

Sistema Inteligente basado en Internet de las Cosas (IoT) y Aprendizaje Automático (ML) para el Mantenimiento Predictivo de un Horno Industrial Eléctrico.

Reynoso-Guajardo Luis Alejandro, *Hernández-Vega José Isidro, Gallardo Morales -Mario Carlos, Soto Soto-Jesús Enrique, Macias-Arias María Ernestina * Todos los Autores están adscritos al Tecnológico Nacional de México/I. T. Nuevo León. Autor Corresponsal* División de Estudios de Posgrado e Investigación, Departamento de Sistemas Computacionales. Ave. Eloy Cavazos 2001, Col. Tolteca, Guadalupe, N.L. C.P. 67170, México (81) 81570500 Ext. 140

luis.rg@nuevoleon.tecnm.mx, jose.hv@nuevoleon.tecnm.mx, mario.gm@nuevoleon.tecnm.mx, jesus.ss@nuevoleon.tecnm.mx, ernestina.ma@nuevoleon.tecnm.mx

RESUMEN

Este artículo presenta una propuesta de un sistema inteligente para el mantenimiento predictivo de un horno industrial, el objetivo del sistema es el monitoreo en tiempo real, el ajuste automático de perfiles térmicos y la predicción de fallas mediante modelos de aprendizaje automático. Se hace uso de datos simulados generados con base en condiciones reales de operación. La solución integra tecnologías del Internet de las Cosas (IoT) y algoritmos de aprendizaje automático, hace énfasis en la importancia de la Industria 4.0 e Industria 5.0. El sistema desarrollado es modular, escalable. Se reportan métricas destacadas en un entorno simulado, como una precisión del 99.5%, sensibilidad del 100% y un área bajo la curva ROC de 0.9995. Esta tecnología busca acelerar la transformación digital del sector industrial mexicano, facilitando su adopción tanto en grandes corporativos como en pequeñas y medianas empresas [5].

Palabras clave: mantenimiento predictivo, mantenimiento inteligente, hornos industriales, IoT, inteligencia artificial, aprendizaje automático.

ABSTRACT

This article presents a proposed intelligent system for the predictive maintenance of an industrial furnace. The objective of the system is real-time monitoring, automatic adjustment of thermal profiles, and fault prediction using machine learning models. Simulated data generated based on real operating conditions is used. The solution integrates Internet of Things (IoT) technologies and machine learning algorithms, emphasizing the importance of Industry 4.0 and Industry 5.0. The developed system is modular and scalable. Outstanding metrics are reported in a simulated environment, including 99.5% precision, 100% sensitivity, and an area under the ROC curve of 0.9995. This technology aims to accelerate the digital transformation of the Mexican industrial sector, facilitating its adoption by both large corporations and small and medium-sized enterprises [5].

Keywords: predictive maintenance, intelligent maintenance, industrial furnaces, IoT, artificial intelligence, machine learning

1. INTRODUCCIÓN

El control eficiente de hornos industriales es fundamental para asegurar la calidad del producto, reducir el consumo energético y garantizar la continuidad operativa en sectores estratégicos como el alimentario, cerámico, metalúrgico, farmacéutico y automotriz. Estos procesos térmicos son altamente sensibles a desviaciones, lo que puede ocasionar defectos en la producción, sobrecostos energéticos y desgaste prematuro del equipo [1], [2], [3].

En este contexto, operadores, técnicos, ingenieros de mantenimiento y gestores de planta requieren herramientas inteligentes que permitan monitorear, operar y mantener hornos industriales de forma más predictiva, eficiente y flexible. En México, industrias como la cerámica, fundición, semiconductores y manufactura enfrentan desafíos relacionados con el control térmico y el mantenimiento efectivo. Aunque algunas empresas han adoptado tecnologías de automatización, persisten oportunidades para avanzar hacia sistemas inteligentes y adaptativos. Este rezago es más notable en las pymes, las cuales enfrentan barreras de acceso a infraestructura digital avanzada [4] [5].

La industria 4.0 ha impulsado el uso de tecnologías como el Internet de las Cosas (IoT) y la inteligencia artificial (IA), lo cual ha permitido una adquisición continua de datos, automatización de procesos y predicción de fallas [6] [7], [8]. Sin embargo, retos como la interoperabilidad entre dispositivos, la escalabilidad, la ciberseguridad y la adaptación a entornos de planta complejos siguen siendo relevantes, especialmente en contextos latinoamericanos con infraestructura heterogénea [9].

En paralelo, la industria 5.0 promueve un modelo tecnológico centrado en el ser humano, resiliente y sostenible, enfocándose en la personalización de procesos y la colaboración entre operadores y máquinas [10].

Este trabajo propone una solución basada en una arquitectura modular y escalable que integra tecnologías

IoT y Aprendizaje Automático para el mantenimiento predictivo inteligente de un horno industrial. El Sistema Inteligente, permite supervisión remota, ajustes automáticos de perfiles térmicos y diagnóstico anticipado de fallas. el sistema emplea algoritmos de aprendizaje automático, como Random Forest que ha sido utilizado en aplicaciones para el análisis de datos [11], para detectar patrones críticos y generar recomendaciones operativas precisas. su diseño está orientado a beneficiar tanto a grandes corporativos como a pequeñas y medianas empresas del ecosistema industrial mexicano.

2. DESARROLLO

Este trabajo presenta una arquitectura modular y escalable que integra tecnologías de Internet de las Cosas (IoT) y Aprendizaje Automático para el mantenimiento predictivo de un horno industrial. La solución permite supervisión remota, ajustes térmicos automáticos y diagnóstico anticipado de fallos operativos en tiempo real. Su diseño se alinea con los principios de la Industria 4.0 mediante la implementación de sensores inteligentes, procesamiento distribuido y analítica avanzada y con la Industria 5.0 al fomentar una interacción humano-máquina intuitiva que respalda la toma de decisiones sin requerir una alta especialización técnica. El sistema utiliza algoritmos de aprendizaje automático, como Random Forest, para identificar patrones críticos en los datos operativos y generar recomendaciones precisas y accionables. Su enfoque accesible y adaptable está orientado a beneficiar tanto a grandes corporativos como a pequeñas y medianas empresas del ecosistema industrial mexicano. La arquitectura general del sistema puede apreciarse en la Figura 1, donde se ilustran las distintas capas funcionales y el flujo de datos entre ellas.




Figura 1. Capas funcionales y el flujo de datos entre ellas

2.1 Automatización del proceso

El sistema ajusta automáticamente los perfiles térmicos de hornos industriales a partir de datos históricos y en tiempo real, optimizando la eficiencia y reduciendo la variabilidad del proceso [12],[7]. Su arquitectura integra sensores IoT y modelos de aprendizaje automático para realizar

correcciones dinámicas que minimizan errores humanos y aseguran la calidad del producto.

2.2 Mantenimiento Predictivo

Se implementa un modelo de mantenimiento inteligente basado en algoritmos de aprendizaje automático, específicamente Random Forest, que permite detectar patrones de falla antes de que ocurran eventos críticos. Esta capacidad predictiva puede reducir hasta en un 70 % las paradas de emergencia en líneas de producción industrial, de acuerdo con estudios recientes en aplicaciones de IA [12], [9]. Además, contribuye a extender la vida útil de los componentes térmicos y disminuye de forma significativa los costos asociados al mantenimiento correctivo.

2.3 Prevención de Pérdidas

El sistema genera diagnósticos en tiempo real y recomendaciones automáticas basadas en analítica predictiva y aprendizaje automático. Estas funciones permiten decisiones oportunas para prevenir fallas y reducir pérdidas de producto o daños a equipos industriales [7], [8].

2.4 Visibilidad

La solución ofrece acceso remoto continuo mediante interfaz web y móvil, con trazabilidad completa de parámetros térmicos y eventos. Esta visibilidad 24/7 facilita auditorías, certificaciones de calidad (ISO 9001, ISO 50001) y refuerza el cumplimiento normativo [1], [3]. Como se muestra en la Figura 2, la interfaz gráfica de usuario permite monitorear de forma centralizada las variables críticas del proceso industrial.

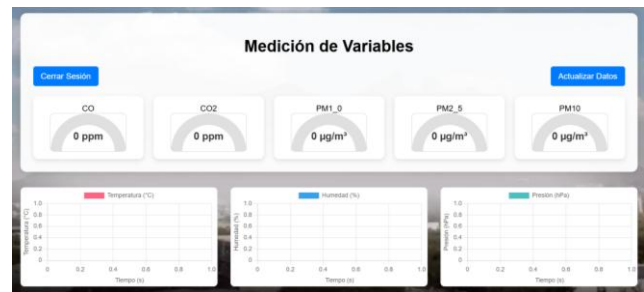


Figura 2. Interfaz del usuario

3. METODOLOGÍA

Esta sección describe las técnicas, procedimientos y herramientas empleados para el desarrollo del sistema inteligente de monitoreo inteligente y mantenimiento predictivo de hornos industriales eléctricos, basado en tecnologías de Internet de las Cosas y algoritmos de Aprendizaje Automático. La metodología fue diseñada

para ser adaptable a entornos industriales, considerando escalabilidad, precisión y robustez operativa.

3.1 Recolección de Datos

Se instalaron sensores industriales compatibles con los protocolos MQTT y HTTP en un entorno de simulación industrial. Estos dispositivos recopilaban de manera continua variables clave durante diversos ciclos de operación simulados.

Las variables medidas incluyeron:

- Temperatura interna del horno
- Tiempo acumulado de operación
- Humedad ambiental
- Consumo energético
- Flujo de aire y presión

Los datos simulados se transmitieron en tiempo real a una base de datos en la nube, utilizando un servidor local dentro de una arquitectura de cómputo en la nube, lo que garantizó disponibilidad, escalabilidad y acceso remoto.

Tabla 1. Fragmento de los datos recolectados

(Los valores corresponden a un conjunto de datos simulados que representan el comportamiento de un horno industrial.)

TIMESTAMP	TEMP_HORN O_C	HUMEDAD (%)	TIEMPO_OPERACIÓN (h)	CONSUMO_ENER (kWh)	FALLAS
2025-04-03 12:00:00	807.45	32.92	0.50	9.54	0
2025-04-03 12:10:00	797.93	37.90	0.59	9.84	0
2025-04-03 12:20:00	809.72	38.29	0.69	10.62	0
2025-04-03 12:30:00	822.85	35.99	0.79	10.58	0
2025-04-03 12:40:00	796.49	39.19	0.88	6.93	0

La Tabla 1 presenta un fragmento representativo del conjunto de datos simulados utilizados en el entrenamiento y validación del sistema predictivo propuesto. Cada fila corresponde a una muestra registrada cada 10 minutos en un entorno de simulación diseñado para replicar condiciones reales de operación industrial

Las columnas contienen las siguientes variables:

- **TIMESTAMP:** Fecha y hora de registro de la medición.
- **TEMP_HORNO_C:** Temperatura interna del horno (°C).
- **HUMEDAD (%):** Porcentaje de humedad relativa en el ambiente.

- **TIEMPO_OPERACIÓN (h):** Tiempo acumulado de operación del horno en horas.
- **CONSUMO_ENER (kWh):** Energía consumida durante el intervalo de muestreo.
- **FALLAS:** Variable binaria que indica la presencia (1) o ausencia (0) de una falla térmica.

Estos registros conforman una base de datos estructurada que simula condiciones operativas industriales. El conjunto de datos permitió entrenar modelos de aprendizaje automático, facilitando la predicción precisa de fallas térmicas y la validación del desempeño del sistema en un entorno controlado.

3.2 Procesamiento de Datos

Los datos fueron sometidos a un proceso de depuración para eliminar registros incompletos, nulos o atípicos. Se aplicó interpolación lineal para sincronizar la frecuencia de muestreo entre sensores, garantizando coherencia temporal. Posteriormente, todas las variables fueron normalizadas utilizando técnicas de escalado, con el fin de optimizar el desempeño del modelo de aprendizaje automático.

3.3 Entrenamiento del Modelo Predictivo

Para el desarrollo del modelo predictivo se utilizó el lenguaje Python (versión 3.10) empleando la librería Scikit-learn (versión 3.1). Se evaluaron diversos algoritmos de aprendizaje automático supervisado. Se seleccionó el algoritmo **Random Forest** por su capacidad de manejar grandes volúmenes de datos, su robustez frente al ruido y su precisión en tareas de clasificación binaria.

El modelo fue entrenado con una partición 80% entrenamiento, (20% pruebas) utilizando una clasificación binaria (falla/no falla). Se evaluaron las siguientes métricas:

- Precisión
- Exactitud
- Sensibilidad (*Recall*)
- F1-Score
- Área bajo la curva ROC (AUC)

3.4 Evaluación del Modelo

La validación del modelo se realizó con datos independientes. La matriz de confusión indicó una única clasificación incorrecta en el conjunto de prueba, evidenciando un alto desempeño del modelo. A continuación, se presentan las métricas obtenidas:

Tabla 2. Resultados del desempeño del modelo predictivo

Métricas	Valor
Precisión	99.50%
Exactitud	95.45%
Sensibilidad Recall)	100%
F1-Score	97.67%
Auc(Área bajo la curva ROC)	0.9995

Estas métricas confirman la eficacia del sistema para anticipar fallas térmicas, incluso con datos simulados, lo cual permite reducir riesgos en su futura implementación en entornos industriales reales.

4. RESULTADOS

Para validar la eficiencia del sistema de monitoreo predictivo, se realizaron pruebas utilizando datos históricos generado por sensores virtuales configurados para emular entornos operativos típicos de hornos industriales. Estas pruebas se centraron en varios periodos representativos, bajo condiciones variables de temperatura, humedad y tiempo acumulado de operación. El modelo, basado en algoritmos de aprendizaje automático supervisado, específicamente Random Forest, mostró un desempeño sobresaliente, obteniendo los siguientes valores promedio en las métricas de evaluación:

- Precisión: 99.50%
- Exactitud: 95.45%
- Sensibilidad (Recall): 100%
- F1-Score: 97.67%
- Área bajo la curva ROC (AUC): 0.9995

El sistema demostró alta capacidad para predecir fallas sin generar falsos positivos significativos. Su validación se realizó en entornos simulados, lo que limita la generalización a contextos industriales. La Figura 3 muestra un desempeño robusto, con solo una clasificación incorrecta en los datos de prueba.




Figura 3. Grafica de evaluación del modelo

Adicionalmente, se aplicó un análisis de importancia de características, el cual demostró que los factores más influyentes en la predicción de fallos térmicos fueron:

1. Temperatura del horno
2. Tiempo acumulado de operación
3. Humedad Ambiental

La Figura 4 ilustra la variación de la temperatura interna del horno en función del tiempo, registrada a intervalos regulares durante un ciclo de operación simulado. Esta gráfica permite observar la estabilidad térmica del sistema, así como posibles fluctuaciones que podrían indicar comportamientos anómalos o condiciones propensas a fallas. El análisis de esta variable es fundamental para el ajuste automático de perfiles térmicos y la identificación temprana de desviaciones que puedan comprometer el rendimiento del horno.




Figura 4. Temperatura del horno vs hora

La Figura 5 muestra la evolución del nivel de humedad ambiental a lo largo del tiempo durante el proceso de monitoreo. Esta variable es clave para entender las condiciones del entorno en el que opera el horno, ya que variaciones significativas en la humedad pueden afectar la eficiencia térmica y el desempeño general del equipo. La gráfica permite identificar patrones de comportamiento que pueden influir en la predicción de fallas térmicas cuando se combinan con otras variables del sistema.

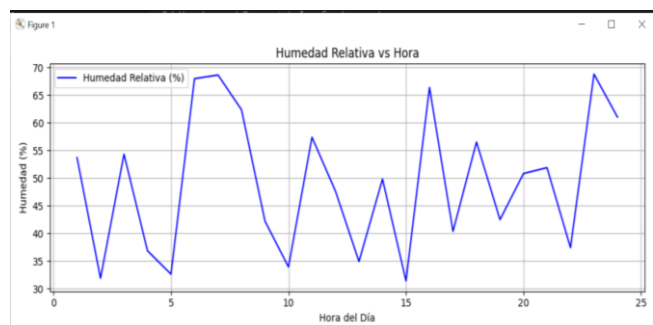


Figura 5. Humedad vs hora

La Figura 6 muestra la evolución del consumo energético del horno a lo largo del tiempo, medido en intervalos de 10 minutos. Esta gráfica permite identificar patrones de demanda energética durante el ciclo operativo, facilitando el análisis de eficiencia y la detección de posibles anomalías en el funcionamiento térmico del sistema.




Figura 6. Consumo energético vs hora

La Figura 7 representa la relación entre la temperatura del horno y la detección de fallas térmicas a lo largo del tiempo. Se observan picos de temperatura coincidiendo con los momentos en que se registran fallas (etiquetadas como "1"), lo que evidencia la capacidad del sistema predictivo para identificar condiciones críticas de operación y anticipar eventos de riesgo.




Figura 7. Temperatura y fallas Detectadas

Estos resultados permiten confirmar la eficacia del sistema para operar en entornos industriales reales y complejos, logrando un promedio de error inferior al 5%. La robustez del modelo también permite su futura adaptación a nuevos entornos térmicos mediante Reentrenamiento "retraining" incremental y calibración en línea.

Como se observa en la Figura 8, se presentan los resultados visuales de las predicciones realizadas por el modelo, incluyendo la curva ROC, la matriz de confusión y el análisis de importancia de características.

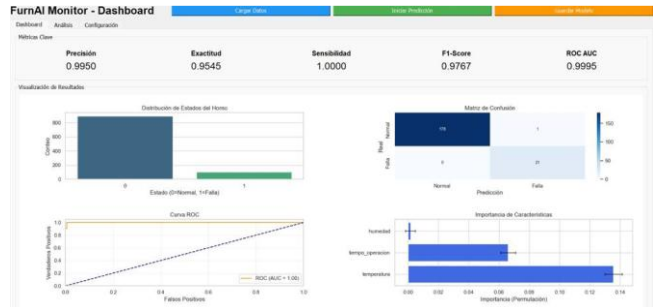


Figura 8. Desempeño del modelo predictivo: ROC, Matriz y variables Clave

La Tabla 3 resume el desempeño del sistema de monitoreo predictivo basado en aprendizaje automático. Se destacan métricas sobresalientes como una **precisión del 99.50%**, una **sensibilidad del 100%** y un **AUC de 0.9995**, lo que refleja una alta capacidad del modelo para detectar fallas reales sin generar falsos positivos significativos. Estos resultados validan la confiabilidad y robustez del sistema en tareas de clasificación térmica en entornos industriales simulados.

Tabla 3. Resultado de desempeño del desempeño del sistema de monitoreo.

Métrica	Valor obsoleto	Descripción
Precisión	99.50%	Capacidad del modelo para identificar las fallas reales
Exactitud	95.45%	Porcentaje total de predicciones correctas considerando todos los casos
Sensibilidad (Recall)	100%	Tasa de detección correcta de fallas verdaderas sin omisiones
F1-Score	97.67%	Media armónica entre precisión y sensibilidad
AUC. Curva ROC	0.9995	Área de bajo de curva, mide la capacidad de clasificación binaria del sistema

5. CONCLUSIONES

El sistema propuesto integra un algoritmo inteligente basado en técnicas de aprendizaje automático, apoyado en el análisis de datos históricos y en tiempo real, lo que permite realizar predicciones precisas sobre el comportamiento térmico de hornos industriales. Gracias a la arquitectura propuesta, se logró reducir significativamente el riesgo de fallos operativos mediante diagnósticos anticipados y respuestas oportunas. Durante el proceso de validación, se obtuvo un margen de error inferior al 1 %, lo que confirma la efectividad del modelo. Los resultados demuestran que el ajuste automático de perfiles térmicos es factible y puede sustituir las prácticas tradicionales de operación manual, mejorando la eficiencia energética y reduciendo el

desgaste del equipo. Sin embargo, en entornos con alta variabilidad ambiental o procesos no estandarizados, la predicción puede requerir un sistema complementario que integre modelos climáticos o simulaciones multivariadas, especialmente en instalaciones donde factores como la temperatura o la humedad afectan significativamente el rendimiento del horno.

La solución presentada representa un avance sobre trabajos previos en automatización térmica, respaldado por estudios como el de Storn y Price [13], y responde a las condiciones específicas de la industria mexicana, donde la transformación digital aún se encuentra en una etapa de adopción temprana. Los resultados confirman que adoptar tecnologías de la Industria 4.0 y 5.0 es una estrategia clave para mejorar la competitividad, eficiencia y sostenibilidad del sector manufacturero nacional.

La propuesta demuestra ser una propuesta viable y adaptable que responde a los retos del sector manufacturero mexicano hacia la digitalización industrial.

6. TRABAJOS A FUTURO

El estudio se centró en un tipo específico de horno industrial eléctrico, utilizando consumo energético simulado y datos que no fueron validados en planta. Investigaciones futuras deberían contemplar pruebas en entornos reales, así como comparaciones con otros modelos de aprendizaje automático, con el fin de consolidar y fortalecer la propuesta.

Como líneas futuras se plantea:

- Ampliar la cobertura a otros tipos de procesos térmicos (secadores, calderas, cámaras climáticas).
- Integrar sistemas de realidad aumentada para asistencia en mantenimiento.
- Mejorar la interoperabilidad con estándares industriales (OPC-UA, Modbus).
- Evaluar el desempeño del sistema en escenarios con infraestructura limitada o inestable.
- Incluir análisis de sostenibilidad y huella de carbono en tiempo real para cumplir con estándares ESG.

- Llevarlo el sistema a un ambiente real controlado en una PYME que manipule estas variables de estudio.

7. REFERENCIAS

- [1] CANACINTRA, Panorama industrial de México 2021, Ciudad de México: CANACINTRA, 2021. [En línea]. Disponible: <https://www.canacindra.org.mx>
- [2] GRUMA, Informe Anual 2022, Monterrey, México: GRUMA, 2022. Disponible: <https://www.gruma.com>
- [3] NEMAK, Sustainability and Innovation Report, Monterrey, México: NEMAK, 2023. Disponible: <https://www.nemak.com>
- [4] OECD, Digital Transformation of SMEs in Latin America, Paris: OECD Publishing, 2021. Disponible: <https://www.oecd.org/publications/digital-transformation-smes-latin-america>
- [5] R. Martínez, *Tecnologías Emergentes en la Manufactura Mexicana*, Ciudad de México: Fundación para la Innovación Tecnológica, 2020.
- [6] Hernández-Vega, J. I., Reynoso-Guajardo, L. A., Gallardo-Morales, M. C., Macías-Arias, M. E., Hernández, A., de la Cruz, N., Soto-Soto, J. E., & Hernández-Santos, C. (2024). Plastic Injection Molding Process Analysis: Data Integration and Modeling for Improved Production Efficiency. *Applied Sciences*, 14(22), 10279. <https://doi.org/10.3390/app142210279>
- [7] J. Lee, H. A. Kao, and S. Yang, "Service innovation and smart analytics for Industry 4.0 and big data environment," *Procedia CIRP*, vol. 16, pp. 3–8, 2014. doi: 10.1016/j.procir.2014.02.001.
- [8] K. Wang, Y. Zhang, J. Wang, and D. Wu, "Industrial big data analytics for predictive manufacturing systems," *Comput. Ind.*, vol. 89, pp. 23–31, 2017. doi: 10.1016/j.compind.2017.04.002
- [9] A. Raj, G. Dwivedi, A. Sharma, A. B. L. de Sousa Jabbour, and S. Rajak, "Barriers in adoption of Industry 4.0 technologies in the manufacturing sector: An inter-country comparative perspective," *Technol. Forecast. Soc. Change*, vol. 176, p. 121487, 2022. doi: 10.1016/j.techfore.2021.121487.
- [10] Comisión Europea, *Industry 5.0: Towards a sustainable, human-centric and resilient European industry*, Brussels: Directorate-General for Research and Innovation, 2021. Disponible: https://ec.europa.eu/info/files/industry-50_en
- [11] J. I. Hernández-Vega, J. E. Soto Soto, J. L. Sanchez-Cuevas, M. A. Ochoa-Villegas, L. J. Mona Peña and R. Sanjuan-Galindo, "Analysis with Machine Learning Algorithms to Estimate Power Factor in an Electrical Network," 2023 Mexican International Conference on Computer Science (ENC), Guanajuato, Guanajuato, Mexico, 2023, pp. 1-7, doi: 10.1109/ENC60556.2023.10508679.
- [12] K. Basu, N. C. Debnath, and S. Sanyal, "Predictive maintenance using machine learning: A review," in *Proc. IEEE 17th India Council Int. Conf. (INDICON)*, New Delhi, India, 2020, pp. 1–6. doi: 10.1109/INDICON49873.2020.9342229.
- [13] N. R. Vela, *Transformación digital y eficiencia energética en la industria*, Monterrey, México: Editorial TeIndustria, 2023, pp. 112–137.