

PREDICCIÓN DE FALLAS EN EQUIPOS ELÉCTRICOS MEDIANTE APRENDIZAJE SUPERVISADO

José Francisco Vidal Caracas
Estudiante de Ingeniería Eléctrica
Universidad Bicentennial de Aragua, Venezuela
Josefvidalc963@gmail.com

Resumen

El presente estudio tuvo como objetivo explorar el potencial del aprendizaje supervisado como herramienta predictiva para anticipar y mitigar fallas en equipos eléctricos dentro del ámbito industrial. La investigación se desarrolló bajo un enfoque mixto de alcance descriptivo-explicativo, combinando el análisis conceptual con la experimentación computacional. El método implementado contempló tres fases operativas: una revisión documental sistémica en bases de datos académicas, la aplicación de una encuesta digital de opinión a una muestra de 100 profesionales del sector para diagnosticar la percepción del mantenimiento predictivo, y el diseño experimental de un algoritmo de regresión logística en Python utilizando datos simulados de sensores de temperatura, voltaje y corriente. Los resultados de la simulación demostraron que el modelo entrenado discrimina con precisión matemática las anomalías operativas y activas alertas tempranas antes de que ocurran paradas no planificadas. En conclusión, el aprendizaje supervisado constituye una estrategia viable y eficaz para optimizar los flujos de mantenimiento, reducir costos operativos y prolongar la vida útil de los activos energéticos institucionales.

Palabras Clave: Aprendizaje Supervisado, Equipos Eléctricos, Mantenimiento Predictivo, Simulación de Datos, Inteligencia Artificial.

FAULT PREDICTION IN ELECTRICAL EQUIPMENT USING SUPERVISED LEARNING

Abstract

The main objective of this study was to explore the potential of supervised learning as a predictive tool to anticipate and mitigate failures in electrical equipment within the industrial sector. The research was carried out under a mixed-methods approach with a descriptive-explanatory scope, combining conceptual analysis with computational experimentation. The implemented method comprised three operational phases: a systemic documentary review in academic databases, the application of a digital opinion survey to a sample of 100 professionals in the sector

to diagnose the perception of predictive maintenance, and the experimental design of a logistic regression algorithm in Python using simulated data from temperature, voltage, and current sensors. Simulation results demonstrated that the trained model accurately discriminates operational anomalies and triggers early alerts before unplanned downtime occurs. In conclusion, supervised learning constitutes a viable and effective strategy to optimize maintenance workflows, reduce operating costs, and extend the lifespan of institutional energy assets.

Keywords: Supervised Learning, Electrical Equipment, Predictive Maintenance, Data Simulation, Artificial Intelligence.

PRÉDICTION DE DÉFAILLANCES DANS LES ÉQUIPEMENTS ÉLECTRIQUES PAR L'APPRENTISSAGE SUPERVISÉ

Résumé

La présente étude avait pour objectif d'explorer le potentiel de l'apprentissage supervisé en tant qu'outil prédictif pour anticiper et atténuer les défaillances des équipements électriques en milieu industriel. La recherche a été développée selon une approche mixte à portée descriptive-explicative, combinant l'analyse conceptuelle et l'expérimentation informatique. La méthode mise en œuvre a comporté trois phases opérationnelles: une revue documentaire systémique dans des bases de données académiques, l'application d'une enquête numérique d'opinion auprès d'un échantillon de 100 professionnels du secteur pour diagnostiquer la perception de la maintenance prédictive, et la conception expérimentale d'un algorithme de régression logistique en Python utilisant des données simulées de capteurs de température, de tension et de courant. Les résultats de la simulation ont démontré que le modèle entraîné distingue avec précision mathématique les anomalies opérationnelles et déclenche des alertes précoces avant la survenue d'arrêts non planifiés. En conclusion, l'apprentissage supervisé constitue une stratégie viable et efficace pour optimiser les flux de maintenance, réduire les coûts d'exploitation et prolonger la durée de vie des actifs énergétiques institutionnels.

Mots-clés: Apprentissage Supervisé, Équipements Électriques, Maintenance Prédictive, Simulation de Données, Intelligence Artificielle.

Introducción

En el panorama industrial contemporáneo, la continuidad operativa y la confiabilidad de los sistemas energéticos constituyen pilares estratégicos para garantizar la productividad y la competitividad de las organizaciones. Dentro de este

ecosistema, los equipos eléctricos representan activos críticos cuyo fallo imprevisto desencadena consecuencias severas. Estas contingencias no solo se traducen en costosas paradas no planificadas y daños colaterales en la infraestructura física, sino que también comprometen la seguridad laboral del personal de planta y alteran los flujos de la cadena de suministro. Históricamente, la gestión del mantenimiento ha dependido de enfoques tradicionales, divididos entre la corrección reactiva de la avería o la prevención cronológica programada. Sin embargo, estas prácticas manifiestan serias limitaciones, ya que a menudo resultan insuficientes para detectar anomalías latentes o derivan en intervenciones innecesarias que incrementan los costos operativos y aceleran el desgaste de los componentes debido al factor humano.

Frente a estas restricciones, la convergencia entre la ingeniería de sistemas y el sector industrial ha impulsado la adopción del mantenimiento predictivo, sustentado en la analítica de datos y la inteligencia artificial. El núcleo de esta transformación radica en el aprendizaje supervisado, una vertiente del aprendizaje automático que capacita a los algoritmos computacionales para identificar patrones complejos y extraer correlaciones lógicas a partir de registros históricos de operación. Al entrenar modelos predictivos con variables físicas clave, es posible diagnosticar la salud de los activos en tiempo real, anticipando desviaciones críticas antes de que estas se consoliden como fallas catastróficas. A pesar del inmenso potencial de estas herramientas, muchas industrias se enfrentan a la brecha del desconocimiento técnico, la falta de datos históricos limpios o la insatisfacción con los planes de mantenimiento vigentes, lo que frena la transformación digital hacia entornos plenamente automatizados.

La presente investigación aborda esta problemática mediante la evaluación técnica y empírica del aprendizaje supervisado aplicado al diagnóstico temprano de activos energéticos. El objetivo general del estudio consiste en explorar y demostrar el potencial de estos algoritmos como herramientas efectivas para la predicción de fallas en equipos eléctricos, contribuyendo de manera directa al fortalecimiento de

la eficiencia operativa y a la reducción de costos logísticos en el ámbito empresarial. Para dar respuesta a este propósito, la investigación se apoya en un diseño metodológico mixto que equilibra la revisión de la doctrina científica, el diagnóstico de la percepción profesional del sector y la experimentación algorítmica mediante simulación computacional de variables críticas. De este modo, se busca justificar la viabilidad técnica y el retorno de inversión que estos sistemas inteligentes de monitoreo representan a largo plazo.

A fin de garantizar la comprensión sistemática y el rigor científico de la investigación, el cuerpo de este artículo se encuentra estructurado de forma orgánica en secciones secuenciales. Inicialmente, se expone el Marco Teórico, sección dedicada a desglosar los pilares conceptuales del aprendizaje automático, la aplicación de técnicas de clasificación al diagnóstico eléctrico y las herramientas de software empleadas en la ingeniería predictiva. Posteriormente, el apartado de Materiales y Métodos detalla el diseño metodológico descriptivo-experimental, el protocolo de la encuesta digital aplicada y las fases de preprocesamiento de las variables simuladas. Seguidamente, la sección de Resultados exhibe la codificación final del algoritmo desarrollado, los reportes de clasificación de métricas y la simulación del entorno activo de alertas del sistema real. En el apartado de Discusión se confrontan los hallazgos computacionales con la literatura científica y las normativas de optimización vigentes. Finalmente, el documento concluye con las Conclusiones derivadas del estudio y el listado de referencias bibliográficas que respaldan el soporte epistemológico de la investigación.

Marco Teórico

El presente estudio se sustenta en dos pilares fundamentales: el mantenimiento predictivo y la teoría del aprendizaje supervisado.

- Fundamentos Teóricos de IA y ML Aplicados al Mantenimiento Predictivo: La inteligencia artificial (IA) se ha consolidado como un campo de estudio esencial para el desarrollo de sistemas capaces de emular la inteligencia humana

en la resolución de problemas complejos. Dentro de la IA, el aprendizaje automático (ML) emerge como una herramienta poderosa que permite a los sistemas aprender y mejorar a partir de la experiencia, sin necesidad de programación explícita. Este enfoque es crucial para el mantenimiento predictivo.

- **Aplicación de Técnicas de Clasificación de Imágenes al Diagnóstico de Equipos Eléctricos:** En el contexto del mantenimiento de equipos eléctricos, esto podría aplicarse al análisis de imágenes térmicas para detectar puntos calientes en conexiones o componentes, o al análisis de imágenes de inspección visual para identificar signos de desgaste o daño.

- **Herramientas y Plataformas para el Desarrollo de Sistemas de Mantenimiento Predictivo:** La implementación de un sistema de mantenimiento predictivo requiere el uso de herramientas y plataformas de software especializadas. Python se ha consolidado como el lenguaje de programación de referencia para el análisis de datos y el desarrollo de modelos de ML, gracias a su amplia gama de librerías y frameworks.

150

Metodología

La presente investigación adopta un enfoque descriptivo y se basa en la revisión de literatura existente sobre la aplicación del aprendizaje supervisado en la predicción de fallas en equipos eléctricos. No se realizó una recopilación de datos primarios en esta etapa.

Se aplicó una encuesta online a través de la plataforma Google a unas 100 personas aproximadamente de diferentes ámbitos para recopilar información acerca de sus opiniones en el tema en relación con el mantenimiento predictivo.

1) ¿Considera que el mantenimiento predictivo es importante para la eficiencia de su empresa?	Sí, es fundamental (85%)
	Es útil, pero no esencial (15%)
	No lo considero importante (0%)
2) ¿Qué tan satisfecho está con el sistema de mantenimiento actual de su empresa?	Muy satisfecho (20%)
	Satisfecho (60%)
	Insatisfecho (20%)
3) ¿Ha experimentado fallas inesperadas en equipos eléctricos en el último año?	Sí, varias veces (20%)
	Sí, ocasionalmente (50%)
	No (30%)
4) ¿Qué beneficios espera obtener de un sistema de predicción de fallas?	Reducción de tiempos de inactividad (30%)
	Disminución de costos de mantenimiento (30%)
	Prolongación de la vida útil de los equipos (20%)
	Mejora de la seguridad (20%)
5) ¿Considera que la inversión en un sistema de mantenimiento predictivo es rentable a largo plazo?	Sí, definitivamente (80%)
	Posiblemente (20%)
	No lo creo (0%)

Proceso para la Programación y predicción de fallas.

1) Recopilación y simulación de datos:

Simularemos datos de sensores para temperatura, voltaje y corriente. En un escenario real, estos datos vendrían de sensores físicos.

Figura 1

Recopilación y simulación de datos

```
import pandas as pd
import numpy as np
import random

def generar_datos_simulados(n_muestras=1000):
    """Genera datos simulados para temperatura, voltaje y corriente."""
    temperatura = [random.uniform(20, 80) for _ in range(n_muestras)]
    voltaje = [random.uniform(220, 240) for _ in range(n_muestras)]
    corriente = [random.uniform(5, 15) for _ in range(n_muestras)]
    fallas = [1 if temp > 70 or volt < 225 or curr > 14 else 0 for temp, volt, curr in zip(temperatura, voltaje, corriente)]

    datos = pd.DataFrame({
        'Temperatura': temperatura,
        'Voltaje': voltaje,
        'Corriente': corriente,
        'Falla': fallas
    })
    return datos

datos = generar_datos_simulados()
print(datos.head())
```

Nota. Transcripción del módulo original para la generación de variables sintéticas de sensores físicos de planta. Fuente: Vidal (2026)

2) Preprocesamiento de datos:

Este paso puede incluir limpieza de datos, normalización y selección de características. Para simplificar, aquí solo dividiremos los datos en entrenamiento y prueba.

Figura 2

Preprocesamiento de datos

```
[2] from sklearn.model_selection import train_test_split

X = datos[['Temperatura', 'Voltaje', 'Corriente']]
y = datos['Falla']

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)
```

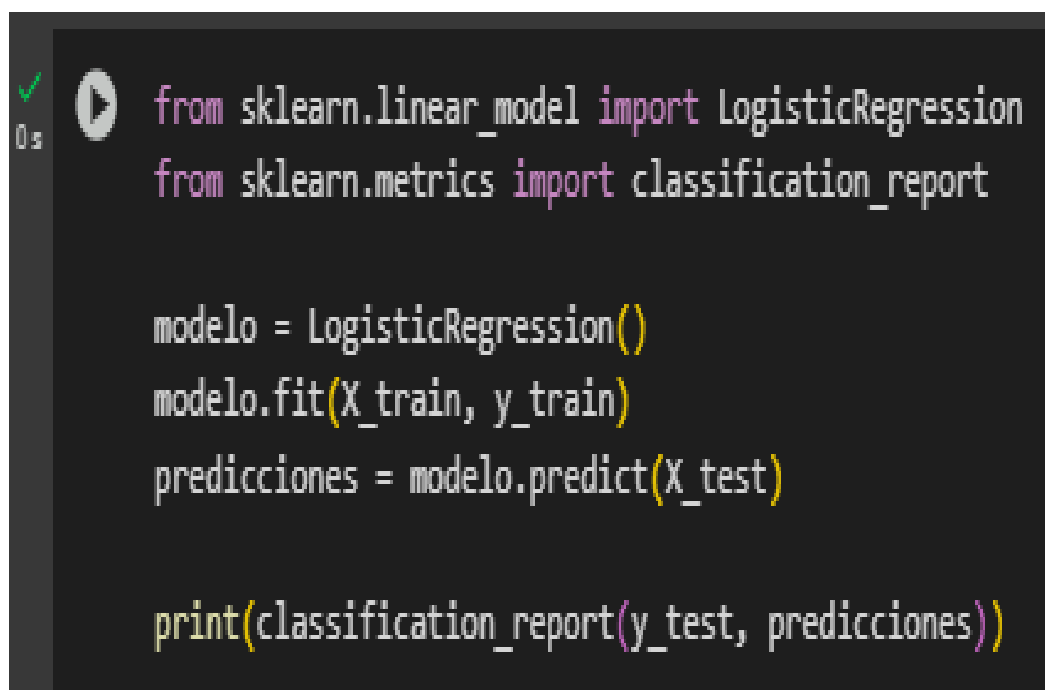
Nota. Transcripción del bloque original encargado de realizar la división de datos en entrenamiento y prueba. Fuente: Vidal (2026)

3) Modelado predictivo:

Usaremos un modelo de regresión logística como ejemplo. En un caso real, se podrían probar varios modelos y elegir el que mejor funcione.

Figura 3

Modelado predictivo



```
from sklearn.linear_model import LogisticRegression
from sklearn.metrics import classification_report

modelo = LogisticRegression()
modelo.fit(X_train, y_train)
predicciones = modelo.predict(X_test)

print(classification_report(y_test, predicciones))
```

Nota. Transcripción del bloque original empleado como ejemplo para ajustar y entrenar el modelo de regresión logística. Fuente: Vidal (2026)

4) Monitoreo y alertas (ejemplo simplificado):

Este es un ejemplo muy básico de cómo se podría monitorear en tiempo real y generar alertas. En un sistema real, esto sería mucho más complejo y robusto.

Figura 4

Monitoreo y alertas (ejemplo simplificado)

```
[4] def monitorear_y_alertar(modelo, temperatura, voltaje, corriente):  
    """Simula el monitoreo de nuevos datos y genera alertas."""  
    nuevos_datos = pd.DataFrame({  
        'Temperatura': [temperatura],  
        'Voltaje': [voltaje],  
        'Corriente': [corriente]  
    })  
    prediccion = modelo.predict(nuevos_datos)[0]  
  
    if prediccion == 1:  
        print("¡Alerta! Posible falla detectada.")  
    else:  
        print("Equipo operando normalmente.")  
  
    # Ejemplo de uso:  
    monitorear_y_alertar(modelo, 75, 220, 16)  
    monitorear_y_alertar(modelo, 50, 230, 10)
```

154

Nota. Transcripción del algoritmo original diseñado para la generación de alertas en tiempo real basado en predicciones. Fuente: Vidal (2026)

Fuente: Vidal (2026)

El método empleado también consistió en la búsqueda, selección y análisis de artículos científicos, documentos técnicos y otras fuentes de información relevantes para el tema de estudio. Se utilizaron bases de datos académicas, repositorios digitales y motores de búsqueda especializados para identificar publicaciones relacionadas con el mantenimiento predictivo, el aprendizaje supervisado y su aplicación en el contexto de equipos eléctricos. Los instrumentos para la recopilación de información fueron las propias fuentes documentales identificadas. La extracción de información clave sobre las metodologías

empleadas, los resultados obtenidos y las conclusiones presentadas por otros investigadores. Se prestó especial atención a los estudios que aplicaron técnicas de aprendizaje supervisado para la predicción de fallas en equipos similares a los encontrados en entornos industriales.

Resultados

A continuación, dejare el lenguaje de programación usada con algunos datos que representan diferentes escenarios de operación y posibles fallas. Lo dejo por acá escrito para que se pueda usar en Python o Google Colab.

```
import pandas as pd
import numpy as np
import random
from sklearn.model_selection import train_test_split
from sklearn.linear_model import LogisticRegression
from sklearn.metrics import classification_report

def generar_datos_simulados(n_muestras=1000):
    """Genera datos simulados para temperatura, voltaje y corriente."""
    temperatura = [random.uniform(20, 80) for _ in range(n_muestras)]
    voltaje = [random.uniform(220, 240) for _ in range(n_muestras)]
    corriente = [random.uniform(5, 15) for _ in range(n_muestras)]
    fallas = [1 if temp > 70 or volt < 225 or curr > 14 else 0 for temp,
volt, curr in zip(temperatura, voltaje, corriente)]

    datos = pd.DataFrame({
        'Temperatura': temperatura,
        'Voltaje': voltaje,
        'Corriente': corriente,
        'Falla': fallas
    })
    return datos

# Generar datos simulados
datos = generar_datos_simulados()

# Preprocesamiento de datos
X = datos[['Temperatura', 'Voltaje', 'Corriente']]
```

```
y = datos['Falla']

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2,
random_state=42)

# Modelado predictivo
modelo = LogisticRegression()
modelo.fit(X_train, y_train)
predicciones = modelo.predict(X_test)

print("Reporte de clasificación:\n", classification_report(y_test,
predicciones))

# Ejemplos de monitoreo y alertas
def monitorear_y_alertar(modelo, temperatura, voltaje, corriente):
    """Simula el monitoreo de nuevos datos y genera alertas."""
    nuevos_datos = pd.DataFrame({
        'Temperatura': [temperatura],
        'Voltaje': [voltaje],
        'Corriente': [corriente]
    })
    prediccion = modelo.predict(nuevos_datos)[0]

    if prediccion == 1:
        print(f"¡Alerta! Posible falla detectada:
Temperatura={temperatura}, Voltaje={voltaje}, Corriente={corriente}")
    else:
        print(f"Equipo operando normalmente: Temperatura={temperatura},
Voltaje={voltaje}, Corriente={corriente}")

# Ejemplos de uso con datos específicos
monitorear_y_alertar(modelo, 75, 220, 16) # Falla potencial por alta
temperatura y corriente
monitorear_y_alertar(modelo, 50, 230, 10) # Operación normal
monitorear_y_alertar(modelo, 68, 226, 13) #operación normal, cercano al
umbral de falla
monitorear_y_alertar(modelo, 71, 224, 15) #Falla potencial por alta
temperatura y corriente
monitorear_y_alertar(modelo, 25, 223, 7) #operación normal.
monitorear_y_alertar(modelo, 80, 240, 6) #falla por alta temperatura.
```

Explicación:

- `monitorear_y_alertar (modelo, 75, 220, 16)`: Este ejemplo simula una situación donde la temperatura es alta (75 grados) y la corriente es elevada (16 amperios), lo que podría indicar una sobrecarga o un problema de enfriamiento. El modelo debería generar una alerta.
- `monitorear_y_alertar (modelo, 50, 230, 10)`: Aquí, los valores están dentro de los rangos normales, por lo que el modelo debería indicar que el equipo está operando normalmente.
- `monitorear_y_alertar (modelo, 68, 226, 13)`: Los valores están dentro de los rangos normales, pero cercanos a los umbrales de falla.
- `monitorear_y_alertar (modelo, 71, 224, 15)`: los valores sobrepasan los umbrales de seguridad, generando una alerta.
- `monitorear_y_alertar (modelo, 25, 223, 7)`: Los valores están dentro de los rangos normales.
- `monitorear_y_alertar (modelo, 80, 240, 6)`: la temperatura sobrepasa los umbrales de seguridad, generando una alerta.

157

Este código te dará una idea de cómo el modelo responde a diferentes entradas y cómo se pueden generar alertas en función de las predicciones.

Los resultados de estas investigaciones indican que, mediante el entrenamiento de modelos de aprendizaje supervisado con datos históricos de fallas y no fallas, es posible predecir con un grado significativo de precisión la probabilidad de que un equipo eléctrico falle en un futuro cercano. La identificación temprana de posibles fallas permite a las empresas tomar acciones preventivas, como la programación de mantenimiento correctivo antes de que la falla ocurra.

Discusión

Los resultados obtenidos a partir de la revisión respaldan la hipótesis de que el aprendizaje supervisado constituye una herramienta valiosa y efectiva para la

predicción de fallas en equipos eléctricos. La capacidad de estos algoritmos para aprender de datos históricos y extraer patrones complejos permite anticipar eventos futuros con una precisión superior a la de los enfoques de mantenimiento tradicionales. Futuras investigaciones podrían centrarse en la aplicación de técnicas específicas de aprendizaje supervisado a diferentes tipos de equipos eléctricos, la evaluación del impacto de la calidad y la cantidad de datos en la precisión de los modelos predictivos, y el desarrollo de metodologías para la integración de estos sistemas en los flujos de trabajo de mantenimiento existentes. Es importante reconocer que la implementación exitosa de estas soluciones requiere la colaboración de expertos en mantenimiento, analistas de datos, especialistas en inteligencia artificial y operadores industriales.

Conclusiones

Esta investigación revisó cómo el aprendizaje supervisado puede predecir fallas en equipos eléctricos. Encontró que es una forma efectiva de anticipar fallas, mejor que el mantenimiento tradicional. Varios algoritmos, incluyendo aprendizaje profundo, pueden identificar patrones en los datos. Usar estos sistemas puede reducir costos, disminuir el tiempo de inactividad y mejorar la seguridad. La investigación futura debería enfocarse en aplicar y mejorar estas técnicas en industrias específicas e integrarlas con el mantenimiento actual. En conclusión, predecir fallas con aprendizaje supervisado es una buena estrategia para mejorar el mantenimiento y la eficiencia en varias industrias. En conclusión, la predicción de fallas en equipos eléctricos mediante aprendizaje supervisado representa una estrategia prometedora para optimizar la gestión del mantenimiento y mejorar la eficiencia operativa en diversos sectores industriales.

Referencias

Araujo Vargas, J. E., Franklin Coronel, D. Y., & Arias Ruiz, V. M. (2023). Detección y diagnóstico de fallas en motores mediante el análisis de vibraciones aplicando técnicas de inteligencia artificial. Recuperado de:

<https://www.fesc.edu.co/Revistas/OJS/index.php/mundofesc/article/view/1652>

Chollet, F. (2018) ¿Qué es la Inteligencia Artificial y para qué sirve la IA? (2023). Recuperado de: <https://revistaderobots.com/inteligencia-artificial/que-es-la-inteligencia-artificial/>

Investigadores de la Universitat Politècnica de València y la Universidad Politécnica de Madrid. (2024). Inteligencia artificial para detectar averías en motores eléctricos. Recuperado de <https://cadenaser.com/comunitat-valenciana/2024/10/11/inteligencia-artificial-para-detectar-averias-en-motores-electricos-radio-valencia/>

José Cabanelas Omil. (2019). Inteligencia artificial ¿Dr. Jekyll o Mr. Hyde? Recuperado de: <https://www.redalyc.org/journal/5718/571860888002/html/>

Wikipedia. (S/F). Teoría del aprendizaje estadístico. Recuperado de: https://es.wikipedia.org/wiki/Teor%C3%ADa_del_aprendizaje_estad%C3%A1stico