

# **SUPERVISIÓN TOLERANTE A FALLOS MEDIANTE REDES NEURONALES EXPLICABLES PARA EL CONTROL DE PROCESOS ALIMENTARIOS**

## **EXPLAINABLE NEURAL NETWORK FAULT-TOLERANT SUPERVISION FOR FOOD PROCESS CONTROL**

Letícia de Souza Lima<sup>1</sup>, Pedro Vieira Souza Santos<sup>2\*</sup>, José Wendel dos Santos<sup>3</sup>

<sup>1</sup> [Universidade Federal do Vale do São Francisco \(UNIVASF\), Juazeiro, Bahia, Brasil.](https://www.univasf.br/) <sup>2\*</sup> [Universidade Federal da Bahia \(UFBA\), Salvador, Bahia, Brasil.](https://www.ufba.br/) <sup>3</sup> [Universidade Federal de Sergipe \(UFS\), São Cristóvão, Sergipe, Brasil.](https://www.ufs.br/)

<sup>1</sup> <https://orcid.org/0009-0007-1019-555X> <sup>2\*</sup> <https://orcid.org/0000-0001-9802-506X>

<sup>3</sup> <https://orcid.org/0000-0002-9138-0437>

<sup>1</sup> [leticiasouzaestagio@gmail.com](mailto:leticiasouzaestagio@gmail.com) <sup>2\*</sup> [pedrovieirass@hotmail.com](mailto:pedrovieirass@hotmail.com) <sup>3</sup> [eng.wendel@live.com](mailto:eng.wendel@live.com)

\*Autor de Correspondencia: Santos, P.V.S.

**RESUMEN:** Este estudio tiene como objetivo desarrollar y evaluar una arquitectura de redes neuronales artificiales explicables para la supervisión tolerante a fallos de un proceso térmico, centrándose en la clasificación de fallos y en la evaluación de acciones correctivas bajo condiciones simuladas de operación. Se utilizó un modelo térmico simplificado para generar datos sintéticos que representan el funcionamiento normal y diferentes escenarios de fallo. Se desarrolló un perceptrón multicapa (MLP) para clasificar las condiciones operativas, mientras que el método SHapley Additive exPlanations (SHAP) se empleó para favorecer la interpretabilidad del modelo. La estrategia de supervisión se evaluó mediante la comparación de indicadores de desempeño del proceso con y sin acciones de control tolerante a fallos. El modelo alcanzó una exactitud de clasificación global del 98,6 %. Para una ventana temporal de 20 muestras, la exactitud reportada fue del 98,7 %, con un tiempo de detección de 5,2 s. Bajo las condiciones simuladas, la incorporación de la supervisión tolerante a fallos se asoció con una reducción de la integral del error absoluto (IAE), de 46,8 a 19,7; del sobreimpulso, del 11,3 % al 4,8 %; y del tiempo de establecimiento, de 95 a 61 s. Estos resultados indican el potencial de integrar la clasificación de fallos basada en redes neuronales, la inteligencia artificial explicable y las acciones correctivas de supervisión para mejorar la respuesta del proceso en las condiciones evaluadas. Sin embargo, el estudio se basa en datos sintéticos y en un modelo térmico simplificado, y no se realizó una validación experimental en una instalación física o industrial. La capacidad de generalización de la arquitectura a diferentes condiciones operativas, así como los efectos de los errores de clasificación sobre las acciones correctivas y la seguridad operacional, requieren investigaciones adicionales. Por tanto, el marco propuesto constituye una alternativa potencial para el diagnóstico de fallos y la supervisión de procesos térmicos, aunque su

fiabilidad y eficacia en entornos industriales reales aún deben demostrarse.

**PALABRAS CLAVE:** Control Tolerante a Fallos; Redes Neuronales Artificiales; Inteligencia Artificial Explicable; Supervisión Industrial.

**ABSTRACT:** This study aims to develop and evaluate an explainable artificial neural network architecture for fault-tolerant supervision of a thermal process, focusing on fault classification and the assessment of corrective actions under simulated operating conditions. A simplified thermal process model was used to generate synthetic data representing normal operation and different fault scenarios. A multilayer perceptron (MLP) was developed to classify operating conditions, while SHapley Additive exPlanations (SHAP) was employed to support model interpretability. The supervisory strategy was evaluated by comparing process performance indicators with and without fault-tolerant control actions. The model achieved an overall classification accuracy of 98.6%. For a temporal window of 20 samples, the reported accuracy was 98.7%, with a detection time of 5.2 s. Under the simulated conditions, the integration of fault-tolerant supervision was associated with a reduction in the integral of absolute error (IAE) from 46.8 to 19.7, overshoot from 11.3% to 4.8%, and settling time from 95 to 61 s. These findings indicate the potential of integrating neural-network-based fault classification, explainable artificial intelligence, and supervisory corrective actions to improve process response under the conditions evaluated. However, the study relies on synthetic data and a simplified thermal model, and no experimental validation in a physical or industrial plant was conducted. The generalization of the architecture to different operating conditions, as well as the effects of classification errors on corrective actions and operational safety, require further investigation. The proposed framework therefore represents a potential approach for fault diagnosis and supervision in thermal processes, although its reliability and effectiveness in real industrial environments remain to be established.

**KEYWORDS:** Fault-Tolerant Control; Artificial Neural Networks; Explainable Artificial Intelligence; Industrial Supervision.

## 1. INTRODUCCIÓN

Las herramientas de calidad aplicadas a la gestión de servicios pueden ser potenciadas mediante el uso de técnicas computacionales avanzadas, como las redes neuronales artificiales, capaces de identificar patrones y contribuir a la optimización de los procesos organizacionales (Santos; Oliveira, 2019; Fernandes et al., 2021). La industria alimentaria depende de sistemas de control automático para garantizar la calidad del producto, la seguridad del proceso y el cumplimiento de estrictos requisitos sanitarios (Cheng et al., 2026; Damián Moran et al., 2025).

Para operaciones térmicas como la fermentación, la esterilización, la pasteurización y la cocción, se necesita un control exacto de las variables del proceso, en particular de la temperatura. Esto se debe a que variaciones mínimas pueden poner en riesgo la calidad del producto, aumentar el gasto de energía o causar pérdidas en

la producción. En estas circunstancias, los controladores PID (proporcional-integral-derivativo) siguen siendo muy empleados por su sencillez, solidez y facilidad de implementación (Ribeiro-Furtini; Abreu, 2006).

Sin embargo, los sistemas que se controlan a través de PID son vulnerables a errores en los sensores, los actuadores o en la dinámica del proceso mismo. El funcionamiento del sistema puede ir empeorando de manera gradual debido a problemas como el sesgo de los sensores, la degradación de las válvulas, la saturación de los actuadores o las fluctuaciones en los parámetros del proceso, antes de que sean percibidos por los métodos tradicionales de supervisión. Por lo tanto, identificar fallos de manera temprana es esencial para optimizar la fiabilidad operativa y respaldar tácticas de control que toleren fallos (Fault-Tolerant Control, FTC) (Brizuela-Mendoza et al., 2025; Amin et al., 2025).

Las Redes Neuronales Artificiales (RNA) han mostrado en años recientes un gran potencial para identificar y clasificar errores, debido a su habilidad para crear modelos de relaciones no lineales utilizando datos de operación (Soares et al., 2022; Artero et al., 2023). No obstante, muchos de los trabajos que se encuentran en la literatura están fundamentados en muestras instantáneas del proceso, lo cual restringe la detección de patrones dinámicos relacionados con fallas incipientes. La naturaleza de "caja negra" de estos modelos, además, complica que sean utilizados en aplicaciones industriales en las que la confianza en las decisiones automatizadas y la capacidad de interpretación son elementos fundamentales (Qin, 2003; Adadi; Berrada, 2018; Rudin, 2019).

En este trabajo, se sugiere una estructura de supervisión fundamentada en una Red Neuronal Artificial explicable con el objetivo de identificar averías y respaldar la regulación tolerante a fallos en procedimientos térmicos de la industria alimentaria. La metodología emplea ventanas temporales deslizantes para ilustrar el desarrollo dinámico de la malla de control, lo que posibilita que el clasificador reconozca patrones temporales propios de diversas clases de fallos. Además, se añade un módulo de Inteligencia Artificial Explicable (Explainable Artificial Intelligence, XAI) que posibilita la interpretación de las decisiones del modelo a través de la identificación de las variables que más afectan cada clasificación. La metodología propuesta se valida mediante simulaciones de un proceso térmico controlado por un PID bajo distintos escenarios de fallo, demostrando su potencial como herramienta de supervisión inteligente para aplicaciones industriales.

El objetivo general de esta investigación es desarrollar y evaluar, mediante simulación, una arquitectura de supervisión inteligente que integre diagnóstico multiclase basado en redes neuronales artificiales, explicación de las predicciones mediante SHAP y activación supervisada de estrategias de control tolerante a fallos en un proceso térmico regulado por un controlador PID. Las contribuciones específicas son: (i) analizar el efecto de diferentes longitudes de ventana temporal sobre la exactitud de clasificación y el tiempo de detección; (ii) identificar las variables que más contribuyen a las decisiones del clasificador mediante valores SHAP; y (iii) evaluar el

comportamiento del sistema de control antes y después de activar las acciones correctivas definidas para los escenarios de fallo considerados.

El alcance del estudio está delimitado por la utilización de un modelo matemático simplificado de un tanque térmico agitado y de datos sintéticos generados por simulación. En consecuencia, los resultados permiten evaluar la viabilidad de la arquitectura en las condiciones modeladas, pero no demuestran su eficacia en una planta industrial real. Asimismo, el desempeño obtenido depende de los escenarios simulados, de las características de los datos y de las acciones correctivas predefinidas. La validación experimental, el uso de datos industriales reales y la evaluación de la robustez ante incertidumbres y condiciones operativas no contempladas se reservan para investigaciones futuras.

## **2. REVISIÓN DE LA LITERATURA**

### **2.1 SUPERVISIÓN, MONITORIZACIÓN Y CONTROL DE PROCESOS INDUSTRIALES**

La automatización industrial distribuye las funciones de medición, control y supervisión entre diferentes elementos de la planta. Los sensores proporcionan información sobre las variables del proceso, los controladores procesan estas señales y accionan los actuadores, mientras que los sistemas de supervisory control and data acquisition (SCADA) presentan a los operadores los estados del proceso, las tendencias y las alarmas (Folgado et al., 2024). La disponibilidad de datos en tiempo real facilita el seguimiento del proceso; sin embargo, no elimina la intervención humana ante situaciones que no han sido previstas por las lógicas de control automático (Zarei; Khan; Abbassi, 2021).

La monitorización permite identificar desviaciones respecto al comportamiento esperado, pero la aparición de una desviación no determina necesariamente su origen. Los efectos de una falla pueden propagarse a través de las relaciones entre las variables del proceso y de la respuesta de los propios lazos de control, haciendo que las alteraciones más evidentes se manifiesten lejos de la causa inicial. Por ello, el diagnóstico requiere identificar las variables involucradas y distinguir el origen de la anomalía de su propagación a través del proceso (Ji; Sun, 2022). En plantas de gran escala, la división de las variables en bloques funcionales permite desarrollar monitores locales y combinar sus decisiones para evaluar el estado general de la planta (Jiang; Yan; Huang, 2019).

El análisis de datos multivariados depende de la representación de las relaciones entre las variables que caracterizan las condiciones normales de operación. El análisis de componentes principales (principal component analysis, PCA) y los mínimos cuadrados parciales (partial least squares, PLS) proyectan datos de alta dimensionalidad en espacios de menor dimensión, en los cuales pueden identificarse desviaciones respecto de las condiciones de referencia. La autocorrelación, la no

linealidad, las distribuciones no gaussianas, los cambios de régimen operativo y la no estacionariedad pueden modificar estas relaciones y comprometer la detección de fallas cuando dichas características no están adecuadamente representadas por el modelo empleado (Ji; Sun, 2022; Melo; Câmara; Pinto, 2024).

El seguimiento de los valores de referencia mediante los lazos de control locales no garantiza que la calidad, la eficiencia y el consumo de recursos permanezcan dentro de los rangos deseados para el conjunto de la planta. Estos resultados también dependen de la interacción entre las diferentes unidades y de la selección de los propios valores de referencia. El control supervisor coordina los lazos de control locales y modifica sus valores de referencia de acuerdo con los objetivos operativos establecidos para la planta (Chai; Qin; Wang, 2014; Nadim et al., 2023). La seguridad operacional impone requisitos diferentes de aquellos asociados con la regulación de las variables. Las alarmas, las restricciones físicas y los sistemas instrumentados de seguridad actúan ante condiciones específicas, y una trayectoria dinámicamente estable aún puede superar los límites seguros del equipo o del proceso (Albalawi; Durand; Christofides, 2018; Zhang et al., 2023).

## **2.2 CONTROL PID DE PROCESOS TÉRMICOS EN LA INDUSTRIA ALIMENTARIA**

El procesamiento térmico de alimentos busca lograr la inactivación microbiana y enzimática necesaria sin someter el producto a una exposición térmica superior a la requerida (Kubo et al., 2023). La temperatura y el tiempo determinan la intensidad del tratamiento y afectan simultáneamente la seguridad, la estabilidad y la calidad del producto. Los tratamientos insuficientes pueden no alcanzar la letalidad requerida, mientras que una exposición excesiva puede favorecer pérdidas nutricionales y alteraciones sensoriales (Chung; Chen; Ting, 2016). El perfil térmico también influye en el tiempo de procesamiento, la productividad y el consumo de energía (Simpson et al., 2020).

El desempeño del controlador proporcional-integral-derivativo (proportional-integral-derivative, PID) depende de su sintonización y de la dinámica del proceso. Su formulación convencional es más adecuada para sistemas de bajo orden y comportamiento aproximadamente lineal, mientras que las no linealidades pueden deteriorar la respuesta transitoria (Huang, 2013). Los procesos alimentarios presentan variabilidad en las materias primas, cambios en las propiedades del producto y limitaciones de medición que dificultan la representación de la dinámica mediante parámetros fijos (Kondakci; Zhou, 2017). Las estrategias basadas en modelos, la lógica difusa y las redes neuronales ofrecen otras alternativas para representar estas relaciones. Las redes neuronales pueden aprender relaciones no lineales entre las entradas y las salidas a partir de los datos del proceso y utilizar esta información para calcular la acción de control (Javed et al., 2026). La elección entre estas estrategias depende de las características de la aplicación; una mayor complejidad no implica

necesariamente una superioridad general en términos de desempeño.

Los cambios en las condiciones de entrada pueden modificar la respuesta térmica incluso cuando los sensores, los actuadores y el controlador permanecen operativos. Cuando una perturbación es medible, una acción anticipativa (feedforward) puede utilizar esta información antes de que su efecto se manifieste completamente en la variable controlada. En el procesamiento de leche mediante temperatura ultraalta (ultra-high temperature, UHT), la temperatura de entrada puede utilizarse para generar esta acción en conjunto con la realimentación de la temperatura de salida (Ahmad; Arsalan, 2023). El error, el tiempo de establecimiento, el sobreimpulso y la recuperación caracterizan la respuesta del lazo ante referencias y perturbaciones, pero no permiten evaluar la integridad de los elementos utilizados para medir y actuar sobre el proceso.

Las fallas en sensores o actuadores modifican una de las premisas fundamentales de la operación nominal del lazo de control. Una falla del sensor compromete la información proporcionada al controlador, mientras que una falla del actuador modifica la acción que efectivamente se aplica al proceso. En general, los controladores PID no están diseñados para tratar directamente las fallas de estos componentes (Albalawi; Durand; Christofides, 2018). Además, la desviación observada en la variable controlada no permite determinar, por sí sola, si su origen se encuentra en el proceso, en la medición o en la actuación.

En arquitecturas activas de control tolerante a fallas, se generan informaciones adicionales sobre la anomalía antes de que el controlador alcance un nuevo estado estacionario. Los residuos sensibles a diferentes tipos de fallas permiten realizar su detección y aislamiento; posteriormente, la falla del sensor o del actuador puede ser estimada (Bernardi; Adam, 2021). La información obtenida se utiliza entonces para compensar sus efectos sobre la acción de control o sobre las variables medidas, permitiendo modificar la estrategia de control ante la presencia de un componente comprometido.

### 3. METODOLOGÍA

La metodología sugerida se basa en una arquitectura de supervisión inteligente que permite la detección temprana de errores en un proceso térmico regulado a través de un controlador PID. El sistema integra un módulo de Inteligencia Artificial Explicable (XAI) y una Red Neuronal Artificial (RNA), la cual ha sido entrenada utilizando ventanas temporales deslizantes. Esto permite ofrecer diagnósticos que se pueden interpretar, los cuales respaldan tácticas de Control Tolerante a Fallos (FTC, por sus siglas en inglés). La arquitectura propuesta se desarrolla en cuatro etapas principales:

- i. Simulación del proceso térmico bajo diferentes condiciones de operación.
- ii. Generación del conjunto de datos mediante la inserción de distintos tipos de fallos.

iii. Entrenamiento de una RNA utilizando ventanas temporales de las variables del proceso.

iv. Interpretación de las predicciones mediante técnicas XAI y aplicación de acciones supervisadas de control tolerante a fallos.

### 3.1 MODELO DEL PROCESO

Como caso de estudio se considera un tanque agitado con calentamiento continuo, representado mediante un modelo dinámico de primer orden (1):

$$dT(t)/dt = -(1/\tau) \cdot [T(t) - T_a] + K \cdot u(t) + d(t) \quad (1)$$

Donde:

- $T(t)$  representa la temperatura del proceso ( $^{\circ}\text{C}$ );
- $T_a$  es la temperatura ambiente ( $^{\circ}\text{C}$ );
- $u(t)$  es la señal de control aplicada al actuador (%);
- $K$  es la ganancia del proceso;
- $\tau$  es la constante de tiempo (s);
- $d(t)$  representa perturbaciones externas.

El objetivo del sistema de control es mantener la temperatura del proceso próxima al valor de referencia ( $SP(t)$ ). Para ello se utiliza un controlador PID convencional, cuya ley de control está dada por (2):

$$u(t) = K_p \cdot e(t) + K_i \cdot \int e(t)dt + K_d \cdot de(t)/dt \quad (2)$$

- $K_p$  representa la ganancia de la acción proporcional;
- $K_i$  representa la ganancia de la acción integral;
- $K_d$  representa la ganancia de la acción derivativa.

Donde el error de control se define como:  $e(t) = SP(t) - T(t)$

- $SP(t)$  representa la temperatura de referencia (setpoint) del sistema de control;
- $T(t)$  representa la temperatura medida del proceso.

El controlador PID mantiene la temperatura cerca del punto de operación y, al

mismo tiempo, compensa las perturbaciones durante el funcionamiento normal. No obstante, si hay fallos en los sensores o actuadores, o en la dinámica del proceso, el funcionamiento del sistema puede ir empeorando con el tiempo. En esta investigación se sostiene que estas anomalías generan patrones temporales distintivos que pueden ser detectados con métodos de aprendizaje profundo. El modelo matemático se utiliza únicamente para crear datos sintéticos en diferentes contextos de operación. La base para entrenar y validar la red neuronal que se propone para detectar fallos tempranamente son estos datos.

### 3.2 GENERACIÓN DEL CONJUNTO DE DATOS

El conjunto de datos se obtiene mediante simulaciones del proceso bajo condiciones normales y diferentes escenarios de fallo. En cada simulación se introduce un único tipo de fallo en un instante aleatorio con el fin de representar situaciones realistas de operación. El procedimiento de generación de datos comprende tres operaciones: (a) ejecución del modelo del tanque térmico bajo condiciones nominales, con el controlador PID regulando la temperatura alrededor de la referencia; (b) ejecución de escenarios con la inserción de una única clase de fallo por simulación, en un instante seleccionado aleatoriamente; y (c) registro sincronizado de las cinco señales de entrada definidas en esta sección y asignación de la etiqueta correspondiente al estado operativo. Las variables registradas en cada instante de muestreo son:

- Temperatura del proceso ( $T$ );
- Referencia ( $SP$ );
- Error de control ( $e$ );
- Señal de control ( $u$ );
- Variación temporal de la temperatura ( $\Delta T$ ).

Cada observación recibe una etiqueta correspondiente al estado operativo del sistema:

- Clase 0: operación normal;
- Clase 1: fallo en el sensor;
- Clase 2: fallo del actuador;
- Clase 3: degradación del proceso;
- Clase 4: perturbación externa.

### 3.3 CONSTRUCCIÓN DE VENTANAS TEMPORALES

La metodología sugerida, en contraste con los métodos tradicionales que se fundamentan en muestras instantáneas, emplea ventanas deslizantes para ilustrar el desarrollo dinámico del proceso. Este método posibilita que la red neuronal reconozca la dependencia temporal entre las variables del sistema, lo que mejora la detección de fallas tempranas que no pueden ser identificadas a través de observaciones individuales. En cada instante de muestreo  $k$ , el estado del proceso se representa mediante el siguiente vector (3) de características:

$$x(k) = [T(k), SP(k), e(k), u(k), \Delta T(k)] \quad (3)$$

Donde:

- $T(k)$ : temperatura medida del proceso.
- $SP(k)$ : temperatura de referencia (setpoint).
- $e(k)$ : error de control, definido como:  $e(k) = SP(k) - T(k)$
- $u(k)$ : señal de control generada por el controlador PID.
- $\Delta T(k)$ : variación de la temperatura entre dos instantes consecutivos, calculada como:  $\Delta T(k) = T(k) - T(k-1)$ .

A partir de estos vectores se construye una ventana temporal de longitud  $L$ , definida por (4):

$$X(k) = [x(k-L+1), x(k-L+2), \dots, x(k)] \quad (4)$$

De esta forma, cada muestra utilizada para el entrenamiento contiene la evolución temporal de todas las variables del proceso durante los últimos  $L$  instantes de muestreo. Se opta por un marco de 20 muestras en esta investigación al principio, pues ofrece un balance apropiado entre la cantidad de datos temporales disponibles y la velocidad para detectar fallas. A continuación, se examinan varios tamaños de ventana para determinar cómo afectan el rendimiento del clasificador.

La red neuronal puede reconocer patrones dinámicos relacionados con diferentes clases de fallos, como la degradación de actuadores, el desvío progresivo de sensores y las fluctuaciones en la dinámica del proceso, gracias al empleo de ventanas temporales. Por lo tanto, el sistema sugerido mejora la detección temprana de anomalías en relación con los métodos que se basan solo en mediciones instantáneas.

### 3.4 RED NEURONAL ARTIFICIAL

Se emplea una Red Neuronal Artificial multicapa (MLP) para la clasificación de los estados del proceso. La arquitectura utilizada está compuesta por:

- Capa de entrada correspondiente a las variables contenidas en la ventana temporal;
- Dos capas ocultas completamente conectadas con función de activación relu;
- Capa de salida softmax para la clasificación multiclase.

El entrenamiento se realiza mediante el algoritmo Adam utilizando la función de pérdida de entropía cruzada categórica. El conjunto de datos se divide en entrenamiento (70%), validación (15%) y prueba (15%). La secuencia de desarrollo del clasificador comprende: definición de la entrada a partir de las variables incluidas en cada ventana; asignación de las etiquetas de las cinco clases operativas; entrenamiento de la MLP con Adam y entropía cruzada categórica; seguimiento del desempeño en el subconjunto de validación; y cálculo de las métricas finales en el subconjunto de prueba.

### 3.5 MÓDULO DE INTELIGENCIA ARTIFICIAL EXPLICABLE

Se evalúan las predicciones de la RNA a través de SHAP (SHapley Additive exPlanations) para mejorar la interpretabilidad del modelo. El método calcula la aportación individual de cada variable de entrada a la decisión del modelo para cada clasificación. Esta información posibilita la identificación de las variables que tienen un mayor impacto en la detección del fallo, brindando una explicación numérica de lo que decidió la red neuronal.

### 3.6 ESTRATEGIA DE CONTROL TOLERANTE A FALLOS

La RNA funciona como un supervisor del sistema de control. Cuando se determina la clase de fallo, se realiza una acción correctiva que fue definida con anterioridad. Se tienen en cuenta las acciones supervisadas:

- Fallo del sensor: cambio hacia una medición estimada o redundante;
- Fallo del actuador: ajuste de los parámetros del controlador PID;
- Degradación del proceso: ajuste de la referencia o activación de una señal de mantenimiento;
- Alteraciones externas: conservación de la táctica de control nominal.

Esta táctica posibilita que el sistema siga funcionando y, al mismo tiempo, logra reducir al mínimo el efecto del error en la variable controlada. La evaluación del supervisor se lleva a cabo comparando el comportamiento simulado del lazo de control antes y después de activar la acción correctiva asociada a la clase detectada. Para cada condición, se registran las métricas de desempeño del control definidas en la sección siguiente: IAE, sobreimpulso máximo, tiempo de establecimiento y tiempo de detección del fallo.

### 3.7 MÉTRICAS DE EVALUACIÓN

El desempeño de la metodología se evalúa mediante indicadores de clasificación y de control. Para la clasificación se consideran:

- Exactitud (Accuracy);
- Precisión (Precision);
- Exhaustividad (Recall);
- Puntuación F1.

Para el sistema de control se analizan:

- Tiempo de detección del fallo;
- Error absoluto integral (IAE);
- Sobreimpulso máximo;
- Tiempo de establecimiento.

Estas métricas permiten evaluar tanto la capacidad diagnóstica de la RNA como el impacto de la estrategia propuesta sobre el desempeño del sistema de control. La validación se interpreta en dos niveles complementarios. En el nivel diagnóstico, las métricas de exactitud, precisión, exhaustividad y F1 se calculan a partir de las clases reales asignadas durante la generación de los escenarios y las clases predichas por la RNA en el conjunto de prueba. En el nivel de control, se comparan las métricas dinámicas del proceso con y sin la activación de las acciones FTC. Los resultados representan una validación computacional bajo las condiciones simuladas descritas; no constituyen una validación experimental en una planta de procesamiento de alimentos.

## 4. RESULTADOS Y DISCUSIÓN

La metodología sugerida fue evaluada a través de simulaciones de un proceso térmico controlado por un controlador PID en diversas condiciones operativas. Se tuvieron en cuenta situaciones de operación normal, avería del actuador, fallo del sensor, alteraciones externas y deterioro del procedimiento. Se generaron numerosas secuencias temporales para cada escenario, las cuales se emplearon en la evaluación y el entrenamiento de la red neuronal.

### 4.1 DESEMPEÑO DEL CLASIFICADOR

La Tabla 1 presenta los indicadores de desempeño obtenidos durante la etapa de prueba.


Tabla 1: Resultados de clasificación de la red neuronal

| Métrica   | Valor  |
|-----------|--------|
| Accuracy  | 98.6 % |
| Precision | 98.2 % |
| Recall    | 98.5 % |
| F1-score  | 98.3 % |

Fuente: Datos de la investigación (2026)

Los hallazgos indican que el uso de ventanas temporales posibilita detectar con alta precisión las distintas clases de fallos, incluso en las fases iniciales de su desarrollo. Como se observa en la Figura 1, la red neuronal artificial alcanza un rendimiento sobresaliente en todas las métricas evaluadas, superando el 98% en exactitud, precisión, exhaustividad y puntuación F1 (Tabla 1). Estos resultados confirman que la inclusión de ventanas temporales permite identificar de manera sólida y efectiva las distintas clases de fallos en el proceso térmico.

Figura 1: Métricas globales de desempeño obtenidas por la red neuronal artificial durante la etapa de prueba.



Fuente: Datos de la investigación (2026)

Gracias a la representación temporal se obtiene información complementaria acerca de cómo el proceso evoluciona con dinamismo, lo cual permite disminuir la confusión entre los fallos reales y las alteraciones transitorias.

## 4.2 INFLUENCIA DEL TAMAÑO DE LA VENTANA TEMPORAL

Con el objetivo de analizar la influencia de la información temporal, se evaluaron diferentes tamaños de ventana.

Tabla 2 - Influencia de la longitud de la ventana temporal


| Longitud de la ventana (muestras) | Accuracy (%) | Tiempo de detección (s) |
|-----------------------------------|--------------|-------------------------|
| 5                                 | 92.8         | 2.3                     |
| 10                                | 96.9         | 3.8                     |
| 20                                | 98.7         | 5.2                     |
| 40                                | 98.1         | 10.8                    |

Fuente: Datos de la investigación (2026)

Se aprecia que ventanas demasiado breves no tienen suficiente información para describir la dinámica del proceso, mientras que ventanas demasiado largas prolongan el tiempo requerido para identificar la anomalía. En las condiciones estudiadas, la ventana

de 20 muestras presentó el balance óptimo entre rapidez y precisión de respuesta. La selección de la ventana temporal de 20 muestras se fundamenta en el análisis conjunto de la exactitud de clasificación y el tiempo de detección de fallos. Para hacer explícito este criterio, el equilibrio entre ambas métricas debe entenderse como la capacidad de identificar correctamente las condiciones de fallo sin introducir un retraso excesivo en la respuesta del sistema. En este sentido, la ventana de 20 muestras presentó un desempeño favorable, con una exactitud del 98,7 % y un tiempo de detección de 5,2 s. Operativamente, este tiempo debe calcularse desde el instante en que el fallo se introduce efectivamente en la simulación hasta el momento en que el sistema supervisor confirma su clasificación, considerando el intervalo de muestreo y la regla de confirmación adoptada. Por tanto, para garantizar la reproducibilidad del análisis, es necesario especificar el intervalo de muestreo, el criterio utilizado para confirmar la detección y el procedimiento de cálculo del tiempo registrado. Asimismo, la ventana seleccionada debe interpretarse como la alternativa más adecuada entre las evaluadas bajo las condiciones simuladas, y no como un óptimo universal, dado que su desempeño depende de la dinámica del proceso y de la configuración del sistema de supervisión. En la Figura 2 se ilustra el compromiso entre la exactitud de clasificación y la velocidad de respuesta en función de la longitud de la ventana temporal. Se evidencia que la ventana de 20 muestras representa el punto óptimo, pues maximiza la exactitud (98.7%) manteniendo un tiempo de detección reducido (5.2 s), antes de que el retraso temporal se incremente significativamente para ventanas más largas.

Figura 2 - Influencia de la longitud de la ventana temporal en la exactitud (accuracy) y el tiempo de detección de fallos



Fuente: Datos de la investigación (2026)

### 4.3 DESEMPEÑO DEL CONTROL TOLERANTE A FALLOS

Una vez identificada la condición de operación, el supervisor ejecutó la estrategia correspondiente de control tolerante a fallos. La Tabla 3 resume el comportamiento del sistema antes y después de la activación del supervisor.

Tabla 3 - Desempeño del sistema de control

| Indicador                     | Sin FTC | Con FTC |
|-------------------------------|---------|---------|
| Tiempo de detección (s)       | 18.4    | 5.2     |
| IAE                           | 46.8    | 19.7    |
| Sobreimpulso (%)              | 11.3    | 4.8     |
| Tiempo de establecimiento (s) | 95      | 61      |


Fuente: Datos de la investigación (2026)

Cuando se emplea la clasificación hecha por la red neuronal para activar acciones de control supervisadas, los resultados indican una disminución considerable del error acumulado y del tiempo requerido para que el sistema se recupere.

### 4.4 INTERPRETABILIDAD MEDIANTE XAI

Con el propósito de analizar las decisiones de la red neuronal, se aplicó el método SHAP para estimar la contribución de cada variable de entrada. La Figura 3 muestra el análisis de la interpretabilidad del modelo a través de los valores SHAP (SHapley Additive exPlanations), lo que posibilita determinar la contribución proporcional de cada variable de entrada en la respuesta del sistema de control PID. Según el gráfico de barras, la señal de control del PID ( $u$ ) tiene el mayor impacto medio sobre la salida del modelo, con un valor absoluto medio SHAP de 0,42; después se encuentra el error de control ( $e$ ), que tiene un valor de 0,28. Las variables relacionadas con la dinámica térmica del proceso, entre las que se encuentran  $\Delta T$  (la variación de temperatura),  $T$  (la temperatura del proceso) y  $SP$  (la temperatura de referencia), tienen aportaciones individuales más bajas, lo que señala distintos grados de incidencia en las predicciones producidas por el modelo.

Figura 3 - Análisis de interpretabilidad basado en shap del modelo de control pid asistido por inteligencia artificial.



Fuente: Datos de la investigación (2026)

Al mostrar el sentido y la magnitud del efecto de cada variable sobre las distintas muestras analizadas, el gráfico de distribución de los valores SHAP añade a este análisis. Se constata que cuando las variables de entrada tienen un valor alto (lo que se muestra con la escala de color rojo), en la salida del modelo resultan contribuciones positivas o negativas, lo cual demuestra que hay relaciones no lineales entre las distintas variables del sistema.

Así, el análisis SHAP aporta más transparencia al modelo de inteligencia artificial que se usa para controlar la temperatura. Esto posibilita entender qué variables son las más relevantes en el proceso de decisión y ayuda a validar el modelo que se propone. En este escenario, las variables que más impactaron la decisión del modelo fueron el error de control, la señal de control del PID y la fluctuación temporal de la temperatura.

Este resultado coincide con lo que se preveía en términos de comportamiento físico, puesto que una pérdida parcial de la capacidad del actuador ocasiona un aumento constante del error y una reducción en la velocidad de respuesta del proceso. La integración de XAI posibilita entender las resoluciones de la red neuronal, lo que brinda información valiosa para los operadores y los sistemas de supervisión industrial. El modelo proporciona, además de la clasificación del tipo de error, pruebas cuantitativas que respaldan cada decisión. Esto hace que se aumente la confianza en el sistema propuesto.

Los resultados obtenidos demuestran que la utilización de ventanas temporales mejora la capacidad de la red neuronal para reconocer patrones dinámicos asociados a fallos incipientes. La estrategia sugerida, a diferencia de las técnicas que se basan en mediciones instantáneas, tiene en cuenta la evolución temporal del proceso. Al emplear ventanas temporales, se optimiza la habilidad de la red neuronal para identificar fallos emergentes, dado que se registra el desarrollo dinámico del proceso en vez de basarse

solamente en mediciones instantáneas.

Esta conclusión concuerda con la de Tarifa y Martínez (2007), que afirmaron que para conseguir un diagnóstico más preciso de las fallas es necesario fundamentarlo en la identificación de trayectorias temporales de las variables del proceso. El desempeño sobresaliente obtenido por el modelo sugerido también concuerda con lo reportado por Chen et al. (2025) y Sarmiento-Ramos (2020), que enfatizan que las técnicas de aprendizaje profundo posibilitan la extracción de rasgos complejos y la modelación de relaciones no lineales, sobrepasando así la eficacia de los métodos convencionales de aprendizaje automático.

La implementación de inteligencia artificial explicable a través de SHAP, como contribución extra, logró determinar que el error de control y la señal de control del PID fueron las variables que más incidieron en las decisiones del modelo, lo cual ofreció mayor transparencia y confianza en el sistema. En resumen, estos resultados corroboran que la combinación de técnicas de XAI, análisis temporal y redes neuronales es una estrategia sólida para la supervisión inteligente y el control tolerante a fallos en procesos industriales térmicos. Esto posibilita identificar anomalías con más precisión y antes. El módulo XAI añade claridad al proceso de toma de decisiones, mientras que la inclusión de un supervisor de control tolerante a fallos disminuye el efecto que las anomalías tienen en el rendimiento de la malha de control. En general, estos hallazgos señalan que la metodología sugerida representa una opción factible para sistemas de monitoreo inteligente en procesos térmicos del sector alimentario.

Los hallazgos obtenidos son coherentes con los de Arias-Montaña et al. (2026), que evidenciaron que las redes neuronales convolucionales posibilitan la detección de errores con gran exactitud a través del análisis de las señales del proceso. Pese a que la aplicación es para motores Otto, los dos estudios demuestran lo que el aprendizaje profundo puede hacer para detectar fallos de forma inteligente.

Asimismo, los resultados logrados apoyan el avance de sistemas inteligentes para la industria, en consonancia con investigaciones recientes que señalan que la incorporación de tecnologías sofisticadas para analizar datos y de inteligencia artificial promueve la innovación, la eficacia operacional y la sostenibilidad en los procesos industriales, sobre todo cuando estas tecnologías son parte de una estrategia organizacional integrada (Dória et al., 2026).

## 5. CONSIDERACIONES FINALES

El objetivo de esta investigación fue desarrollar y evaluar una arquitectura de supervisión tolerante a fallos basada en redes neuronales artificiales explicables para la identificación de condiciones anómalas y el apoyo al control de un proceso térmico. Los resultados obtenidos mediante simulación indican que la arquitectura propuesta tiene potencial para clasificar las condiciones operativas consideradas y apoyar la selección de acciones correctivas en el entorno evaluado. El modelo alcanzó una exactitud de clasificación del 98,6 % y, para la ventana temporal de 20 muestras, se

obtuvo una exactitud del 98,7 % y un tiempo de detección de 5,2 s. Asimismo, en las condiciones simuladas, la incorporación de la estrategia de supervisión tolerante a fallos se asoció con una reducción del índice de error absoluto integral (IAE), de 46,8 a 19,7, del sobreimpulso, del 11,3 % al 4,8 %, y del tiempo de establecimiento, de 95 a 61 s. Estos resultados sugieren que la combinación de clasificación mediante redes neuronales, interpretación basada en SHAP y supervisión de las acciones correctivas puede contribuir al diagnóstico de fallos y a la mejora de la respuesta del sistema bajo las condiciones estudiadas.

No obstante, los resultados deben interpretarse considerando las limitaciones del estudio. La evaluación se realizó con datos sintéticos generados a partir de un modelo térmico simplificado, por lo que el comportamiento observado puede no representar completamente la dinámica, las perturbaciones y la variabilidad presentes en instalaciones industriales reales. Además, no se llevó a cabo una validación experimental en una planta física, ni se evaluó de manera exhaustiva la capacidad de generalización del modelo ante condiciones operativas diferentes de las consideradas durante su desarrollo. También deben contemplarse los posibles errores de clasificación, especialmente los falsos positivos y falsos negativos, así como sus consecuencias sobre la selección y ejecución de las acciones correctivas. La seguridad operacional tampoco fue evaluada mediante un análisis integral de riesgos, por lo que no es posible afirmar, a partir de los resultados disponibles, que la arquitectura garantice la seguridad o la fiabilidad del proceso en aplicaciones industriales.

Como trabajo futuro, se recomienda validar la metodología en una instalación experimental o industrial, ampliar los escenarios de fallo y las condiciones de operación, y evaluar la robustez del modelo ante variaciones de parámetros, ruido y cambios en la dinámica del proceso. Asimismo, será necesario analizar sistemáticamente los errores de clasificación y sus efectos sobre las acciones de supervisión, además de incorporar métricas y procedimientos específicos para evaluar la seguridad operacional. En consecuencia, la contribución principal de este trabajo consiste en demostrar, bajo condiciones simuladas, la viabilidad potencial de integrar redes neuronales explicables y estrategias de supervisión tolerante a fallos en un proceso térmico, sin asumir que el desempeño obtenido pueda extrapolarse directamente a entornos industriales reales.

## REFERENCIAS

ADADI, A.; BERRADA, M. Peeking inside the black-box: a survey on explainable artificial intelligence (XAI). *IEEE Access*, v. 6, p. 52138–52160, 2018. DOI: <https://doi.org/10.1109/ACCESS.2018.2870052>.

AHMAD, N.; ARSALAN, M. Fuzzy-proportional-integral-derivative hybrid controller design for ultra-high temperature milk processing. *IAES International Journal of Robotics and Automation (IJRA)*, v. 12, n. 3, p. 289, 2023. Disponível em: <https://doi.org/10.11591/ijra.v12i3.pp289-299>

ALBALAWI, F.; DURAND, H.; CHRISTOFIDES, P. D. Process operational safety via model predictive control: Recent results and future research directions. *Computers & Chemical Engineering*, v. 114, p. 171–190, 2018. Disponível em: <https://doi.org/10.1016/j.compchemeng.2017.10.006>

AMIN, A. A.; IRFAN, M.; ALSUWIAN, T.; RAHMAN, S.; MUBARAK, A.; WASEEM, S. Applications of fault-tolerant control system in the design of wind turbine generation systems: a comprehensive review and future prospects. *Results in Engineering*, v. 27, art. 106205, 2025. DOI: <https://doi.org/10.1016/j.rineng.2025.106205>.

ARIAS-MONTAÑO, E. I.; LEÓN-JAPA, R. S.; GARCÍA-JARAMILLO, P.; MALDONADO-ORTEGA, J. Estimación de emisiones por fallos en motores Otto mediante redes neuronales convolucionales. *Ingenius, Revista de Ciencia y Tecnología*, n. 35, p. 97–109, 2026. DOI: <https://doi.org/10.17163/ings.n35.2026.07>.

ARTERO, L. E. A.; PIVETA, W. G. dos S.; BRATIFICH, R.; SILVA, M. M. da. Estudo da aplicação de redes neurais artificiais para identificação de curto-circuitos no sistema elétrico de distribuição. *Colloquium Exactarum*, v. 14, n. 1, p. 164–177, 2023.

BERNARDI, E.; ADAM, E. J. Fault-tolerant predictive control based on linear parameter varying scheme for industrial processes. *Journal of the Taiwan Institute of Chemical Engineers*, v. 129, p. 1–14, 2021. Disponível em: <https://doi.org/10.1016/j.jtice.2021.10.003>

BRIZUELA-MENDOZA, J. A.; SORCIA-VÁZQUEZ, F. D. J.; ORTIZ-TORRES, G.; RUMBO-MORALES, J. Y.; TORRES-CANTERO, C. A.; RAMOS-MARTINEZ, M.; PÉREZ-VIDAL, A. F. MPC-based sensor fault-tolerant control: application to a heat exchanger with measurement noise. *Automation*, v. 6, n. 3, art. 48, 2025. DOI: <https://doi.org/10.3390/automation6030048>.

CHAI, T.; QIN, S. J.; WANG, H. Optimal operational control for complex industrial processes. *Annual Reviews in Control*, v. 38, n. 1, p. 81–92, 2014. Disponível em: <https://doi.org/10.1016/j.arcontrol.2014.03.005>

CHEN, J.; LIU, W.; QIU, X.; et al. CRGT-SA: an interlaced and spatiotemporal deep learning model for network intrusion detection. *Frontiers of Information Technology & Electronic Engineering*, v. 26, n. 7, p. 1115–1130, 2025. DOI: <https://doi.org/10.1631/FITEE.2400459>.

CHENG, Jianhong; REIS, Paula L.; SILVA, A. L.; BRAGA, M. F. F. A preliminary reference architecture for integrating charcoal blast furnace ironmaking processes: enhancing interoperability in a Brazilian company. *Iberoamerican Journal of Industrial Engineering*, v. 18, 2026. DOI: <https://doi.org/10.5007/2175-8018.2026.e108008>.

CHUNG, C.-C.; CHEN, H.-H.; TING, C.-H. Fuzzy logic for accurate control of heating temperature and duration in canned food sterilisation. *Engineering in Agriculture, Environment and Food*, v. 9, n. 2, p. 187–194, 2016. Disponível em: <https://doi.org/10.1016/j.eaef.2015.11.003>

DAMIÁN MORAN, G. J.; MAYHUA AYUQUE, J.; INGA QUINTO, J. E.; LARREA CERNA, C. O.; CALLIRGOS ROMERO, D. Industria 4.0 y su relación con la automatización en la industria alimentaria: una revisión sistemática y bibliométrica. *Manglar*, v. 22, n. 2, p. 229–

243, 2025. DOI: <https://doi.org/10.57188/manglar.2025.025>.

DÓRIA, R. de C. M.; COTRIM, S. L.; PEZZOTT, G. L. M.; DOS SANTOS FILHO, V. H.; SANTOS, P. V. S.; DOS SANTOS, J. W. Sustainable innovation maturity in the cosmetics industry: an item response theory-based analysis. *Journal of Technology Management & Innovation*, v. 21, n. 2, p. 99–109, 2026. DOI: <https://doi.org/10.4067/S0718-2724202600025059>

FERNANDES, C. H. A.; SILVA, A. C. G. C.; FERRAZ, A. V.; SANTOS, P. V. S. Aplicação da metodologia DMAIC para redução dos desperdícios em uma indústria de gesso do interior de Pernambuco, Brasil. *NAVUS - Revista de Gestão e Tecnologia*, v. 11, p. 1–19, 2021. DOI: <https://doi.org/10.22279/navus.2021.v11.p01-19.1622>.

FOLGADO, F.; CALDERÓN, D.; GONZÁLEZ, I.; CALDERÓN, A. Review of Industry 4.0 from the Perspective of Automation and Supervision Systems: Definitions, Architectures and Recent Trends. *Electronics*, v. 13, n. 4, p. 782, 2024. Disponível em: <https://doi.org/10.3390/electronics13040782>

HUANG, Y. Automatic process control for the food industry: an introduction. In: *Robotics and Automation in the Food Industry*. [S. l.]: Elsevier, 2013. p. 3–20. E-book. Disponível em: <https://doi.org/10.1533/9780857095763.1.3>

JAVED, T.; LUKE, L. P.; ISSA, W.; SPENDLOVE, J.; AKMAL, M.; BREIKIN, T.; MILLMAN, C.; RASHVAND, M.; ZHANG, H. Neural Network-Based Intelligent Control of Continuous Flow Ohmic Heating Systems for Enhanced Dynamic Performance and Sustainable Food Processing. *Food and Bioprocess Technology*, v. 19, n. 7, p. 371, 2026. Disponível em: <https://doi.org/10.1007/s11947-026-04450-7>

JI, C.; SUN, W. A Review on Data-Driven Process Monitoring Methods: Characterization and Mining of Industrial Data. *Processes*, v. 10, n. 2, p. 335, 2022. Disponível em: <https://doi.org/10.3390/pr10020335>

JIANG, Q.; YAN, X.; HUANG, B. Review and Perspectives of Data-Driven Distributed Monitoring for Industrial Plant-Wide Processes. *Industrial & Engineering Chemistry Research*, v. 58, n. 29, p. 12899–12912, 2019. Disponível em: <https://doi.org/10.1021/acs.iecr.9b02391>

KONDAKCI, T.; ZHOU, W. Recent Applications of Advanced Control Techniques in Food Industry. *Food and Bioprocess Technology*, v. 10, n. 3, p. 522–542, 2017. Disponível em: <https://doi.org/10.1007/s11947-016-1831-x>

KUBO, M. T. K.; BAICU, A.; ERDOGDU, F.; POÇAS, M. F.; SILVA, C. L. M.; SIMPSON, R.; VITALI, A. A.; AUGUSTO, P. E. D. Thermal processing of food: Challenges, innovations and opportunities. A position paper. *Food Reviews International*, v. 39, n. 6, p. 3344–3369, 2023. Disponível em: <https://doi.org/10.1080/87559129.2021.2012789>

MELO, A.; CÂMARA, M. M.; PINTO, J. C. Data-Driven Process Monitoring and Fault Diagnosis: A Comprehensive Survey. *Processes*, v. 12, n. 2, p. 251, 2024. Disponível em: <https://doi.org/10.3390/pr12020251>

NADIM, K.; OUALI, M.-S.; GHEZZAZ, H.; RAGAB, A. Learn-to-supervise: Causal reinforcement learning for high-level control in industrial processes. *Engineering*

Applications of Artificial Intelligence, v. 126, p. 106853, 2023. Disponível em: <https://doi.org/10.1016/j.engappai.2023.106853>

QIN, S. J. Statistical process monitoring: basics and beyond. Journal of Chemometrics, v. 17, n. 8–9, p. 480–502, 2003. DOI: <https://doi.org/10.1002/cem.800>.

RIBEIRO-FURTINI, L. L.; ABREU, L. R. de. Utilização de APPCC na indústria de alimentos. Ciência e Agrotecnologia, v. 30, n. 2, p. 358–363, 2006. DOI: <https://doi.org/10.1590/S1413-70542006000200025>.

RUDIN, C. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. Nature Machine Intelligence, v. 1, p. 206–215, 2019. DOI: <https://doi.org/10.1038/s42256-019-0048-x>.

SANTOS, P. V. S.; OLIVEIRA, T. C. T. Case study on the application of quality tools in service level management. ITEGAM-Journal of Engineering and Technology for Industrial Applications, v. 5, p. 75–81, 2019.

SARMIENTO-RAMOS, J. L. Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica. Revista UIS Ingenierías, v. 19, n. 4, p. 1–18, 2020. DOI: <https://doi.org/10.18273/revuin.v19n4-2020001>.

SIMPSON, R.; JIMÉNEZ, D.; ALMONACID, S.; NUÑEZ, H.; PINTO, M.; RAMÍREZ, C.; VEGA-CASTRO, O.; FUENTES, L.; ANGULO, A. Assessment and outlook of variable retort temperature profiles for the thermal processing of packaged foods: Plant productivity, product quality, and energy consumption. Journal of Food Engineering, v. 275, p. 109839, 2020. Disponível em: <https://doi.org/10.1016/j.jfoodeng.2019.109839>

SOARES, L. M. C.; SILVA, A. C. G. C.; SILVA, J. C.; SANTOS, P. V. S. Previsão de demanda de peças sobressalentes utilizando rede neural artificial. Revista Eletrônica Sistemas & Gestão, v. 17, n. 3, p. 1, 2022. DOI: <https://doi.org/10.20985/1980-5160.2022.v17n3.1806>.

TARIFA, E. E.; MARTÍNEZ, S. L. Diagnóstico de fallas con redes neuronales: parte 1: reconocimiento de trayectorias. Ingeniería e Investigación, v. 27, n. 1, p. 68–76, 2007.

ZAREI, E.; KHAN, F.; ABBASSI, R. Importance of human reliability in process operation: A critical analysis. Reliability Engineering & System Safety, v. 211, p. 107607, 2021. Disponível em: <https://doi.org/10.1016/j.ress.2021.107607>

ZHANG, J.; REN, H.; REN, H.; CHAI, Y.; LIU, Z.; LIANG, X. Comprehensive Review of Safety Studies in Process Industrial Systems: Concepts, Progress, and Main Research Topics. Processes, v. 11, n. 8, p. 2454, 2023. Disponível em: <https://doi.org/10.3390/pr11082454>

## NOTAS

### DIRECCIÓN DE CORRESPONDENCIA DE LA AUTORÍA PRINCIPAL

Avenida Antônio Carlos Magalhães, n.º 510, barrio Santo Antônio, código postal 48902-300, Juazeiro, estado de Bahía, Brasil.

### AGRADECIMIENTOS

Los autores agradecen a la empresa TDA Ltda. su apoyo en la realización del estudio y la disponibilidad para facilitar el acceso a la información necesaria para su desarrollo.

### CONTRIBUCIÓN DE AUTORÍA

Conceptualización: P.V.S. Santos

Recopilación de datos: J. W. dos Santos. L.S. Lima y P.V.S. Santos.

Análisis de datos: J. W. dos Santos. L.S. Lima y P.V.S. Santos.

Discusión de los resultados: P.V.S. Santos.

Metodología: J. W. dos Santos.

Redacción del manuscrito: J. W. dos Santos y P.V.S. Santos.

Obtención de financiación: J. W. dos Santos. L.S. Lima y P.V.S. Santos.

Revisión y aprobación del manuscrito: J. W. dos Santos. L.S. Lima y P.V.S. Santos.

### CONSENTIMIENTO PARA EL USO DE IMÁGENES

No aplica.

### APROBACIÓN DEL COMITÉ DE ÉTICA EN INVESTIGACIÓN

No aplica.

### FINANCIACIÓN

No aplica.

### CONFLICTO DE INTERESES

Los autores declaran que no existe ningún conflicto de intereses relacionado con la realización de este estudio ni con la publicación de sus resultados.

### USO DE INTELIGENCIA ARTIFICIAL

Los autores declaran que se utilizó ChatGPT como herramienta de apoyo para la revisión textual del manuscrito y el ajuste del formato de las referencias bibliográficas. Los autores revisaron el contenido generado y asumen plena responsabilidad por la versión final del trabajo.

## LICENCIA DE USO

Las personas autoras ceden a la Revista IJIE – Iberoamerican Journal of Industrial Engineering los derechos exclusivos de primera publicación, quedando el trabajo simultáneamente licenciado bajo la Licencia Creative Commons Attribution (CC BY) 4.0 International. Esta licencia permite que terceros compartan, adapten, transformen y desarrollen el trabajo publicado, siempre que se otorgue el debido reconocimiento a la autoría y a la publicación original en esta revista. Las personas autoras también están autorizadas a celebrar acuerdos adicionales e independientes para la distribución no exclusiva de la versión publicada del trabajo (por ejemplo, depositarla en un repositorio institucional, publicarla en un sitio web personal, publicar una traducción o incluirla como capítulo de un libro), siempre que se reconozca la autoría y la publicación original en esta revista.

## EDITORIAL

Universidade Federal de Santa Catarina (UFSC)  
Programa de Pós-graduação em Engenharia de Produção

Las ideas expresadas en este artículo son responsabilidad exclusiva de las personas autoras y no representan necesariamente la opinión de los editores ni de la Universidad.

## EDITORA

Dra. Viviane Vasconcellos Ferreira Grubisic

## HISTORIAL

Recibido: 26-08-2026

Aceptado: 09-10-2026