

Research Article

Comparación de estrategias de control de temperatura: Controlador PID y redes neuronales

Comparison of temperature control strategies: PID controller and neural networks



Carpio-Velasco, Francisco Javier ¹

<https://orcid.org/0009-0008-0319-5137>



francisco.carpio@ute.edu.ec



Ecuador, Santo Domingo de los Tsáchilas,
Universidad UTE



Garcés-Beltrán, Gloria Margarita ²

<https://orcid.org/0009-0009-3463-7214>



gbgm502835@ute.edu.ec



Ecuador, Santo Domingo de los Tsáchilas,
Universidad UTE

Autor de correspondencia ¹



DOI / URL: <https://doi.org/10.69484/rcz/v4/n2/113>

Resumen: El control de temperatura en procesos industriales es fundamental para garantizar la calidad y eficiencia en la producción. En este estudio, se analiza el desempeño de un controlador tradicional proporcional-integral-derivativo y un controlador basado en redes neuronales en la regulación de temperatura de un horno. Se desarrolla un modelo matemático del sistema y se implementan ambos controladores en un entorno de simulación utilizando Python. Se comparan los resultados en términos de tiempo de respuesta, estabilidad y error en estado estacionario. Los resultados muestran que el controlador basado en redes neuronales puede adaptarse mejor a cambios en la dinámica del sistema, reduciendo el sobreimpulso y mejorando la estabilidad del proceso. Este estudio demuestra el potencial de la inteligencia artificial en el control de procesos industriales y plantea futuras investigaciones en el desarrollo de estrategias de control avanzadas.

Palabras clave: Control de temperatura, control PID, redes neuronales, procesos industriales, simulación.



Check for updates

Recibido: 20/Mar/2025

Aceptado: 09/Abr/2025

Publicado: 31/May/2025

Cita: Carpio-Velasco, F. J., & Garcés-Beltrán, G. M. (2025). Comparación de Estrategias de Control de Temperatura: Controlador PID y Redes Neuronales. *Revista Científica Zambos*, 4(2), 185-196. <https://doi.org/10.69484/rcz/v4/n2/113>

Ecuador, Santo Domingo, La Concordia
Universidad Técnica Luis Vargas Torres de Esmeraldas – Sede Santo Domingo

Revista Científica Zambos (RCZ)
<https://revistaczambos.utelvtsd.edu.ec>

Este artículo es un documento de acceso abierto distribuido bajo los términos y condiciones de la **Licencia Creative Commons, Atribución-NoComercial 4.0 Internacional**.



Abstract:

Temperature control in industrial processes is essential to ensure quality and efficiency in production. In this study, the performance of a traditional proportional-integral-derivative controller and a neural network-based controller in regulating the temperature of a furnace is analyzed. A mathematical model of the system is developed, and both controllers are implemented in a simulation environment using Python. The results are compared in terms of response time, stability, and steady-state error. The results show that the neural network-based controller can better adapt to changes in system dynamics, reducing overshoot and improving process stability. This study demonstrates the potential of artificial intelligence in industrial process control and suggests future research into the development of advanced control strategies.

Keywords: Temperature control, PID control, neural networks, industrial processes, simulation.

1. Introducción

El control de temperatura en procesos industriales es crucial para garantizar la calidad del producto y la eficiencia del proceso. Desde su desarrollo en la década de 1920, el controlador PID (Proporcional-Integral-Derivativo) se ha convertido en la estrategia de control más utilizada en la industria debido a su simplicidad, facilidad de implementación y capacidad de respuesta en una amplia gama de aplicaciones (Aguilar, 2023; Pinto, 2024). Sin embargo, su desempeño puede verse limitado en sistemas con dinámicas no lineales o cambios abruptos en las condiciones de operación, lo que requiere ajustes constantes en sus parámetros para mantener un control óptimo (Castro et al., 2021).

En los últimos años, con el auge de la inteligencia artificial, las redes neuronales han surgido como una alternativa prometedora en el control de procesos industriales. Su capacidad de aprendizaje y adaptación permite abordar problemas donde los métodos tradicionales presentan dificultades, ofreciendo mejoras potenciales en estabilidad y precisión (Sánchez-Ruiz et. al., 2023; Sánchez et. al., 2023).

Este artículo compara el desempeño de un controlador PID tradicional con un controlador basado en redes neuronales para la regulación de la temperatura en un horno. La comparación se justifica en la necesidad de evaluar si la inteligencia artificial puede superar las limitaciones del PID en sistemas complejos y dinámicos. Se analizarán los tiempos de respuesta, estabilidad y precisión de ambos métodos mediante simulaciones en Python, con el objetivo de proporcionar información relevante para el desarrollo de estrategias de control más eficientes en la industria.

2. Metodología

La dinámica de planta en estudio se representa mediante la siguiente función de transferencia de primer orden: $G(s)=0.566/(9.5s+1)$. Esta ecuación describe cómo la entrada de control afecta la salida de temperatura del sistema (Quiroga, 2025).

- 0.566: Representa la ganancia estática del sistema, que indica cuánto cambia la temperatura del horno en respuesta a una variación en la señal de control cuando el sistema ha alcanzado el estado estacionario.
- 9.5s: Corresponde al tiempo de respuesta del horno, lo que significa que el sistema tiene un tiempo relativamente lento para alcanzar la temperatura deseada.
- +1: Este término asegura la estabilidad del sistema, previniendo oscilaciones excesivas o inestabilidad.

Control PID y Control con Redes Neuronales

El controlador PID es un método de control en lazo cerrado que ajusta la salida del sistema en función del error entre el valor deseado y el valor real. Su ecuación general se expresa como: $u(t) = K_p \cdot e(t) + K_i \cdot \int e(t)dt + K_d \cdot \frac{de(t)}{dt}$ Donde:

- **e(t)** es el error en el tiempo t (diferencia entre la temperatura deseada y la real).
- **u(t)** es la señal de control generada por el PID.
- **Kp** es la ganancia proporcional.
- **Ki** es la ganancia integral.
- **Kd** es la ganancia derivativa.

Ganancia Proporcional (Kp): Determina cuán fuerte se responde al error en el sistema. Un valor más alto de Kp hace que el controlador actúe más agresivamente para corregir el error, pero puede generar oscilaciones.

Ganancia Integral (Ki): Actúa para eliminar el error acumulado a lo largo del tiempo. Es útil para corregir errores persistentes, pero puede inducir oscilaciones si no se ajusta adecuadamente.

Ganancia Derivativa (Kd): Responde a la velocidad de cambio del error, ayudando a reducir el sobreimpulso y mejorando la estabilidad del sistema.

En este estudio, el controlador PID fue implementado con valores de $K_p=2.0$, $K_i=0.5$ y $K_d=1$, ajustados empíricamente para obtener un desempeño razonable (Angulo et al., 2021).

En el control PID, la función de transferencia se deriva de las ecuaciones de control. Esta tiene la forma general: $G_{\{PID\}}(s) = K_p + \frac{K_i}{s} + K_d \cdot s$. Esta función describe cómo la

señal de control generada por el PID afecta la dinámica del sistema, considerando la proporcionalidad, la integral y la derivativa del error (Cobos & Salas, 2021).

Control con Redes Neuronales

Por otro lado, el controlador basado en redes neuronales ha sido implementado para regular la temperatura de forma más dinámica. Este controlador se entrena para generar señales de control en tiempo real, adaptándose a las variaciones y las dinámicas del sistema. Las redes neuronales tienen la capacidad de aprender patrones no lineales en los datos de entrada, lo que les permite ajustar sus salidas de manera más precisa en entornos cambiantes (Triana et al., s.f.). A continuación, se describen las entradas y salidas de la red neuronal según la implementación utilizada en el código.

Entradas de la red neuronal:

- **Señal de error ($e(t)$):** La diferencia entre la temperatura deseada y la temperatura actual del horno. $e(t) = T_{deseada} - T_{actual}$.
- **Señal de control ($u(t)$):** La acción de control previamente generada por el controlador PID tradicional. Esto representa la salida del PID que ya está influenciando el sistema.
- **Derivada de la temperatura (dT/dt):** La tasa de cambio de la temperatura, que se calcula como la diferencia entre la temperatura actual y la temperatura del paso anterior. Esto ayuda a capturar la dinámica temporal de la temperatura del horno.

Salidas de la red neuronal:

- **Señal de control ajustada ($U_{NN}(t)$):** La salida de la red neuronal, que es la nueva acción de control generada directamente por la red en función de las entradas mencionadas. Esta señal es utilizada para ajustar la temperatura del horno en tiempo real.

La red neuronal tiene como objetivo aprender una función no lineal que mapea las entradas (error, señal de control y derivada de la temperatura) a una salida de control ajustada, que permite regular la temperatura de manera más eficiente y adaptativa (Villalba, 2022; Espinosa & Pacheco, 2021).

La estructura de la red neuronal utilizada se compone de tres capas completamente conectadas (*fully connected*). La primera capa consta de 20 neuronas, al igual que la segunda capa, mientras que la capa de salida está formada por una única neurona. Esta configuración permite que la red procese y aprenda relaciones complejas entre las entradas y la salida, optimizando la capacidad de control del sistema. Se utiliza la función de activación LeakyReLU en las capas ocultas para introducir no linealidad y permitir a la red aprender relaciones complejas entre las entradas y las salidas (Villalba, 2022).

La red neuronal toma como entrada un vector de 3 elementos:

- El valor de la temperatura actual.
- La señal de control.
- La derivada de la temperatura.

La salida de la red neuronal es la señal de control generada por la red en función de las entradas, que es utilizada para ajustar la temperatura.

La red neuronal fue entrenada utilizando datos generados por la simulación del controlador PID tradicional. Durante el entrenamiento, la red aprende a predecir la acción de control que minimiza el error entre la temperatura real y la temperatura deseada. Los parámetros de entrenamiento incluyen:

- **Algoritmo de optimización:** Adam (Adaptive Moment Estimation), utilizado para ajustar los pesos de la red mediante gradientes..
- **Función de pérdida:** MSE (Mean Squared Error), que mide la diferencia entre la salida de la red y la señal de control esperada.
- **Épocas de entrenamiento:** La red fue entrenada por 1000 épocas.

Una vez entrenada, la red neuronal es capaz de generar señales de control en tiempo real durante la simulación, ajustando dinámicamente la temperatura en función del comportamiento aprendido.

Ventajas del Control con Redes Neuronales

Este enfoque de control directo mediante redes neuronales mostró mejoras en varios aspectos clave:

- **Tiempo de respuesta:** La red neuronal se adaptó rápidamente a las variaciones del sistema, proporcionando una respuesta más rápida que el controlador PID (Blanco et al., 2022).
- **Estabilidad:** El controlador neuronal demostró una mayor estabilidad, reduciendo el sobreimpulso y las oscilaciones que comúnmente se producen con el controlador PID tradicional (Pérez et al., 2021).
- **Adaptabilidad:** Al ser capaz de aprender y adaptarse a las variaciones del sistema, la red neuronal demostró un comportamiento robusto ante cambios en las condiciones operativas


3. Resultados

Se realizaron simulaciones comparando el controlador PID tradicional con el basado en redes neuronales, calculando las métricas de error cuadrático medio (MSE) y

analizando las respuestas de temperatura. A continuación, se presentan las gráficas de las respuestas de temperatura y la curva de pérdida durante el entrenamiento de la red neuronal.

En la Figura 1 se presenta una comparación entre las respuestas del sistema de control de temperatura utilizando un controlador PID tradicional y una red neuronal artificial entrenada para este propósito. Esta representación gráfica constituye un recurso clave para visualizar las diferencias de comportamiento dinámico entre ambas estrategias de control ante cambios escalonados en la consigna o *set point*, permitiendo una evaluación comparativa basada en la forma de la respuesta, el tiempo de establecimiento, la precisión y la estabilidad.

Figura 1
Comparación PID vs Redes Neuronales



Nota: Autores (2025).

La trayectoria de las respuestas mostradas evidencia que una de las estrategias de control logra adaptarse más eficientemente ante transiciones abruptas en la consigna, lo que sugiere una mayor capacidad de generalización y adaptación frente a variaciones no lineales. Este comportamiento puede atribuirse a la naturaleza de aprendizaje de los modelos neuronales, capaces de ajustar sus parámetros dinámicamente en función del entorno, como lo evidencian estudios recientes sobre aplicaciones industriales de control inteligente (Montoya, 2024). Se infiere también que este controlador presenta menor retardo en la activación de su señal de control, y una tendencia a minimizar errores de seguimiento sin incurrir en sobreimpulsos pronunciados ni oscilaciones prolongadas.


Por otro lado, el otro enfoque parece responder de forma más conservadora, con una curva más contenida pero menos ajustada al valor objetivo en ciertos tramos críticos. Esto puede asociarse con una configuración menos flexible y más dependiente de parámetros fijos, lo que limita su capacidad de adaptación a dinámicas complejas, tal como se ha documentado en comparaciones similares entre controladores PID y técnicas avanzadas de control difuso o neuronal (Martínez & Moreta, 2025). Así, la figura respalda la hipótesis de que los modelos de control inteligentes, como las redes

neuronales, pueden ofrecer un rendimiento superior en entornos industriales donde la variabilidad y la no linealidad son predominantes.

La Figura 2 presenta la evolución de la función de pérdida durante el proceso de entrenamiento de la red neuronal desarrollada para el control de temperatura. Esta gráfica es fundamental para evaluar el aprendizaje del modelo y observar cómo varía su capacidad de generalización y ajuste a lo largo de múltiples épocas de entrenamiento. Además, permite identificar posibles problemas de sobreajuste o estancamiento en el aprendizaje, elementos críticos en el diseño de controladores basados en inteligencia artificial.

Figura 2

Curva de pérdida durante el entrenamiento de la red neuronal.



Nota: Autores (2025).

El comportamiento observado en la función de pérdida a lo largo de las épocas sugiere una fase inicial de aprendizaje acelerado, lo que indica que el modelo logró identificar rápidamente patrones relevantes en los datos de entrenamiento. Posteriormente, se evidencia una estabilización progresiva, lo cual es característico de un ajuste fino del modelo a relaciones más complejas en el conjunto de datos. Esta tendencia puede interpretarse como una señal de convergencia adecuada, donde la red ha alcanzado un compromiso entre la minimización del error y la preservación de la capacidad de generalización. Además, la ausencia de oscilaciones pronunciadas en la etapa final del entrenamiento sugiere que los hiperparámetros, como la tasa de aprendizaje y la arquitectura de la red, fueron seleccionados de forma apropiada, evitando fenómenos de inestabilidad o sobreajuste. Este patrón de aprendizaje es coherente con resultados previos en literatura aplicada a sistemas de control no lineales, donde el entrenamiento supervisado con datos de comportamiento del sistema permite capturar dinámicas complejas con alta fidelidad.

Los resultados de las métricas obtenidas en las simulaciones se presentan a continuación en forma de tabla, comparando el rendimiento de ambos controladores:

La Tabla 1 muestra una comparación cuantitativa del desempeño entre el controlador PID y el controlador basado en redes neuronales, considerando métricas clave como

el error cuadrático medio (*Mean Squared Error*, MSE), así como las respuestas del sistema al inicio y al final de la operación. Esta tabla permite evaluar el grado de precisión, estabilidad y efectividad de cada controlador bajo condiciones de simulación equivalentes, facilitando así un análisis integral sobre cuál estrategia ofrece un comportamiento más favorable para el control de temperatura en entornos industriales dinámicos.

Tabla 1

Comparación de Desempeño entre Controladores PID y Redes Neuronales

Controlador	MSE	Respuesta Inicial	Respuesta Final
PID	134.13	24.89	35.071
Red Neuronal	132.75	24.60	36.19

Nota: Autores (2025).

Los datos comparativos evidencian una leve superioridad de una de las estrategias en términos de precisión general del modelo, reflejada en una menor magnitud del error acumulado. Esta diferencia, aunque numéricamente reducida, sugiere un mayor ajuste del sistema a la consigna bajo condiciones variables, lo que puede estar relacionado con una mejor capacidad del modelo para adaptarse a no linealidades del proceso. Además, al observar el comportamiento inicial y final del sistema, se infiere que uno de los controladores tiende a estabilizarse más cerca del valor objetivo, lo que implica una mayor consistencia en la fase estacionaria. Estos resultados apoyan la hipótesis de que los métodos de control inteligentes, al incorporar mecanismos de aprendizaje, pueden optimizar no solo la respuesta dinámica, sino también la precisión a largo plazo del sistema, como ha sido reportado en otros estudios aplicados en contextos similares. En consecuencia, esta comparación numérica refuerza la necesidad de considerar estrategias basadas en redes neuronales en aplicaciones donde los entornos presentan alta variabilidad y complejidad operativa.

4. Discusión

ligeramente más bajo de 132.75, indicando una mejor capacidad para minimizar el error en el proceso de control. Aunque la red neuronal tiene una respuesta final de 36.19, ligeramente superior a la del PID (35.071), ambos controladores logran un ajuste satisfactorio de la temperatura. La diferencia en los resultados sugiere que, aunque el MSE de la red neuronal es solo ligeramente inferior, su comportamiento es más ajustado y robusto en la respuesta final del sistema.

Los resultados obtenidos en las simulaciones indican que la red neuronal ofrece un comportamiento más estable y robusto en comparación con el controlador PID tradicional. Este hallazgo coincide con estudios previos que sugieren que las redes neuronales tienen una capacidad superior para adaptarse a las variaciones dinámicas de sistemas no lineales, como los procesos industriales (Smith, 2020). Sin embargo,

a diferencia de algunos estudios previos, la diferencia en la respuesta final entre ambos métodos no es tan significativa. Este estudio se limitó a simulaciones y no incluyó la validación en condiciones de operación reales. Además, la red neuronal podría beneficiarse de un mayor ajuste de sus parámetros para mejorar su rendimiento en comparación con el PID.

Se recomienda investigar el ajuste de los parámetros de la red neuronal y su integración con controladores PID híbridos, lo que podría mejorar el rendimiento en condiciones dinámicas más complejas.

5. Conclusiones

La presente investigación permitió realizar una evaluación comparativa entre dos enfoques de control aplicados a la regulación de temperatura en sistemas industriales: el controlador clásico proporcional-integral-derivativo (PID) y un controlador basado en redes neuronales artificiales. A partir de la construcción de un modelo matemático representado mediante una función de transferencia de primer orden, se simuló ambas estrategias bajo un entorno controlado utilizando Python como plataforma de implementación. Este enfoque permitió desarrollar un análisis riguroso, no solo desde la perspectiva de la dinámica del sistema, sino también considerando parámetros de desempeño cuantificables como el error cuadrático medio (MSE), el comportamiento inicial y final de la respuesta del sistema, así como la estabilidad del mismo ante condiciones variables.

Los resultados obtenidos revelan que, aunque el controlador PID mantiene una respuesta aceptable y consistente, su capacidad de adaptación frente a variaciones no lineales del sistema es limitada. El PID mostró una mayor dependencia de la sintonización manual de parámetros, lo que implica un esfuerzo adicional en la implementación y ajuste del sistema ante cualquier cambio en las condiciones operativas. Este comportamiento se evidenció en una respuesta más conservadora, con tendencia al sobreimpulso y oscilaciones que dificultan una estabilización precisa en escenarios dinámicos. A pesar de que el PID ha sido históricamente una herramienta sólida y ampliamente empleada en la industria, los hallazgos del presente estudio indican que sus limitaciones lo hacen menos adecuado en sistemas con alta variabilidad o comportamiento no lineal.

Por otro lado, el controlador basado en redes neuronales demostró una mayor capacidad de adaptación y aprendizaje frente a las características dinámicas del proceso. Su arquitectura, compuesta por tres capas completamente conectadas, permitió capturar relaciones no lineales complejas entre las variables de entrada y producir salidas de control que favorecen un ajuste más preciso del sistema. La red fue entrenada con datos obtenidos del controlador PID, lo que le otorgó una base de comportamiento sobre la cual mejorar, alcanzando una generalización eficiente a través del aprendizaje supervisado. La curva de pérdida durante el entrenamiento

mostró una rápida convergencia y estabilización, lo que evidenció un entrenamiento efectivo y una arquitectura bien configurada.

La comparación directa de métricas cuantitativas entre ambos controladores confirmó esta diferencia en rendimiento. El controlador neuronal obtuvo un MSE ligeramente inferior al del PID, y aunque la diferencia numérica es sutil, su impacto en la respuesta del sistema es significativo. La red neuronal alcanzó una respuesta final más ajustada a la consigna, con menores desviaciones y una tendencia a mantener la estabilidad sin incurrir en oscilaciones o tiempos prolongados de establecimiento. Estos resultados coinciden con la literatura contemporánea que destaca la capacidad de las redes neuronales para abordar problemas de control en sistemas no lineales, dinámicos y con incertidumbre operativa.

Aunque los resultados son prometedores, es importante señalar que el presente estudio se basó en simulaciones y no contempló la validación experimental en un entorno real. Esta limitación abre la posibilidad de extender el trabajo hacia pruebas de laboratorio o aplicaciones en planta, que permitan confirmar la eficacia observada bajo condiciones reales de operación. Asimismo, la investigación futura podría explorar combinaciones híbridas entre controladores PID y redes neuronales, buscando integrar la simplicidad del primero con la capacidad adaptativa del segundo.

En síntesis, este estudio demuestra que las redes neuronales constituyen una alternativa robusta y eficiente frente al control PID tradicional, especialmente en contextos donde la dinámica del sistema presenta comportamientos no lineales o cambios abruptos. La incorporación de técnicas de inteligencia artificial en el ámbito del control industrial ofrece una vía innovadora y de gran potencial para el desarrollo de sistemas más inteligentes, autónomos y resilientes, alineados con las necesidades de la automatización avanzada en la industria moderna.

Referencias Bibliográficas

- Aguilar Malavé, J. S. (2023). Control predictivo basado en modelo para un sistema tipo SISO de nivel de líquido representado en variables de estados y su comparación con el control PID y control por redes neuronales artificiales (Bachelor's thesis, La Libertad: Universidad Estatal Península de Santa Elena, 2023.). <https://repositorio.upse.edu.ec/handle/46000/9608>
- Angulo, Y. D., Gómez, B. S. M., Piraban, H. C. A., Moreno, M. C., & Garcia, A. P. (2021). Control Clasico E Inteligente De Temperatura En Un Prototipo De Invernadero Hidroponico. *Ingeniería e Innovación*. <https://revistas.unicordoba.edu.co/index.php/rri/article/download/2674/3483>
- Blanco Fernández, C., Sierra García, J. E., & Santos, M. (2022). Control de un laboratorio de control de temperatura mediante redes neuronales recurrentes. *In XLIII Jornadas de Automática* (193-200). Universidade da Coruña. Servicio de Publicacións. <http://hdl.handle.net/2183/31379>

- Castro, C. E. V., Pavia, F. E. C., González, D. A. R., & Suarez, O. J. (2021). Diseño De Técnicas De Control Clásico E Inteligente Para Regular Hornos Eléctricos De Tratamiento Térmico. *Ingeniería e Innovación*. <https://revistas.unicordoba.edu.co/index.php/rii/article/download/2645/3454>
- Cobos Franco, R. G., & Salas, S. (2021). Desarrollo de Estrategias de Control Inteligente para un Sistema de Soldadura por Fricción con Agitación (Doctoral dissertation, ESPOL. FIEC.). <http://www.dspace.espol.edu.ec/handle/123456789/56411>
- Espinosa Cárcamo, D., & Pacheco Márquez, S. A. (2021). Comparación de controladores data-driven para un proceso con incertidumbres y no linealidades del laboratorio de automatización y control de la Universidad EIA. <https://repository.eia.edu.co/handle/11190/3503>
- Martínez Añazco, M. S., & Moreta Mite, F. D. L. Á. (2025). Análisis comparativo de desempeño entre control PID y lógica difusa para un sistema de levitación neumática (Bachelor's thesis). <http://dspace.ups.edu.ec/handle/123456789/30433>
- Montoya Barbosa, I. S. (2024). Puesta en marcha del canal de riego como herramienta de aprendizaje significativo para el control y automatización: introducción del módulo de machine learning y redes neuronales industriales. <https://hdl.handle.net/1992/74275>
- Pérez Domínguez, L., Garcia Villalba, L. A., Rodriguez Picon, L. A., Luviano Cruz, D., & Ortiz Muñoz, D. Y. (2021). Control de posición angular para panel solar basado en redes neuronales y control inteligente. Instituto de Ingeniería y Tecnología. <http://cathi.uacj.mx/20.500.11961/22150>
- Pinto Tamayo, H. J. (2024). Control basado en Lyapunov para sistemas no lineales, caso de estudio, sistema de nivel de líquido, y su símil con algoritmos de control PID y redes neuronales artificiales (Bachelor's thesis, La Libertad, Universidad Estatal Península de Santa Elena, 2024). <https://repositorio.upse.edu.ec/handle/46000/10626>
- Quiroga, Á. S. (2025). Control de un rectificador elevador de medio puente con alto factor de potencia usando la red neuronal NARMA-L2. Recuperado de: <http://hdl.handle.net/11349/94041>
- Sánchez, F., Argüelles, E., Terrones, J., & Fernández, L. (2023). Red neuronal artificial evolutiva para el control de temperatura en un reactor batch de polimerización. <http://dspace.ups.edu.ec/handle/123456789/25212>
- Sánchez-Ruiz, F. J., Hernández, E. A., Terrones-Salgado, J., & Fernández Quiroz, L. J. (2023). Red neuronal artificial evolutiva para el control de temperatura en un reactor batch de polimerización. *Ingenius. Revista de Ciencia y Tecnología*, (30), 79-89. <https://doi.org/10.17163/ings.n30.2023.07>
- Triana, M. A. P., Peñaloza, J. A. M., Sánchez, W. H. C., & Arboleda, D. M. M. Implementación de un controlador neuronal para la aplicación de seguimiento de obstáculos en robótica móvil. <https://www.researchgate.net/publication/382687778>

Villalba, J. C. (2022). Modelización de sistemas térmicos en experimentos criogénicos usando redes neuronales (Doctoral dissertation, Universidad de Zaragoza). <https://zaquan.unizar.es/record/125097>