DOI: 10.5281/zenodo.22257329

Análisis del Uso de Redes Neuronales en Procesos de Energía Nuclear y Altas Energías

Analysis of the Use of Neural Networks in Nuclear and High Energy Processes

Néstor A. Sánchez V.[1], **Juan C. Cabanillas N.**[1], **Jaredt G. Torres L.**[1], **Julio C. Picos P.**[1], **Jesús N. Leal L.**[1]

[1]Tecnológico Nacional de México Campus Culiacán, Académica de Ingeniería Electrónica

Autor de correspondencia: juan.cn@culiacan.tecnm.mx

Resumen

En las plantas de energía nuclear y experimentos para estudios de física de altas energías se llevan a cabo procesos que son de gran trascendencia y complejidad por sus requisitos de alta precisión y fiabilidad, como son el control y monitoreo de sus parámetros operativos relevantes. Este trabajo aborda una revisión literaria que ha tenido el uso de herramientas computacionales relacionadas con la inteligencia artificial (IA), y en particular de las redes neuronales artificiales (ANN), para este tipo aplicaciones; y de esta manera definir los alcances y limitaciones actuales, así como las perspectivas de mejoras contempladas en un futuro. El uso de las ANN en diversos ámbitos de aplicación se debe a la capacidad que tienen para manejar datos complejos y no lineales. Primeramente, se realiza una contextualización del uso de ANN en procesos de control relacionados con áreas de la energías, medicina e industria. Después, se describen brevemente los fundamentos de los procesos de la energía nuclear y de las redes neuronales artificiales. En seguida, se explican los criterios y el procedimiento de selección de la literatura para su posterior clasificación, análisis y descripción. Finalmente, de acuerdo con los estudios realizados en este trabajo se puede afirmar que, en particular para las aplicaciones de procesos nucleares, las herramientas computaciones de las ANN continúan siendo una asignatura pendiente en muchos ámbitos de desarrollo y operativos; sin embargo, ya se están dando pasos importantes para una mayor apertura y aceptación sobre todo las relacionadas con aplicaciones de aprendizaje automático. Por otro lado, el uso de ANN en experimentos de estudios de física de altas energías se distingue por tener un desarrollo más consolidado en lo que concierne a la optimización, simulación y análisis de datos físicos, como resultados de las colisiones de partículas en los experimentos de estos aceleradores; y en gran medida se ha tenido un desarrollo avanzado en el uso de herramientas de inteligencia artificial en lo que respecta a las tecnologías de sistemas de control de detectores y experimentos, así como en la definición de los valores de parámetros operativos con base en los comportamientos previos bajo determinadas condiciones.

Palabras clave: Redes neuronales artificiales, control de energía nuclear, monitoreo, inteligencia artificial.

Abstract

In nuclear power plants and experiments for high-energy physics studies, processes of great significance and complexity are carried out due to their strict requirements for high precision and reliability, such as the control and monitoring of their relevant operational parameters. This work presents a literature review of the use of computational tools related to artificial intelligence (AI), and particularly artificial neural networks (ANNs), for these types of applications, thereby defining their current scope and limitations, as well as prospects for future improvements. The adoption of ANNs across various application domains stems from their ability to handle complex and non-linear data.

First, a contextualization of the use of ANNs in control processes related to energy, medicine, and industry is presented. Next, the fundamentals of nuclear energy processes and artificial neural networks are briefly described. Subsequently, the literature selection criteria and procedures for subsequent classification, analysis, and description are detailed. Finally, based on the studies conducted in this work, it can be stated that, specifically for nuclear process applications, ANN computational tools remain a work in progress across many operational and development areas; nevertheless, significant strides are being made toward broader adoption and acceptance, particularly regarding machine learning applications. On the other hand, the deployment of ANNs in high-energy physics experiments is characterized by a more consolidated state of development concerning the optimization, simulation, and analysis of physical data resulting from particle collisions in accelerator experiments. Furthermore, advanced progress has been made in leveraging artificial intelligence tools for detector and experiment control system technologies, as well as in defining operational parameter values based on historical behavior under specific operating conditions.

Keywords: Artificial neural networks, nuclear power control, monitoring, artificial intelligence.

Recibido: 26/07/2026; Aceptado: 21/08/2026; Publicado 31/08/2026

CC BY-NC-SA 4.0

Introducción

El control y monitoreo de los procesos en plantas de energía nuclear son una tarea compleja, que requiere alta precisión, fiabilidad y robustez debido a que involucra conocer en todo momento el comportamiento de una serie de variables críticas que deben ser evaluadas y/o ajustadas continuamente para asegurar la operación segura y eficiente de estas plantas [1][2]. Tradicionalmente, los sistemas de control han utilizado métodos basados en modelos matemáticos, sin embargo estos enfoques a menudo presentan limitaciones cuando se enfrentan a condiciones de tipo dinámicas y no lineales, que son inherentes a los sistemas nucleares. Por su parte, el significativo avance que ha tenido la inteligencia artificial en año recientes, y en particular las redes neuronales artificiales (ANN, Artificial Neural Networks), han surgido como una herramienta potencialmente disruptiva para mejorar estos procesos. Las ANN tienen la capacidad de aprender y adaptarse a partir del conocimiento de grandes volúmenes de datos, lo que las hace particularmente pertinentes para gestionar la complejidad e incertidumbre en el control de procesos nucleares. No obstante, la adopción generalizada de las ANN en los diversos procesos nucleares todavía está en etapas tempranas, y aún no se cuenta con una regulación ni entendimiento claro de las potencialidades de esta tecnología subyacente, necesaria

para su implementación de una manera efectiva, eficiente y confiable en la actualidad. Este escenario inicial, enfatiza la necesidad de un análisis exhaustivo y sistemático del estado actual de las ANN en el control de procesos nucleares, así como de experimentos de altas energías para estudios de física.

El uso de ANN para el control de procesos en diversas áreas de la energía ha sido un tema de interés desde hace últimos años. Por ejemplo, en [3] exploraron la aplicación de ANN para la inspección de gránulos (pellets, en inglés) de combustible nuclear fabricados a través de la extracción de características. Adicionalmente, estudios han demostrado el potencial de las ANN en aplicaciones de control y monitoreo de alta precisión, como es [4] que propuso un proceso de optimización basado en modelos para sistemas de Calentamiento, Ventilación y Aire Acondicionado (HVAC) utilizando ANN para la modelización y algoritmos evolutivos para la optimización, resaltando la capacidad de las ANN para mejorar la eficiencia en sistemas complejos. Así como en [5], en donde investigaron la viabilidad de usar ANN para la garantía de calidad en las interpretaciones de imágenes de perfusión miocárdica. En [6] se enfocaron en el desarrollo de ANN semifísicas para el control de la fase de combustión en motores de encendido por chispa de múltiples combustibles, enfatizando la reducción del tamaño de la red y el esfuerzo de calibración. En [7] estudiaron el uso de ANN para el control de digestores anaeróbicos con el fin de mejorar la eficiencia de producción de biogás, y en [8] discutieron las aplicaciones de ANN en la tecnología de invernaderos, destacando el potencial para adaptar estos modelos a nuevas tecnologías como el internet de las cosas y el aprendizaje automático. Estos ejemplos muestran la diversidad de aplicaciones de ANN en el control de procesos energéticos y la necesidad de integrar esta tecnología en la industria nuclear.

Por otra parte, la mayor parte de la literatura encontrada incluye múltiples estudios que exploran diferentes aspectos de las ANN, pero existen pocos relacionados con la aplicación directa en procesos nucleares. La falta de estudios integradores en ese sentido dificulta la identificación de las áreas de desarrollo y las tendencias actuales en el uso de ANN para el control de estos procesos. Asimismo, esta fragmentación de información impide determinar áreas potenciales que requieren mayor investigación y desarrollo. Por lo tanto, la ausencia de una visión consolidada y crítica sobre los avances en la implementación de las ANN en la industria nuclear también puede llevar a una subutilización de estas tecnologías avanzadas, lo que limitaría su potencial para optimizar sus operaciones y recursos. Asimismo, es de gran relevancia realizar un análisis más detallado que no solo compare e integre los diferentes enfoques y resultados obtenidos hasta la fecha, sino que además identifique las áreas de oportunidad a nivel tecnológico, científico e incluso legislativo de este campo emergente. Bajo la premisa de que los sistemas de control y seguridad son esenciales para garantizar que el reactor opere dentro de los parámetros seguros y para responder rápidamente a cualquier desviación de las condiciones normales de operación.

La literatura sobre los procesos de energía nuclear abarca una amplia gama de temas, desde la explotación eficiente de los recursos de combustibles fósiles hasta la producción de hidrógeno para la economía del hidrógeno. [9] discute el papel de la energía nuclear en extender y sustituir los recursos limitados de combustibles fósiles, destacando la eficiencia de la ruta nuclear. Mientras que [10][11] profundizan en la producción a gran escala de hidrógeno utilizando energía nuclear, con un enfoque en reactores nucleares avanzados de alta temperatura. [12] explora procesos de conversión de energía sinérgicos que combinan energía nuclear y combustibles fósiles para producir portadores de energía como electricidad, hidrocarburos e hidrógeno.

Además, [13] examinan la energía de simetría nuclear y su impacto en las estrellas de neutrones, en tanto que en [14] conectan la ecuación de estado nuclear con procesos de fusión y quasifisión en reacciones nucleares de baja energía. En [15] aplican el análisis de exergía y anergía a un ciclo nuclear termoquímico para la producción de hidrógeno, destacando la eficiencia del ciclo e identificando los procesos que generan más anergía. Szargut *et al*., en [16] definen a la exergía como la cantidad máxima de trabajo útil que se puede extraer de un sistema cuando este se encuentra en equilibrio con su entorno. En otras palabras, es la parte de la energía disponible para realizar trabajo mecánico o térmico antes de alcanzar el equilibrio con el ambiente. A diferencia de la energía total, la exergía toma en cuenta la capacidad de transformación de la energía y no solo su cantidad. Asimismo, Berjan en [17] comprende a la anergía como la parte de la energía de un sistema que no puede convertirse en trabajo útil debido a limitaciones termodinámicas. Es la fracción de la energía total que se degrada y no puede aprovecharse para la producción de trabajo mecánico o eléctrico. Chirwa en [18] discute el desarrollo de procesos de tratamiento biológico para la separación y recuperación de desechos radiactivos, con el objetivo de mejorar la viabilidad de la energía nuclear al abordar las preocupaciones sobre la acumulación de desechos radiactivos. Por último, [19] evalúa el proceso de selección de emplazamientos de instalaciones de desechos nucleares en Ontario, Canadá, desde la perspectiva de la justicia energética, enfatizando la importancia del contexto local y la geografía en la equidad del proceso.

La Figura 1 presenta la energía simétrica e_{sym} y el parámetro de presión relacionado con la densidad nuclear ρ para diferentes valores de Λ_b que representa un parámetro de interacción en el modelo utilizado [13]. El gráfico superior (a) muestra cómo la energía simétrica varía en función de la densidad nuclear, mientras que el gráfico inferior (b) detalla el comportamiento del término relacionado con la presión (L/AL/AL/A). Las curvas de colores corresponden a distintos valores de que refleja la influencia de este parámetro en las propiedades de la materia nuclear a diferentes densidades. La relación entre la energía simétrica y la densidad nuclear se expresa como:

$$e_{sym}(\rho) = e_0 + \int_{\rho_0}^{\rho} f(\rho', \Lambda_b) d\rho' \qquad (1)$$

Donde:

$e_{sym}(\rho)$ representa la energía simétrica en función de la densidad nuclear.

e_0 es un valor de referencia de la energía simétrica en una densidad normal.

$f(\rho', \Lambda_b)$ es una función de ajuste que depende de la densidad y del parámetro de interacción Λ_b.

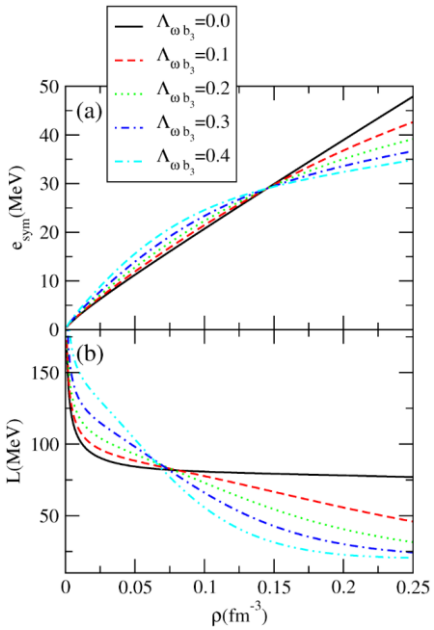

Figura 1. *Energía simétrica como función de densidad [13].*

De acuerdo con [13] estos resultados son cruciales para comprender la ecuación de estado de la materia nuclear, particularmente en condiciones extremas como las presentes en estrellas de neutrones o colisiones nucleares. La dependencia de la energía simétrica y la presión respecto a la densidad ofrece información sobre la estabilidad y estructura de sistemas nucleares densos. Además, la sensibilidad al parámetro Λ_b sugiere que variaciones en las interacciones nucleares pueden alterar significativamente las predicciones del comportamiento de la materia nuclear, impactando modelos astrofísicos y experimentos en física nuclear.

El control de procesos en las plantas de energía nuclear es complejo debido a la necesidad de mantener la estabilidad del reactor, gestionar la transferencia de calor, y asegurar la integridad de los sistemas de contención. Esto implica la monitorización y control de múltiples variables como: temperatura, presión, flujo y niveles de radiación, utilizando una combinación de sensores, actuadores y sistemas de control automatizados [4][6].

A. Redes neuronales artificiales

Por otro lado, las redes neuronales artificiales (ANN) son un modelo computacional inspirado en la estructura y funcionamiento del cerebro humano. Estas redes consisten en un conjunto de unidades de procesamiento llamadas *neuronas*, organizadas en capas. Generalmente, una ANN consta de una capa de entrada, una o más capas ocultas y una capa de salida. Cada neurona está conectada a otras mediante pesos sinápticos que se ajustan durante el proceso de entrenamiento.

La Figura 2, muestra la estructura de una red neuronal artificial (ANN) de tipo multicapa. De acuerdo con [20], este modelo consiste en tres capas principales:

1) La capa de entrada representada por los nodos $x_1, x_2, \dots, x_n$ que corresponden a las entradas de datos o características del sistema que se está analizando. Estas entradas alimentan la red neuronal con información del entorno o del sistema a modelar.

2) La capa oculta, representada por los nodos $y_1, y_2, \dots, y_m$ que procesan la información proveniente de la capa de entrada. Cada nodo está conectado a los nodos de entrada a través de pesos sinápticos $v_{11}, v_{1i}, v_{ji}, \dots, v_{mn}$ los cuales determinan la contribución de cada entrada al nodo oculto correspondiente. La capa oculta aplica funciones de activación para modelar relaciones no lineales entre las entradas y las salidas.

3) La capa de salida representada por los nodos $z_1, \dots, z_k, \dots, z_p$ que generan los resultados finales de la red. Estas salidas corresponden a las predicciones o decisiones realizadas por la ANN. Cada nodo en la capa oculta está conectado a los nodos de salida mediante pesos $w_{1j}, \dots, w_{pm}$

En el contexto del control de procesos nucleares, las ANN multicapa pueden utilizarse para modelar dinámicas complejas en reactores, predecir condiciones críticas o detectar anomalías en tiempo real, mejorando la seguridad y eficiencia de las operaciones [20].

A medida que se desarrollaron las ANN, se introdujeron nuevas estructuras y métodos de aprendizaje.

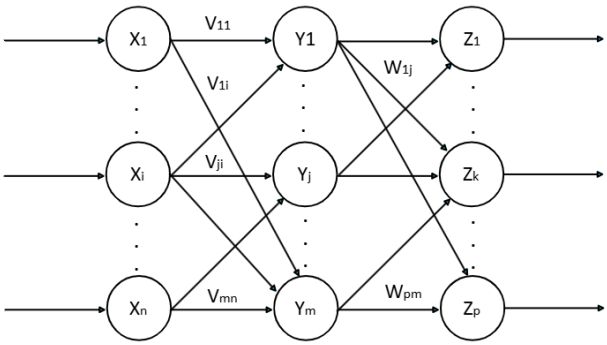

Figura 2. *ANN multicapa [20].*

En principio, Hebb en [21] propuso una regla fundamental conocida como aprendizaje Hebbiano, que establece que las conexiones entre dos neuronas se fortalecen cuando ambas son activadas simultáneamente. Esta idea influyó significativamente en los enfoques iniciales de entrenamiento de las redes neuronales artificiales, y permitió sentar las bases para el aprendizaje basado en la variación de pesos sinápticos. Estos pesos son valores numéricos que determinan el grado de importancia o fuerza de la conexión entre estas dos neuronas. El proceso de entrenamiento de una ANN implica la alimentación de datos de entrada a la red y la adaptación de los pesos sinápticos para minimizar el error en las predicciones de la red. Este ajuste de pesos se realiza mediante algoritmos de aprendizaje, siendo el más común el algoritmo de retropropagación del error (backpropagation). A través del entrenamiento, las ANN pueden aprender patrones y relaciones complejas en los datos, lo que les permite realizar tareas como: clasificación, regresión y reconocimiento de patrones.

Las ANN han demostrado ser herramientas poderosas en una variedad de aplicaciones, incluyendo el reconocimiento de imágenes, procesamiento de lenguaje natural y control de procesos industriales [3][5]. Su capacidad para manejar datos no lineales y aprender de grandes volúmenes de datos las hace especialmente adecuadas para entornos complejos y dinámicos como los sistemas de energía nuclear.

Metodología

En este apartado se describe la metodología utilizada para realizar la investigación sobre el estado del arte en el uso de ANN para el monitoreo y control de procesos en energía nuclear. Cabe mencionar que este análisis también abarca literatura de aplicación de ANN en estudios de física de altas energías (HEP, High Energy Physics), en particular experimentos del Gran Colisionador de Hadrones (LHC, Large Hadron Collider) perteneciente a la Organización Europea de la Investigación Nuclear (CERN), el experimento Bell II de SuperKEKB y el Colisionador Electrón-Ion (EIC).

A continuación se detallan los criterios para la selección de fuentes de información, así como el procedimiento metodológico seguido en esta investigación:

A. Criterios para la selección de fuentes de información

Para asegurar la relevancia y calidad de los estudios incluidos en esta investigación, se establecieron los siguientes criterios de selección:

1. Relevancia temática: Se seleccionaron estudios que abordaran directamente el uso de ANN en el control de procesos nucleares y experimentos HEP.
2. Calidad del estudio: Se eligieron principalmente artículos publicados en revistas académicas de alto impacto en donde la revisión por pares fue un requisito fundamental para su publicación; así como conferencias reconocidas y tesis posgrado.
3. Fecha de publicación: Se escogieron estudios publicados en los últimos 10 años para asegurar la actualidad y pertinencia temática de la información, aunque también se consideraron investigaciones históricamente significativas que han sentado las bases en estas áreas del conocimiento.
4. Accesibilidad de los datos: Solo se incluyeron estudios cuyos datos y resultados eran claramente presentados y accesibles para su análisis.
5. Diversidad geográfica: Se seleccionaron estudios de diferentes regiones y países para tener una visión global y evitar sesgos regionales en el análisis.

B. Procedimiento para la elaboración del estado del arte

El procedimiento seguido para la elaboración del estado del arte se desarrolló en varias etapas, descritas a continuación:

A. Búsqueda bibliográfica: Se realizó una búsqueda exhaustiva de la literatura utilizando bases de datos académicas como IEEE Xplore, ScienceDirect, SpringerLink, y Google Scholar. Se utilizaron palabras clave como "artificial neural networks", "nuclear energy", "process control", "machine learning", y "energy systems".

B. Selección de estudios: Aplicando los criterios previamente establecidos en la sección anterior, se seleccionaron los estudios más relevantes y pertinentes.

C. Clasificación y organización: Los estudios seleccionados se clasificaron según su enfoque y aplicación. Las categorías definidas fueron: 1) aplicaciones de ANN en el control de

procesos nucleares y de estudios de física de altas energías (HEP), 2) optimización, simulación y predicción en experimentos de HEP, y 3) estudios comparativos en sistemas de control distribuidos para estos procesos.

D. Síntesis de lectura: La información obtenida de cada fuente fue sintetizada para identificar las principales características, y su tipo de red neuronal artificial u algoritmo utilizado.

E. Análisis comparativo: Se contrastaron los diferentes enfoques y técnicas de inteligencia artificial utilizadas en los estudios seleccionados.

F. Presentación de resultados: Se elaboraron tablas concentradoras de acuerdo con las categorías definidas, las cuales son indicadas más adelante.

Resultados

Seguidamente, se presenta una breve síntesis de los principales hallazgos encontrados en los artículos y reportes científicos seleccionados clasificados por categoría; así como una tabla concentradora de los tipos de redes ANN y/o algoritmos de IA utilizados en cada fuerte por categoría.

Categoría 1. Aplicación en el Control de Procesos Nucleares y de Altas Energías

En los últimos años, el uso de ANN en el control de procesos nucleares ha cobrado gran relevancia debido a su capacidad para manejar datos complejos y no lineales, y su potencial para mejorar el desempeño de estos sistemas. Las ANN se han utilizado en una variedad de aplicaciones dentro del campo de la física nuclear y la ingeniería de aceleradores de partículas, demostrando su versatilidad y eficacia en diferentes contextos operativos. Uno de los principales desafíos en el control de procesos nucleares es el monitoreo y análisis de grandes volúmenes de datos en tiempo real, lo que requiere sistemas avanzados que puedan aprender y adaptarse rápidamente a las condiciones cambiantes. Las investigaciones recientes han explorado diversas aplicaciones usando diversas técnicas de ANN para abordar estos desafíos, proporcionando soluciones innovadoras y eficaces, véase la Tabla 1.

Primeramente, en Edelen *et al*., en [22] establece que los recientes avances teóricos y computacionales como son: hardware acelerado, algoritmos de aprendizaje profundo y redes recurrentes tipo LSTM (Long Short-Term Memory), han resuelto problemáticas históricas de inestabilidad y tiempo de cálculo. Asimismo, se determina que las redes neuronales son herramientas viables, robustas y altamente flexibles para permitir el modelado, diagnóstico y control de aceleradores.

Tabla 1. *Publicaciones en la categoría 1: Aplicación de ANN en el Control de Procesos Nucleares y de Altas Energías.*

Autores	Título (Año)	Tipo de Red / Algoritmo
Edelen, A. L., Biedron, S. G., Chase, B. E., Edstrom, D., Milton, S. V., & Stabile, P.	Neural networks for modeling and control of particle accelerators (2016)	-Redes Neuronales Alimentadas Hacia Adelante (FFNN, Feed-forward Neural Networks) -Redes Neuronales Recurrentes (RNN, Recurrent Neural Network) / LSTM -Redes Neuronales Convolucionales (CNN, Convolutional Neural Network)
Pol, A. A., Cerminara, G., Germain, C., Pierini, M., & Seth, A.	Detector Monitoring with Artificial Neural Networks at the CMS Experiment at the CERN Large Hadron Collider (2019)	-Red Neuronal Convolucional (CNN) -Red Neuronal Densa / Somera (SNN)
Arpaia, P., Giordano, F., Prevete, R., & Salvant, B.	Machine learning-based heating detection from pressure measurements in the CERN Large Hadron Collider (2021)	-Red Neuronal Convolucional Unidimensional (1D-CNN)
Schwenker, B., Herzberg, L., Buch, Y., Frey, A., Natochii, A., Vahsen, S., & Nakayama, H.	A neural network for beam background decomposition in Belle II at SuperKEKB (2023)	-Red neuronal profunda con arquitectura híbrida/modular compuesta por múltiples Redes Neuronales Alimentadas Hacia Adelante Completamente Conectadas (Fully Connected Feed-Forward Neural Networks o MLPs - Multi-Layer Perceptrons)
Mejía, J.M., Cabanillas, J.C., León-Monzón, I., & Herrera, G.	Neural network-based predicting model of power supply voltage for a scintillator plastic detector in high energy physics (2025)	-Red Neuronal Artificial Prealimentada de Dos Capas (Two-layer Feed-Forward Neural Network)

Fuente: Elaboración propia, 2026.

Finalmente, concluye que los sistemas de control impulsados por IA y RN permiten procesar múltiples parámetros en tiempo real, manejar sistemas no lineales complejos y mitigar tiempos muertos/retardos. Por otro lado, Pol *et al*., en [23] demostraron en el experimento de física CMS perteneciente al CERN, que la aplicación de aprendizaje profundo para la automatización del Monitoreo de Calidad de Datos (DQM, Data Quality Monitoring) supera con creces el rendimiento de los métodos estadísticos tradicionales. Asimismo, en Arpaia *et al*., en [24] exploraron la detección de calentamiento basada en aprendizaje automático a partir de mediciones de presión en el LHC del CERN. Su trabajo ilustra cómo las técnicas de ANN pueden ser aplicadas para el monitoreo térmico, permitiendo una detección más precisa y rápida de anomalías térmicas.

En [25], Schwenker *et al*., desarrollaron una red neuronal para la descomposición del fondo de haz en el experimento Belle II del acelerador de partículas SuperKEKB en Japón, con el objetivo de garantizar la calidad de los datos experimentales. Su investigación

demuestra cómo las ANN pueden ser utilizadas para separar señales útiles de ruido, mejorando la calidad de los experimentos de física de partículas. Finalmente, Mejía *et al*., en [26] proponen una metodología basada en un modelo de redes neuronales para predecir el posible cambio de los niveles de voltaje de la fuente de alimentación a lo largo del tiempo para los tubos fotomultiplicadores (PMT, Photo Multiplier Tube) utilizados en un detector de plástico centellador ubicado en un experimento de física de altas energías (HEP) del CERN.

Categoría 2. Optimización, Simulación y Predicción de Estudios de Física de Altas Energías

La optimización de sistemas energéticos es una de las áreas donde las ANN han demostrado un gran potencial. La capacidad de las ANN para aprender y adaptarse a partir de grandes volúmenes de datos les permite abordar problemas complejos y no lineales que son comunes en los sistemas energéticos. En esta sección se explora cómo las ANN se han aplicado en la optimización, simulación y predicción de parámetros relevantes en los sistemas HEP. La Tabla 2 muestra el concentrado de las publicaciones analizadas en esta categoría 2.

Primeramente, Teodorescu en [20] aborda el uso de redes neuronales artificiales en experimentos de física de altas energías. Su trabajo proporciona una visión general de cómo las ANN pueden ser utilizadas para mejorar la eficiencia y precisión en la recolección y análisis de datos en estos experimentos. De igual forma, este estudio destaca la importancia de las ANN en la optimización de los sistemas de detección y en la reducción de errores experimentales, que es crucial para la interpretación precisa de los resultados.

Mishra *et al*., en [27] implementaron técnicas de aprendizaje automático para predecir el parámetro de impacto y la esfericidad transversal en colisiones de iones pesados en el LHC. Esta investigación demuestra cómo las ANN pueden ser empleadas para optimizar la interpretación de los datos experimentales, permitiendo una mejor comprensión de los procesos físicos subyacentes. Las capacidades de las ANN para manejar grandes cantidades de datos experimentales y extraer patrones significativos, contribuyen significativamente a la mejora de la precisión en la predicción de parámetros críticos. Dubiński *et al*., en [28] se aborda la necesidad de desarrollar métodos de simulación más eficientes, como lo es Machine Learning (ML), para un detector de física de altas energías del CERN, denominado ZDC (Zero Degree Calorimeter) en el experimento ALICE. Esta alternativa permite incrementar la velocidad de simulación por un orden de magnitud de 2, mientras se mantiene la alta fidelidad de las simulaciones. De igual forma, Muñoz *et al*., en [29] se presentan los resultados de evaluación de diferentes prototipos de detectores mexicanos que participaron en la prueba de haz del futuro detector de rayos cósmicos denominado MID (Muon IDentifier), efectuada en octubre del 2024 en las instalaciones del CERN. Asimismo, se aplicaron diferentes técnicas de ML para correlacionar los resultados experimentales con los resultados de las simulaciones de estos detectores a prueba.

Tabla 2. *Publicaciones en la categoría 2: Optimización, Simulación y Predicción en Estudios de Física de Altas Energías mediante ANN.*

Autores	Título (Año)	Tipo de Red / Algoritmo
Teodorescu, L.	Artificial neural networks in high-energy physics (2008)	-Propagación hacia delante multicapa (MLFF - ANN) -Redes Recurrentes (Recurrent ANN) -Redes con Enlaces Funcionales (Functional Link ANN) -Redes No Supervisadas (Unsupervised ANNs)
Mishra, A. N., Mallick, N., Tripathy, S., Deb, S., & Sahoo, R.	Implementation of machine learning techniques to predict impact parameter and transverse spherocity in heavy-ion collisions at the LHC (2021)	-Árboles de Decisión con Aumento de Gradiente (GBDT)
Dubiński, J., Deja, K., Wenzel, S., Rokita, P., & Trzciński, T	Machine Learning methods for simulating particle response in the Zero-Degree Calorimeter at the ALICE experiment, CERN (2023)	-Perceptrón Multicapa (MLP) -Autoencoders Variacionales Condicionales (CVAE) -Redes Generativas Antagónicas Convolucionales Profundas (DC-GAN Condicional) -Regresor Auxiliar (Red Regularizadora Convolucional)
Allaire, C., Ammendola, R., Aschenauer, E.C., Hernández, R., *et al*.	Artificial Intelligence for the Electron Ion Collider (AI4EIC) (2024)	-Redes Neuronales Convolucionales (CNN) -Redes Neuronales de Grafos (GNN) -Modelos Generativos: Autoencoders Variacionales (VAE) y Autoencoders Condicionales (CAE) -Redes Generativas Adversarias (GAN) -Flujos de Normalización (Normalizing Flows - NF) / Conditional Masked Autoregressive Flow (cMAF) -Modelos de Difusión (Diffusion Models) -Redes Neuronales Recurrentes (RNN) y LSTM (Long Short-Term Memory) -Perceptrón Multicapa (MLP) y Redes Informadas por la Física (PINN)
Muñoz, J.E., Ortiz, A., Paz, A., Vargas, P., Alfaro, R., González, L.H., Grabski, V., Fernández, F., Regules, H.D., Rodríguez, M., Cabanillas, J.C., Rojas, S., *et al*.	ML-based muon identification using a FNAL-NICADD scintillator chamber for the MID subsystem of ALICE 3 (2025)	-Algoritmo de Machine Learning implementado es un Boosted Decision Tree (BDT) (Árboles de Decisión Potenciados)

Fuente: Elaboración propia, 2026.

Por último, Allaire *et al*., en [30] se explora el desarrollo de equipos experimentales innovadores en el Colisionador Electrón-Ion (EIC), en donde se buscan aprovechar los avances algorítmicos de vanguardia dentro del dinámico panorama de las metodologías inspiradas en la inteligencia artificial (IA).

Estos estudios reflejan el papel esencial de las ANN en la optimización de sistemas energéticos, mostrando cómo pueden mejorar tanto la eficiencia operativa como la precisión en la recolección y análisis de datos. Al abordar problemas complejos y mejorar la interpretación de los resultados experimentales, las ANN se consolidan como una herramienta valiosa en el campo de la física de altas energías y en la optimización de sistemas energéticos en general.

Categoría 3. Estudios Comparativos en Sistemas de Control Distribuido

A pesar de que las redes ANN han emergido como herramientas poderosas y versátiles en campos del control, monitoreo, simulación y predicción de procesos, sin embargo, su implementación extendida en sistemas distribuidos y de control industrial presenta una serie de desafíos y oportunidades que han sido explorados en diversas investigaciones. Esta sección se centra en los estudios comparativos de implementación de redes ANN en sistemas de control distribuido, en donde se analizan los diferentes enfoques y tecnologías utilizadas en el control de sistemas complejos enfocados a sistemas nuclear y HEP. La Tabla 3 muestra el concentrado de las publicaciones de esta categoría 3.

Inicialmente, Huh *et al*., en [31] presentan un análisis detallado sobre el control de acceso de próxima generación para sistemas de control distribuidos. Este estudio examina cómo las redes ANN pueden ser integradas en estos sistemas para mejorar la seguridad y eficiencia del control de acceso. Además, este trabajo destaca la importancia de estas redes en un aspecto relevante como es la protección de infraestructuras críticas, proporcionando un marco comparativo para evaluar diferentes metodologías de implementación.

Balador *et al*., en [32] realizan una revisión exhaustiva de las tecnologías de middleware de comunicación para sistemas de control distribuidos industriales. Este estudio establece que los sistemas de control distribuidos modernos exigen evolucionar de redes aisladas a arquitecturas altamente conectadas, y el integrar estas tecnologías de middleware es el prerrequisito para habilitar análisis predictivo, modelos de Machine Learning (ML) e Internet de las Cosas (IoT) industrial en plataformas Cloud (como Microsoft Azure IoT), manteniendo al mismo tiempo la seguridad (encriptación, auditoría y autenticación) y la tolerancia a fallos.

Tabla 3. *Publicaciones en la categoría 3: Estudios Comparativos de Aplicación de ANN en Sistemas de Control Distribuido.*

Autores	Título (Año)	Tipo de Red / Algoritmo
Huh, J. H., Bobba, R. B., Markham, T., Nicol, D. M., Hull, J., Chernoguzov, A., & Huang, J.	Next-generation access control for distributed control systems (2016)	Control de Acceso Basado en Roles (RBAC, Role-Based Access Control) combinado con Control de Acceso Basado en Atributos (ABAC, Attribute-Based Access Control)
Balador, A., Ericsson, N., & Bakhshi, Z.	Communication middleware technologies for industrial distributed control systems: A literature review (2017)	-Aprendizaje automático (machine learning) como un servicio externo
Tang, W., & Daoutidis, P.	Distributed control and optimization of process system networks: A review and perspective (2019)	-Redes de Creencia Profunda (DBN-ANN) -Redes Neuronales Convolucionales Profundas (CNN-ANN)
Chochula, P., Augustinus, A., Kurepin, A., Lechman, M., Pinazza, O. & Voscek, D.	15 Years of ALICE DCS	Sin información del uso de ANN, no obstante actualmente se encuentre en desarrollo un sistema de agentes con IA para detección y corrección de errores en el ALICE-DCS.

Fuente: Elaboración propia, 2026.

Tang y Daoutidis en [33] abordan la complejidad, escalabilidad e inflexibilidad de controlar y optimizar redes industriales químicas y de energía a gran escala mediante el uso de esquemas distribuidos. Su trabajo ofrece una perspectiva integral sobre cómo las ANN pueden ser utilizadas para mejorar la eficiencia y efectividad de los sistemas de control distribuido. Al comparar diferentes metodologías, este estudio proporciona valiosas recomendaciones para la implementación de ANN en la optimización de redes de sistemas de procesos. Por otro lado, estas tecnologías avanzadas de control y monitoreo son requeridas también en los sistemas HEP; en particular Chochula *et al*., en [34] se hace una descripción del Sistema de Control del Detector (DCS) del experimento ALICE del CERN. En donde se hace una recopilación de las principales características técnicas del DCS, que han permitido operar de manera segura y estable en la recolección de datos físicos derivados de las colisiones del LHC (de 2008 a 2023). La parte principal del DCS está conformada por el sistema SCADA (Supervisory Control and Data Acquisition) denominado WINCC-OA® de la compañía Siemens, así como por los *frameworks* estandarizados desarrollados en CERN: a) JCOP y b) extensiones específicas del experimento. Entre sus principales características del DCS destacan: unidades autónomas para cada detector, interfaces de usuario, máquinas de estado finito (FSM, Finite State Machine) con estados y acciones discretas, control jerárquico, interfaces con otros sistemas, bases de datos ORACLE, entre otras. A pesar de que en [34]

no se hace referencia a un desarrollo directo de ANN u otro relacionado, sin embargo se han iniciado trabajos para el desarrollo de asistentes de soporte basados en IA para lo que los detectores del proyecto FIT en lo que será la corrida 4 (Run 4) del LHC en el experimento ALICE [35].

Estos estudios son fundamentales para avanzar en la comprensión y aplicación de ANN en el control de procesos industriales y sistemas distribuidos. Al evaluar diversas metodologías y tecnologías, estas investigaciones ofrecen una base sólida para futuras implementaciones, destacando las mejores prácticas y señalando las áreas que requieren mayor investigación y desarrollo.

Conclusiones

La inteligencia artificial (IA) en general y las redes neuronales artificiales de manera particular, presentan un potencial significativo para revolucionar el control de procesos en la energía nuclear. Sin embargo, actualmente la IA generativa y explicable son áreas poco exploradas en sistemas de generación nucleoeléctrica, y es el aprendizaje automático quien ha destacado en aplicaciones de monitoreo en tiempo real, filtrado de datos e información relevante para detectar condiciones de error y supervisión de procesos [36].

Por lo que, a medida que las investigaciones y aspectos legislativos avancen, se superarán los desafíos y limitantes actuales, y es probable que estas tecnologías jueguen un papel cada vez más importante en la optimización y seguridad de los sistemas energéticos.

De igual forma, existen numerosas oportunidades para futuras tecnologías emergentes, como el internet de las cosas (IoT) y los sistemas de control ciberfísicos, en el uso de ANN para el control de estos procesos. Algunas áreas clave incluyen el desarrollo de algoritmos avanzados de aprendizaje profundo, automatización tareas mediante robótica, la exploración, optimización y maximización de procesos en nuevos dominios dentro de la energía nuclear, así como la combinación de ANN con tecnologías emergentes para el monitoreo y control en tiempo real. Estas investigaciones pueden abrir nuevas vías de innovación y mejorar la eficiencia y seguridad de los procesos nucleares.

Finalmente, la implementación de ANN en entornos nucleares críticos presenta desafíos significativos en términos de robustez, fiabilidad, integración y seguridad. Por lo que es necesario continuar desarrollando técnicas avanzadas de entrenamiento y validación, así como mecanismos robustos de control de acceso y protección de datos.

Referencias

[1] Urcia, A., Baltuano, O., Chan, R., Tincopa, J. P., Arrieta, R., Urquizo, R., & Salvador, B. (2016). Desarrollo de un sistema de vigilancia remota, por medio del monitoreo de parámetros claves de seguridad, para un reactor nuclear de investigación. Informe Científico Tecnológico., 14(2014), 161–166.

[2] Zanelli, J. (2011). Dilema energético: La energía nuclear. Estudios Públicos, (121). https://biblat.unam.mx/hevila/EstudiospublicosSantiago/2011/no121/6.pdf

[3] Keyvan, S., Kelly, M. L. & Song, X. (1997). Feature extraction for artificial neural network application to fabricated nuclear fuel pellet inspection. Nuclear technology, 119(3), 269-275.

[4] Nassif, N. (2014). Modeling and optimization of HVAC systems using artificial neural network and genetic algorithm. En Building Simulation (Vol. 7, No. 3, pp. 237-245). Berlin/Heidelberg: Springer Berlin Heidelberg.

[5] Tägil, K., Marving, J., Lomsky, M., Hesse, B., & Edenbrandt, L. (2008). Use of neural networks to improve quality control of interpretations in myocardial perfusion imaging. The international journal of cardiovascular imaging, 24, 841-848.

[6] Xiao, B., Wang, S., & Prucka, R. G. (2014). An investigation of semiphysical artificial neural networks for multi-fuel combustion phasing control of spark ignition engines. Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering, 228(11), 1262-1273.

[7] Mougari, N. E., Largeau, J. F., Himrane, N., Hachemi, M., & Tazerout, M. (2021). Application of artificial neural network and kinetic modeling for the prediction of biogas and methane production in anaerobic digestion of several organic wastes. International Journal of Green Energy, 18(15), 1584-1596.

[8] Escamilla-García, A., Soto-Zarazúa, G. M., Toledano-Ayala, M., Rivas-Araiza, E., & Gastélum-Barrios, A. (2020). Applications of artificial neural networks in greenhouse technology and overview for smart agriculture development. Applied Sciences, 10(11), 3835.

[9] Seifritz, W. (1978). The role of nuclear energy in the more efficient exploitation of fossil fuel resources. International Journal of Hydrogen Energy, 3(1), 11-20.

[10] Schultz, K. R., Brown, L. C., Besenbruch, G. E., & Hamilton, C. J. (2003). Large-scale production of hydrogen by nuclear energy for the hydrogen economy. General Atomics.

[11] Forsberg, C. W. (2003). Hydrogen, nuclear energy, and the advanced high-temperature reactor. International Journal of Hydrogen Energy, 28(10), 1073-1081.

[12] Hori, M. (2009). Synergistic energy conversion processes using nuclear energy and fossil fuels. International Journal of Nuclear Governance, Economy and Ecology, 2(4), 362-374

[13] Boukari, O., & Rabhi, A. (2023). Nuclear Symmetry Energy Effects on Neutron Star Properties within Bogoliubov Quark–Meson Coupling Model. Symmetry, 15(9), 1742.

[14] Zheng, H., Burrello, S., Colonna, M., Lacroix, D., & Scamps, G. (2018). Connecting the nuclear equation of state to the interplay between fusion and quasifission processes in low-energy nuclear reactions. Physical Review C, 98(2), 024622.

[15] Romero-Paredes, H., Rodríguez, A. V., Paredes, G. E., Vidales, H. V., García, J. A., & Nuñez-Carrera, A. (2015). Exergy and separately anergy analysis of a thermochemical nuclear cycle for hydrogen production. Applied Thermal Engineering, 75, 1311-1320.

[16] Szargut, J., Morris, D. R. & Steward, F. R. (1987). Exergy analysis of thermal, chemical, and metallurgical processes. Hemisphere Publishing Corporation.

[17] Bejan, A. (2013). Entropy generation minimization: the method of thermodynamic optimization of finite-size systems and finite-time processes. CRC press.

[18] Chirwa, E. M. N. (2011). Development of biological treatment processes for the separation and recovery of radioactive wastes. En K. L. Nash y G. J. Lumetta, Advanced

Separation Techniques for Nuclear Fuel Reprocessing and Radioactive Waste Treatment (pp. 436-472). Woodhead Publishing.

[19] Bell, M. Z. (2021). Energy Justice, Nuclear Landscapes and Consent: An Examination of Canadian Nuclear Waste Siting (Tesis Doctoral, Universidad del Estado de Nueva York en Buffalo).

[20] Teodorescu, L. (2008). Artificial neural networks in high-energy physics. En Inverted CERN School of Computing: 2005 and 2006 edition. CERN, Geneva, Switzerland.

[21] Hebb, D. O. (1949). The Organization of Behavior: A Neuropsychological Theory. John Wiley & Sons.

[22] Edelen, A. L., Biedron, S. G., Chase, B. E., Edstrom, D., Milton, S. V., & Stabile, P. (2016). Neural networks for modeling and control of particle accelerators. IEEE Transactions on Nuclear Science, 63(2), 878-897.

[23] Pol, A. A., Cerminara, G., Germain, C., Pierini, M., & Seth, A. (2019). Detector monitoring with artificial neural networks at the CMS experiment at the CERN Large Hadron Collider. Computing and Software for Big Science, 3, 1-13.

[24] Arpaia, P., Giordano, F., Prevete, R., & Salvant, B. (2021). Machine learning-based heating detection from pressure measurements in the CERN Large Hadron Collider. Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment, 990, 164995.

[25] Schwenker, B., Herzberg, L., Buch, Y., Frey, A., Natochii, A., Vahsen, S., & Nakayama, H. (2023). A neural network for beam background decomposition in Belle II at SuperKEKB. Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment, 1049, 168112.

[26] Mejía-Camacho, J.M., Cabanillas-Noris, J. C., León-Monzón, I. L., & Herrera-Corral, G.H. (2025). Neural network-based predicting model of power supply voltage for a scintillator plastic detector in high energy physics. Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment, 171268.

[27] Mishra, A. N., Mallick, N., Tripathy, S., Deb, S. & Sahoo, R. (2021). Implementation of machine learning techniques to predict impact parameter and transverse spherocity in heavy-ion collisions at the LHC. In The Ninth Annual Conference on Large Hadron Collider Physics (p. 265).

[28] Dubiński, J., Deja, K., Wenzel, S., Rokita, P., & Trzciński, T. (2024, March). Machine learning methods for simulating particle response in the zero-degree calorimeter at the ALICE experiment, CERN. In AIP Conference Proceedings (Vol. 3061, No. 1, p. 040001). AIP Publishing LLC.

[29] Muñoz, J. E., Ortiz, A., Paz, A., Vargas, P., Alfaro, R., González, L. H., Gravski, V., Fernández, A., Regules, D., Rodríguez, M., Tejeda, G., Vásquez, Y.A., Cabanillas, J.C., Rojas, S., Barnaföldi, G.G., Száraz, D., Varga, D., Vértesi, R. & García-Solis, E. (2025). ML-based muon identification using a FNAL-NICADD scintillator chamber for the MID subsystem of ALICE 3. Journal of Instrumentation, 20(09), P09015.

[30] Allaire, C., Ammendola, R., Aschenauer, EC. *et al*. Artificial Intelligence for the Electron Ion Collider (AI4EIC). Comput Softw Big Sci 8, 5 (2024). https://doi.org/10.1007/s41781-024-00113-4

[31] Huh, J. H., Bobba, R. B., Markham, T., Nicol, D. M., Hull, J., Chernoguzov, A., & Huang, J. (2016). Next-generation access control for distributed control systems. IEEE Internet Computing, 20(5), 28-37.

[32] Balador, A., Ericsson, N., & Bakhshi, Z. (2017, September). Communication middleware technologies for industrial distributed control systems: A literature review. En 2017 22nd IEEE International Conference on Emerging Technologies and Factory Automation (ETFA) (pp. 1-6). IEEE

[33] Tang, W., & Daoutidis, P. (2019). Distributed control and optimization of process system networks: A review and perspective. Chinese Journal of Chemical Engineering, 27(7), 1461-1473.

[34] Chochula, P., Augustinus, A., Pinazza, O., Lechman, M., Kurepin, A., Bond, P., & Voscek, D. (2023). JACOW: 15 Years of ALICE DCS. JACoW ICALEPCS, 2023, 1002-1007.

[35] Mermer, I., Muszyński, J., Możaryn, J., & Roslon, K. (2025). Proposal of an AI-Based Support Assistant for the ALICE-FIT Detector Setup at CERN. arXiv preprint arXiv:2511.17154.

[36] Picot, W. (2023). Mejora de la producción de energía nucleoeléctrica gracias a la inteligencia artificial. Boletín del OIEA, 19.