

## **DISEÑO DE UN SISTEMA DE CONTROL MEDIANTE LA APLICACIÓN DE REDES NEURONALES PARA EL CONTROL DE TEMPERATURA EN UN HORNO DE TERMOFORMADO.**

### **DESIGN OF A CONTROL SYSTEM USING NEURAL NETWORKS FOR TEMPERATURE CONTROL IN A THERMOFORMING OVEN.**

**Autores:** <sup>1</sup>José Luis Cortés Llanganate y <sup>2</sup>Mario Efraín Audelo Guevara.

<sup>1</sup>ORCID ID: <https://orcid.org/0000-0002-3228-2669>

<sup>2</sup>ORCID ID: <https://orcid.org/0000-0002-0932-8876>

<sup>1</sup>E-mail de contacto: [jose.cortes@unach.edu.ec](mailto:jose.cortes@unach.edu.ec)

<sup>2</sup>E-mail de contacto: [maudelo@unach.edu.ec](mailto:maudelo@unach.edu.ec)

Afiliación:<sup>1\*</sup><sup>2\*</sup>Universidad Nacional de Chimborazo, (Ecuador).

Artículo recibido: 09 de Abril del 2026

Artículo revisado: 11 de Abril del 2026

Artículo aprobado: 13 de Abril del 2026

<sup>1</sup>Ingeniero en Electronica Control y Redes Industriales, egresado de la Escuela Superior Politecnica de Chimborazo, (Ecuador), Magister en Sistemas de Control y Automatizacion Industrial, egreaddo de la Escuela Superior Politecnica de Chimborazo, (Ecuador).

<sup>2</sup>Doctor en Fisica, egresado de la Escuela Superior Politecnica de Chimborazo, (Ecuador). Magister en Matematica Aplicada mencion Modelacion Matematica y Simulacion Numerica, egresado de la Escuela Superior Politecnica de Chimborazo, (Ecuador).

#### **Resumen**

En el presente trabajo se desarrolla el diseño e implementación de un sistema de control de temperatura adaptativo para un horno de termoformado, basado en la integración de una red neuronal artificial con un controlador PID. Se parte del análisis de un controlador PI convencional, en el cual se identifican limitaciones en términos de sobre oscilación, variabilidad en la respuesta y baja capacidad de rechazo ante perturbaciones, lo que motiva la adopción de una estructura PID. Se diseña una red neuronal encargada de ajustar dinámicamente las ganancias del controlador mediante el cálculo de los incrementos  $\Delta k_p$ ,  $\Delta k_i$  y  $\Delta k_d$ , utilizando métricas de desempeño como variables de entrada. El modelo se entrena a partir de múltiples escenarios de operación que incluyen cambios de referencia y perturbaciones en el sistema. El sistema adaptativo se implementa en un entorno de simulación en MATLAB/Simulink, donde se evalúa su desempeño frente a un controlador convencional. Los resultados evidencian una mejora en la estabilidad del sistema, una reducción de la sobre oscilación y una mayor robustez ante perturbaciones. El controlador propuesto mantiene la temperatura dentro de un rango de  $\pm 1^\circ\text{C}$  respecto a la referencia. Los resultados obtenidos posicionan al enfoque

propuesto como una alternativa eficiente para el control de procesos térmicos no lineales.

**Palabras clave:** Control de temperatura, Control PID adaptativo, Red neuronal, Retro propagación, Sistemas no lineales.

#### **Abstract**

This work presents the design and implementation of an adaptive temperature control system for a thermoforming oven, based on the integration of an artificial neural network with a PID controller. The study begins with the analysis of a conventional PI controller, where limitations are identified in terms of overshoot, response variability, and low disturbance rejection capability, which motivates the adoption of a PID structure. A neural network is designed to dynamically adjust the controller gains by computing the increments  $\Delta k_p$ ,  $\Delta k_i$  and  $\Delta k_d$ , using performance metrics as input variables. The model is trained using multiple operating scenarios, including setpoint changes and system disturbances. The adaptive system is implemented in a MATLAB/Simulink simulation environment, where its performance is evaluated against a conventional controller. The results show an improvement in system stability, a reduction in overshoot, and greater robustness to disturbances. The proposed controller

maintains the temperature within a range of  $\pm 1^\circ\text{C}$  with respect to the reference value. The obtained results position the proposed approach as an efficient alternative for the control of nonlinear thermal processes.

**Keywords: Temperature control, Adaptive PID control, Neural network, Feedback, Nonlinear systems.**

### **Sumário**

Este trabalho apresenta o projeto e a implementação de um sistema de controle adaptativo de temperatura para um forno de termoformagem, baseado na integração de uma rede neural artificial com um controlador PID. O estudo começa com a análise de um controlador PI convencional, onde são identificadas limitações em termos de sobreimpulso, variabilidade de resposta e baixa capacidade de rejeição de perturbações, o que motiva a adoção de uma estrutura PID. Uma rede neural é projetada para ajustar dinamicamente os ganhos do controlador, calculando os incrementos  $\Delta k_p$ ,  $\Delta k_i$  e  $\Delta k_d$ , usando métricas de desempenho como variáveis de entrada. O modelo é treinado usando múltiplos cenários operacionais, incluindo mudanças de ponto de ajuste e perturbações do sistema. O sistema adaptativo é implementado em um ambiente de simulação MATLAB/Simulink, onde seu desempenho é avaliado em comparação com um controlador convencional. Os resultados mostram uma melhoria na estabilidade do sistema, uma redução no sobreimpulso e maior robustez a perturbações. O controlador proposto mantém a temperatura dentro de uma faixa de  $\pm 1^\circ\text{C}$  em relação ao valor de referência. Os resultados obtidos posicionam a abordagem proposta como uma alternativa eficiente para o controle de processos térmicos não lineares.

**Palavras-chave: Controle de temperatura, Controle PID adaptativo, Rede neural, Realimentação, Sistemas não lineares.**

### **Introducción**

La producción de plástico a nivel mundial ha crecido significativamente desde la década de 1950, por su versatilidad y amplia aplicación en envases, productos de uso cotidiano y construcción. (Jiménez et al., 2023). La industria del plástico ha experimentado un crecimiento impulsado por la demanda en sectores como la construcción y el transporte, aportando cerca del 4% al PIB industrial y generando empleo para más de 200.000 trabajadores. No obstante, diversas empresas del sector presentan bajos niveles de disponibilidad en sus procesos productivos (Seborg et al., 2016).

Varios estudios señalan que estos bajos niveles de disponibilidad se deben a los largos tiempos de preparación y paradas por fallas en el equipamiento, por una inadecuada automatización, pues para cada proceso productivo se debe configurar los equipos, lo que resta tiempo a la producción y genera una cantidad importante de tiempos muertos; es así que varios autores proponen la implementación de herramientas de modelación matemática y aprendizaje autónomo para reducir tiempos de configuración y paradas excesivas, lo que garantizaría una producción constante (Bai et al., 2024; Tsamatsoulis, 2025).

Actualmente la industria de plástico experimenta transformaciones importantes, de manera especial en la eficiencia de los procesos productivos, para reducir tiempos y defectos, Jiménez y otros (Ghazali et al., 2019) en su estudio, identificaron una eficiencia productiva del 73%, que es inferior en comparación con otras industrias manufactureras y determinaron que las causas principales son los tiempos prolongados de reparación o configuración de elementos de automatización, ante esta problemática se plantea soluciones matemáticas

y de control que permitan reducir estos fallos (SB y Thangavel, 2026). Una técnica ampliamente utilizada para la producción de este plástico es el termoformado, que se caracteriza por su alto grado de automatización, por lo que su disponibilidad resulta clave para mantener la productividad (Zhu et al., 2024).

El control de procesos industriales ha evolucionado debido a la incorporación de técnicas de inteligencia artificial que permite mejorar la precisión, adaptabilidad y robustez de los sistemas de control, y precisamente, procesos industriales como el termoformado de plásticos y el control de temperatura son factores críticos, que influyen directamente en la calidad del producto final y de la eficiencia del proceso productivo (Chen et al., 2026). Diversos estudios han analizado la aplicación de técnicas de inteligencia artificial para mejorar el desempeño de sistemas de control tradicionales, en investigaciones actuales se ha evaluado controladores proporcional-integral (PI), proporcional-integral-derivativo (PID) y controladores fraccionales (FOPI/FOPID), que se configuran mediante inteligencia artificial como redes neuronales artificiales, sistemas de inferencia neuro difusa adaptativa y aprendizaje por refuerzo (Liu et al., 2024).

Varios estudios han demostrado que estos controladores optimizados mediante inteligencia artificial presentan un mejor desempeño dinámico, reducción de sobre impulso y mayor estabilidad frente a variaciones en la carga, lo que evidencia que estas técnicas matemáticas y computacionales mejoran el control en sistemas electrónicos complejos (Pal y Nestorovic, 2021). Existen otras propuestas con enfoque híbrido que combinan controladores clásicos con técnicas de aprendizaje automático, un ejemplo es el uso de controladores PID y reguladores cuadráticos

lineales (LQR) mediante una red neuronal de aprendizaje con refuerzo (Shuraiji y Shneen, 2025), a partir de esta técnica se mostraron mejoras significativas en el desempeño del sistema, con una reducción de estabilidad del 68.3% y una disminución del sobre impulso del 45.5%, lo que demuestra la capacidad de los métodos inteligentes para optimizar estos sistemas de control (Zhao et al., 2025).

Para el ámbito de sistemas industriales de medición y control, se han desarrollado soluciones que combinan herramientas de simulación con modelos de aprendizaje automático. En varias investigaciones se presentan diseños de controladores PID, utilizando MATLAB/Simulink y además el uso de modelos de redes neuronales para el análisis predictivo del comportamiento del sistema, lo que mejora en un 15% la precisión de las mediciones y un incremento del 20% en la estabilidad del sistema, lo que evidencia que la integración de estas herramientas mejora significativamente la confiabilidad y desempeño de los sistemas industriales (Fathi et al., 2025).

Las redes neuronales artificiales han sido ampliamente utilizadas para mejorar la adaptabilidad de los controladores PID frente a cambios en las condiciones de operación, de forma tradicional el ajuste de los parámetros del controlador se realiza mediante métodos clásicos como el método de Ziegler-Nichols (Govind, 2026), el cual proporciona valores constantes para las ganancias del controlador. Sin embargo, estos métodos presentan limitaciones cuando el sistema experimenta variaciones en sus parámetros o perturbaciones externas. Para superar estas limitaciones, en estudios propone un controlador PID autoajutable basado en redes neuronales, en el cual una red neuronal artificial se encarga de

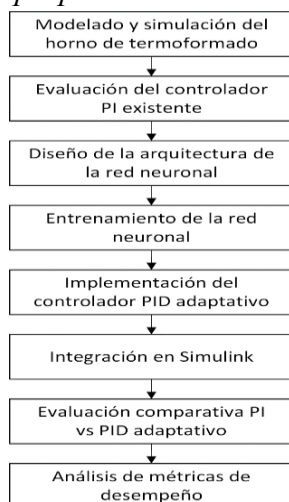
modificar dinámicamente los parámetros del controlador en función del comportamiento del sistema, pues presenta una respuesta más robusta frente a perturbaciones y retardos de tiempo en comparación con el controlador tradicional (Yakout et al., 2024).

Estudios recientes evidencian que la incorporación de técnicas de inteligencia artificial, particularmente redes neuronales y algoritmos de aprendizaje automático, permite superar las limitaciones de los controladores tradicionales al proporcionar mayor capacidad de adaptación (Sui y Huang, 2026), robustez frente a perturbaciones y mejor desempeño en sistemas no lineales (Van et al., 2026). La aplicación de redes neuronales en el diseño de sistemas de control representa una alternativa prometedora para optimizar procesos industriales que requieren alta precisión, como el control de temperatura en hornos de termoformado (Weiss et al., 2026).

### **Materiales y Métodos**

La metodología seguida para la ejecución de este estudio se resume gráficamente a través de la Figura 1.

**Figura 1.** Metodología utilizada. Fuente: Elaboración propia.



Fuente: Elaboración propia

En el presente trabajo se ha utilizado el modelo matemático del horno resistivo para la producción de planchas termoformadas (Castro y Cortés, 2022), el cual describe el comportamiento térmico del sistema a partir del análisis de los principales fenómenos de transferencia de calor que intervienen en el proceso. El horno analizado corresponde a un equipo de fabricación local empleado en una planta de producción ubicada en la ciudad de Riobamba.

Su estructura presenta forma de paralelepípedo y está conformada por dos cajas metálicas: una interior y otra exterior, construidas con láminas de acero galvanizado de 2 mm de espesor. Ambas estructuras se encuentran separadas aproximadamente 5 cm y entre ellas se dispone un material aislante de fibra de vidrio, compuesto por una mezcla de arenas, boratos y silicatos. Este material permite reducir las pérdidas térmicas hacia el exterior y mantener un perfil de temperatura relativamente estable dentro de la cámara de calentamiento. El sistema de calentamiento del horno se basa en resistencias eléctricas óhmicas que generan calor mediante el efecto Joule. La energía térmica producida es transferida hacia el interior del horno y hacia las planchas en proceso de termoformado a través de los mecanismos de conducción, convección y radiación.

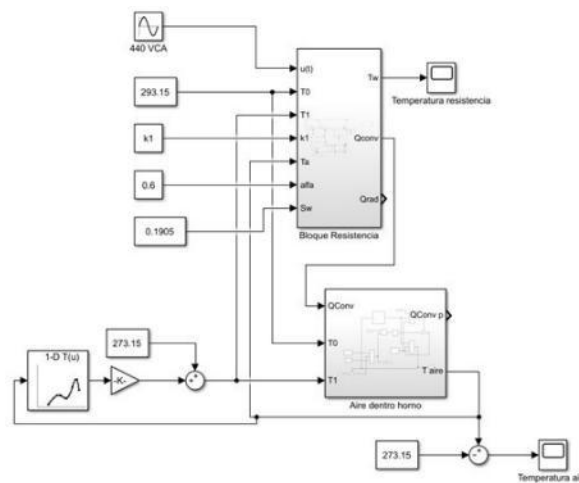
En el estudio previo se analizaron estos fenómenos físicos y se formularon las ecuaciones que describen el comportamiento dinámico del sistema térmico. Para la obtención del modelo matemático, el funcionamiento del horno se ha dividido en tres componentes principales. En primer lugar, se han formulado las ecuaciones que describen el calentamiento de las resistencias eléctricas. Posteriormente, se han planteado las ecuaciones asociadas a la

transferencia de calor desde las resistencias hacia el interior del horno mediante los fenómenos de radiación y convección. Finalmente, se han considerado las ecuaciones relacionadas con el calentamiento de las paredes del horno y las pérdidas de calor a través de la estructura del sistema. Debido a la ausencia de información detallada sobre algunas propiedades térmicas del material aislante presente en las paredes del horno, ciertos parámetros del modelo han sido estimados a partir de datos experimentales obtenidos mediante el sistema de adquisición de datos del equipo. Esto ha permitido complementar el modelo teórico con información proveniente del sistema real y mejorar su representatividad.

Las ecuaciones obtenidas en dicho estudio han sido implementadas en el entorno de simulación Simulink, lo que ha permitido reproducir el perfil de temperatura del horno bajo diferentes condiciones de operación, Figura 2. Asimismo, el modelo ha sido validado mediante la comparación con datos experimentales del sistema real y con modelos obtenidos mediante técnicas de identificación de sistemas, evidenciando un mejor ajuste al comportamiento físico del horno.

En el presente trabajo, este modelo matemático previamente validado se ha utilizado como base para la simulación del proceso térmico del horno de termoformado. A partir de este modelo se evaluará el desempeño del controlador existente y posteriormente se desarrollará la estrategia de control adaptativo basada en redes neuronales artificiales.


**Figura 2.** Implementación del modelo matemático en Simulink.



Fuente: Elaboración propia

El sistema de control actualmente utilizado en el horno de termoformado ha sido implementado mediante un controlador proporcional-integral (PI), cuyo objetivo es regular la temperatura del horno durante el proceso de calentamiento de las planchas termoformadas. En el estudio previo se ha implementado el controlador PI en el modelo matemático del horno dentro del entorno de simulación, lo que ha permitido analizar su desempeño en el seguimiento de la referencia controlador es funcional y permite mantener la temperatura del sistema dentro de rangos operativos adecuados para el proceso de termoformado. de temperatura, Figura 3 Los resultados obtenidos han evidenciado que el controlador es funcional y permite mantener la temperatura del sistema dentro de rangos operativos adecuados para el proceso de termoformado.

**Figura 3.** Esquema del sistema de control implementado mediante un controlador PI.



Fuente: Elaboración propia.

Sin embargo, el proceso térmico del horno se ha caracterizado por estar expuesto a diversas perturbaciones e incertidumbres inherentes a su operación, tales como variaciones en las condiciones ambientales, cambios en las propiedades térmicas del material procesado, pérdidas de calor a través de la estructura del horno y variaciones en la carga térmica durante el proceso productivo. Estas condiciones pueden afectar el desempeño del sistema de control, generando desviaciones respecto a la temperatura de referencia o respuestas dinámicas menos eficientes.

Considerando estas características del proceso, se ha planteado la necesidad de analizar estrategias de control más avanzadas que permitan mejorar el comportamiento del sistema frente a dichas perturbaciones. En este contexto, en el presente trabajo se ha propuesto el desarrollo de un sistema de control adaptativo basado en redes neuronales artificiales, el cual permitirá ajustar dinámicamente las ganancias del controlador en función del estado del sistema. Para continuar con el análisis del sistema de control del horno de termoformado, y partiendo del controlador PI previamente implementado, se ha procedido a calcular un controlador proporcional-integral-derivativo (PID). Esta ampliación del esquema de control tiene como finalidad mejorar la respuesta dinámica del sistema y proporcionar una mayor capacidad de adaptación frente a perturbaciones presentes en el proceso térmico. El controlador

PI existente ha demostrado ser funcional para la regulación de la temperatura del horno; sin embargo, su estructura limita la capacidad de anticipación ante cambios rápidos en la dinámica del sistema. En particular, este tipo de controlador puede presentar tiempos de respuesta más prolongados y una menor capacidad para amortiguar variaciones bruscas en la temperatura, especialmente cuando el proceso se ve afectado por perturbaciones externas o cambios en las condiciones de operación. Según varios estudios realizados por diferentes autores (Åström y Hägglund, 2006; Seborg et al., 2016), un controlador PID se puede calcular a partir de un controlador PI. Para ello el tiempo derivativo se calcula con se muestra en la Ecuación (1):

$$T_d = \alpha \cdot T_i \quad (1)$$

donde típicamente:

$$0.1 \leq \alpha \leq 0.25 \quad (2)$$

Se desarrolló un conjunto de pruebas para los varios valores de  $\alpha$ , donde se ha determinado que el valor que mejor responde es  $\alpha=0.2$ . El resultado que se ha obtenido proporciona un compromiso adecuado entre rapidez de respuesta y robustez frente al ruido en la señal de control. Se ha determinado el punto de operación del horno que es de interés para el análisis respectivo. El mismo responde a temperaturas que van de 120 °C a 140 °C para los distintos tipos de productos que se obtienen en la termoformadora. A pesar de que el controlador PID diseñado ha permitido regular la temperatura del horno en torno al punto de operación definido, durante el análisis de las respuestas del sistema en las simulaciones se ha observado que aún se presentan variaciones en la temperatura ante cambios en la referencia y posibles perturbaciones en el proceso. Estas

variaciones se han asociado principalmente a la elevada inercia térmica del sistema y a las características dinámicas propias de los procesos térmicos.

En este contexto, se ha evidenciado que un controlador PID con parámetros fijos puede presentar limitaciones para mantener un desempeño óptimo en todas las condiciones de operación del sistema. Debido a que las ganancias del controlador permanecen constantes durante la operación, cualquier cambio en las condiciones dinámicas del proceso puede provocar variaciones en el desempeño del control, tales como incrementos en el error de seguimiento, tiempos de respuesta prolongados o la presencia de oscilaciones en la variable de proceso.

Considerando estas limitaciones, se ha planteado la implementación de un controlador PID adaptativo, el cual permite ajustar dinámicamente las ganancias del controlador en función del comportamiento observado del sistema. Este enfoque ha permitido introducir un mecanismo de adaptación capaz de modificar los parámetros del controlador con el propósito de mejorar la respuesta dinámica del sistema y reducir las variaciones de temperatura durante la operación del horno.

Con el propósito de desarrollar el modelo de aprendizaje automático propuesto, se ha generado un conjunto de datos experimentales a partir de simulaciones del sistema de control del horno eléctrico. Estos experimentos han permitido obtener información representativa del comportamiento dinámico del sistema bajo diferentes configuraciones del controlador. El proceso térmico analizado presenta un rango de operación comprendido aproximadamente entre 120 °C y 140 °C, siendo 130 °C el punto de operación nominal del sistema. Con base en

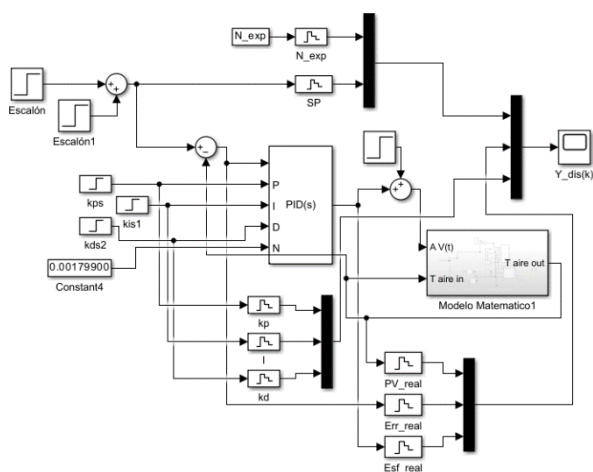
estas condiciones de funcionamiento, se han diseñado los experimentos de simulación considerando variaciones de referencia en el entorno de dicho punto de operación, con el fin de analizar la respuesta dinámica del sistema.

En cada experimento se ha estabilizado inicialmente el sistema en una referencia de 120 °C, tras lo cual se ha aplicado un cambio escalón en la referencia hacia 140 °C. Este procedimiento ha permitido observar el comportamiento transitorio del sistema durante el proceso de seguimiento de referencia y analizar la respuesta del controlador bajo diferentes condiciones de operación. De igual forma se ha realizado cambios de mayor a menor grado, pues esto representa una operación real de la planta en sí. El cambio escalón aplicado en la referencia se ha complementado con la variación sistemática de las ganancias del controlador PID durante la realización de los experimentos de simulación. Para ello, se han considerado distintas combinaciones de los parámetros  $k_p$ ,  $k_i$  y  $k_d$ , con el propósito de analizar cómo influyen estas configuraciones en la respuesta dinámica del sistema.

Esta estrategia ha permitido generar diferentes comportamientos del controlador frente al mismo cambio de referencia, lo que ha facilitado la obtención de un conjunto de datos más representativo del desempeño del sistema bajo diversas condiciones de control. Como resultado, se han obtenido múltiples respuestas del sistema que han servido como base para el posterior procesamiento de los datos y la extracción de las métricas utilizadas en el entrenamiento de la red neuronal. En la Figura 4 se observa la configuración a la simulación del proceso para obtener la información necesaria. Se ha almacenado los datos generados aplicando un tiempo de muestreo de

1 segundo. Todas esas simulaciones han sido transferidas al *Workspace* para su almacenamiento y procesamiento.

**Figura 4.** Esquema de simulación para la obtención de datos.



Fuente: Elaboración propia.

Durante cada simulación se han registrado las principales variables del sistema, entre las que se incluyen: Tiempo de simulación ( $t$ ); Referencia del sistema (Setpoint,  $SP$ ); Variable de proceso (Process value,  $PV$ ); Error de control ( $E = SP - PV$ ). A partir de estas variables se ha obtenido el error de control, el cual ha sido utilizado como indicador principal para evaluar el desempeño del sistema de control. Los datos generados durante las simulaciones han sido procesados. Esto incluye la limpieza de los datos al seleccionar los datos útiles (generados posterior a la aplicación de los distintos escalones).

Se ha realizado un análisis adicional del comportamiento del error de control con el objetivo de extraer características relevantes que permitan describir el desempeño dinámico del sistema. Para este propósito se ha empleado un enfoque basado en ventanas temporales de análisis, dentro de las cuales se han calculado diferentes métricas del error. Entre las métricas

consideradas se encuentran el error absoluto medio (MAE), la desviación estándar del error y la pendiente del error. El error absoluto medio (MAE) se ha utilizado como una medida del desempeño global del sistema dentro de cada ventana temporal, permitiendo cuantificar el error promedio de seguimiento entre la referencia y la variable de proceso.

La desviación estándar del error se ha empleado para evaluar la variabilidad del error dentro de la ventana de análisis, lo que permite identificar la presencia de oscilaciones o comportamientos inestables en la respuesta del sistema. Por otra parte, la pendiente del error se ha utilizado para capturar la tendencia dinámica del sistema dentro de la ventana temporal analizada. Este indicador permite identificar si el error presenta un comportamiento creciente, decreciente o cercano al estado estacionario, proporcionando información sobre la velocidad de convergencia del sistema hacia la referencia. La selección de estas métricas se ha fundamentado en su capacidad para describir distintos aspectos del desempeño del sistema de control, tales como la magnitud del error, la estabilidad de la respuesta y la tendencia dinámica del proceso.

En conjunto, estas variables han permitido caracterizar el estado del sistema y han sido utilizadas como variables de entrada para el entrenamiento de la red neuronal encargada de estimar los ajustes de las ganancias del controlador. Con el objetivo de implementar el mecanismo de adaptación del controlador, se ha seleccionado el uso de una red neuronal artificial capaz de estimar ajustes en las ganancias del controlador PID a partir del comportamiento dinámico del sistema. Este enfoque permite establecer una relación no lineal entre las métricas de desempeño obtenidas del sistema y las variaciones requeridas en los parámetros del controlador.

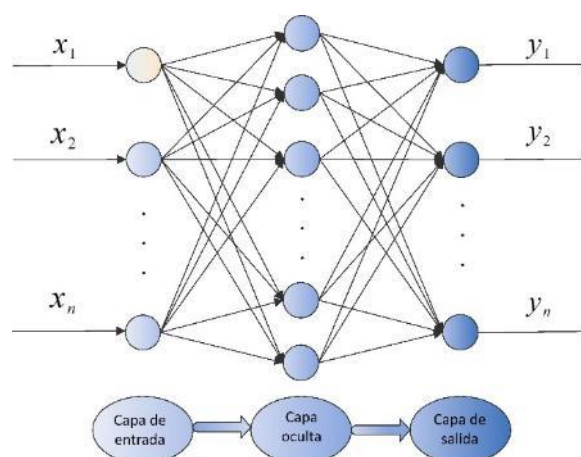
Para este propósito, se ha seleccionado una red neuronal del tipo *feedforward* multicapa (MLP, *Multi-Layer Perceptron*), debido a su capacidad para aproximar funciones no lineales y modelar relaciones complejas entre variables de entrada y salida. Este tipo de arquitectura ha sido ampliamente utilizado en aplicaciones de control adaptativo, ya que permite aprender patrones presentes en los datos y generalizar su comportamiento ante nuevas condiciones de operación.

Diversos estudios recientes han demostrado que este tipo de arquitectura permite aproximar relaciones no lineales entre las variables de desempeño del sistema y los parámetros del controlador, facilitando la adaptación de las ganancias ante cambios en la dinámica del proceso. En particular, trabajos recientes han empleado redes neuronales entrenadas mediante algoritmos de retro propagación para estimar los parámetros  $k_p$ ,  $k_i$  y  $k_d$ , logrando mejoras significativas en la respuesta dinámica del sistema frente a controladores PID convencionales (Demirtaş, 2023; Krok et al., 2025; Liu et al., 2023).

La red neuronal utilizada en este trabajo corresponde a una red neuronal artificial multicapa de tipo *feedforward*, también conocida como perceptrón multicapa (MLP). Esta arquitectura está compuesta por tres tipos de capas: una capa de entrada, una capa oculta y una capa de salida, tal como se muestra en la figura correspondiente. La capa de entrada recibe las variables que describen el comportamiento del sistema, las cuales son procesadas mediante conexiones ponderadas hacia la capa oculta, donde se realiza la transformación no lineal de la información mediante funciones de activación. Esta capa permite capturar las relaciones complejas existentes entre las variables del sistema.

Finalmente, la capa de salida genera las respuestas estimadas por la red neuronal, las cuales, en el contexto de este trabajo, corresponden a los valores asociados al proceso de adaptación del controlador. Esta estructura multicapa permite modelar relaciones no lineales entre las variables de entrada y salida, lo que la convierte en una herramienta adecuada para aplicaciones de identificación y control en sistemas dinámicos. En la Figura 5 se observa la estructura básica de una red neuronal tipo MLP.

**Figura 5.** Estructura básica de una red neuronal de tipo perceptrón multicapa (MLP).



Fuente: Elaboración propia.

La arquitectura de la red neuronal se ha definido considerando como variables de entrada las métricas extraídas del análisis del error de control en ventanas temporales del sistema. En particular, se han utilizado tres indicadores que describen el desempeño dinámico del controlador: el error absoluto medio (MAE), la desviación estándar del error y la pendiente del error. Estas variables permiten capturar información relacionada con la magnitud del error, la estabilidad de la respuesta y la tendencia dinámica del sistema. En cuanto a las salidas de la red neuronal, se ha definido un conjunto de tres variables correspondientes a

los ajustes requeridos en las ganancias del controlador, representadas como  $\Delta k_p$ ,  $\Delta k_i$  y  $\Delta k_d$ . Esta relación se muestra en la Ecuación (3).

$$f(MAE, \sigma, pendiente) \rightarrow (\Delta k_p, \Delta k_i, \Delta k_d) \quad (3)$$

Estas salidas permiten modificar de manera incremental las ganancias del controlador PID durante la operación del sistema, de modo que las nuevas ganancias se obtienen a partir de la Ecuación (4):

$$k_{nuevo} = k_{anterior} + \Delta k \quad (4)$$


Donde  $\Delta k$  representa el ajuste estimado por la red neuronal para cada uno de los parámetros del controlador.

La red neuronal ha sido estructurada con una capa de entrada compuesta por tres neuronas, correspondientes a las métricas de desempeño utilizadas como variables de entrada, una capa oculta encargada de capturar las relaciones no lineales presentes en los datos y una capa de salida formada por tres neuronas, asociadas a los ajustes de las ganancias del controlador. Esta configuración ha permitido construir un modelo capaz de aprender la relación existente entre el comportamiento dinámico del sistema y las modificaciones necesarias en los parámetros del controlador, constituyendo así el núcleo del esquema de control PID adaptativo propuesto.

Una vez definida la arquitectura de la red neuronal, se ha realizado el proceso de entrenamiento utilizando el conjunto de datos generado a partir de los experimentos de simulación. El objetivo del entrenamiento ha sido aprender la relación existente entre las métricas de desempeño del sistema y los ajustes necesarios en las ganancias del controlador PID. Previo al entrenamiento, el conjunto de datos disponible se ha dividido en tres subconjuntos independientes con el fin de evaluar

adecuadamente la capacidad de generalización del modelo. En particular, el 70% de los datos se ha utilizado para el entrenamiento de la red, mientras que el 15% se ha destinado al proceso de validación y el 15% restante se ha reservado para la evaluación final del modelo. Esta estrategia permite evitar el sobreajuste del modelo y evaluar su desempeño frente a datos no utilizados durante el entrenamiento. En la Figura 6 se observa la estructura de la red utilizada en el presente trabajo con 3 entradas, 12 neuronas ocultas y 3 salidas.

**Figura 6.** Estructura de la red neuronal utilizada.



Fuente: Elaboración propia.

Se ha realizado la normalización de los datos de entrada y salida con el fin de mejorar la estabilidad numérica del entrenamiento y acelerar la convergencia del algoritmo de

aprendizaje. Para ello, se ha aplicado una normalización basada en la media y la desviación estándar de los datos del conjunto de entrenamiento, de modo que cada variable ha sido transformada según (5).

$$x_{norm} = \frac{x - \mu}{\sigma} \quad (5)$$

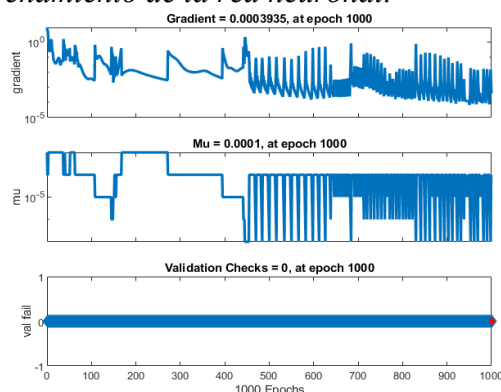
Donde  $\mu$  corresponde a la media de la variable y  $\sigma$  a su desviación estándar. Los mismos parámetros de normalización obtenidos a partir del conjunto de entrenamiento se han utilizado para transformar los conjuntos de validación y prueba.

En cuanto al proceso de aprendizaje, se ha empleado el algoritmo de entrenamiento de Levenberg–Marquardt, el cual es ampliamente utilizado en redes neuronales tipo *feedforward* debido a su rápida convergencia y buen desempeño en problemas de aproximación de funciones (Liu et al., 2023). Este algoritmo ha permitido ajustar los pesos de la red neuronal minimizando el error cuadrático medio entre las salidas estimadas por la red y los valores reales presentes en el conjunto de entrenamiento.

La arquitectura final de la red se ha definido con una única capa oculta compuesta por doce neuronas. Esta configuración ha sido seleccionada debido a que las redes con una sola capa oculta han demostrado ser capaces de aproximar funciones no lineales complejas, manteniendo al mismo tiempo una estructura relativamente simple que facilita el entrenamiento y reduce el riesgo de sobreajuste. En la capa oculta se ha utilizado la función de activación tangente sigmoideal (*tansig*), mientras que en la capa de salida se ha empleado una función lineal (*purelin*), adecuada para problemas de regresión continua (Laabid et al., 2023). Durante el proceso de

entrenamiento se ha establecido un máximo de 1000 épocas de aprendizaje y un criterio de convergencia basado en alcanzar un error objetivo de  $10^{-6}$ . Una vez finalizado el entrenamiento, el modelo obtenido ha sido evaluado utilizando el conjunto de datos de prueba, calculando métricas de desempeño tales como el error absoluto medio (MAE) y el coeficiente de determinación  $R^2$ , con el fin de verificar la capacidad del modelo para predecir adecuadamente los ajustes requeridos en las ganancias del controlador. En la Figura 7 se observa los indicadores del proceso de entrenamiento de la red neuronal.

**Figura 7.** Indicadores del proceso de entrenamiento de la red neuronal.




Fuente: Elaboración propia.

Como resultado del proceso de entrenamiento, se ha observado que la red neuronal ha alcanzado la época máxima establecida de 1000 iteraciones. El valor del gradiente obtenido, igual a 0.0003935, ha evidenciado una reducción significativa en los ajustes realizados sobre los pesos sinápticos, lo que indica que el algoritmo de optimización se ha aproximado a una condición de convergencia. Asimismo, el parámetro  $\mu$  ha presentado valores bajos, lo que sugiere que el algoritmo de entrenamiento basado en Levenberg–Marquardt ha operado en una fase de refinamiento del mínimo del error. Por otra parte, no se han registrado

verificaciones de validación durante el proceso, lo que indica que el criterio de parada asociado al conjunto de validación no ha sido activado y, en consecuencia, el entrenamiento se ha desarrollado hasta alcanzar el número máximo de épocas definido.

A partir del histograma de error obtenido durante el proceso de entrenamiento, Figura 8 se ha observado que la mayoría de los errores se concentran en valores cercanos a cero, lo que evidencia que la red neuronal ha logrado aproximar adecuadamente los valores objetivo. Asimismo, la distribución de los errores presenta una forma aproximadamente simétrica alrededor del valor cero, lo que indica que no se ha producido un sesgo significativo en las predicciones del modelo. Aunque se han identificado algunos errores de mayor magnitud en los extremos de la distribución, estos se presentan con baja frecuencia, por lo que su influencia en el desempeño global de la red neuronal resulta limitada.

**Figura 8.** Histograma de error del entrenamiento de la red neuronal.



Fuente: Elaboración propia.

En la Tabla 1 se observa los resultados de los procesos de validación calculados para la red neuronal. Se han obtenido los valores del error absoluto medio (MAE) y del coeficiente de

determinación ( $R^2$ ) para cada una de las salidas asociadas a los incrementos de las ganancias del controlador PID. Estos indicadores han permitido evaluar la capacidad del modelo para aproximar los valores objetivo durante la etapa de validación.

Los resultados obtenidos han mostrado que el modelo presenta un adecuado nivel de ajuste, especialmente en las salidas correspondientes a las ganancias  $\Delta k_i$  y  $\Delta k_d$ , donde se han registrado valores elevados del coeficiente de determinación. Esto ha indicado que la red neuronal ha logrado capturar de manera adecuada la relación existente entre las variables de entrada y las variaciones de dichas ganancias. En el caso de la ganancia  $\Delta k_p$ , aunque el valor de  $R^2$  ha sido menor en comparación con las otras salidas, el modelo ha mantenido una capacidad aceptable para explicar la variabilidad de los datos.

Los valores del error absoluto medio han permitido observar que las diferencias promedio entre los valores estimados por la red neuronal y los valores objetivo se han mantenido dentro de rangos reducidos, lo que ha evidenciado una adecuada capacidad de predicción del modelo. Estos resultados han indicado que la red neuronal ha alcanzado un desempeño satisfactorio para la estimación de los incrementos de las ganancias del controlador PID.

**Tabla 1.** Resultados de validación de la red neuronal.


Salida	MAE	$R^2$
$\Delta k_p$	0.1358	0.7581
$\Delta k_i$	0.0001	0.9066
$\Delta k_d$	70.393	0.9450

Fuente: Elaboración propia.

Para finalizar esta etapa, el modelo entrenado ha sido exportado para su implementación en el

entorno de simulación, permitiendo su integración dentro del esquema de control adaptativo desarrollado en Simulink. En la Figura 9 se observa los bloques creados para Simulink de la red neuronal entrenada mediante el comando *gensim()*.

**Figura 9.** Representación en Simulink de la red neuronal entrenada.



Fuente: Elaboración propia.

Una vez finalizado el proceso de entrenamiento de la red neuronal, el modelo obtenido se ha integrado en el esquema de control con el propósito de actuar como un mecanismo de adaptación en línea de las ganancias del controlador PID. De esta manera, la red neuronal ha sido empleada para estimar los incrementos necesarios en los parámetros del controlador a partir del desempeño observado del sistema. El algoritmo de adaptación se ha implementado de forma periódica durante la ejecución de la simulación. En primer lugar, el sistema ha operado utilizando los valores actuales de las ganancias del controlador PID. Posterior, cada 500 segundos de operación se ha realizado una evaluación del desempeño del sistema mediante el cálculo de las métricas previamente definidas.

Estas métricas han sido utilizadas como variables de entrada para la red neuronal entrenada. A partir de estas entradas, la red neuronal ha generado como salidas los diferenciales asociados a las ganancias del controlador, correspondientes a  $\Delta k_p$ ,  $\Delta k_i$  y  $\Delta k_d$ . Dichos diferenciales representan las variaciones

necesarias en cada parámetro con el objetivo de mejorar el comportamiento dinámico del sistema frente a las condiciones de operación observadas. Las ganancias del controlador se han actualizado de manera acumulativa utilizando la Ecuación (4), en la cual el nuevo valor del parámetro se obtiene a partir del valor previamente utilizado más el diferencial estimado por la red neuronal.

Este procedimiento se ha repetido de manera iterativa a lo largo de la simulación, permitiendo que el controlador ajuste progresivamente sus parámetros en función del comportamiento observado del sistema. Como resultado, se ha logrado incorporar un mecanismo de adaptación que permite mejorar el desempeño del control frente a posibles variaciones en la dinámica del proceso o perturbaciones presentes en el sistema. Con el fin de describir de forma estructurada el procedimiento implementado, en el Algoritmo 1 se ha presentado el proceso de actualización adaptativa de las ganancias del controlador PID mediante el uso de la red neuronal entrenada.

---

**Algoritmo 1** Algoritmo de adaptación de las ganancias del controlador PID mediante red neuronal

**Input:** Métricas de desempeño del sistema  
**Output:** Ganancias actualizadas  $k_p$ ,  $k_i$ ,  $k_d$   
 Inicializar las ganancias del controlador  $k_p$ ,  $k_i$  y  $k_d$   
 Definir el intervalo de adaptación  $T_{adapt} = 500$  s  
**while** la simulación se encuentre en ejecución **do**  
     El sistema opera con las ganancias actuales del controlador PID;  
     **if** ha transcurrido el intervalo de adaptación  $T_{adapt}$  **then**  
         Calcular las métricas de desempeño del sistema  
         Introducir las métricas como entradas de la red neuronal La red neuronal genera  $\Delta k_p$ ,  $\Delta k_i$  y  $\Delta k_d$  Actualizar las ganancias del controlador:  
          $k_p = k_p + \Delta k_p$   $k_i = k_i + \Delta k_i$   $k_d = k_d + \Delta k_d$   
     **end**  
**end**


---

Fuente: Elaboración propia.

El sistema completo de control se ha implementado en el entorno de simulación de MATLAB/Simulink, integrando los diferentes componentes necesarios para la evaluación del esquema de control adaptativo propuesto. Esta implementación ha permitido representar de manera estructurada tanto la dinámica del proceso como los módulos encargados del cálculo de métricas, la estimación de las variaciones de las ganancias y la actualización del controlador. En primer lugar, se ha incorporado el modelo dinámico del proceso térmico, el cual ha sido utilizado para representar el comportamiento del sistema bajo estudio. Este modelo ha permitido simular la respuesta del proceso frente a los cambios en la señal de control generada por el controlador PID. Luego, se ha integrado el controlador PID encargado de regular la variable de salida del sistema. Dicho controlador ha operado inicialmente con valores de ganancias previamente definidos.

La señal de control generada por el controlador ha sido aplicada al modelo del proceso con el objetivo de mantener la variable controlada en torno al valor de referencia establecido. Con el propósito de evaluar el desempeño del sistema durante la simulación, se ha implementado un módulo de almacenamiento temporal de datos utilizando buffers. Estos buffers han permitido registrar segmentos de la respuesta del sistema durante intervalos de tiempo definidos, los cuales posteriormente han sido utilizados para el cálculo de las métricas de desempeño. En la Figura 10 se observa la implementación realizada en Simulink. Las métricas se han calculado al interior de un bloque de función de Matlab y la salida ha sido resumida a través de un multiplexor, misma que alimenta al resto de proceso.

*Figura 10. Cálculo de métricas en el intervalo de 500s.*



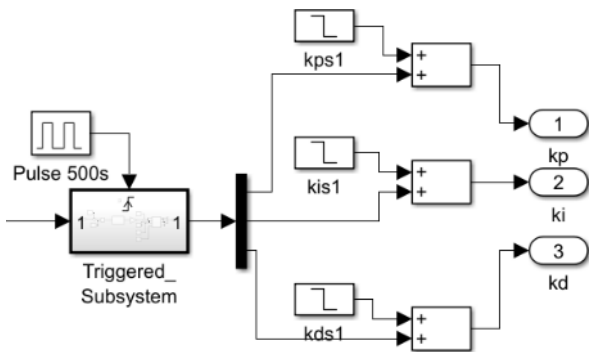
Fuente: Elaboración propia.

Estas métricas han sido utilizadas como variables de entrada para la red neuronal previamente entrenada, permitiendo evaluar el comportamiento dinámico del sistema bajo las condiciones actuales de operación. Se ha garantizado que la actualización de las ganancias del controlador PID se realice únicamente cada ventana de tiempo comentada. El proceso de actualización se ha ejecutado de forma periódica cada 500 segundos mediante una señal de disparo generada por un bloque tipo pulso. Esta señal ha activado un subsistema disparado (Triggered Subsystem), dentro del cual se ha evaluado la red neuronal utilizando las métricas disponibles en ese instante.

Tanto las entradas como las salidas de la red neuronal han sido normalizadas y desnormalizadas respectivamente. Como resultado de esta evaluación, la red neuronal mostrada en la Figura 9 ha generado tres señales de salida correspondientes a los diferenciales de las ganancias del controlador, es decir,  $\Delta k_p$ ,  $\Delta k_i$  y  $\Delta k_d$ . Estas señales han sido separadas mediante un bloque de distribución de señales, permitiendo su procesamiento individual para cada parámetro del controlador aplicando la Ecuación (4). Para finalizar, las salidas de los bloques de suma han generado los valores actualizados de las ganancias  $k_p$ ,  $k_i$  y  $k_d$ , los cuales han sido utilizados por el controlador PID durante el siguiente intervalo de operación del sistema. Este procedimiento se ha repetido de manera periódica a lo largo de la simulación,

permitiendo que el controlador ajuste progresivamente sus parámetros en función del desempeño observado del sistema.

**Figura 11.** Implementación de actualización de ganancias PID.




Fuente: Elaboración propia.

En el sistema de control global se ha implementado un mecanismo de actualización adaptativa encargado de modificar las ganancias del controlador PID. Este mecanismo ha actualizado las ganancias de forma discreta y acumulativa, manteniendo el valor previamente calculado y sumando el diferencial generado por la red neuronal. De esta manera, el sistema de control ha sido capaz de ajustar progresivamente sus parámetros en función del desempeño observado durante la simulación.

La integración de estos módulos dentro del entorno de Simulink ha permitido construir un esquema completo de control adaptativo basado en redes neuronales, facilitando la evaluación del comportamiento del sistema y la validación del método propuesto bajo diferentes condiciones de operación. En la Figura 12 se muestra el bloque implementado en Simulink para la actualización adaptativa de las ganancias del controlador PID dentro del esquema de control propuesto.

**Figure 12.** Esquema del sistema de control adaptativo PID.



Fuente: Elaboración propia.

## Resultados y Discusión

Con el propósito de evaluar el desempeño del sistema de control propuesto, se han definido distintos escenarios de simulación que permiten analizar el comportamiento del controlador tanto en condiciones nominales como ante cambios en la referencia y presencia de perturbaciones. En una primera instancia, se ha considerado un escenario con un valor de referencia constante de  $130^{\circ}\text{C}$ , con el fin de analizar la respuesta del sistema en condiciones estacionarias y verificar la estabilidad del controlador.

Luego, se ha introducido un cambio ascendente en el valor de referencia, pasando de  $130^{\circ}\text{C}$  a  $135^{\circ}\text{C}$ , lo que ha permitido evaluar la capacidad del sistema para adaptarse a variaciones en la consigna y analizar su comportamiento transitorio. De manera complementaria, se ha definido un escenario con un cambio descendente en el valor de referencia, pasando de  $130^{\circ}\text{C}$  a  $125^{\circ}\text{C}$ , con el objetivo de analizar la respuesta del sistema ante disminuciones en la consigna. Adicionalmente, se ha considerado un escenario combinado en el cual se ha aplicado un cambio en la referencia de  $130^{\circ}\text{C}$  a  $135^{\circ}\text{C}$  junto con la inclusión de una perturbación externa. Este caso ha permitido evaluar la robustez del controlador frente a condiciones más exigentes de operación. Estos escenarios han permitido realizar una evaluación integral del sistema de

control, considerando tanto condiciones nominales como situaciones dinámicas que exigen capacidad de adaptación y robustez por parte del controlador propuesto. Los escenarios considerados para la evaluación del sistema de control se resumen en la Tabla 2.

**Tabla 2.** Escenarios de evaluación del sistema de control.

Escenario	Descripción
1	Referencia constante en 130°C
2	Cambio ascendente de la referencia (130°C → 135°C)
3	Cambio descendente de la referencia (130°C → 125°C)
4	Cambio descendente de la referencia (130°C → 123°C) con perturbación


Fuente: Elaboración propia.

Una vez realizadas las distintas pruebas, se ha realizado una comparación entre el controlador PID convencional y el controlador PID adaptativo basado en red neuronal, bajo los escenarios de evaluación previamente definidos. En la Figura 13, se presentan las respuestas del sistema ante una referencia fija (130°C), considerando tanto el controlador PID como el controlador adaptativo. Se ha observado que el controlador PID convencional presenta un menor tiempo de respuesta; sin embargo, este comportamiento se ve acompañado de una mayor sobreoscilación.

En contraste, el controlador PID adaptativo ha logrado mantener un tiempo de respuesta adecuado, eliminando prácticamente la sobreoscilación y proporcionando una respuesta más suave y estable. Asimismo, se ha evidenciado que la desviación estándar de la señal de salida es menor en el caso del sistema adaptativo, lo que indica una mejora en la estabilidad y consistencia del control. Estos

resultados han permitido concluir que, aunque el controlador convencional puede ofrecer respuestas más rápidas, el enfoque adaptativo proporciona un mejor equilibrio entre rapidez, estabilidad y calidad de la respuesta del sistema.

**Figura 13.** Respuesta del sistema ante referencia constante de 130°C para el controlador PID y PID adaptativo.




Fuente: Elaboración propia.

En la Figura 14, se presentan las respuestas del sistema ante un cambio ascendente de la referencia (130°C → 135°C), se ha observado que el controlador PID convencional presenta, en apariencia, un mejor desempeño en términos de rapidez de respuesta y una menor desviación estándar en comparación con el controlador adaptativo. No obstante, este comportamiento se debe a las condiciones iniciales del sistema en el instante en que se aplica el cambio de referencia.

En particular, se ha evidenciado que, previo al cambio, la salida del sistema controlado mediante PID convencional se encuentra en valores cercanos a 133°C, lo que implica que la distancia hasta la nueva referencia es reducida. En consecuencia, el sistema requiere un menor esfuerzo para alcanzar el nuevo valor de consigna, lo que se traduce en una respuesta más rápida y con menor variabilidad. Por el contrario, el controlador PID adaptativo ha

mantenido la salida del sistema más próxima al valor de referencia inicial de 130°C en el instante del cambio (5000 s). Esto implica que el sistema debe recorrer una mayor distancia hasta alcanzar el nuevo valor de 135°C, lo que influye en un mayor tiempo de respuesta relativo y una desviación estándar ligeramente superior durante el transitorio. Estos resultados han permitido evidenciar que la aparente ventaja del controlador convencional en este escenario no se debe necesariamente a un mejor desempeño dinámico, sino a una condición inicial favorable. En este sentido, el controlador adaptativo mantiene una regulación más precisa en estado estacionario, lo que constituye una característica deseable desde el punto de vista del control.

**Figura 14.** Respuesta del sistema ante cambio de referencia de 130°C → 135°C para el controlador PID y PID adaptativo.

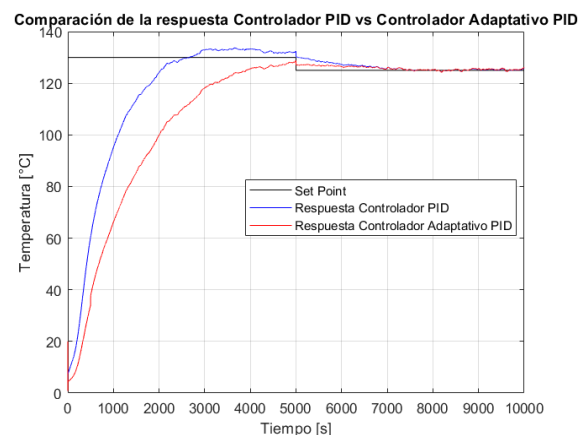


Fuente: Elaboración propia

En la Figura 15 se presentan las respuestas al cambio descendente de la referencia (135°C → 130°C), se ha observado que el controlador PID adaptativo presenta un mejor desempeño en comparación con el controlador PID convencional. En particular, el sistema adaptativo ha mostrado una respuesta más suave y estable, con una menor presencia de oscilaciones durante el régimen transitorio. Por otro lado, el controlador PID convencional ha

evidenciado una mayor oscilación en la respuesta del sistema. Este comportamiento se debe a que, previo al cambio descendente, el sistema ya presentaba una sobreoscilación asociada a su dinámica, lo que influye negativamente en la forma en que responde ante la nueva referencia. En consecuencia, se ha determinado que el controlador adaptativo ofrece una mejor capacidad para gestionar cambios descendentes en la consigna, manteniendo una respuesta más controlada y reduciendo los efectos de oscilaciones previas en el sistema.

**Figura 15.** Respuesta del sistema ante cambio de referencia de 135°C → 130°C para el controlador PID y PID adaptativo.




Fuente: Elaboración propia.

En la Figura 16, se presentan las respuestas del escenario en el que se ha considerado la presencia de una perturbación externa con el fin de analizar la robustez del sistema de control. En una primera instancia, se ha aplicado una perturbación en el instante de 4500 segundos, la cual simula una pérdida de temperatura asociada a la apertura de la puerta del horno. Posteriormente, se ha introducido un cambio descendente en la referencia, pasando de 130°C a 123°C. A partir de los resultados obtenidos, se ha observado que el controlador PID adaptativo presenta un mejor desempeño frente a estas

condiciones, evidenciando una respuesta más estable y sin presencia significativa de sobre oscilaciones. En contraste, el controlador PID convencional ha mostrado una mayor sensibilidad ante la perturbación, reflejándose en oscilaciones más pronunciadas y una recuperación menos eficiente. Estos resultados han permitido evidenciar que el mecanismo adaptativo implementado mejora la capacidad del sistema para rechazar perturbaciones y ajustarse a nuevas condiciones de operación, lo que constituye una ventaja significativa en aplicaciones reales donde este tipo de eventos es frecuente.

**Figura 16.** Respuesta del sistema ante cambio de referencia de  $130^{\circ}\text{C} \rightarrow 123^{\circ}\text{C}$  para el controlador PID y PID adaptativo que incluye una perturbación en el sistema.



Fuente: Elaboración propia.

En la Tabla 3 se presentan los valores de la desviación estándar obtenidos para cada uno de los escenarios de evaluación, considerando tanto el controlador PID convencional como el controlador PID adaptativo. Estos resultados permiten cuantificar la variabilidad de la respuesta del sistema y complementar el análisis cualitativo previamente realizado.

**Tabla 3.** Comparación de la desviación estándar en los diferentes escenarios de evaluación

Escenario	Condición	PID	PID Adaptativo
1	Referencia constante ( $130^{\circ}\text{C}$ )	10.911	0.7183
2	Cambio ascendente ( $130^{\circ}\text{C} \rightarrow 135^{\circ}\text{C}$ )	0.2954	11.093
3	Cambio descendente ( $130^{\circ}\text{C} \rightarrow 125^{\circ}\text{C}$ )	14.364	0.7389
4	Cambio descendente ( $130^{\circ}\text{C} \rightarrow 123^{\circ}\text{C}$ ) con perturbación	13.350	0.5620

Fuente: Elaboración propia.

A partir de los resultados presentados en la Tabla 3, se ha realizado un análisis comparativo del comportamiento de ambos controladores en términos de la desviación estándar de la señal de salida, la cual constituye un indicador de la variabilidad y estabilidad del sistema. En el escenario de referencia constante ( $130^{\circ}\text{C}$ ), se ha observado que el controlador PID adaptativo presenta una menor desviación estándar (0.7183) en comparación con el controlador PID convencional (1.0911), lo que indica una respuesta más estable y con menor variabilidad en estado estacionario. En el caso del cambio ascendente de la referencia ( $130^{\circ}\text{C} \rightarrow 135^{\circ}\text{C}$ ), se ha evidenciado que el controlador PID convencional presenta una menor desviación estándar (0.2954) frente al controlador adaptativo (1.1093). No obstante, como se ha discutido previamente, este resultado se encuentra influenciado por las condiciones

iniciales del sistema, dado que el controlador convencional se encontraba operando en valores cercanos a la nueva referencia antes de aplicar el cambio. Para el escenario de cambio descendente ( $130^{\circ}\text{C} \rightarrow 125^{\circ}\text{C}$ ), el controlador PID adaptativo ha mostrado nuevamente un mejor desempeño, con una desviación estándar de 0.7389 frente a 1.4364 del controlador convencional, evidenciando una reducción significativa en la variabilidad de la respuesta.

En el escenario que incluye perturbación y cambio descendente ( $130^{\circ}\text{C} \rightarrow 123^{\circ}\text{C}$ ), se ha obtenido la mayor diferencia a favor del controlador adaptativo, con una desviación estándar de 0.5620 en comparación con 1.3350 del controlador PID convencional. Este resultado confirma la mayor robustez del sistema adaptativo frente a condiciones externas adversas. En conjunto, estos resultados han permitido concluir que el controlador PID adaptativo ofrece un mejor desempeño global en términos de estabilidad y reducción de la variabilidad de la respuesta, especialmente en escenarios dinámicos y ante la presencia de perturbaciones.

A partir de los resultados obtenidos en los diferentes escenarios de evaluación, se ha evidenciado que la incorporación de un mecanismo adaptativo basado en red neuronal permite mejorar el desempeño global del sistema de control en comparación con un controlador PID convencional. En términos generales, se ha observado que el controlador PID adaptativo presenta una respuesta más estable, caracterizada por una reducción significativa de la sobreoscilación y una menor variabilidad en la señal de salida, lo cual ha sido corroborado mediante los valores de desviación estándar obtenidos. Esta mejora resulta particularmente evidente en escenarios dinámicos y en presencia de perturbaciones,

donde el sistema adaptativo ha demostrado una mayor capacidad de rechazo y una recuperación más eficiente. No obstante, también se ha identificado que, en ciertos escenarios específicos, como el cambio ascendente de la referencia, el controlador PID convencional puede presentar un mejor desempeño aparente.

Se ha determinado que este comportamiento se encuentra influenciado por condiciones iniciales favorables, lo que implica que no responde necesariamente a una superioridad en la estrategia de control, sino a una ventaja circunstancial en el estado del sistema previo al cambio. Desde una perspectiva general, se ha establecido que el controlador adaptativo ofrece un mejor equilibrio entre rapidez de respuesta, estabilidad y robustez, lo cual constituye una característica deseable en sistemas de control aplicados a procesos reales, especialmente en aquellos sujetos a perturbaciones e incertidumbre.

En el contexto de la aplicabilidad en entornos industriales, se ha analizado la posibilidad de integrar una red neuronal preentrenada en un sistema de control basado en PLC, identificando que el elemento clave para su implementación radica en la exportación de los pesos y parámetros obtenidos durante el entrenamiento. En este sentido, se ha determinado que dichos valores podrían ser trasladados a un formato compatible con el entorno de programación del PLC, permitiendo su incorporación mediante bloques de función o estructuras equivalentes dentro del sistema de control. Bajo este enfoque, la red neuronal no requeriría ser ejecutada en su fase de entrenamiento, sino que operaría como un modelo de inferencia estático, en el cual los pesos previamente calculados serían utilizados para procesar las entradas del sistema en cada ciclo de control. Esta característica permitiría que el PLC implemente

la lógica de la red neuronal mediante operaciones matemáticas básicas, lo que sugiere la viabilidad de su ejecución dentro de las limitaciones propias de estos dispositivos. De esta manera, se ha establecido que, desde el punto de vista conceptual y técnico, resulta posible trasladar el conocimiento adquirido en la etapa de entrenamiento hacia un entorno industrial, utilizando la exportación de pesos como mecanismo principal de integración.

No obstante, se ha considerado que su implementación práctica requeriría una validación adicional en condiciones reales de operación, así como el análisis de aspectos relacionados con el tiempo de ejecución y la capacidad de procesamiento del sistema. La implementación en un entorno real requeriría considerar aspectos adicionales como el tiempo de muestreo, la robustez del modelo entrenado, la validación en línea y la seguridad del sistema ante posibles fallos. Asimismo, sería necesario garantizar que el proceso de inferencia de la red neuronal se realice en tiempos compatibles con la dinámica del sistema controlado.

Se ha identificado como una limitación del enfoque propuesto la dependencia del desempeño de la red neuronal respecto a la calidad y representatividad de los datos utilizados durante el entrenamiento. En este sentido, una adecuada selección de escenarios de entrenamiento resulta fundamental para garantizar un comportamiento óptimo en condiciones reales de operación. De igual forma, se ha identificado que sería oportuno evaluar diferentes ventanas de tiempo para el cálculo de las métricas de desempeño, con el fin de analizar su influencia en el proceso de adaptación y verificar si es posible obtener un comportamiento aún más eficiente del sistema. En conjunto, los resultados obtenidos han permitido validar la viabilidad del uso de redes

neuronales como mecanismo de adaptación en sistemas de control, destacando su potencial para mejorar el desempeño frente a estrategias convencionales, especialmente en entornos dinámicos y sujetos a perturbaciones.

En relación con el objetivo planteado en la presente investigación, se ha verificado que el sistema de control propuesto cumple con el criterio de estabilidad definido, manteniendo la variable controlada dentro de un rango de  $\pm 1^\circ\text{C}$  respecto al valor de referencia en la mayoría de los escenarios evaluados. Este comportamiento ha sido especialmente evidente en el controlador PID adaptativo, el cual ha mostrado una menor variabilidad en la señal de salida, tal como se refleja en los valores de desviación estándar obtenidos. En este sentido, se ha confirmado que la estrategia de control desarrollada permite garantizar un desempeño estable y adecuado para aplicaciones térmicas donde se requiere alta precisión.

Con el fin de obtener una visión global del desempeño de ambos controladores, se ha calculado el valor promedio de la desviación estándar para los diferentes escenarios evaluados. Como resultado, se ha obtenido un valor promedio de 1.0395 para el controlador PID convencional y de 0.7821 para el controlador PID adaptativo. Estos resultados han permitido evidenciar que, en términos generales, el controlador adaptativo presenta una menor variabilidad en la respuesta del sistema, lo que confirma su mejor desempeño global en comparación con el controlador convencional. No obstante, es importante señalar que este valor promedio constituye únicamente un indicador referencial, dado que cada escenario presenta condiciones específicas que influyen en el comportamiento del sistema.

### **Conclusiones**

Se diseñó un sistema de control de temperatura adaptativo utilizando el modelo matemático de un horno de termoformado, empleando redes neuronales artificiales para la sintonización dinámica de las ganancias del controlador PID. Los resultados obtenidos evidencian una mejora en la precisión y robustez del sistema frente a variaciones del proceso y presencia de perturbaciones, cumpliendo con el objetivo general planteado.

Se analizó y caracterizó el desempeño del controlador convencional existente, basado en una estructura PI, identificando limitaciones como la presencia de sobreoscilación, una respuesta poco eficiente ante perturbaciones, debido principalmente a la ausencia de acción derivativa que permita anticipar cambios en el sistema. A partir de estas limitaciones, se procedió al cálculo e implementación de un controlador PID, incorporando la acción derivativa con el fin de mejorar la respuesta dinámica y la estabilidad del sistema. Este proceso permitió establecer una línea base más robusta para la comparación con el sistema adaptativo propuesto.

Se diseñó la arquitectura de la red neuronal definiendo las métricas del sistema como variables de entrada y los diferenciales de las ganancias del controlador PID ( $\Delta k_p$ ,  $\Delta k_i$ ,  $\Delta k_d$ ) como salidas. Asimismo, se estableció una metodología de entrenamiento que permitió obtener un modelo capaz de generalizar el comportamiento del sistema bajo distintas condiciones de operación. Se implementó el sistema de control adaptativo integrando la red neuronal con el controlador PID dentro del entorno de simulación. Este mecanismo permitió la actualización periódica y acumulativa de las ganancias del controlador, logrando una adaptación dinámica al

comportamiento del sistema. Se evaluó el desempeño del sistema propuesto frente al controlador convencional PID, evidenciando mejoras en la estabilidad, reducción de la sobreoscilación y mayor capacidad de rechazo a perturbaciones.

Los resultados obtenidos, muestran que el controlador adaptativo presenta una menor variabilidad en la respuesta del sistema en la mayoría de los escenarios analizados. Esto se evidenció en la desviación estándar calculada. Se verificó que el sistema de control adaptativo cumple con el criterio de estabilidad definido, manteniendo la temperatura dentro de un rango de  $\pm 1^\circ\text{C}$  respecto al valor de referencia, lo cual resulta adecuado para aplicaciones térmicas que requieren alta precisión. Se determinó que la aparente superioridad del controlador convencional en ciertos escenarios se encuentra influenciada por condiciones iniciales favorables, lo que no representa una mejora estructural en su desempeño frente al sistema adaptativo.

Se estableció la posibilidad de implementar el sistema propuesto en entornos industriales mediante la exportación de los pesos de la red neuronal hacia plataformas de control como PLC, permitiendo su ejecución como un modelo de inferencia en tiempo real. No obstante, se reconoce la necesidad de validar este enfoque en condiciones reales de operación, así como analizar aspectos relacionados con tiempos de ejecución y capacidad de procesamiento. Los resultados obtenidos permiten concluir que el uso de redes neuronales como mecanismo de adaptación en controladores PID constituye una alternativa viable y eficiente para mejorar el desempeño de sistemas térmicos, especialmente en entornos donde existen perturbaciones y variaciones en la dinámica del proceso.

### Referencias Bibliográficas

- Bai, J., Zhou, D., Zhao, H., & Zhang, B. (2024). The application of self-tuning neural network PID controller on longitudinal motion reduction in head waves. En *Proceedings of the International Seminar on Artificial Intelligence, Networking and Information Technology (AINIT)* (pp. 76–82). <https://www.scopus.com/pages/publications/85199150650?origin=resultslist>
- Castro L., & Cortés, J. (2022). Modelo matemático de un horno resistivo para termoformado de láminas de polipropileno. *Ingenius. Revista de Ciencia y Tecnología*, (28), 80–91. <https://doi.org/10.1007/s11768-024-00234-6>
- Chen, M., Fan, X., Huang, Z., Yu, X., & Wang, L. (2026). Coordination control strategy of anti-lock braking system/electronic stability program using improved global sliding mode control and whale optimization PID algorithm. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 48. <https://www.scopus.com/pages/publications/105029752142?origin=resultslist>
- Demirtaş, M. (2023). A hybrid algorithm for adaptive neuro-controllers. *Black Sea Journal of Engineering and Science*, 6(2), 87–97. <https://izlik.org/JA37DS96SZ>
- Fathi, M., Wu, C., Lu, Y., Zhu, X., & Wang, Y. (2025). Research and analysis of the dynamic weighing system for aggregates in cement stabilized soil mixing plant based on machine learning. En *Proceedings of SPIE – The International Society for Optical Engineering* (p. 243). <https://www.scopus.com/pages/publications/105022732826?origin=resultslist>
- Ghazali, M., Ahmad, M., & Ismail, R. (2019). Data-driven neuroendocrine PID tuning based on safe experimentation dynamics for control of TITO coupled tank system with stochastic input delay. *Communications in Computer and Information Science*, 1015, 1–12. <https://www.scopus.com/pages/publications/85065091757?origin=resultslist>
- Govind, A. (2026). Enhancing fault tolerance and robustness in chemical process control using learning-based PID design. *Chemical Product and Process Modeling*. <https://www.scopus.com/pages/publications/105027283825?origin=resultslist>
- Jimenez, A., Rodríguez, D., & Castro, P. (2023). Improvement proposal to increase the availability of machines in the thermoforming line of a plastic industry applying TPM, SMED and standardized work tools. *ACM International Conference Proceedings Series*, 395–402. <https://www.scopus.com/pages/publications/85182605966?origin=resultslist>
- Krok, M., Hunek, W. P., Mielczarek, S., Buchwald, F., & Kolender, A. (2025). Application of feedforward and recurrent neural networks for model-based control systems. *Control Theory and Technology*, 23(1), 91–104. <https://doi.org/10.1007/s11768-024-00234-6>
- Laabid, Z., Moumen, A., Mansouri, K., & Siadat, A. (2023). Numerical study of the speed response of intelligent models using tansig, logsig and purelin activation functions in artificial neural networks. *IAES International Journal of Artificial Intelligence*, 12(1), 155.
- Liu, H., Yu, Q., & Wu, Q. (2023). PID control model based on back propagation neural network optimized by adversarial learning-based grey wolf optimization. *Applied Sciences*, 13(8), 4767. <https://doi.org/10.3390/app13084767>
- Liu, S., Zuo, Y., Li, T., Wang, H., Gao, X., & Xiao, Y. (2024). Adaptive fixed-time PID-based control of uncertain nonlinear systems and its application to unmanned surface vehicles. *International Journal of Systems Science*, 55, 2815–2824. <https://www.scopus.com/pages/publications/85193836798?origin=resultslist>
- Pal, A., & Nestorovic, T. (2021). Artificial intelligence neural network approach to self-tuning of a discrete-time PID control system. En *Proceedings of the International Conference on Systems and Control (ICSC)* (pp. 146–151).

- <https://www.scopus.com/pages/publications/85124976540?origin=resultlist>  
SB, R., & Thangavel, T. (2026). Optimized neural network-based FOC of trapezoidal back-EMF BLDC motors using dung-beetle algorithm. *Engineering Research Express*, 8. <https://www.scopus.com/pages/publications/105027627389?origin=resultlist>
- Seborg, D., Edgar, T, Mellichamp, D. & Doyle, F. (2016). *Process dynamics and control*. John Wiley & Sons.
- Shurajji, A., & Shneen, S. (2025). Analysis of improved performance and dynamics of an induction motor using an artificial neural network controller and a conventional proportional integral derivative controller. *Buletin Ilmiah Sarjana Teknik Elektro*, 7, 397–408. <https://www.scopus.com/pages/publications/105019319666?origin=resultlist>
- Sui, Y., & Huang, L. (2026). Design and realization of neural network-based intelligent control system for aeronautical applications. En *Lecture Notes in Computer Science* (Vol. 15225, pp. 109–122). <https://www.scopus.com/pages/publications/105021210182?origin=resultlist>
- Tsamatsoulis, D. (2025). Robust enhanced auto-tuning of PID controllers for optimal quality control of cement raw mix via neural networks. *ChemEngineering*, 9. <https://www.scopus.com/pages/publications/105009269840?origin=resultlist>
- Van, J., Le Roux, J., & Craig, I. (2026). Artificial intelligence-based learning methods for the automatic tuning of fixed-parameter MIMO PID controllers for industrial applications: A review and comparison. *Control Engineering Practice*. <https://www.scopus.com/pages/publications/105030280838?origin=resultlist>
- Weiss, M., Pawluchin, A., Ewering, J. H., Seel, T., & Boblan, I. (2026). Lagrangian neural network-based control: Improving robotic trajectory tracking via linearized feedback. *IEEE Robotics and Automation Letters*. <https://www.scopus.com/pages/publications/105027452617?origin=resultlist>
- Yakout, A., Dashtdar, M., Aboras, K., Ghadi, Y., Elzawawy, A., Yousef, A., & Kotb, H. (2024). Neural network-based adaptive PID controller design for over-frequency control in microgrid using honey badger algorithm. *IEEE Access*, 12, 27989–28005. <https://www.scopus.com/pages/publications/85186086825?origin=resultlist>
- Zhao, R., Alkhayyat, A., & Khan, M. (2025). Reinforcement learning-enhanced expert mixture of LQR and PID for optimized control in DC–DC boost converters. *Electrical Engineering*, 107, 11891–11910. <https://www.scopus.com/pages/publications/105005092397?origin=resultlist>
- Zhu, J., Liu, B., Song, E., & Wang, Y. (2024). Adaptive temperature control system for vertical heater based on PLC intelligent model conversion. En *Proceedings of SPIE – The International Society for Optical Engineering* (p. 38). <https://www.scopus.com/pages/publications/85206797431?origin=resultlist>



Esta obra está bajo una licencia de Creative Commons Reconocimiento-No Comercial 4.0 Internacional. Copyright © José Luis Cortés Llanganate y Mario Efraín Audelo Guevara.

**Declaraciones éticas y editoriales del artículo**

Contribución de los autores (Taxonomía CRediT)

**José Luis Cortés Llanganate:** conceptualización de la investigación, diseño metodológico, desarrollo del proceso investigativo, análisis formal de los datos, redacción del borrador original del manuscrito, revisión crítica del contenido científico y supervisión general del estudio.

**Mario Efraín Audelo Guevara:** conceptualización de la investigación, diseño metodológico, desarrollo del proceso investigativo, análisis formal de los datos, redacción del borrador original del manuscrito, revisión crítica del contenido científico y supervisión general del estudio.

**Declaración de conflicto de intereses**

Los autores declaran que no existe conflicto de intereses en relación con la investigación presentada, la autoría del manuscrito ni la publicación del presente artículo.

**Declaración de financiamiento**

La presente investigación no recibió financiamiento específico de agencias públicas, comerciales o de organizaciones sin fines de lucro. En caso de existir financiamiento institucional o externo, este deberá ser declarado explícitamente por los autores en esta sección.

**Declaración del editor**

El editor responsable certifica que el proceso editorial del presente artículo se desarrolló conforme a los principios de integridad científica, transparencia y buenas prácticas editoriales. El manuscrito fue sometido a un proceso de evaluación mediante revisión por pares doble ciego, garantizando la confidencialidad de la identidad de los autores y revisores durante todo el proceso de dictamen académico. Asimismo, el editor declara que el artículo cumple con los criterios científicos, metodológicos y éticos establecidos por la revista.

**Declaración de los revisores**

Los revisores externos que participaron en la evaluación del presente manuscrito declaran haber realizado el proceso de revisión de manera objetiva, independiente y confidencial. Asimismo, manifiestan que no mantienen conflictos de interés con los autores ni con la investigación evaluada, y que sus observaciones y recomendaciones se fundamentan exclusivamente en criterios científicos, metodológicos y académicos.

**Declaración ética de la investigación**

Los autores declaran que la investigación se desarrolló respetando los principios éticos de la investigación científica, garantizando la confidencialidad de los datos y el respeto a los participantes del estudio. En los casos en que la investigación involucre seres humanos, los procedimientos deben ajustarse a los principios éticos establecidos en la Declaración de Helsinki y a las normativas institucionales correspondientes.

**Declaración sobre el uso de inteligencia artificial**

Los autores declaran que el uso de herramientas de inteligencia artificial, en caso de haberse utilizado durante el proceso de investigación o redacción del manuscrito, se realizó únicamente como apoyo técnico para mejorar la claridad del lenguaje o el análisis de información, manteniendo siempre la responsabilidad intelectual sobre el contenido del artículo. Las herramientas de inteligencia artificial no fueron utilizadas como autoras del manuscrito ni sustituyen la responsabilidad académica de los investigadores.

**Disponibilidad de datos**

Los datos que respaldan los resultados de esta investigación estarán disponibles previa solicitud razonable al autor de correspondencia, respetando las normas éticas y de confidencialidad establecidas por la investigación.