido como:

$$SHI = 1 - \frac{1}{|V|} \sum_{v \in V} P_{\text{falla}}(v) \quad (11)$$

donde $P_{\text{falla}}(v)$ es la probabilidad de

$$R(t) = \frac{R_{\max}}{1 + \exp(-\lambda(t - t_0))} \quad (12)$$

donde $R_{\max}$ es el riesgo asintótico, λ es la tasa de crecimiento y t_0 es el punto de inflexión temporal.

El tratamiento térmico post-soldadura (PWHT) reduce las tensiones residuales σ_{res} según la ley de relajación (Withers, 2007; James *et al.*, 2007):

$$\sigma_{\text{res}}(t) = \sigma_0 \exp\left(-\frac{t}{\tau(T)}\right) \quad (13)$$

donde $\tau(T)$ es el tiempo de relajación dependiente de la temperatura T , y σ_0 es la tensión residual inicial. La regla de acumulación de daño de Miner (Miner, 1945; Rojas *et al.*, 2025b) establece la falla cuando:

$$D = \sum_{i=1}^k \frac{n_i}{N_{f,i}} = 1 \quad (14)$$

donde n_i es el número de ciclos aplicados al nivel de tensión i y $N_{f,i}$ es la vida a fatiga correspondiente.

METODOLOGÍA

La metodología integrada comprende tres etapas secuenciales que alimentan un cuadro de mando (*dashboard*) de inteligencia de negocios (BI) para la toma de decisiones en ingeniería de turno. La Fig. 1 presenta el flujo completo.

Etapas 1: Simulación Estructural por Elementos Finitos

Se desarrolló un modelo FEA tridimensional del puente de celosía soldado, incluyendo la superestructura de celosía, los cordones superior e inferior, las riostras diagonales y las conexiones de semisecciones. El modelo incorpora:

- **Material:** Acero estructural ASTM A36 / A572 Gr.50, con $E = 200$ GPa, $\nu = 0.3$, $\sigma_y = 345$ MPa.
- **Elementos:** Barras tipo *beam* (2 nodos, 6 GDL/nodo) para los cordones y riostras; elementos *shell* (4 nodos) para las planchas de conexión.
- **Cargas:** Peso propio ($g = 9.81$ m/s²), carga viva del *tripper* ($FT = 450$ kN), cargas dinámicas por traslación ($\mu = 1.15$ factor de impacto).
- **Condiciones de borde:** Apoyos sobre orugas con restricción de traslación vertical y lateral; libertad de movimiento longitudinal.




Fig. 1: Metodología integrada de tres etapas: (1) Simulación FEA 3D, (2) Mapeo fractal de fisuras, (3) Modelo predictivo GNN. Las salidas convergen en un panel BI que sustenta el plan de intervención de ingeniería de turno.




Fig. 2: Simulación FEA del puente de celosía soldado: (a) Estructura indeformada; (b) Deformada con mapa de tensión de von Mises (factor de escala 908.2x). Los nodos críticos se concentran en las zonas de unión de semisecciones y riostras inferiores.

La resolución del sistema (Ec. 1), que se muestra en la Fig. 2, entrega los campos de desplazamiento y tensión en los $n = 300$ nodos del modelo. La visualización de la deformada emplea el factor de escala $\alpha_s = 908.2$ (Ec. 2) para amplificar los desplazamientos a escala visible, manteniendo la proporcionalidad cinemática.

Etapa 2: Mapeo Fractal de Fisuras

A partir de la inspección visual y los ensayos no destructivos (END) realizados *in situ*, se construyó un mapa topológico de las fisuras detectadas en el plano crítico de la estructura (zona de unión de semisecciones y celosía sobre orugas). Para cada trayectoria de grieta, se estimó la dimensión fractal D_f mediante el método de *box-counting* (Ec. 7).

El procedimiento incluye:

- **Digitalización:** Las fotografías de las fisuras se procesaron con filtros de detección de bordes (Canny) para extraer los perfiles de grieta.
- **Box-counting:** Se superpuso una grilla de cajas de tamaño ϵ decreciente ($\epsilon \in [0.05, 2.0]$ m) y se contó el número $N(\epsilon)$ de cajas que intersectan la trayectoria.
- **Regresión log-log:** La pendiente de $\ln N(\epsilon)$ vs. $\ln(1/\epsilon)$ proporciona la estimación de D_f .

Los valores de D_f obtenidos se incorporan como atributos nodales en el grafo estructural de la GNN, enriqueciendo la representación con información del estado de daño real como lo muestra la Fig. 3.




Fig. 3: Mapeo fractal de fisuras: (a) Mapa de grietas ramificadas en el plano crítico, con orígenes de nucleación marcados (puntos rojos). La coloración indica la profundidad de ramificación fractal. (b) Estimación de D_f mediante *box-counting*: la regresión log-log arroja $D_f = 1.73$, indicando un patrón de propagación altamente ramificado.

Etapa 3: Modelo Predictivo GNN

Construcción del grafo. La malla de FEA se transforma en un grafo $G = (V, E, \Phi)$:

- $|V| = 300$ nodos (uniones estructurales).
- $|E| = 520$ aristas (elementos barra y conexiones).
- Atributos nodales: $\mathbf{x}_v = [\sigma_{VM,v}, \epsilon_v, T_v, D_{f,v}] \in \mathbb{R}^4$.
- Atributos de arista: $\mathbf{e}_{vu} = [d_{vu}, K_{vu}, \theta_{vu}] \in \mathbb{R}^3$.

Arquitectura. El modelo emplea una arquitectura *encoder-processor-decoder* inspirada en (Jiang *et al.*, 2025, Pfaff *et al.*, 2021):

- **Encoder:** Proyección de atributos a un espacio latente de dimensión $d = 64$ mediante MLPs.
- **Processor:** $T = 6$ capas de *message passing* (Ec. 9) con funciones de activación ReLU y normalización por capas.

- **Decoder:** MLP de salida que predice $P_{\text{falla}}(v) \in [0, 1]$ y $\text{RUL}_v \in \mathbb{R}^+$ para cada nodo.
- **Módulo temporal:** Integración con LSTM (Hochreiter & Schmidhuber, 1997) para capturar la evolución temporal del riesgo.

Entrenamiento: El modelo de la Fig. 4, se entrenó con datos históricos de inspecciones, registros de reparaciones y mediciones de tensión *in situ* de 5 puentes apiladores similares, totalizando 12,000 muestras nodo-tiempo. La función de pérdida combina error cuadrático medio (MSE) para RUL y entropía cruzada binaria (BCE) para la clasificación de riesgo:

$$\mathcal{L} = \alpha \text{MSE}(\hat{y}_{\text{RUL}}, y_{\text{RUL}}) + (1 - \alpha) \text{BCE}(\hat{p}_{\text{falla}}, p_{\text{falla}}) \quad (15)$$

con $\alpha = 0.6$, optimizador Adam ($\eta = 10^{-3}$), 200 épocas con *early stopping*.




Fig. 4: Arquitectura de la GNN propuesta: la malla FEA se mapea al grafo $G = (V, E, \Phi)$; el mecanismo de *message passing* (Ec. 9) propaga información topológica para la predicción de probabilidades de falla y RUL a nivel nodal.

RESULTADOS Y DISCUSIÓN

Identificación de Nodos Críticos (Etapa 1)

El análisis FEA revela una distribución de tensiones de von Mises con máximos localizados en las zonas de unión de semisecciones y en las conexiones de riostras inferiores de la celosía sobre orugas (Fig. 2). La Tabla 1 resume los 10 nodos con mayor concentración de tensión.

La correlación entre la tensión de von Mises y la dimensión fractal local confirma la hipótesis de que los nodos con mayor concentración de esfuerzos exhiben trayectorias de grieta más ramificadas ($D_f > 1.5$), consistente con los hallazgos de Bouchaud (Bouchaud, 1997) sobre la universalidad de la rugosidad fractal en superficies de fractura.

La correlación entre la tensión de von Mises y la dimensión fractal local confirma la hipótesis de que los nodos con mayor concentración de esfuerzos exhiben trayectorias de grieta más ramificadas ($D_f > 1.5$), consistente con los hallazgos de Bouchaud (Bouchaud, 1997) sobre la universalidad de la rugosidad fractal en superficies de fractura.

Tabla 1: Nodos críticos identificados por el análisis FEA y la GNN: tensión de von Mises, dimensión fractal local y probabilidad de falla predicha.

Nodo	σ_{VM} [MPa]	D_f (local)	P_{falla} [%]
Nodo 253	312.4	1.73	57.7
Nodo 23	287.1	1.68	50.5
Nodo 24	281.9	1.65	50.0
Nodo 264	274.3	1.61	49.2
Nodo 28	270.5	1.59	48.8
Nodo 256	269.8	1.58	48.7
Nodo 8	266.2	1.55	48.6
Nodo 257	263.7	1.53	48.4
Nodo 4	261.0	1.51	48.2
Nodo 216	259.8	1.49	48.1

Análisis de Propagación Fractal (Etapa 2)

El mapeo fractal (Fig. 3) revela seis focos principales de nucleación de fisuras, todos localizados en zonas de alta concentración de tensiones residuales (pie de soldadura). La dimensión fractal global del patrón de grietas es $D_f = 1.73 \pm 0.04$, significativamente superior al valor teórico de una grieta recta ($D_f = 1.0$) y cercano al exponente universal de rugosidad reportado por Ponson y otros (Ponson *et al.*, 2006) para metales ($D_f \approx 1.7-1.8$).




Fig. 5: Caracterización de la propagación por fatiga: (a) Curva de Paris (da/dN vs. ΔK) con datos experimentales y ajuste analítico ($C = 6 \times 10^{-12}$, $m = 3.0$). (b) Evolución de la dimensión fractal D_f con la longitud de grieta, mostrando convergencia al valor crítico $D_f^{crit} = 1.35$ que precede la falla inestable.

La evolución de D_f con la longitud de la grieta (Fig. 5b) muestra un comportamiento asintótico que converge hacia $D_f^{crit} \approx 1.35$, valor que se propone como umbral de transición entre la propagación estable (Región II de Paris) y la fractura inestable (Región III). Este resultado es consistente con los estudios de Carpinteri y Paggi (Carpinteri & Paggi, 2009) sobre la anomalía del escalamiento fractal en fatiga.

Proyección de Vida Útil (Etapa 3: GNN)

La GNN entrenada alcanza un MSE de validación de 0.035 y una exactitud de clasificación del 91.0% en la categorización de riesgo (bajo/medio/alto), como se muestra en la Fig. 6.




Fig. 6: Evaluación del modelo GNN: (a) Convergencia del entrenamiento (pérdida MSE en escala logarítmica). (b) Matriz de confusión para la clasificación de riesgo nodal, con exactitud global del 91.0%.

Los resultados integrados se presentan en el panel BI de mantenimiento predictivo (Fig. 7), que sintetiza:

- *SHI global*: 52.9%, ubicado en zona crítica (< 50%: riesgo inaceptable; 50-80%: zona de advertencia).
- *Ranking de nodos*: El nodo 253 presenta la mayor probabilidad de falla (57.7%), seguido por los nodos 23 y 24 de la zona de semisecciones.
- *Curva de riesgo GNN*: Proyección de riesgo sistémico que alcanza el umbral de falla inminente en el horizonte de 3 a 6 meses de operación continuada.




Fig. 7: Panel BI predictivo: (a) Proyección GNN de vida útil a la fatiga con zona crítica (3-6 meses) sombreada. (b) *Ranking* de los 10 nodos con mayor probabilidad de falla, con el nodo 253 como punto más vulnerable (57.7%).

Análisis de Confiabilidad y Diagnóstico Integral

La convergencia de los tres enfoques permite formular el siguiente diagnóstico como lo muestra la Fig.8: El análisis FEA identifica la concentración de tensiones en las uniones de semisecciones como la causa primaria de nucleación de fisuras. El mapeo fractal confirma que las trayectorias de grieta son altamente ramificadas ($D_f = 1.73$), lo que indica un campo de tensiones complejo con múltiples planos de deslizamiento activos. La GNN cuantifica la

probabilidad de falla nodal y proyecta un horizonte de riesgo que coincide con la estimación clásica basada en la regla de Miner (Ec. 14), validando la consistencia del modelo híbrido.




Fig. 8: Evaluación de confiabilidad: (a) Indicador *gauge* del SHI (52.9%, zona de advertencia). (b) Curvas S-N comparativas: condición *as-welded* vs. post-intervención, mostrando el incremento del límite de resistencia a la fatiga.

PLAN DE INTERVENCIÓN

A partir de los resultados predictivos, se formula un plan de intervención de 60 días corridos, cuyas directrices operativas se resumen en la Tabla 2 y los Protocolos de control de calidad post-soldadura están en la Fig. 9

Tabla 2: Plan de intervención de ingeniería de turno: directrices operativas para la recuperación estructural del puente apilador.

Elemento de Control	Directriz Operativa
Plazo de Ejecución	60 días corridos.
Control de Torsión	Reemplazo de riostras inferiores de la celosía sobre orugas y refuerzo en unión de semisecciones.
Vida Útil a la Fatiga	Objetivo modificado: factor de mejora de 0.5 a 2.0 (4× respecto a condición <i>as-welded</i>).
Tratamiento Post-Soldadura	PWHT controlado por 30 minutos para alivio de tensiones residuales (Ec. 13).
Control de Calidad (WPS)	100% líquidos penetrantes (LP) en todas las uniones intervenidas. Reforzamiento y reparación protocolizada de fisuras según norma AWS D1.1.
Garantía Técnica	Mejora certificada de la performance de la celosía ante las variables que afectan la estructura (cargas cíclicas, torsión, fatiga termomecánica).

El impacto proyectado del plan de intervención se cuantifica en la Fig. 10, donde se observa:

- *Recuperación del SHI*: De 52.9% (estado actual) a un objetivo de 85% al completar las 60 jornadas.
- *Factor de mejora de vida a la fatiga*: La combinación de reemplazo de riostras, PWHT y END alcanza un factor multiplicador de 4.0x, lo que extiende la vida útil remanente proporcionalmente.




Fig. 9: Protocolo de control de calidad post-soldadura: flujo de trabajo que integra inspección pre-soldadura, ejecución WPS, PWHT controlado, ensayos no destructivos (100% LP) y certificación final con reevaluación del SHI.




Fig. 10: Impacto de la intervención estructurada: (a) Evolución del SHI durante el plan de 60 días, comparando Los escenarios con y sin intervención. (b) Factor multiplicador de vida a la fatiga por tipo de intervención, alcanzando un 4.0x acumulado.

CONCLUSIONES

El presente trabajo ha demostrado la viabilidad y eficacia de un enfoque integrado que combina análisis por elementos finitos, mecánica fractal y redes neuronales de grafos para la evaluación predictiva de la integridad estructural de puentes de celosía soldados empleados como apiladores de mineral en la industria minera.

Las principales contribuciones y hallazgos se sintetizan a continuación:

1. Convergencia metodológica. La integración de FEA, mapeo fractal y GNN constituye una aproximación original que supera las limitaciones de los enfoques aislados. La malla de elementos finitos se mapea naturalmente al grafo de la GNN, enriquecida con la dimensión fractal como descriptor del estado de daño, generando un marco unificado para la predicción de falla.
2. Validación del modelo GNN. El modelo predictivo alcanza una exactitud de clasificación del 91.0% y un MSE de validación de 0.035, demostrando la capacidad de las GNN para capturar las dependencias topológicas del riesgo en estructuras de celosía. El mecanismo de *message passing* permite la propagación de información de riesgo entre nodos vecinos, replicando el fenómeno físico de redistribución de tensiones.
3. Diagnóstico estructural. Se identifica un SHI global del 52.9%, con el nodo 253 como punto de mayor vulnerabilidad (57.7% de probabilidad de falla). La dimensión fractal $D_f = 1.73$ del patrón de grietas confirma un campo de tensiones altamente complejo, consistente con la rugosidad fractal universal reportada en la literatura para metales.
4. Horizonte de riesgo. La curva de riesgo GNN proyecta falla sistémica inminente en el horizonte de 3 a 6 meses de operación continuada sin intervención, lo que sustenta la urgencia del plan de mantenimiento propuesto.
5. Plan de intervención cuantificado. El protocolo de 60 días corridos, que integra reemplazo de riostras, PWHT controlado de 30 min y END con 100% de LP, alcanza un factor de mejora de vida a la fatiga de 4x, recuperando el SHI hasta un objetivo del 85%.

A futuro se deben explorar otras líneas de investigación, tales como: (a) la incorporación de redes neuronales informadas por la física (PINNs) (Raissi *et al.*, 2019; Karniadakis *et al.*, 2021) para imponer restricciones de equilibrio y compatibilidad directamente en la función de pérdida de la GNN; (b) la extensión del marco hacia un gemelo digital (*digital twin*) (Tao *et al.*, 2019; Grieves & Vickers, 2017; Martínez *et al.*, 2024; Martínez *et al.*, 2025) con actualización en tiempo real a partir de sensores IoT instalados en la estructura; y (c) la validación del modelo en una flota ampliada de equipos de apilamiento para evaluar su transferibilidad entre geometrías similares.

ABREVIACIONES

Tabla 3: Abreviaciones clave utilizadas en el documento.

Abreviación	Significado
FEA	Análisis de Elementos Finitos (<i>Finite Element Analysis</i>)
GNN	Red Neuronal de Grafos (<i>Graph Neural Network</i>)
SHI	Índice de Salud Estructural (<i>Structural Health Index</i>)
SHM	Monitoreo de Salud Estructural (<i>Structural Health Monitoring</i>)
RUL	Vida Útil Remanente (<i>Remaining Useful Life</i>)
LEFM	Mecánica de Fractura Elástica Lineal (<i>Linear Elastic Fracture Mechanics</i>)
SIF	Factor de Intensidad de Tensiones (<i>Stress Intensity Factor</i>)
PWHT	Tratamiento Térmico Post-Soldadura (<i>Post-Weld Heat Treatment</i>)
END	Ensayos No Destructivos (<i>Non-Destructive Examination</i>)
LP	Líquidos Penetrantes (<i>Liquid Penetrant</i>)
BI	Inteligencia de Negocios (<i>Business Intelligence</i>)
PdM	Mantenimiento Predictivo (<i>Predictive Maintenance</i>)
WPS	Especificación del Procedimiento de Soldadura (<i>Welding Procedure Specification</i>)

AGRADECIMIENTOS

A la Pontificia Universidad Católica de Valparaíso (PUCV), en especial al programa de Doctorado en Industria Inteligente de la Escuela de Construcción y Transporte, por el soporte académico e institucional. Asimismo, se agradece el patrocinio técnico, monetario y la provisión de parámetros de campo suministrados por la compañía GMT Group, cuya colaboración fue determinante para la validación industrial de los modelos propuestos.

REFERENCIAS

- Anderson, T.L. (2017). *Fracture Mechanics: Fundamentals and Applications*. CRC Press, 4th edition. <https://doi.org/10.1201/9781315370293>
- Arsić, M., Bošnjak, S., Zrnić, N., Sedmak, A. & Gnjatović, N. (2011). Bucket wheel failure caused by residual stresses in welded joints. *Engineering Failure Analysis*, 18 (2), 700-712. <https://doi.org/10.1016/j.engfailanal.2010.11.009>
- Bao, Y., Chen, Z., Wei, S., Xu, Y., Tang, Z. & Li, H. (2019). The state of the art of data science and engineering in structural health monitoring. *Engineering*, 5 (2), 234-242. <https://doi.org/10.1016/j.eng.2018.11.027>
- Basquin, O.H. (1910). The exponential law of endurance tests. *Proceedings of the American Society for Testing and Materials*, 10, 625-630.
- Bathe, K.-J. (2014). *Finite Element Procedures*. K.J. Bathe, 2nd edition.
- Bošnjak, S.M., Arsić, M.A., Zrnić, N.D., Odanović, Z.D. & Dordević, M.D. (2011). Failure analysis of the stacker crawler chain link. *Procedia Engineering*, 10, 2244-2249. <https://doi.org/10.1016/j.proeng.2011.04.371>
- Bošnjak, S.M., Petković, Z.D., Zrnić, N.D., Simić, G. & Simonović, A. (2013). Cracks, repair and reconstruction of bucket wheel excavator slewing platform. *Engineering Failure Analysis*, 35, 708-718. <https://doi.org/10.1016/j.engfailanal.2012.12.007>
- Bouchaud, E. (1997). Scaling properties of cracks. *Journal of Physics: Condensed Matter*, 9, 4319-4344. <https://doi.org/10.1088/0953-8984/9/21/002>
- Carpinteri, A. & Paggi, M. (2009). A unified fractal approach for the interpretation of the anomalous scaling laws in fatigue and comparison with existing models. *International Journal of Fracture*, 154, 67-79.
- Carvalho, T.P., Soares, F.A.A.M.N., Vita, R., Francisco, R., Basto, J.P. & Alcalá, S.G.S. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137, 106024. <https://doi.org/10.1016/j.cie.2019.106024>
- Chen, Z., Lai, J., Liu, J., Li, R. & Ji, G. (2024). A review of graph neural network applications in mechanics-related domains. *Artificial Intelligence Review*, 57, 274. <https://doi.org/10.5772/intechopen.107726>
- Farrar, C.R. & Worden, K. (2007). An introduction to structural health monitoring. *Philosophical Transactions of the Royal Society A*, 365, 303-315. <https://doi.org/10.1098/rsta.2006.1928>
- Flah, M., Nunez, I., Ben Chaabene, W. & Nehdi, M.L. (2021). Machine learning algorithms in civil structural health monitoring: a systematic review. *Archives of Computational Methods in Engineering*, 28, 2621-2643. <https://doi.org/10.1007/s11831-020-09471-9>
- Fuštar, B., Lukačević, I. & Androic, B. (2018). Review of fatigue assessment methods for welded steel structures. *Advances in Civil Engineering*, 2018, 3597356. <https://doi.org/10.1155/2018/3597356>
- Garcia, J., Rios-Colque, L., Peña, A. & Rojas, L. (2025). Condition monitoring and predictive maintenance in industrial equipment: An nlp-assisted review of signal processing, hybrid models, and implementation challenges. *Applied Sciences*, 15 (10), 5465. <https://doi.org/10.3390/app15105465>
- Gilmer, J., Schoenholz, S.S., Riley, P.F., Vinyals, O. & Dahl, G.E. (2017). *Neural message passing for quantum chemistry*. Proceedings of the 34th International Conference on Machine Learning, pages 1263-1272.
- Grieves, M. & Vickers, J. (2017). Digital twin: Mitigating unpredictable, undesirable emergent behavior in complex systems. *Transdisciplinary Perspectives on Complex Systems*, pages 85-113. https://doi.org/10.1007/978-3-319-38756-7_4

- Hashmi, M., Koloor, S.R., Abdul Hamid, M.F. & Tamin, N. (2022a). Exploiting fractal features to determine fatigue crack growth rates of metallic materials. *Engineering Fracture Mechanics*, 270, 108579. <https://doi.org/10.1016/j.engfracmech.2022.108589>
- Hashmi, M., Koloor, S.R., Abdul Hamid, M.F. & Tamin, N. (2022b). Fractal analysis for fatigue crack growth rate response of engineering structures with complex geometry. *Fractal and Fractional*, 6 (11), 635. <https://doi.org/10.3390/fractalfract6110635>
- Hobbacher, A.F. (2016). Recommendations for fatigue design of welded joints and components. *IIW Document IIW-2259-15*. <https://doi.org/10.1007/978-3-319-23757-2>
- Hochreiter, S. & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9 (8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Irwin, G.R. (1957). Analysis of stresses and strains near the end of a crack traversing a plate. *Journal of Applied Mechanics*, 24, 361-364. <https://doi.org/10.1115/1.4011547>
- James, M.N., Hughes, D.J., Chen, Z., Lombard, H., Hattingh, D. G., Asquith, D., *et al.* (2007). Residual stresses and fatigue performance. *Engineering Failure Analysis*, 14 (2), 384-395. <https://doi.org/10.1016/j.engfailanal.2006.02.011>
- Jiang, C., El Moctar, O. & Ren, H. (2025). G-Twin: Graph neural network-based digital twin for real-time and high-fidelity structural health monitoring for offshore wind turbines. *Reliability Engineering & System Safety*, 254, 110620. <https://doi.org/10.1016/j.marstruc.2025.103813>
- Karniadakis, G.E., Kevrekidis, I.G., Lu, L., Perdikaris, P., Wang, S. & Yang, L. (2021). Physics-informed machine learning. *Nature Reviews Physics*, 3, 422-440. <https://doi.org/10.1038/s42254-021-00314-5>
- Kipf, T.N. & Welling, M. (2017). Semi-supervised classification with graph convolutional networks. *arXiv preprint arXiv:1609.02907*.
- Lei, Y., Li, N., Guo, L., Li, N., Yan, T. & Lin, J. (2018). Machinery health prognostics: A systematic review from data acquisition to RUL prediction. *Mechanical Systems and Signal Processing*, 104, 799-834. <https://doi.org/10.1016/j.ymssp.2017.11.016>
- Li, Q., Wang, Z., Li, L., Hao, H., Chen, W. & Shao, Y. (2023a). Machine learning prediction of structural dynamic responses using graph neural networks. *Computers & Structures*, 289, 107188. <https://doi.org/10.1016/j.compstruc.2023.107188>
- Li, Y., Dong, L. & Chen, Z. (2023b). Deep learning for structural health monitoring: data, algorithms, applications, challenges, and trends. *Sensors*, 23 (21), 8824. <https://doi.org/10.3390/s23218824>
- Liu, Y., Zhang, L., Xin, J. & Peng, S. (2025). TPS-GNN: Predictive model for bridge health monitoring data based on temporal periodicity and global spatial distribution characteristics. *Structural Health Monitoring*. <https://doi.org/10.3390/books978-3-7258-3706-9>
- Mandelbrot, B.B. (1982). *The Fractal Geometry of Nature*. W.H. Freeman.
- Mandelbrot, B.B., Passoja, D.E. & Paullay, A.J. (1984). Fractal character of fracture surfaces of metals. *Nature*, 308, 721-722. <https://doi.org/10.1038/308721a0>
- Martinez, Y., Rojas, L., Peña, A., Valenzuela, M. & Garcia, J. (2025). Physics-informed neural networks for the structural analysis and monitoring of railway bridges: A systematic review. *Mathematics*, 13 (10), 1571. <https://doi.org/10.3390/math13101571>

- Martínez, Y., Rojas, L., Peña, A., Valenzuela, M., Hernández, B. & García, J. (2024). Pinns fraccionarias: Nuevos horizontes para la memoria prolongada en modelos continuos. *Avances en Ciencias e Ingeniería*, 15 (3), 93-110. <https://doi.org/10.65093/aci.v15.n3.2024.10>
- Miner, M.A. (1945). Cumulative damage in fatigue. *Journal of Applied Mechanics*, 12, A159-A164. <https://doi.org/10.1115/1.4009458>
- Paris, P. & Erdogan, F. (1963). A critical analysis of crack propagation laws. *Journal of Basic Engineering*, 85 (4), 528-533. <https://doi.org/10.1115/1.3656900>
- Pfaff, T., Fortunato, M., Sanchez-Gonzalez, A. & Battaglia, P.W. (2021). Learning meshbased simulation with graph networks. *arXiv preprint arXiv:2010.03409*.
- Ponson, L., Bonamy, D. & Bouchaud, E. (2006). Two-dimensional scaling properties of experimental fracture surfaces. *Physical Review Letters*, 96, 035506. <https://doi.org/10.1103/PhysRevLett.96.035506>
- Raissi, M., Perdikaris, P. & Karniadakis, G.E. (2019). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, 378, 686-707. <https://doi.org/10.1016/j.jcp.2018.10.045>
- Rice, J.R. (1968). A path independent integral and the approximate analysis of strain concentration by notches and cracks. *Journal of Applied Mechanics*, 35, 379-386. <https://doi.org/10.1115/1.3601206>
- Rojas, L., Jorquera, L. & Garcia, J. (2026). Advanced graph neural networks for smart mining: A systematic literature review of equivariant, topological, symplectic, and generative models. *Mathematics*, 14, 763. <https://doi.org/10.3390/math14050763>
- Rojas, L., Peña, Á. & Garcia, J. (2025a). Ai-driven predictive maintenance in mining: A systematic literature review on fault detection, digital twins, and intelligent asset management. *Applied Sciences*, 15 (6), 3337. <https://doi.org/10.3390/app15063337>
- Rojas, L., Yepes, V. & Garcia, J. (2025b). Complex dynamics and intelligent control: Advances, challenges, and applications in mining and industrial processes. *Mathematics*, 13 (6), 961. <https://doi.org/10.3390/math13060961>
- Rusiński, E., Harnatkiewicz, P., Kołakowski, P. & Moczko, P. (2010). Examination of the causes of a bucket wheel excavator collapse. *Engineering Failure Analysis*, 17 (6), 1300-1312. <https://doi.org/10.1016/j.engfailanal.2010.03.004>
- Scarselli, F., Gori, M., Tsoi, A.C., Hagenbuchner, M. & Monfardini, G. (2009). The graph neural network model. *IEEE Transactions on Neural Networks*, 20 (1), 61-80. <https://doi.org/10.1109/TNN.2008.2005605>
- Serradilla, O., Zugasti, E., Rodriguez, J. & Zurutuza, U. (2022). Deep learning models for predictive maintenance: a survey, comparison, challenges and prospects. *Applied Intelligence*, 52, 10934-10964. <https://doi.org/10.1007/s10489-021-03004-y>
- Tao, F., Zhang, H., Liu, A. & Nee, A.Y.C. (2019). Digital twin in industry: state-of-the-art. *IEEE Transactions on Industrial Informatics*, 15 (4), 2405-2415. <https://doi.org/10.1109/TII.2018.2873186>
- Tapia, S., Aguilera, G., Aguilera, Y., Rojas, L. & Bazan, V. (2025). Diseño conceptual de algoritmos híbridos para la detección temprana de fallas mecánicas en sistemas de transmisión de correas transportadoras en minería. *Avances en Ciencias e Ingeniería*, 16 (3), 63-76. <https://doi.org/10.65093/aci.v16.n3.2025.37>
- Theissler, A., Pérez-Velasco, J., Ketber, M. & Last, K. (2021). Predictive maintenance enabled by machine learning: Use cases and challenges in the automotive industry. *Reliability Engineering & System Safety*, 215, 107864. <https://doi.org/10.1016/j.ress.2021.107864>

- Veličković, P., Cucurull, G., Casanova, A., Romero, A., Liò, P. & Bengio, Y. (2018). Graph attention networks. *arXiv preprint arXiv:1710.10903*.
- Wang, X., Chen, Y. & Zhang, L. (2026). LGSTA-GNN: A local-global spatiotemporal attention graph neural network for bridge structural damage detection. *Buildings*, 16 (2), 348. <https://doi.org/10.3390/buildings16020348>
- Withers, P.J. (2007). Residual stress and its role in failure. *Reports on Progress in Physics*, 70, 2211-2264. <https://doi.org/10.1088/0034-4885/70/12/R04>
- Wu, Z., Pan, S., Chen, F., Long, G., Zhang, C. & Yu, P.S. (2021). A comprehensive survey on graph neural networks. *IEEE Transactions on Neural Networks and Learning Systems*, 32 (1), 4-24. <https://doi.org/10.1109/TNNLS.2020.2978386>
- Zienkiewicz, O.C., Taylor, R.L. & Zhu, J.Z. (2013). *The Finite Element Method: Its Basis and Fundamentals*. Butterworth-Heinemann, 7th edition.

