

Aplicación de redes neuronales en la industria siderúrgica

Application of neural networks in the steel industry

Aplicação de redes neurais na indústria siderúrgica

Recibido: 19/04/2025 | Revisado: 28/04/2025 | Aceptado: 28/04/2025 | Publicado: 30/04/2025

José de Jesús Calderón-Sánchez

ORCID: <https://orcid.org/0009-0003-4037-949X>

Escuela Superior de Ciudad Sahagún, Universidad Autónoma del Estado de Hidalgo, México

E-mail: jjcs200220@gmail.com

Rafael Granillo-Macías

ORCID: <https://orcid.org/0000-0002-1015-667X>

Escuela Superior de Ciudad Sahagún, Universidad Autónoma del Estado de Hidalgo, México

E-mail: rafaelgm@uaeh.edu.mx

Francisca Santana Robles

ORCID: <https://orcid.org/0000-0002-3301-9790>

Escuela Superior de Ciudad Sahagún, Universidad Autónoma del Estado de Hidalgo, México

E-mail: profe_7739@uaeh.edu.mx

Héctor Rivera-Gómez

ORCID: <https://orcid.org/0000-0002-2903-2909>

Universidad Autónoma del Estado de Hidalgo, México

E-mail: hector_rivera@uaeh.edu.mx

Resumen

El objetivo de este artículo es presentar un estudio de caso de investigación aplicada sobre la implementación de redes neuronales profundas en el proceso de laminación de una acería. El estudio se desarrolla dentro del contexto de la Industria 4.0 y se apoya en la metodología Lean Six Sigma para abordar una problemática real relacionada con defectos en productos derivados del proceso de laminado. La metodología incluye la aplicación de diversas herramientas de calidad con el propósito de identificar la causa raíz y proponer métodos que ofrezcan una solución innovadora. A través del diseño, entrenamiento y evaluación de una red neuronal multicapa, se logró una mejora en la clasificación de productos conforme (prime) y no conforme (scrap), alcanzando una eficiencia cercana al 85%. El estudio demuestra cómo la inteligencia artificial puede ser una solución viable para procesos industriales complejos donde intervienen múltiples variables, aportando mejoras significativas en calidad, eficiencia y toma de decisiones.

Palabras clave: Seis Sigma; Red Neuronal; Optimización; Fundición; Laminación.

Abstract

The objective of this article is to present a case study of applied research on the implementation of deep neural networks in the rolling process of a steel mill. The study is developed within the context of Industry 4.0 and is based on the Lean Six Sigma methodology to address a real-life problem related to defects in products derived from the rolling process. The methodology includes the application of various quality tools to identify the root cause and propose methods that offer an innovative solution. Through the design, training, and evaluation of a multi-layer neural network, an improvement in the classification of conforming (prime) and non-conforming (scrap) products was achieved, reaching an efficiency close to 85%. The study demonstrates how artificial intelligence can be a viable solution for complex industrial processes involving multiple variables, providing significant improvements in quality, efficiency, and decision-making.

Keywords: Six Sigma; Neural Network; Optimization; Foundation; Lamination.

Resumo

O objetivo deste artigo é apresentar um estudo de caso de pesquisa aplicada sobre a implementação de redes neurais profundas no processo de laminação de uma siderúrgica. O estudo é desenvolvido no contexto da Indústria 4.0 e baseia-se na metodologia Lean Six Sigma para abordar um problema real relacionado a defeitos em produtos derivados do processo de laminação. A metodologia inclui a aplicação de diversas ferramentas da qualidade para identificar a causa raiz e propor métodos que ofereçam uma solução inovadora. Por meio do projeto, treinamento e avaliação de uma rede neural multicamadas, obteve-se uma melhoria na classificação de produtos conformes (prime) e não conformes (sucata), atingindo uma eficiência próxima a 85%. O estudo demonstra como a inteligência artificial pode ser uma solução viável para processos industriais complexos que envolvem múltiplas variáveis, proporcionando melhorias significativas em qualidade, eficiência e tomada de decisão.

Palavras-chave: Seis Sigma; Rede Neural; Otimização; Fundação; Laminação.

1. Introducción

La Inteligencia Artificial (IA) ha emergido como una tecnología transformadora en la era de la digitalización industrial, reconfigurando los métodos tradicionales de producción, control de calidad y toma de decisiones estratégicas. Esta revolución tecnológica, que forma parte del paradigma de la Industria 4.0, integra sistemas inteligentes que emulan capacidades cognitivas humanas como el razonamiento, el aprendizaje, la percepción y la toma de decisiones autónoma (Rouhiainen, 2018; Shrivastava et al., 2024). Uno de los campos con mayor adopción de estas tecnologías es el industrial, donde la necesidad de eficiencia, calidad, trazabilidad y adaptación continua a la demanda ha incentivado la implementación de soluciones basadas en IA, incluyendo algoritmos de aprendizaje automático, aprendizaje profundo y redes neuronales artificiales (Arora et al., 2024).

Particularmente, las redes neuronales representan una de las herramientas más potentes dentro del ecosistema de la IA por su capacidad de detectar patrones complejos en grandes volúmenes de datos. Estas redes, inspiradas en el funcionamiento del cerebro humano, son capaces de aprender de manera autónoma mediante el ajuste de pesos entre nodos interconectados (Goodfellow et al., 2016). En el contexto industrial, su aplicación ha permitido mejorar los procesos de producción mediante la automatización inteligente, la detección de anomalías, la predicción de fallas y la optimización de parámetros de operación (Graglia & Von Huelsen, 2020). La industria siderúrgica no ha sido ajena a esta evolución. Este sector, crucial para la infraestructura, construcción y automotriz, enfrenta desafíos constantes relacionados con la calidad del producto, la eficiencia de los procesos, el control de defectos y la reducción de desperdicios. En este sentido, la integración de técnicas de IA ha generado oportunidades para abordar problemáticas complejas como la predicción de defectos de laminación, la clasificación de productos y la toma de decisiones en condiciones de alta variabilidad (Jiménez-Sánchez & Arzola-Ruiz, 2017; Ojeda-Roldán et al., 2022). Este artículo presenta el desarrollo e implementación de una red neuronal profunda dentro de un entorno siderúrgico real, con el propósito de mejorar el proceso de laminación de barras metálicas. A través de un caso de estudio, se analiza cómo la IA puede resolver un problema crítico de calidad originado por múltiples variables en el área de laminado, el cual genera productos no conformes (scrap). La investigación se estructura utilizando la metodología Lean Six Sigma, que permite definir, medir, analizar, mejorar y controlar el proceso, facilitando una mejora continua apoyada en el análisis de datos masivos. La hipótesis central de este estudio se fundamenta en la premisa de que, mediante la aplicación de redes neuronales profundas entrenadas con grandes volúmenes de datos de producción, es posible predecir con alta eficiencia el resultado de calidad de las barras metálicas, minimizando la generación de scrap y contribuyendo a la estabilidad del proceso de laminación. Este enfoque no solo busca resolver una problemática puntual, sino que también representa un paso hacia la transformación digital del proceso productivo, con miras a una manufactura más inteligente, sostenible y competitiva.


En los apartados siguientes se desarrollará una revisión de literatura que contextualiza la aplicación de IA en entornos industriales, una descripción detallada de la metodología utilizada, los resultados obtenidos a partir del entrenamiento de la red neuronal, así como las conclusiones sobre su efectividad, limitaciones y recomendaciones para futuras investigaciones en el ámbito de la siderurgia y otras industrias con procesos complejos.

2. Metodología

La aplicación de la inteligencia artificial en procesos industriales ha sido ampliamente documentada en los últimos años, especialmente en el contexto de la Industria 4.0. Diversos estudios han evidenciado su impacto en sectores como el automotriz, energético, salud, financiero y manufacturero. Uno de los enfoques más prometedores dentro de la IA es el uso de redes neuronales artificiales, las cuales permiten el reconocimiento de patrones complejos, clasificación de datos, predicción de resultados y optimización de procesos (Goodfellow et al., 2016; Graglia & Von Huelsen, 2020). La Figura 1 muestra la

descripción general de una red neuronal conformada por una capa de entrada, capas ocultas y una capa de salida.

Figura 1 - Red neuronal.



Fuente: Elaboración propia.

En la industria automotriz, por ejemplo, se han implementado robots inteligentes basados en IA que colaboran con operarios humanos para incrementar la precisión y seguridad en las líneas de ensamblaje (Aguirre et al., 2021). En el sector energético, sistemas de IA permiten anticipar fallos en equipos críticos, lo que ha resultado en la reducción de tiempos de inactividad y una mayor confiabilidad de operación (Ahmad et al., 2022). Estas implementaciones han sido posibles gracias a la capacidad de las redes neuronales para analizar grandes volúmenes de datos y encontrar relaciones no lineales entre múltiples variables. Desde una perspectiva estructural, las redes neuronales pueden clasificarse en diversos tipos según su arquitectura, flujo de datos y funcionalidad. Entre ellas se destacan las redes multicapa (MLP), redes convolucionales (CNN), redes recurrentes (RNN), redes con memoria a largo plazo (LSTM), y redes generativas antagónicas (GAN). Cada tipo responde a necesidades específicas, como el procesamiento de imágenes, análisis de series temporales, generación de texto o clasificación de señales industriales (Acevedo et al., 2017). La Tabla 1 muestra un comparativo entre diferentes tipos de redes neuronales, destacando las características principales y aplicaciones.

Tabla 1 - Comparación de tipos de redes neuronales.

Tipo de Red Neuronal	Características principales	Aplicaciones típicas
MLP (Red Multicapa)	Estructura en capas completamente conectadas; adecuada para clasificación de datos tabulares.	Clasificación de señales, reconocimiento de patrones.
CNN (Red Convolucional)	Utiliza capas de convolución para extraer características espaciales; ideal para procesamiento de imágenes.	Reconocimiento de imágenes, visión por computadora.
RNN (Red Recurrente)	Procesa datos secuenciales considerando dependencias temporales; útil en análisis de series temporales.	Análisis de texto, predicción temporal.
LSTM (Memoria a Largo Plazo)	Extensión de RNN con memoria interna que evita el desvanecimiento del gradiente; adecuada para secuencias largas.	Traducción automática, modelado de lenguaje.
GAN (Red Generativa Antagónica)	Compuesta por dos redes (generador y discriminador) que se entrenan en conjunto; usada para generación de datos.	Síntesis de imágenes, creación de contenido artificial.

Fuente: Boden (2018) y Bonilla & Bonilla (2024)

La literatura también destaca la aplicación de redes neuronales en la industria siderúrgica. Por ejemplo, Geng et al. (2023) proponen el uso de modelos basados en aprendizaje automático para el descubrimiento de nuevos materiales de acero y la optimización de sus procesos de fabricación. Ojeda-Roldán et al. (2022) desarrollaron un agente de aprendizaje por refuerzo

que mejora el control del proceso de soplado de oxígeno en una fundición, usando tanto datos históricos como simulaciones de procesos dinámicos. Abduljabbar et al. (2019) proporcionan una visión crítica de los desafíos existentes en la implementación de IA en sectores industriales, incluyendo limitaciones tecnológicas, cuestiones de seguridad y privacidad, así como barreras regulatorias. Balmer et al. (2020) ponen énfasis en la capacidad de la IA para gestionar grandes volúmenes de datos generados por sistemas interconectados, extrayendo valor mediante algoritmos que permiten detectar patrones, anticipar fallos y proponer decisiones automatizadas con alta precisión. Esta visión es especialmente relevante para sectores industriales como el siderúrgico, donde la complejidad de los procesos y la necesidad de mantener estándares de calidad elevados hacen que las soluciones basadas en IA sean particularmente útiles.

Díaz-Ramírez (2021) enfatiza que la capacidad de las redes neuronales profundas para abstraer características relevantes de grandes volúmenes de datos las convierte en herramientas especialmente poderosas para tareas de clasificación, predicción y reconocimiento. Li et al. (2017) realizan una revisión exhaustiva sobre las aplicaciones de la inteligencia artificial (IA) en el contexto de la manufactura inteligente, destacando su papel transformador en el desarrollo de sistemas de producción autónomos, adaptativos y optimizados, subrayando que la IA no solo permite el análisis y la toma de decisiones basadas en grandes volúmenes de datos, sino que también impulsa la integración de tecnologías como el Internet de las Cosas (IoT), la computación en la nube y los sistemas ciberfísicos dentro del entorno industrial.

En estudios previos, Jiménez-Sánchez y Arzola-Ruiz (2017) aplicaron redes neuronales para predecir propiedades mecánicas de perfiles de acero a partir de la composición química y características geométricas, mientras que Ometto et al. (2018) analizaron plataformas colaborativas basadas en IA orientadas a la mejora de sostenibilidad y competitividad de la industria siderúrgica. Estos estudios coinciden en que las redes neuronales representan una herramienta eficaz para abordar problemas complejos que requieren modelado predictivo y análisis de datos masivos. Una revisión adicional realizada por Jan et al. (2023) destaca los principales retos en la implementación de IA en entornos industriales, incluyendo la falta de infraestructura de datos, la necesidad de profesionales capacitados, y los desafíos regulatorios. Sin embargo, también se resaltan las oportunidades como la mejora en la toma de decisiones, personalización de productos, reducción de desperdicios y mantenimiento predictivo. Finalmente, en un estudio integral sobre la industria petrolera, Hemmati-Sarapardeh et al. (2020) exploran diversas técnicas de IA, entre ellas las redes neuronales, aplicadas al análisis de yacimientos, predicción de producción y simulación de procesos complejos. Estos trabajos refuerzan el papel de la IA como una tecnología transversal que puede adaptarse a múltiples contextos industriales, entre ellos la laminación siderúrgica, como el caso de estudio que se desarrolla en este artículo.

Se realizó una investigación descriptiva, de carácter cualitativo y del tipo específico de estudio de caso (Pereira et al., 2018; Yin, 2015), aplicada dentro de una empresa del sector siderúrgico, especializada en la producción de elementos de acero estructural y laminados. Esta organización, con presencia en México y otros países de Latinoamérica, opera bajo un modelo de producción continua y emplea chatarra como materia prima principal para sus procesos de fundición. Según Mexico Industry (2023), la industria siderúrgica en México presenta un notable potencial de crecimiento, impulsado por factores como el desarrollo de infraestructura, el fortalecimiento del sector automotriz y la creciente demanda de acero a nivel nacional e internacional. Este entorno ofrece un contexto favorable para la adopción de tecnologías emergentes que permitan mejorar la competitividad y eficiencia del sector, destacando que para alcanzar dicho potencial, es necesario apostar por la innovación tecnológica, incluyendo herramientas digitales como la inteligencia artificial, la automatización de procesos y el análisis de datos industriales. El estudio se centra en el proceso de laminación en caliente de barras metálicas, donde se identificó una alta variabilidad en la calidad del producto debido a múltiples factores operacionales.

Para abordar esta problemática, se adoptó la metodología Lean Six Sigma, la cual combina herramientas de mejora continua del enfoque Lean con el análisis estadístico de Six Sigma. Esta metodología fue implementada bajo el ciclo DMAIC

(Definir, Medir, Analizar, Mejorar y Controlar), que permitió estructurar la investigación de forma rigurosa:

1. Definir: Se identificó como problemática principal la inestabilidad del proceso de laminación en el área de TANDEM, la cual estaba generando productos no conformes (scrap). Se delimitaron los objetivos del proyecto y los indicadores clave de desempeño.
2. Medir: Se recolectaron datos históricos del proceso, incluyendo registros de producción, parámetros de laminado y características de los productos. Se utilizó un diagrama de Pareto para identificar los tipos de defectos más frecuentes y su impacto en el rendimiento del proceso.
3. Analizar: A través de herramientas como el diagrama causa-efecto y sesiones de lluvia de ideas, se determinaron las principales variables asociadas a los defectos de laminación. Se evaluaron distintas metodologías para el análisis de variables, incluyendo el diseño de experimentos, el método de Taguchi, árboles de decisión y redes neuronales.
4. Mejorar: Con base en las ventajas de modelado de relaciones no lineales y capacidad de aprendizaje automático, se eligió el uso de una red neuronal profunda para clasificar los productos como conformes (prime) o no conformes (scrap). Se diseñó una arquitectura de ocho capas y se entrenó utilizando una base de datos compuesta por más de 3,000 muestras con variables extraídas del proceso de TANDEM.
5. Controlar: Se establecieron métricas de desempeño del modelo, incluyendo eficiencia, precisión y tipo de errores cometidos (falsos positivos y falsos negativos). Asimismo, se propuso la implementación de la red neuronal en tiempo real dentro del sistema de control del tren de laminación, una vez que se completaran las pruebas en campo.

El enfoque metodológico se apoya en fundamentos teóricos de la gestión de calidad, inteligencia artificial y análisis estadístico. Además, se consideraron aspectos prácticos relacionados con la disponibilidad de datos, capacidades computacionales y experiencia del personal involucrado en el proyecto. Esta combinación de herramientas permitió abordar una problemática compleja desde una perspectiva multidisciplinaria, maximizando las probabilidades de éxito en la implementación de una solución basada en IA.

3. Resultados y Discusión

La etapa de desarrollo del proyecto se centró en la identificación, análisis y solución de una problemática específica dentro del proceso de laminación en caliente de una empresa siderúrgica.

Este proceso consta de múltiples fases: calentamiento de la barra a más de 1200°C, descascarillado con agua a alta presión, elongación inicial mediante un tren de laminación BD, y finalmente, el proceso principal de laminación en la unidad TANDEM, compuesto por cuatro módulos: UR1, UR2, UF y UE. La Figura 2 muestra la representación esquemática de estas etapas durante el proceso de laminación, destacando la operación de TANDEM que incluye los cuatro módulos para su operación.

Figura 2 – Etapas.




Fuente: Datos de esta investigación (2025).

Fue precisamente en esta última etapa donde se identificó una alta variabilidad en la calidad del producto, manifestada en defectos como escamas, grietas transversales, ondulaciones, incrustaciones de óxido y variaciones de grosor.

Como punto de partida, se realizó un análisis mediante diagrama de Pareto para identificar las familias de productos con mayor incidencia de defectos (Figura 3). El diagrama de Pareto reveló que la mayoría de las no conformidades se concentraba en un número reducido de categorías de defectos. En particular, se observó que los defectos de escamas, grietas transversales, ondulaciones, incrustaciones de óxido y variaciones de grosor constituían la proporción más alta de incidencias de falla en el proceso de laminación en caliente. Esta visualización confirmó la aplicación del principio 80/20 de Pareto, según el cual aproximadamente el 80% de los problemas proviene del 20% de las causas. Consecuentemente, el análisis de Pareto permitió identificar de forma clara los problemas de calidad más críticos, proporcionando un enfoque objetivo para la priorización de acciones correctivas.


Figura 3 - Diagrama de Pareto.



Fuente: Datos de esta investigación (2025).

Posteriormente, se utilizaron diagramas causa-efecto para explorar las posibles fuentes de variabilidad, destacando las condiciones operativas del equipo TANDEM como la causa principal (Figura 4). Entre los factores críticos se encontraron temperaturas desiguales, fuerzas axiales mal ajustadas, desgaste de rodillos y fallas en el sistema de enfriamiento.

Figura 4 - Diagrama de Causa Efecto.



Fuente: Datos de esta investigación (2025).

En las fases iniciales del proyecto se evaluaron diversas herramientas de análisis y modelado de datos. Se consideraron metodologías como el Diseño de Experimentos y el Método de Taguchi, los cuales fueron descartados debido a la elevada cantidad de variables y el alto costo de la experimentación directa. Asimismo, se analizaron los árboles de decisión, los cuales, aunque interpretables, presentaban baja capacidad de generalización. La Tabla 2 muestra un comparativo en relación a las principales ventajas y desventajas detectadas en cada metodología.

Tabla 2 - Comparación de metodologías.

Metodología	Ventajas	Desventajas
Diseño de Experimentos	Permite identificar relaciones causa-efecto entre variables mediante pruebas estructuradas.	Requiere muchas pruebas cuando hay muchas variables; alto costo experimental.
Método de Taguchi	Reduce la variabilidad del proceso y el número de experimentos necesarios para optimización.	Similar al DOE, limitado por el número de variables; complejo en procesos industriales reales.
Árboles de Decisión	Interpretación sencilla y visual; útil para entender decisiones basadas en reglas.	Baja capacidad de generalización; sensible a pequeñas variaciones en los datos.
Red Neuronal Profunda	Maneja datos no lineales y complejos; alta capacidad de clasificación y predicción.	Requiere gran cantidad de datos y recursos computacionales; difícil de interpretar internamente.

Fuente: Elaboración propia.

Finalmente, se optó por el uso de una red neuronal profunda debido a su capacidad de manejar datos complejos y no lineales, y su eficacia comprobada en tareas de clasificación y predicción industrial. Para el entrenamiento de la red neuronal se diseñaron tres plantillas de extracción de datos. La primera incluyó más de 980 señales, pero su complejidad generó resultados ambiguos. La segunda redujo el enfoque al área del TANDEM, depurando señales irrelevantes. Finalmente, se consolidó una tercera plantilla con 142 variables específicas de dicha área, mejorando la calidad de los datos.

La arquitectura seleccionada para la red incluyó ocho capas con funciones de activación Sigmoide y ReLU. El modelo

fue entrenado utilizando 36 barras, equilibrando muestras entre productos conformes (prime) y no conformes (scrap), en ciclos de 500 épocas. El objetivo fue que la red aprendiera a distinguir con precisión entre ambos tipos de productos con base en las señales del proceso. Los resultados preliminares indicaron que los valores de salida se agrupaban alrededor de 0.29 (scrap) y 0.30 o superiores (prime), lo cual permitía establecer un umbral de clasificación confiable. Posteriormente, se realizaron experimentos modificando la arquitectura de la red y los algoritmos de optimización (ADAM y SGD), lo que permitió evaluar diferentes configuraciones en cuanto a número de capas, neuronas y funciones de activación. Se analizaron múltiples métricas, entre ellas: eficiencia general, porcentaje de falsos positivos y negativos, y la dispersión de los resultados en relación a los valores ideales de 0 y 1.

El desarrollo técnico también incluyó la preparación del entorno de entrenamiento, considerando requerimientos computacionales como tarjetas gráficas dedicadas, y la programación de la red neuronal, que consistió en aproximadamente 48 líneas de código en su versión final. Todo el desarrollo fue documentado y validado por un equipo multidisciplinario, garantizando la trazabilidad y reproducibilidad de los resultados.

Los resultados obtenidos tras el entrenamiento y prueba de la red neuronal profunda reflejan una mejora significativa en la capacidad de clasificación del proceso de laminación, en comparación con los métodos tradicionales. A través de múltiples sesiones de entrenamiento utilizando la arquitectura definida de ocho capas y funciones de activación Sigmoide y ReLU, se alcanzaron niveles de eficiencia superiores al 78% en los mejores escenarios.

En total se probaron cinco configuraciones distintas, variando el número de capas, neuronas y algoritmos de optimización. La configuración más efectiva, denominada ADAM 0, logró una eficiencia del 78.83%, con un margen de error del 21.17%. Este modelo mostró un comportamiento más estable y preciso, con resultados verdaderos en 87,442 de las 110,929 instancias evaluadas.

Los errores fueron clasificados en falsos positivos y falsos negativos. Se observó una alta proporción de falsos negativos (93.3%), lo cual sugiere que la red aún requiere refinamiento en la identificación de productos no conformes. Este comportamiento es común en etapas iniciales de implementación, especialmente cuando se cuenta con un número limitado de datos de entrenamiento y ruido en las variables. La Tabla 3 muestra en resumen de las diferentes configuraciones utilizadas para evaluar los diferentes modelos de RN considerando la eficiencia obtenida, el margen de error y la relación de falsos negativos (FN) y falsos positivos (FP).

Tabla 3 - Resultados comparados de modelo de red.

Modelo	Eficiencia (%)	Margen de Error (%)	Errores (%) (FN / FP)
ADAM 0	78.83	21.17	93.3 / 6.7
ADAM 1	78.80	21.20	Alta / Baja
ADAM 2	70.80	29.20	Alta / Baja
ADAM 3	77.30	22.70	Alta / Baja
SGD	71.92	28.08	Alta / Baja


Fuente: Datos de esta investigación (2025).

La eficiencia de otros modelos fue la siguiente: ADAM 1 con 78.80%, ADAM 2 con 70.80%, ADAM 3 con 77.30% y el modelo entrenado con SGD alcanzó un 71.92%. En todos los casos, se detectó una tendencia general a presentar más falsos negativos que positivos, lo cual refuerza la necesidad de ampliar y depurar la base de datos.

Adicionalmente, se utilizó el software Minitab para realizar análisis estadístico descriptivo sobre los resultados obtenidos (Figura 5). Las gráficas X-S y NP mostraron la dispersión de los valores de predicción respecto a los valores ideales

(0 para scrap, 1 para prime). Estas gráficas confirmaron que el modelo logra aproximarse a los valores esperados, aunque con variabilidad significativa en los límites intermedios.

Figura 5 - Grafica X-S, NP.



Fuente: Datos de esta investigación (2025).

Para una visualización más precisa, se calculó una muestra representativa a partir de los 110,928 datos totales, usando un intervalo de confianza del 95% y un margen de error del 5%, lo que permitió interpretar gráficamente los resultados sin sobrecargar el análisis visual. Esta estrategia facilitó la comparación entre configuraciones y proporcionó información clave para el ajuste fino del modelo.

En términos generales, los resultados indican que el uso de redes neuronales en procesos industriales de laminación es viable y efectivo. Si bien los modelos aún requieren mejoras para alcanzar niveles óptimos de precisión (85% o superior), el desempeño actual representa un avance considerable frente a las herramientas analíticas previas utilizadas en la empresa. Finalmente, se concluyó que una estructura de red más simple resultó ser más eficaz que configuraciones complejas, en el contexto de los datos disponibles. Esta observación representa una recomendación importante para futuras implementaciones, donde la simplicidad arquitectónica puede ser clave para la eficiencia computacional y precisión del modelo.

4. Conclusiones

La presente investigación demuestra que la aplicación de redes neuronales profundas en procesos industriales complejos, como la laminación en la industria siderúrgica, representa una solución viable, eficiente y con alto potencial de escalabilidad. A través del desarrollo de un caso de estudio real, se evidenció que el uso de inteligencia artificial permite identificar patrones en grandes volúmenes de datos operativos, optimizando la clasificación de productos conformes y no conformes, y reduciendo significativamente la variabilidad del proceso. La implementación de la metodología Lean Six Sigma fue clave para estructurar el proyecto bajo un enfoque riguroso y basado en datos, permitiendo la identificación de las causas raíz del problema, la evaluación de posibles soluciones y el control de los resultados obtenidos. El uso del ciclo DMAIC favoreció la integración entre el conocimiento técnico del proceso y las herramientas de análisis estadístico y computacional. Los resultados obtenidos indican que, si bien se alcanzaron niveles aceptables de eficiencia (superiores al 78%), aún existen áreas de mejora relacionadas con el perfeccionamiento de la arquitectura de la red, la depuración de las variables de entrada y el aumento de la cantidad de datos de entrenamiento. En particular, la predominancia de errores tipo falso negativo sugiere la

necesidad de fortalecer el modelo para una mejor detección de productos defectuosos.

Uno de los hallazgos más relevantes fue que las estructuras de red neuronal más simples lograron un rendimiento superior a configuraciones más complejas, lo cual enfatiza la importancia de adaptar el diseño del modelo a la naturaleza del problema y a la calidad de los datos disponibles. Asimismo, se identificó que el uso de herramientas estadísticas como gráficos de control y análisis de muestras resultó fundamental para validar los resultados de la red.

Como línea futura de trabajo, se recomienda ampliar la base de datos mediante la recolección continua de información en tiempo real, así como explorar técnicas de preprocesamiento avanzadas y enfoques híbridos que combinen redes neuronales con otros algoritmos de inteligencia artificial. También se sugiere la implementación gradual del modelo en ambiente productivo, acompañada de pruebas piloto que validen su eficacia en condiciones reales de operación.

Agradecimientos

Los autores expresan su agradecimiento a la Escuela Superior de Ciudad Sahagun de la Universidad Autonoma del Estado de Hidalgo por el apoyo otorgado para la realizacion de este estudio.

Referencias

- Abduljabbar, R., Dia, H., Liyanage, S., & Bagloee, S. A. (2019). Applications of artificial intelligence in transport: An overview. *Sustainability*, 11(1), 189. <https://doi.org/10.3390/su11010189>
- Acevedo, E., Serna, A., & Serna, E. (2017). Principios y características de las redes neuronales artificiales. *Desarrollo e innovación en ingeniería*, 173.
- Ahmad, T., Zhu, H., Zhang, D., Tariq, R., Bassam, A., Ullah, F., ... & Alshamrani, S. S. (2022). Energetics Systems and artificial intelligence: Applications of industry 4.0. *Energy Reports*, 8, 334-361. <https://doi.org/10.1016/j.egyrs.2021.11.256>
- Aguirre, J., García, F., Ramírez, C., Floreano, S., Guarda, T., Sanchez, I., ... & Sanchez, C. (2021). Aplicación de la inteligencia artificial en la industria automotriz. *Revista Ibérica de Sistemas e Tecnologías de Informação*, (E42), 149-158.
- Arora, A., Kacker, R., & Kumar, S. S. (2024). Artificial intelligence role, techniques, and optimization algorithms in industrial-level applications. *Artificial Intelligence and Their Applications*, 20-30. <https://doi.org/10.58532/nbennurch337>
- Balmer, R. E., Levin, S. L., & Schmidt, S. (2020). Artificial Intelligence Applications in Telecommunications and other network industries. *Telecommunications Policy*, 44(6), 101977. <https://doi.org/10.1016/j.telpol.2020.101977>
- Boden, M. A. (2018). Artificial intelligence: A very short introduction. Oxford University Press. <https://doi.org/10.1093/acrade/9780199602919.001.0001>
- Bonilla, L., & Bonilla, L. (2024). Qué es el Deep learning y cómo funciona. Desafíos y retos. *Data Center Market*. <https://www.datacentermarket.es/dcm-xl/que-es-el-deep-learning-y-como-functiona-desafios-y-retos/>
- Díaz-Ramírez, J. (2021). Aprendizaje automático y aprendizaje profundo. *Ingeniare. Revista chilena de ingeniería*, 29(2), 180-181. <http://dx.doi.org/10.4067/S0718-33052021000200180>
- Geng, X., Wang, H.-H., Wang, S., Gao, J., & Ma, X. (2023). Data-driven and artificial intelligence accelerated steel material research and intelligent manufacturing technology. <https://doi.org/10.1002/mgea.10>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Graglia, M. A. V., & Von Huelsen, P. G. (2020). The sixth wave of innovation: Artificial intelligence and the impacts on employment. *Journal on Innovation and Sustainability RISUS*, 11(1), 3-17.
- Hemmati-Sarapardeh, A., Larestani, A., Menad, N. A., & Hajirezaie, S. (2020). Applications of artificial intelligence techniques in the petroleum industry. Gulf Professional Publishing.
- Jan, Z., Ahamed, F., Mayer, W., Patel, N., Grossmann, G., Stumptner, M., & Kuusk, A. (2023). Artificial intelligence for industry 4.0: Systematic review of applications, challenges, and opportunities. *Expert Systems with Applications*, 216, 119456. <https://doi.org/10.1016/j.eswa.2022.119456>
- Jiménez-Sánchez, D., & Arzola-Ruiz, J. (2017). Redes neuronales regularizadas aplicadas a la estimación de propiedades mecánicas de perfiles de acero. *Ingeniería Mecánica*, 20(3), 115-121.
- Li, B. H., Hou, B. C., Yu, W. T., Lu, X. B., & Yang, C. W. (2017). Applications of artificial intelligence in intelligent manufacturing: A review. *Frontiers of Information Technology & Electronic Engineering*, 18(1), 86-96. <https://doi.org/10.1631/FITEE.1601885>
- Mexico Industry. (2023). Industria siderúrgica en México con potencial de crecimiento. <https://mexicoindustry.com/noticia/industria-siderurgica-en-mexico-con-potencial-de-crecimiento>

Ojeda-Roldán, Á., Gassner, G., Schlautmann, M., Acevedo Galicia, L. E., Andreiana, D. S., Heiskanen, M., ... & del Real Torres, A. (2022). Optimisation of Operator Support Systems through Artificial Intelligence for the Cast Steel Industry. *Journal of manufacturing and materials processing*, 6(2), 34. <https://doi.org/10.3390/jmmp6020034>

Ometto, L., Challapalli, S., Polo, G., Cestari, A., Villagrossi, M., Sandri, E., & Pellegrini, A. (2018). Successful Use Case Applications of Artificial Intelligence in the Steel Industry.

Pereira A. S. et al. (2018). *Metodologia da pesquisa científica*. [free e-book]. Editora UAB/NTE/UFSM. Yin, R.K. (2015). *O estudo de caso*. Porto Alegre: Bookman.

Rouhiainen, L. (2018). *Inteligencia artificial*. Editorial Alienta.

Shrivastava, A., Pandey, A., Singh, N., Srivastava, S., Srivastava, M., & Srivastava, A. (2024). Artificial Intelligence (AI): Evolution, Methodologies, and Applications. *International Journal for Research in Applied Science and Engineering Technology*. <https://doi.org/10.22214/ijraset.2024.61241>