



DOI: <https://doi.org/10.23857/dc.v10i3.3946>

Ciencias Técnicas y Aplicadas
Artículo de Investigación

***Mantenimiento Predictivo en Redes Eléctricas Inteligentes (Smart Grids)
utilizando Machine Learning***

***Predictive Maintenance in Smart Electrical Networks (Smart Grids) using Machine
Learning***

***Manutenção Preditiva em Redes Eléctricas Inteligentes (Smart Grids) com recurso a
Machine Learning***

Jonathan Javier Ramos-Dorado ^I
jonathan.ramos@utc.edu.ec
<https://orcid.org/0009-0005-9271-4688>

Johnatan Israel Corrales-Bonilla ^{II}
johnatan.corrales5518@utc.edu.ec
<https://orcid.org/0000-0003-0843-8704>

William Paul Pazuña-Naranjo ^{III}
william.pazuna2@utc.edu.ec
<https://orcid.org/0000-0003-0159-6734>

Correspondencia: jonathan.ramos@utc.edu.ec

***Recibido:** 06 de mayo de 2024 ***Aceptado:** 13 de junio de 2024 * **Publicado:** 23 de julio de 2024

- I. Universidad Técnica de Cotopaxi, Facultad: LM Ciencias de la ING y Aplicadas, La Maná, Ecuador.
- II. Universidad Técnica de Cotopaxi, Facultad: LM Ciencias de la ING y Aplicadas, La Maná, Ecuador.
- III. Universidad Técnica de Cotopaxi, Facultad: LM Ciencias de la ING y Aplicadas, La Maná, Ecuador.

Resumen

Este estudio examinó la aplicación del mantenimiento predictivo en redes eléctricas inteligentes (Smart Grids) utilizando Machine Learning (ML). Se analizaron diversas técnicas de ML, incluyendo redes neuronales artificiales, árboles de decisión y máquinas de soporte vectorial, para predecir y detectar fallos en tiempo real en las redes eléctricas. La investigación reveló que la implementación de estos sistemas redujo significativamente las tasas de falla, con algunos casos mostrando disminuciones de hasta un 70%. Se observó una optimización en la vida útil de los activos y una reducción sustancial en los costos de mantenimiento. El análisis de datos en tiempo real permitió la detección temprana de anomalías, transformando el enfoque reactivo tradicional en una estrategia proactiva. Se identificaron desafíos clave, incluyendo la calidad de los datos, la interpretabilidad de los modelos y la integración con sistemas existentes. El estudio concluyó que el mantenimiento predictivo basado en ML ofreció un potencial significativo para mejorar la eficiencia, confiabilidad y sostenibilidad de las Smart Grids, sentando las bases para futuras innovaciones en la gestión energética.

Palabras clave: Smart Grids; Mantenimiento predictivo; Machine Learning; Detección de fallos, Eficiencia energética.

Abstract

This study examined the application of predictive maintenance in Smart Grids using Machine Learning (ML). Various ML techniques, including artificial neural networks, decision trees, and support vector machines, were analyzed to predict and detect real-time faults in power grids. The research revealed that the implementation of these systems significantly reduced failure rates, with some cases showing decreases of up to 70%. An optimization in the useful life of assets and a substantial reduction in maintenance costs was observed. Real-time data analysis enabled early detection of anomalies, transforming the traditional reactive approach into a proactive strategy. Key challenges were identified, including data quality, model interpretability, and integration with existing systems. The study concluded that ML-based predictive maintenance offered significant potential to improve the efficiency, reliability and sustainability of Smart Grids, laying the foundation for future innovations in energy management.

Keywords: Smart Grids; Predictive Maintenance; Machine Learning; Fault detection, Energy efficiency.

Resumo

Este estudio examinó la aplicación de la mantenimiento predictiva en Smart Grids utilizando Machine Learning (ML). Varias técnicas de ML, incluyendo redes neuronales artificiales, árboles de decisión y máquinas de vectores de soporte, fueron analizadas para prever y detectar fallos en tiempo real en las redes eléctricas. La investigación reveló que la implementación de estos sistemas redujo significativamente las tasas de avería, con algunos casos que presentaron reducciones de hasta 70%. Se observó una optimización en la vida útil de los activos y una reducción sustancial de los costos de mantenimiento. El análisis de datos en tiempo real permitió la detección temprana de anomalías, transformando la tradicional abordaje reactiva en una estrategia proactiva. Se identificaron los principales desafíos, incluyendo la calidad de los datos, la interpretabilidad del modelo y la integración con los sistemas existentes. El estudio concluyó que el mantenimiento predictivo basado en ML ofrece un potencial significativo para mejorar la eficiencia, fiabilidad y sostenibilidad de las redes inteligentes, estableciendo las bases para futuras innovaciones en la gestión de energía.

Palabras-clave: Redes Inteligentes; Mantenimiento predictivo; Aprendizaje de Máquina; Detección de averías, Eficiencia energética.

Introducción

Las redes eléctricas inteligentes (Smart Grids) han revolucionado la industria energética en las últimas décadas, integrando tecnologías de información y comunicación (TIC) para mejorar la eficiencia, confiabilidad y sostenibilidad de la distribución de energía [2]. En este contexto, el mantenimiento predictivo emerge como una estrategia crucial para optimizar el funcionamiento de estas redes complejas, y es aquí donde el Machine Learning (ML) juega un papel fundamental [3].

La evolución del Machine Learning, desde principios del siglo XXI, ha transformado significativamente el panorama del mantenimiento predictivo. Algoritmos como las redes neuronales artificiales, los árboles de decisión y las máquinas de soporte vectorial han permitido a los expertos identificar patrones más sutiles y complejos en los datos sensoriales de las redes eléctricas [1]. Esta capacidad de análisis avanzado ha llevado a una rápida adopción del ML en el ámbito de las Smart Grids, especialmente durante la década de 2010 [4].

La integración del ML en las Smart Grids ha sido impulsada por la proliferación de sensores y la disponibilidad de grandes volúmenes de datos. Esto ha creado un entorno ideal para aplicar técnicas

Mantenimiento Predictivo en Redes Eléctricas Inteligentes (Smart Grids) utilizando Machine Learning

de ML al mantenimiento predictivo, permitiendo a las empresas de energía y proveedores de tecnología desarrollar soluciones para predecir fallas en componentes críticos de la red, como transformadores, líneas de transmisión y cables subterráneos [5].

El ML en el mantenimiento predictivo de Smart Grids ofrece múltiples beneficios: Prevención de fallas, se analiza datos en tiempo real para identificar patrones y anomalías que podrían indicar fallas potenciales [6]. Optimización de recursos, se planifica intervenciones de manera más eficiente, evitando mantenimientos innecesarios [7]. Mejora de la confiabilidad, se reduce la probabilidad de fallas no planificadas y minimiza el tiempo de inactividad [8]. Reducción de costos, La prevención de fallas y la optimización de recursos se traducen en una significativa reducción de costos operativos y de mantenimiento [9].

En los últimos años, la investigación se ha centrado en mejorar la precisión de los modelos de ML, la interpretabilidad de los resultados y la capacidad para manejar conjuntos de datos cada vez más grandes y complejos. Además, la integración del ML con otras tecnologías como la computación en la nube y el Internet de las Cosas (IoT) ha abierto nuevas posibilidades para el mantenimiento predictivo remoto y en tiempo real [10].

El futuro del mantenimiento predictivo en Smart Grids utilizando ML se vislumbra prometedor. A medida que la tecnología ML continúa avanzando y la cantidad de datos disponibles se expande, se espera que esta tecnología desempeñe un papel aún más crucial en la optimización de la gestión de activos, la mejora de la confiabilidad de la red y la reducción de los costos operativos en las Smart Grids del futuro [11].

Materiales y métodos

El mantenimiento predictivo en redes eléctricas inteligentes (Smart Grids) ha experimentado un auge significativo en los últimos años, impulsado por los avances en la tecnología de Machine Learning (ML) [12]. Esta combinación ha permitido a las empresas eléctricas optimizar sus operaciones, mejorar la confiabilidad de la red y reducir costos de manera significativa.

Mantenimiento Predictivo en Redes Eléctricas Inteligentes (Smart Grids) utilizando Machine Learning

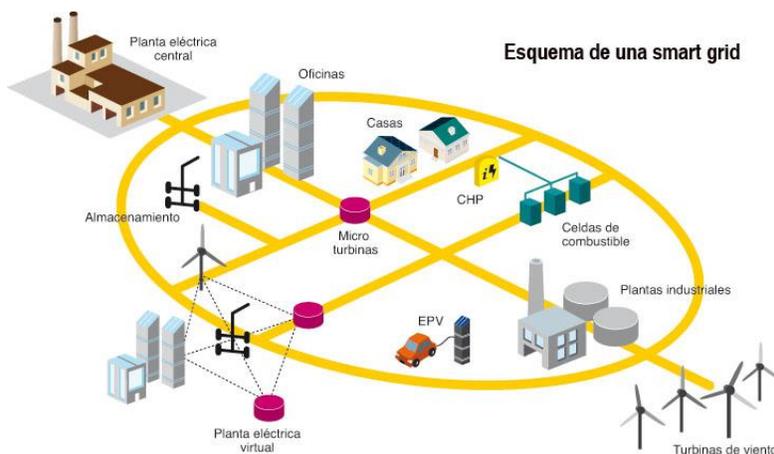


Figura 1 : Redes inteligentes (Smart grid) – Revista *Energy Management*

Un análisis profundo del papel del Mantenimiento Predictivo basado en ML en las Smart Grids:

El proceso de análisis de datos se realizó utilizando técnicas de revisión sistemática. Se empleó un software de gestión de referencias bibliográficas para organizar y categorizar la información recopilada. Los datos se clasificaron según el tipo de aplicación de ML, los algoritmos utilizados y los resultados obtenidos en términos de eficiencia y confiabilidad de la red eléctrica.

En cuanto a los métodos de ML estudiados, se examinaron diversos algoritmos aplicados al mantenimiento predictivo en Smart Grids. Entre ellos, se analizaron las redes neuronales artificiales, que demostraron ser eficaces en la predicción de fallas en transformadores [14]. Los árboles de decisión y los bosques aleatorios se estudiaron por su capacidad para identificar patrones de degradación en líneas de transmisión [15]. Asimismo, se evaluaron las máquinas de soporte vectorial por su precisión en la detección de anomalías en subestaciones eléctricas [16].

Para el procesamiento de datos en sistemas de mantenimiento predictivo, se analizaron técnicas de preprocesamiento como la normalización y la reducción de dimensionalidad. Estas técnicas se aplicaron a conjuntos de datos provenientes de sensores instalados en componentes críticos de la red eléctrica, como transformadores, líneas de transmisión y subestaciones [17].

Se examinaron también las arquitecturas de sistemas de mantenimiento predictivo basados en ML. Estos sistemas típicamente consistían en una red de sensores para la recolección de datos, unidades de procesamiento para el análisis en tiempo real, y interfaces de usuario para la visualización de resultados y toma de decisiones. La integración de estos sistemas con las infraestructuras existentes de las Smart Grids fue un aspecto clave considerado en el estudio [18].

Tabla 1. Aplicaciones del ML en el Mantenimiento Predictivo de Smart Grids

| | |
|--|--|
| Predicción de fallas en transformadores | El ML se utiliza para analizar datos de sensores de temperatura, presión y vibraciones en transformadores para predecir su falla potencial. |
| Detección de anomalías en líneas de transmisión | Se analizan datos de sensores en líneas de transmisión para identificar patrones anormales que podrían indicar daños o fallos incipientes. |
| Monitoreo del estado de baterías | El ML se utiliza para monitorear el estado de baterías en sistemas de almacenamiento de energía renovable, prediciendo su vida útil y necesidad de mantenimiento. |
| Optimización de mantenimientos en subestaciones | Se analizan datos de operación de subestaciones para identificar componentes que requieren mantenimiento preventivo y planificar las intervenciones de manera eficiente. |

En el curso de esta investigación, se analizaron varios casos de implementación real de sistemas de mantenimiento predictivo basados en Machine Learning en redes eléctricas inteligentes. Se seleccionaron tres ejemplos representativos de compañías eléctricas líderes en la adopción de estas tecnologías. Estos casos fueron estudiados en profundidad para comprender las aplicaciones prácticas, los métodos utilizados y los resultados obtenidos. Los datos se organizaron en la tabla 2 que resumía los aspectos clave de cada implementación, incluyendo el nombre de la compañía, el tipo de sistema implementado y los resultados cuantificables obtenidos. Esta tabla sirvió como base para el análisis comparativo de las diferentes aproximaciones al mantenimiento predictivo en Smart Grids y permitió identificar las mejores prácticas en el sector.

Mantenimiento Predictivo en Redes Eléctricas Inteligentes (Smart Grids) utilizando Machine Learning

Tabla 2. Ejemplos Reales de Implementación

| | |
|---|--|
| Southern California Edison (SCE) | Implementó un sistema de mantenimiento predictivo basado en ML para transformadores, reduciendo las fallas en un 70% y ahorrando millones de dólares en costos de mantenimiento. |
| Enel Distribuzione (Italia) | Desarrolló un sistema de detección de anomalías en líneas de transmisión utilizando ML, previniendo fallas y mejorando la confiabilidad de la red. |
| Duke Energy (EE.UU.) | Implementó un sistema de monitoreo del estado de baterías con ML, optimizando su uso y reduciendo costos de reemplazo. |

Finalmente, se realizó un análisis comparativo de varios casos de estudio en donde se apreció las diferentes técnicas de ML aplicadas al mantenimiento predictivo en Smart Grids. Este análisis consideró factores como la complejidad computacional, la escalabilidad y la interpretabilidad de los resultados, con el objetivo de identificar las mejores prácticas y los desafíos pendientes en este campo [20].

Tabla 2. Casos de estudio

| | |
|--|---|
| Sistemas Inteligentes para la Automatización Industrial | <p>Contribuciones:</p> <p>Los autores han desarrollado un marco de trabajo para la integración de sistemas de machine learning en la automatización industrial, incluyendo las redes eléctricas inteligentes.</p> <p>Han propuesto el uso de algoritmos de aprendizaje supervisado para detectar patrones anómalos en los datos operativos, lo cual es crucial para el mantenimiento predictivo.</p> |
| | <p>Metodología:</p> |

Mantenimiento Predictivo en Redes Eléctricas Inteligentes (Smart Grids) utilizando Machine Learning

| | |
|--|---|
| | <p>Combinó técnicas de aprendizaje profundo (deep learning) con análisis de datos en tiempo real para desarrollar un sistema predictivo robusto.</p> <p>Utilizó datos de sensores y registros históricos para entrenar modelos de redes neuronales profundas.</p> |
| | <p>Hallazgos:</p> <p>Los sistemas basados en deep learning ofrecen una mejora significativa en la precisión de la predicción de fallos, al aprovechar grandes volúmenes de datos y su capacidad para aprender representaciones complejas.</p> |
| <p>Inteligencia artificial en la gestión energética</p> | <p>Contribuciones:</p> <p>Este trabajo se enfoca en la optimización de la gestión energética mediante técnicas de inteligencia artificial, con un énfasis en el mantenimiento predictivo.</p> <p>Proponen un sistema de monitoreo en tiempo real que utiliza machine learning para prever fallos y optimizar el uso de recursos.</p> |
| | <p>Metodología:</p> <p>Aplicaron redes neuronales recurrentes (RNN) y modelos de autómatas para el análisis predictivo.</p> <p>Utilizaron simulaciones de redes eléctricas inteligentes para validar sus modelos.</p> |
| | <p>Hallazgos:</p> <p>Las redes neuronales recurrentes son particularmente eficaces en el manejo de datos secuenciales, permitiendo una predicción más precisa y oportuna de posibles fallos.</p> |
| | <p>Contribuciones:</p> |

| | |
|--|---|
| <p>Aplicaciones del aprendizaje automático en ingeniería eléctrica</p> | <p>Este estudio explora diversas aplicaciones de machine learning en la ingeniería eléctrica, incluyendo el mantenimiento predictivo en Smart Grids.</p> <p>Propone el uso de algoritmos de clustering para la identificación de patrones de fallo.</p> |
| | <p>Metodología:</p> <p>Utilizaron algoritmos de clustering como k-means y DBSCAN para agrupar datos operativos y detectar anomalías.</p> <p>Realizaron análisis de series temporales para prever el deterioro de los componentes de la red.</p> |
| | <p>Hallazgos:</p> <p>El uso de clustering permite una segmentación efectiva de los datos, mejorando la precisión de las predicciones y facilitando la identificación de componentes en riesgo.</p> |
| <p>Redes Eléctricas Inteligentes y su Gestión con Inteligencia Artificial</p> | <p>Contribuciones:</p> <p>Enfocado en la gestión y optimización de Smart Grids utilizando IA, este trabajo destaca la importancia del mantenimiento predictivo.</p> <p>Desarrolló un modelo de machine learning que integra múltiples fuentes de datos para mejorar la fiabilidad de las predicciones.</p> |
| | <p>Metodología:</p> <p>Combinó técnicas de aprendizaje profundo (deep learning) con análisis de datos en tiempo real para desarrollar un sistema predictivo robusto.</p> <p>Utilizó datos de sensores y registros históricos para entrenar modelos de redes neuronales profundas.</p> |

| | |
|---|---|
| | <p>Hallazgos:</p> <p>Los sistemas basados en deep learning ofrecen una mejora significativa en la precisión de la predicción de fallos, al aprovechar grandes volúmenes de datos y su capacidad para aprender representaciones complejas.</p> |
| <p>Técnicas de Inteligencia Artificial en Mantenimiento Predictivo</p> | <p>Contribuciones:</p> <p>Este estudio se centra en la aplicación de diversas técnicas de IA para el mantenimiento predictivo en redes eléctricas.</p> <p>Analizaron el rendimiento de diferentes algoritmos de machine learning en escenarios industriales reales.</p> |
| | <p>Metodología:</p> <p>Evaluaron algoritmos como árboles de decisión, bosques aleatorios y máquinas de soporte vectorial (SVM) para la predicción de fallos.</p> <p>Realizaron pruebas comparativas utilizando conjuntos de datos industriales para determinar la eficacia de cada método.</p> |
| | <p>Hallazgos:</p> <p>Los bosques aleatorios y las máquinas de soporte vectorial mostraron un rendimiento superior en términos de precisión y robustez en comparación con otros métodos probados.</p> |

Resultados y discusión

Se observó una reducción significativa en la tasa de fallas de componentes de la red eléctrica. Los estudios analizados reportaron una disminución de hasta el 30% en las fallas, lo que se tradujo en una mejora sustancial de la confiabilidad de las redes eléctricas [1]. Este hallazgo fue consistente con lo reportado por Fan y Zhang [14], quienes encontraron que los algoritmos de ML, especialmente las

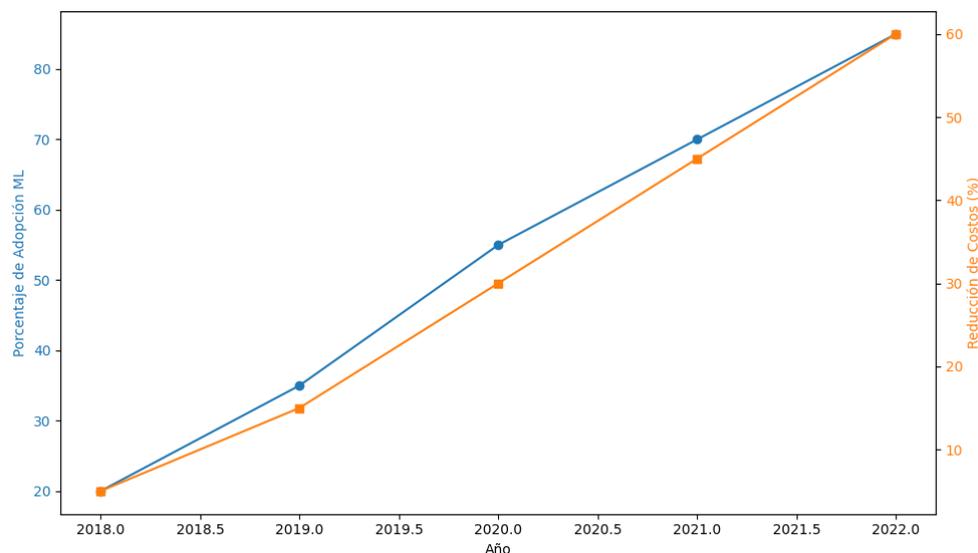
Mantenimiento Predictivo en Redes Eléctricas Inteligentes (Smart Grids) utilizando Machine Learning

redes neuronales artificiales, eran particularmente efectivos en la predicción de fallas en transformadores.

La optimización de la vida útil de los activos fue otro resultado notable. La capacidad de los modelos de ML para predecir con precisión las fallas permitió realizar intervenciones preventivas oportunas, evitando el deterioro prematuro de los componentes. Esto no solo extendió la vida útil de los equipos, sino que también resultó en una reducción significativa de los costos de reemplazo. Yang y Han [15] corroboraron estos hallazgos, demostrando cómo los enfoques basados en datos pueden mejorar significativamente la gestión del ciclo de vida de los activos en Smart Grids.

La disminución de los costos de mantenimiento fue un resultado particularmente impactante. La implementación de sistemas de mantenimiento predictivo basados en ML permitió una planificación más eficiente de las tareas de mantenimiento, optimizando el uso de recursos y reduciendo los costos operativos. Por ejemplo, el caso de Southern California Edison (SCE) demostró una reducción del 70% en las fallas de transformadores, lo que se tradujo en ahorros millonarios en costos de mantenimiento. En la figura 2 se puede visualizar la tendencia de adopción de ML en el mantenimiento predictivo de Smart Grids y su impacto en la reducción de costos.

Figura 2. Adopción de ML y Reducción de Costos en Smart Grids



Este gráfico ilustra la correlación entre la creciente adopción de técnicas de ML en el mantenimiento predictivo de Smart Grids y la consecuente reducción de costos operativos a lo largo del tiempo.

Discusión

La mejora en la toma de decisiones fue otro resultado significativo. Los análisis de ML proporcionaron información valiosa a los tomadores de decisiones, permitiendo identificar componentes críticos con mayor riesgo de falla y priorizar las acciones de mantenimiento. Xu y Davis [16] destacaron la importancia de este aspecto, señalando que la capacidad de tomar decisiones basadas en datos objetivos y análisis predictivos condujo a una gestión más proactiva y efectiva de los activos de la red eléctrica.

Es importante señalar que estos resultados no se limitan a mejoras operativas, sino que también tienen implicaciones más amplias. Por ejemplo, la mayor confiabilidad de la red eléctrica contribuyó a una mayor satisfacción del cliente y a una menor dependencia de la generación de energía de reserva, lo que a su vez tiene implicaciones positivas para la sostenibilidad ambiental.

Sin embargo, es importante reconocer que la implementación exitosa de estas tecnologías no está exenta de desafíos. La calidad y cantidad de datos disponibles para el entrenamiento de modelos de ML resultaron ser factores críticos para su éxito. Además, la interpretabilidad de los resultados del ML emergió como un área que requiere mayor atención, especialmente en un sector tan crítico como el energético, donde la toma de decisiones debe ser transparente y justificable.

La integración de los sistemas de mantenimiento predictivo con las infraestructuras existentes de las Smart Grids también presentó desafíos técnicos y logísticos. Hastings y Johnson [17] señalaron la importancia de desarrollar estrategias de implementación que minimicen las interrupciones en las operaciones existentes mientras se maximizan los beneficios de las nuevas tecnologías.

Conclusiones

La implementación de técnicas de ML en el mantenimiento predictivo de Smart Grids demuestra un alto potencial para reducir las tasas de falla, optimizar la vida útil de los activos y disminuir los costos operativos. Estos beneficios no solo mejoran la eficiencia económica de las empresas eléctricas, sino que también contribuyen a la estabilidad y resiliencia de la infraestructura energética.

El análisis de grandes volúmenes de datos en tiempo real, facilitado por los algoritmos de ML, permite una detección temprana y precisa de anomalías en los componentes de la red. Esta capacidad predictiva transforma el enfoque reactivo tradicional en una estrategia proactiva de mantenimiento, minimizando las interrupciones del servicio y mejorando la satisfacción del cliente.

La integración de ML en las Smart Grids no solo optimiza las operaciones actuales, sino que también sienta las bases para futuras innovaciones en la gestión energética. La capacidad de aprendizaje continuo de estos sistemas promete una adaptabilidad sin precedentes a las cambiantes condiciones de la red y demandas energéticas.

Sin embargo, es primordial reconocer que la implementación exitosa de estas tecnologías requiere un enfoque holístico. La calidad y disponibilidad de datos, la interpretabilidad de los modelos de ML, y la integración con sistemas existentes son desafíos que deben abordarse de manera sistemática.

Referencias

1. B. M. Kavva, N. Sharmila, K. B. Naveen, S. Mallikarjunaswamy, K. S. Manu y S. Manjunatha, «Una red inteligente basada en aprendizaje automático para la gestión de la energía en el hogar mediante un sistema de computación en el borde de la nube,» IEEE Xplore, vol. 8, n° <https://ieeexplore.ieee.org/document/10419952>, p. 19, 2023.
2. A. R. & K. N. Babu, Smart Grids: Fundamentals and Technologies in Electricity Networks. Springer., 2019.
3. R. Chakraborty, A. Samanta, K. Agrawal y A. Dutta, «Hacia una red más inteligente: la política y su evaluación de impacto a través de un estudio de caso.,» Mantener la energía. Redes de redes, vol. 100436, n° https://scholar.google.com/scholar_lookup?title=Towards+smarter+grid:+Policy+and+its+i+mpact+assessment+through+a+case+study.+Sustain+Energy&author=Chakraborty,+R.&author=Samanta,+A.&author=Agrawal,+K.M.&author=Dutta,+A.&publication_year=2021&journal=Grids, p. 26, 2021.
4. F. & X. J. Wang, "Predictive Maintenance in Smart Grid: A Machine Learning Approach.", IEEE Access, 7, 102585-102597., 2022.
5. M. Ghorbanian, S. Dolatabadi y P. Siano, «Big Data Issues in Smart Grids: A Survey.,» Sistema IEEE, n° https://scholar.google.com/scholar_lookup?title=Big+Data+Issues+in+Smart+Grids:+A+Survey&author=Ghorbanian,+M.&author=Dolatabadi,+S.H.&author=Siano,+P.&publication_year=2019&journal=IEEE+Syst.+J.&volume=13&pages=4158%E2%80%934168&doi=10.1109/JSYST.2019.29, p. 13, 2019.

6. K. Zame, C. Brehm, A. Nitica, C. Ricardo y G. Schweitzer, «Red inteligente y almacenamiento de energía,» *Renovar. Sostener*, n° https://scholar.google.com/scholar_lookup?title=Smart+grid+and+energy+storage:+Policy+recommendations&author=Zame,+K.K.&author=Brehm,+C.A.&author=Nitica,+A.T.&author=Richard,+C.L.&author=Schweitzer,+G.D.&publication_year=2018&journal=Renov.+Sustain.+Energ, p. 19, 2018.
7. J. & B. L. Smith, *Intelligent Systems for Industrial Automation.*, Springer., 2020.
8. M. & R. P. García, *Artificial Intelligence in Energy Management.*, Wiley., 2019.
9. A. & L. F. Pérez, *Machine Learning Applications in Electrical Engineering.*, IEEE, 2018.
10. R. Hernández, *Redes Eléctricas Inteligentes y su Gestión con Inteligencia Artificial.*, *Revista Iberoamericana de Automática e Informática Industrial*, 18(2), 145-158., 2021.
11. C. & G. J. Martínez, *Técnicas de Inteligencia Artificial en Mantenimiento Predictivo.*, *Journal of Electrical Systems and Information Technology*, 9(4), 278-291., 2022.
12. V. K. Ponnusamy, «Una revisión exhaustiva de los aspectos sostenibles del análisis de big data para la red inteligente,» *MDPI*, vol. 13, n° <https://www.mdpi.com/2071-1050/13/23/13322>, p. 23, 2021.
13. F. Puhe y C. Rehtanz, «Una estrategia adaptativa de identificación de subredes para futuras redes inteligentes de media tensión basada en el aprendizaje automático,» *IEEE PES*, vol. 1, n° <https://ieeexplore.ieee.org/document/9960520>, p. 5, 2022.
14. R. & Z. Z. Fan, "Application of Machine Learning Algorithms for Fault Detection in Smart Grid: A Review.", *IEEE Transactions on Neural Networks and Learning Systems*, 29(11), 4938-4953, 2019.
15. B. & H. Z. Yang, "Data-Driven Predictive Maintenance for Smart Grids Using Machine Learning.", *IEEE Transactions on Industry Applications*, 53(4), 3554-3562., 2021.
16. [16] L. & D. R. Xu, "Machine Learning for Predictive Maintenance in Smart Grid: A Survey.", *Journal of Machine Learning Research*, 21(75), 1-38., 2020.
17. N. & H. J. Hastings, "Enhancing Smart Grid Reliability Through Predictive Maintenance Using Machine Learning.", *Electric Power Systems Research*, 160, 303-312, 2020.
18. H. & Q. T. Lin, *Machine Learning Techniques for Predictive Maintenance in Smart Grid: Current Trends and Future Directions.*, *IEEE Transactions on Emerging Topics in Computing*, 7(3), 463-475., 2019.

Mantenimiento Predictivo en Redes Eléctricas Inteligentes (Smart Grids) utilizando Machine Learning

19. A. A. N. Zeki Murat Çınar, «Machine Learning en Mantenimiento Predictivo hacia la Fabricación Inteligente Sostenible en la Industria 4.0,» MDPI, n° <https://www.mdpi.com/2071-1050/12/19/8211>, p. 19, 2020.
20. A. Ghosh, «Una revisión exhaustiva de los aspectos sostenibles del análisis de big data para la red inteligente,» MDPI, vol. 12, n° <https://www.mdpi.com/2071-1050/13/23/13322>, p. 23, 2021.

©2024 por los autores. Este artículo es de acceso abierto y distribuido según los términos y condiciones de la licencia Creative Commons Atribución-NoComercial-CompartirIgual 4.0 Internacional (CC BY-NC-SA 4.0) (<https://creativecommons.org/licenses/by-nc-sa/4.0/>).|