

Contextualización educativa del control predictivo basado en redes neuronales artificiales en la formación en Automatización

Educational contextualization of predictive control based on artificial neural networks in automation training

Carlos Gabriel Mackencie Tobar¹**Deivis Rodrigo Parrales Chancay¹**¹Universidad Técnica Estatal de Quevedo. Ecuador**ORCID:** <https://orcid.org/0009-0006-3494-1839><https://orcid.org/0009-0006-5651-4899>**Correo electrónico(s):**

cmackencie@uteq.edu.ec

dparralesc2@uteq.edu.ec

Recibido: 26 de febrero de 2026

Revisado: 17 de marzo de 2026

Aceptado: 01 de abril de 2026

RESUMEN: El artículo tiene como objetivo proponer pautas pedagógicas centrales para la integración del control predictivo basado en redes neuronales artificiales en la formación universitaria en automatización. La metodología se sustentó en una revisión sistemática de literatura especializada publicada entre 2013 y 2024. El análisis permitió identificar elementos técnicos con mayor potencial educativo para la enseñanza del control avanzado. Como resultado, se sistematizan cuatro pautas centrales. Se concluye que la implementación didáctica del control predictivo neuronal requiere un enfoque intencional que transforme la complejidad matemática en experiencias de aprendizaje significativas y orientadas al desarrollo de competencias profesionales.

Palabras clave: Didáctica de la ingeniería; Control predictivo neuronal; Sistemas no lineales; Educación en automatización; Laboratorio virtual; Competencias en ingeniería

ABSTRACT: This article aims to propose core pedagogical guidelines for integrating predictive control based on artificial neural networks into university-level automation education. The methodology was based on a systematic review of specialized literature published between 2013 and 2024. The analysis identified technical elements with the greatest educational potential for teaching advanced control. As a result, four core guidelines are systematized. It is concluded that the didactic implementation of predictive neural control requires an intentional approach that transforms mathematical complexity into meaningful learning experiences geared toward developing professional competencies.

Keywords: Engineering didactics; Neural predictive control; Nonlinear systems; Automation education; Virtual laboratory; Engineering competencies

Introducción

La formación en ingeniería de control y automatización se encuentra en un punto de inflexión. Por una parte, los avances en inteligencia artificial y aprendizaje automático han revolucionado las estrategias para el control de sistemas complejos, dando lugar a enfoques como el control predictivo neuronal (ANN-MPC) que combinan la capacidad predictiva del MPC tradicional con la

flexibilidad de aprendizaje de las redes neuronales. Por otra parte, las aulas universitarias enfrentan el reto constante de hacer accesibles estos conceptos avanzados a estudiantes que aún dominan los fundamentos de la teoría de control clásica, (Mosso *et al.*, 2021).

Esta desconexión entre los avances técnicos y su asimilación pedagógica constituye una brecha significativa. Existe abundante literatura técnica que demuestra la eficacia del ANN-MPC en aplicaciones industriales (Montes, 2021); Rajasekhar *et al.* (2024), pero son escasos los trabajos que trascienden el reporte de desempeño técnico para proponer marcos sistemáticos de integración curricular.

¿Cómo transformar la complejidad matemática del control predictivo no lineal (NMPC) en experiencias de aprendizaje significativas? ¿Qué elementos del diseño ANN-MPC poseen mayor valor formativo? ¿Cómo utilizar entornos de simulación no solo como herramientas de verificación, sino como espacios para el desarrollo del razonamiento de ingeniería?

El presente artículo aborda precisamente esta brecha, proponiendo un conjunto de pautas para la contextualización educativa del control predictivo neuronal. Como escenario pedagógico, se retoma el sistema de tanques interconectados, un clásico en la enseñanza del control por su dinámica intrínsecamente no lineal, su naturaleza multivariable y los fenómenos de fase no mínima que presenta.

Este sistema ofrece una ventaja didáctica crucial: su comportamiento es físicamente intuitivo (el flujo entre tanques, el nivel del líquido), lo que permite a los estudiantes concentrarse en los conceptos de control sin perder la conexión con la realidad física.

La formación en automatización y control enfrenta el reto de preparar a los estudiantes para comprender y gestionar sistemas dinámicos cada vez más complejos, caracterizados por comportamientos no lineales, acoplamientos multivariables e incertidumbres difíciles de representar mediante modelos matemáticos tradicionales. En este escenario, la integración de técnicas de inteligencia artificial, particularmente las redes neuronales artificiales (ANN) y las redes neuronales profundas (DNN), ha adquirido un papel relevante tanto en el ámbito científico como en el educativo, al posibilitar nuevas formas de modelación, predicción y análisis de sistemas dinámicos complejos Castaneda *et al.* (2023); Alzubaidi *et al.* (2021).

El control predictivo basado en modelos (MPC) se ha consolidado como una estrategia avanzada ampliamente utilizada en aplicaciones industriales; no obstante, su incorporación en contextos

educativos presenta limitaciones asociadas a la elevada complejidad matemática de los modelos no lineales y al alto costo computacional del control predictivo no lineal (NMPC) Alzubaidi *et al.* (2021).

En respuesta a estas dificultades, diversos estudios han propuesto el uso de redes neuronales artificiales como modelos internos del controlador predictivo, dando lugar al enfoque conocido como control predictivo neuronal (ANN-MPC), el cual permite aproximar dinámicas complejas a partir de datos, reduciendo la carga computacional y facilitando su comprensión desde una perspectiva formativa (Montes, 2021).

Los sistemas de tanques interconectados constituyen un referente clásico en la enseñanza del control automático, debido a su carácter no lineal, multivariable y a la presencia de fenómenos como la fase no mínima. Investigaciones previas han demostrado que estos sistemas permiten ilustrar de manera efectiva conceptos fundamentales de modelación, identificación de parámetros, sintonización de controladores y análisis de estabilidad, lo que los convierte en un recurso didáctico idóneo para la contextualización educativa del control predictivo avanzado Roa *et al.* (2017).

En este sentido, la literatura reciente evidencia que la integración de redes neuronales artificiales y profundas en esquemas de control predictivo mejora el desempeño técnico de los sistemas y, al mismo tiempo, ofrece un alto valor pedagógico al favorecer el aprendizaje basado en datos y el uso de la simulación computacional como laboratorio virtual Bamimore *et al.* (2019); (Yankai & Bhushan, 2020). Estudios comparativos han mostrado que los enfoques ANN-MPC y RNN-MPC alcanzan niveles de precisión similares a los del NMPC tradicional, pero con menores tiempos de cómputo, lo cual resulta especialmente ventajoso para su implementación en entornos educativos y plataformas de simulación en tiempo real Rajasekhar *et al.* (2024); Jian *et al.* (2024).

Desde esta perspectiva, se hace necesario sistematizar las pautas que orienten la contextualización educativa del uso de redes neuronales integradas al control predictivo, atendiendo no solo a su eficiencia técnica, sino a su potencial formativo en la enseñanza de la automatización, el control inteligente y la inteligencia artificial aplicada. En consecuencia, el presente artículo busca responder a la pregunta: ¿Cómo podemos diseñar actividades de aprendizaje que permitan a los estudiantes de ingeniería no solo comprender, sino también diseñar, implementar y evaluar estrategias de control predictivo basadas en redes neuronales, utilizando recursos y plazos compatibles con un curso universitario?

La investigación se sustenta en un enfoque cualitativo, mediante el empleo del método de análisis documental, orientado a la interpretación pedagógica de los avances científicos en el área del control predictivo basado en redes neuronales. El análisis–síntesis, para examinar los fundamentos de las redes neuronales artificiales, profundas y su integración en estrategias de control predictivo, y sintetizar pautas para su aplicación educativa y el método de inducción–deducción, con el propósito de identificar regularidades en los estudios analizados y derivar principios didácticos aplicables a la enseñanza del control no lineal.

La metodología se estructuró en cuatro etapas, orientadas explícitamente a la contextualización educativa del contenido, en correspondencia con el objetivo planteado.

Etapas 1. Identificación y selección de fuentes relevantes.

Se realizó una búsqueda intencional de literatura científica publicada entre 2019 y 2024, relacionada con: redes neuronales artificiales y profundas, control predictivo no lineal (MPC, NMPC, ANN-MPC, RNN-MPC), sistemas de tanques interconectados, aplicaciones de simulación y modelación con fines formativos.

Se priorizaron estudios con aportes metodológicos claros, resultados reproducibles y potencial de uso educativo.

Etapas 2. Análisis técnico–pedagógico de los modelos

Las fuentes seleccionadas fueron analizadas considerando: tipos de arquitecturas neuronales (MLP, NARX, RNN, DNN), algoritmos de entrenamiento y optimización, parámetros de sintonización del controlador predictivo (NP, NC, Ts, Q, R), nivel de complejidad y comprensión para estudiantes. Este análisis permitió identificar qué modelos resultan más adecuados para ser utilizados como recursos didácticos en la enseñanza del control avanzado.

Etapas 3. Sistematización de pautas para la contextualización educativa

A partir del análisis realizado, se sistematizaron pautas orientadas al uso de la simulación computacional como laboratorio virtual, el aprendizaje basado en datos generados por sistemas dinámicos, la comprensión de la no linealidad y el acoplamiento multivariable, el desarrollo de competencias en modelación, predicción y toma de decisiones. Se consideró el sistema de tanques interconectados como escenario pedagógico idóneo para introducir conceptos de control predictivo neuronal.

Etapas 4. Integración del marco teórico–referencial

Se construyó un marco teórico integrado que articula los aportes de diversos autores, destacando su valor para la docencia universitaria, la investigación formativa y la enseñanza de la inteligencia artificial aplicada al control de procesos.

Desarrollo

Las redes neuronales profundas (Deep Neural Networks, DNN) son una extensión de las redes neuronales tradicionales que utilizan múltiples capas ocultas para procesar información compleja. Estas arquitecturas están diseñadas para aprender representaciones jerárquicas de datos, lo que les permite capturar características de alto nivel y patrones complejos. Se consideran parte del aprendizaje profundo (Deep Learning) y pueden manejar millones de parámetros, dependiendo de la complejidad del problema que abordan Alzubaidi *et al.* (2021)

Las DNN están formadas por múltiples capas ocultas situadas entre la capa de entrada y la capa de salida. Cada capa oculta realiza cálculos no lineales y transforma la entrada para que la capa siguiente pueda extraer características más abstractas. Estas capas pueden estar totalmente conectadas (fullyconnected) o parcialmente conectadas, dependiendo del diseño del modelo. Además, algunas arquitecturas incluyen estructuras recurrentes para permitir la realimentación y el aprendizaje de dependencias temporales Alzubaidi *et al.* (2021)

En las DNN, los datos se propagan hacia adelante a través de las capas (feed-forward), pasando por funciones de activación no lineales que permiten al modelo aprender relaciones complejas. En el proceso de entrenamiento, el modelo modifica sus pesos a través de un algoritmo de optimización que busca reducir una función de error, utilizando el método de retro propagación. Este proceso iterativo ajusta gradualmente los pesos para mejorar la precisión del modelo Alzubaidi *et al.* (2021).

El modelo propuesto por Roa *et al.* (2017) permite simular dinámicas no lineales complejas en sistemas de tres tanques, utilizando ecuaciones diferenciales basadas en principios de conservación de masa.

Según (Montes, 2021), uno de los principales desafíos en el diseño de controladores predictivos no lineales (MPC) es la selección adecuada del modelo de predicción, así como de parámetros de sintonización como el horizonte de predicción (NP), el horizonte de control (NC) y las matrices de

ponderación Q y R en la función de costo. Además, destaca la importancia de considerar restricciones en entradas y salidas para garantizar estabilidad y seguridad operativa del sistema.

El análisis de la literatura reveló que los estudios técnicos sobre ANN-MPC, aunque no escritos con fines pedagógicos, encierran un valioso potencial formativo cuando se examinan a través de una lente educativa.

1. El sistema de tanques interconectados: un microcosmos para el aprendizaje integrado

Más que un simple ejemplo, el sistema de tanques constituye un "microcosmos" pedagógico. Su dinámica, descrita por ecuaciones diferenciales no lineales basadas en principios de conservación de masa es lo suficientemente compleja para desbordar las técnicas de control lineal convencionales, pero lo suficientemente transparente como para que los estudiantes puedan formarse una intuición física, Roa *et al.* (2017).

La riqueza didáctica de este escenario radica en su capacidad para ilustrar múltiples conceptos de control avanzado de manera interconectada: acoplamiento multivariable (el nivel en un tanque afecta al otro), comportamientos de fase no mínima (una respuesta inicial en dirección contraria a la deseada) y la necesidad de manejar restricciones físicas (niveles máximos, caudales limitados). Al mantener este escenario constante a lo largo de un curso, los estudiantes pueden observar cómo diferentes estrategias de control (PID, MPC lineal, ANN-MPC) abordan los mismos desafíos fundamentales, facilitando la comparación profunda.

2. El modelado basado en datos como democratizador del control avanzado

Uno de los obstáculos históricos para la enseñanza del NMPC ha sido la necesidad de un modelo analítico preciso del sistema, cuya derivación y linealización consume tiempo y se enfoca en habilidades matemáticas más que de ingeniería. Aquí es donde el ANN-MPC introduce un cambio de paradigma con profundo valor pedagógico.

Investigaciones como las de Saldaña *et al.* (2023) y Bamimore *et al.* (2019) muestran cómo una red neuronal (por ejemplo, una NARX o una LSTM) puede aprender la dinámica del sistema de tanques directamente a partir de datos operativos, obtenidos ya sea de un banco físico o, más accesible para un aula, de una simulación detallada en MATLAB/Simulink o Python. Este enfoque centra el esfuerzo del estudiante en el proceso de ingeniería: diseño de experimentos para la recolección de datos, preprocesamiento, entrenamiento y validación del modelo neuronal.

El aprendizaje basado en datos reduce la barrera de entrada matemática y alinea la enseñanza con las prácticas actuales de la industria, donde los modelos basados en datos son cada vez más prevalentes. Además, permite discutir conceptos cruciales como el sobreajuste, la generalización y la importancia de los conjuntos de datos de validación, conectando así el control con temas fundamentales de la ciencia de datos, Zhang *et al.* (2021).

3. *El Sistema de Tanques como Plataforma Didáctica Integradora*

Los sistemas de tanques interconectados han sido ampliamente utilizados en la literatura como casos de estudio para la enseñanza del control automático, debido a su comportamiento no lineal, su acoplamiento multivariable y la presencia de dinámicas de fase no mínima Roa *et al.* (2017). Estos sistemas permiten que los estudiantes visualicen y analicen cómo pequeñas variaciones en las entradas pueden producir efectos significativos en las salidas, un fenómeno que, desde la perspectiva educativa, favorece la comprensión de conceptos como estabilidad, tiempo de respuesta y acoplamiento dinámico.

Además, los estudios de Bamimore *et al.* (2019) muestran que las redes neuronales alimentadas con datos de simulación pueden modelar con eficacia este tipo de sistemas multivariados. Esta evidencia sugiere que la introducción de tanques interconectados como plataforma didáctica favorece la integración de teoría y práctica, permitiendo a los estudiantes trabajar con datos reales o simulados y observar de primera mano cómo los modelos neuronal-predictivos responden ante condiciones diversas.

4. *Ventajas Pedagógicas del Enfoque ANN-MPC frente al NMPC Clásico*

El análisis comparativo de estudios recientes revela que el enfoque ANN-MPC presenta ventajas pedagógicas significativas frente al control predictivo no lineal clásico (NMPC). Por un lado, Rajasekhar *et al.* (2024) y Jian *et al.* (2024) evidencian que los esquemas basados en redes neuronales reducen el tiempo de cómputo requerido para obtener acciones de control, manteniendo niveles de precisión similares a los del NMPC tradicional. Desde una perspectiva didáctica, esta reducción del tiempo de ejecución permite a los estudiantes realizar experimentos iterativos en tiempo casi real, lo que incrementa la oportunidad de aprender mediante la experimentación y la prueba-error.

Por otro lado, Saldaña *et al.* (2023) señalan que las ANN permiten abstraer dinámicas complejas sin necesidad de formular explícitamente ecuaciones diferenciales sofisticadas. Esta abstracción

facilita que los estudiantes se centren en entender el comportamiento del sistema y la lógica del control predictivo, en lugar de quedar atrapados en derivaciones matemáticas extensas, lo cual refuerza un aprendizaje conceptual más profundo.

5. *La Simulación Computacional como Laboratorio Virtual Esencial*

La utilización de simulación computacional se revela como un componente clave para la enseñanza del control predictivo neuronal. Los trabajos de Bamimore *et al.* (2019) y Yankai y Bhushan (2020), muestran que la generación de datos sintéticos a través de simulaciones proporciona un entorno seguro y controlado donde los estudiantes pueden explorar, modificar parámetros y observar respuestas del sistema sin los riesgos y costos asociados a experimentos físicos.

Esta estrategia se alinea con enfoques pedagógicos constructivistas, donde el aprendizaje se construye a partir de la experiencia y la reflexión sobre los resultados obtenidos Yankai y Bhushan (2020). Además, los entornos de simulación computacional permiten introducir herramientas de visualización y retroalimentación inmediata, aspectos que potencian la motivación y la autoevaluación de los estudiantes.

6. *Síntesis de Pautas para la Contextualización Educativa*

La síntesis de los hallazgos revisados permite identificar un conjunto de pautas metodológicas que orientan la contextualización educativa del control predictivo basado en redes neuronales, teniendo en cuenta la progresión lógica de los contenidos y las necesidades formativas de los estudiantes:

1. **Secuenciación progresiva de modelos:** Introducir inicialmente redes neuronales simples (p. ej., MLP) antes de avanzar hacia modelos más complejos (NARX, RNN, DNN), facilitando así la construcción gradual de competencias cognitivas.
2. **Uso de sistemas de tanques interconectados:** Emplear este tipo de sistema como escenario didáctico integrador que permite observar fenómenos no lineales y respuestas multivariables en tiempo real o simulado.
3. **Simulación computacional como laboratorio:** Favorecer el uso de entornos de simulación para generar y manipular datos, permitiendo a los estudiantes experimentar con modelos neuronales y controladores predictivos sin riesgos prácticos.

4. **Comparación de enfoques de control:** Diseñar actividades que permitan contrastar enfoques de MPC lineal, NMPC y ANN-MPC, de modo que los estudiantes comprendan ventajas, limitaciones y aplicaciones de cada uno.
5. **Interpretación de resultados y análisis crítico:** Enfatizar la interpretación de respuestas del sistema, análisis de errores y evaluación de desempeño de los controladores en términos de conceptos formativos.
6. **Desarrollo de competencias transversales:** Promover actividades que integren modelación, programación, análisis de datos y toma de decisiones responsable, consolidando habilidades aplicables en contextos reales.

El análisis de la literatura revisada permitió identificar un conjunto de resultados relevantes para la **contextualización educativa del control predictivo basado en redes neuronales artificiales y profundas**, particularmente en escenarios formativos vinculados a la automatización y el control de procesos.

En primer lugar, se constató que las redes neuronales artificiales, especialmente las arquitecturas tipo MLP, NARX y RNN, constituyen modelos adecuados para representar sistemas dinámicos no lineales desde una perspectiva educativa, al permitir aproximar el comportamiento del sistema sin recurrir a formulaciones matemáticas complejas Bamimore *et al.* (2019); Saldaña *et al.* (2023). Esta característica facilita su introducción progresiva en asignaturas de control avanzado, favoreciendo la comprensión conceptual de la predicción y la toma de decisiones en sistemas dinámicos.

En segundo lugar, los estudios analizados evidencian que la integración de ANN y DNN en esquemas de control predictivo (ANN-MPC y RNN-MPC) reduce significativamente la carga computacional en comparación con el NMPC tradicional, manteniendo niveles de precisión aceptables Rajasekhar *et al.* (2024); Jian Yi *et al.* (2024). Desde el punto de vista educativo, este resultado posibilita la implementación de estas estrategias en entornos de simulación académicos y plataformas con recursos limitados, lo que amplía su accesibilidad para procesos de enseñanza–aprendizaje.

Otro resultado relevante es la identificación de los **sistemas de tanques interconectados** como recurso didáctico eficaz para contextualizar el uso de controladores predictivos neuronales. La literatura demuestra que estos sistemas permiten ilustrar fenómenos complejos como la no

linealidad, el acoplamiento multivariable y la fase no mínima, favoreciendo el aprendizaje significativo mediante la experimentación virtual y el análisis de datos simulados Roa *et al.* (2017).

Asimismo, se evidenció que el empleo de datos generados por simulación computacional constituye una estrategia pedagógica válida para el entrenamiento de modelos neuronales en contextos educativos, promoviendo el aprendizaje basado en datos y el desarrollo de competencias en modelación, análisis y validación de sistemas Bamimore *et al.* (2019); Yankai y Bhushan (2020).

El análisis permitió sistematizar un conjunto de **pautas metodológicas** orientadas a guiar la incorporación progresiva del control predictivo neuronal en la formación académica, atendiendo a la complejidad cognitiva del estudiante, la gradualidad de los contenidos y la articulación entre teoría y práctica.

Los resultados obtenidos confirman que el control predictivo basado en redes neuronales artificiales y profundas no solo representa un avance técnico en el ámbito del control de sistemas no lineales, sino que posee un elevado potencial educativo cuando se emplea de forma contextualizada y didácticamente estructurada.

La posibilidad de utilizar redes neuronales como modelos internos del controlador predictivo permite desplazar el énfasis formativo desde la resolución analítica de ecuaciones complejas hacia la comprensión del comportamiento dinámico del sistema y la interpretación de los resultados, lo cual coincide con los enfoques pedagógicos centrados en el aprendizaje activo y basado en problemas. En este sentido, los aportes de Saldaña *et al.* (2023) refuerzan la idea de que las ANN facilitan el tránsito desde modelos teóricos abstractos hacia representaciones funcionales comprensibles para el estudiante.

Se connota también que la reducción del tiempo de cómputo lograda por los esquemas ANN-MPC y RNN-MPC, reportada por Rajasekhar *et al.* (2024) y Jian *et al.* (2024), tiene implicaciones educativas relevantes, al permitir la interacción en tiempo casi real durante actividades de simulación, lo que incrementa la motivación y el aprendizaje experimental.

Por otra parte, el uso de sistemas de tanques interconectados como escenario de aprendizaje refuerza la contextualización del contenido, al tratarse de sistemas ampliamente reconocidos en la literatura y en la enseñanza del control automático. Esto favorece la transferencia de conocimientos y la integración de conceptos de inteligencia artificial, control predictivo y modelación no lineal en un mismo entorno formativo.

En consecuencia, la discusión reafirma que la incorporación de redes neuronales en el control predictivo debe concebirse no solo como una estrategia de optimización del desempeño del sistema, sino como un recurso pedagógico que contribuye al desarrollo de competencias profesionales en automatización, análisis de sistemas y toma de decisiones basada en datos.

Conclusiones

El análisis realizado permitió identificar que la integración de redes neuronales artificiales y profundas en esquemas de control predictivo no lineal constituye una alternativa pedagógica pertinente para la formación en automatización y control, al facilitar la comprensión de sistemas dinámicos complejos desde un enfoque basado en datos y simulación computacional.

Se constató que el control predictivo neuronal favorece la contextualización educativa de conceptos avanzados como la no linealidad, el acoplamiento multivariable y la fase no mínima, reduciendo la dependencia de modelos matemáticos de alta complejidad y promoviendo un aprendizaje más significativo y aplicado.

Los sistemas de tanques interconectados se consolidan como un recurso didáctico eficaz para la enseñanza del control predictivo basado en redes neuronales, al permitir la integración coherente de contenidos de modelación, identificación, predicción y toma de decisiones en un mismo entorno formativo.

Las pautas metodológicas propuestas ofrecen una guía estructurada para la incorporación progresiva del control predictivo basado en redes neuronales en los procesos de enseñanza–aprendizaje, atendiendo a la complejidad cognitiva del estudiante y al desarrollo de competencias en modelación, análisis de sistemas y uso de herramientas de inteligencia artificial aplicada.

El enfoque educativo del control predictivo basado en redes neuronales contribuye a fortalecer la formación integral de los futuros profesionales de la automatización, al articular teoría y práctica mediante estrategias didácticas innovadoras, contextualizadas y alineadas con las demandas actuales de la ingeniería y la educación superior.

Este marco se ha derivado de la revisión de literatura técnica, por lo que su validación empírica en aulas reales es el paso natural siguiente. Futuras investigaciones deberían medir el impacto de estas pautas en el desarrollo de competencias específicas y en la motivación de los estudiantes. Además, se requiere el desarrollo colaborativo de recursos educativos abiertos (conjuntos de datos, modelos

de simulación, guías de actividades) que permitan a más docentes adoptar este enfoque sin comenzar desde cero.

Referencias bibliográficas

- Bamimore, K. M., Kehinde, L. O., & Abajo, O. A. (2019). Artificial neural network model-based predictive real-time control of a cascaded two tank system. *European Journal of Engineering Research and Science*, 4(5), 1-7.
<https://ijt.oauife.edu.ng/index.php/ijt/article/view/141>
- Castaneda, W. A., Benjamín, P. E., y Vega, F. (2023). Redes neuronales artificiales: una medición de aprendizajes de pronósticos como demanda potencial. *Revista de Ingeniería y Automatización*, 27(18), 45-58
http://ve.scielo.org/scielo.php?script=sci_arttext&pid=S1316-48212023000100051
- Montes, D. A. (2021). *Implementación de un controlador predictivo no lineal y una estrategia de optimización en tiempo real a una planta piloto híbrida* (Trabajo de fin de Máster) Universidad de Valladolid
- Mosso, A., Hernández-Pérez, J. A., Nagarajan, G., & Juárez-Romero, D. (2021). Una incursión al aprendizaje profundo para la regulación de procesos. *Programación Matemática y Software*, 13(2). <https://doi.org/10.30973/progmat/2021.13.2/4>
- Roa, B., Contreras, O. L., Medina, G. A., Vega, L. V. (2017). Modelado matemático, simulación, análisis y control de un sistema hidráulico interactivo-tres tanques. *Revista de Tecnología*, 16(1), 77-98 <https://revistas.unbosque.edu.co/index.php/RevTec/article/view/2318>
- Jian, Y., Xialai, W., Ling, L., Jiabin, Q., y Junghui, C. (2024). Data-driven model predictive control for vehicle trajectory tracking using recurrent neural networks. *IFAC PapersOnLine*, 58(29), 367-372. www.sciencedirect.com
- Yankai, R. y Bhushan, R. (2020). Deep Neural Network Approximation of Nonlinear Model Predictive Control. *IFAC PapersOnLine*, 53(2), 11319-11324
<http://creativecommons.org/licenses/by-nc-nd/4.0>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., Farhan, L. (2021). Review of deep learning: concepts, CNN

architectures, challenges, applications, future directions. *J BigData*, 8(1), 53.
<https://pubmed.ncbi.nlm.nih.gov/33816053/>

Saldaña, C. A., Tumbaco, A. R., Kuonquí, F. I., Pasmay, P. I., & Malave, C. A. (2023). Simulación y comparación de controladores PID, Liapunov y redes neuronales artificiales: Abordando el rechazo de perturbaciones en sistemas no lineales a través de modelado computacional. *Ciencia Latina Revista Científica Multidisciplinar*, 7(4), 3849-3865.
https://doi.org/10.37811/cl_rcm.v7i4.7234

Rajasekhar, N., Nagappan, K. K., Radhakrishnan, T. K., y Samsudeen, N. (2024). Effective MPC strategies using deep learning methods for control of nonlinear system. *International Journal of Dynamics and Control*, (10), 3694-3707
https://www.researchgate.net/publication/380820118_Effective_MPC_strategies_using_deep_learning_methods_for_control_of_nonlinear_system

Zhang, A., Zhiyun, B. Wangand, H. (2021). Differential evolution optimized RNN-based NMPC for flexible joint robots. *Electronics*, 10(19), 2426. <https://doi.org/10.3390/electronics10192426>