

Machine learning para la predicción de energía eléctrica: una revisión sistemática de literatura

Machine learning for electric power prediction: a systematic literature review

Kandel L. Yandar¹ Oscar Revelo-Sánchez¹ Manuel E. Bolaños-González¹

¹Departamento de Sistemas, Universidad de Nariño, San Juan de Pasto, Colombia.

Resumen

Este estudio presenta una Revisión Sistemática de la Literatura (RSL) sobre las técnicas de inteligencia artificial (IA) aplicadas para la predicción de energía eléctrica. Las bases de datos especializadas que se emplearon en esta revisión son Scopus, IEEE, ACM y Google Scholar. Este análisis ofreció una perspectiva sobre las técnicas de inteligencia artificial utilizadas en este campo, lo que facilitó la identificación de las tendencias presentes y en desarrollo. Esto proporciona una comprensión clara de las oportunidades venideras para mejorar la precisión en la predicción de la energía eléctrica y, en consecuencia, en la toma de decisiones. Un hallazgo destacado de esta revisión fue el predominio del uso de redes neuronales artificiales (RNA) como la técnica más prevalente dentro del campo de Machine Learning aplicado a la predicción de energía eléctrica. Esta preferencia se justifica por la capacidad inherente de las RNA para identificar patrones complejos y relaciones en los datos, lo que las convierte en una herramienta valiosa para la predicción de energía eléctrica. Además, se destaca la importancia de varios factores fundamentales en la predicción de energía eléctrica, como la importancia de recolectar datos relevantes y representativos, que abarquen tanto información histórica como contextual. El preprocesamiento de datos, el cual implica la limpieza y transformación de los datos recopilados para prepararlos adecuadamente para su análisis y modelado y la división de datos, crucial para evitar sesgos y evaluar de manera precisa la capacidad predictiva del modelo.

Abstract

This study presents a Systematic Literature Review (SLR) on artificial intelligence (AI) techniques applied to electric power prediction. The specialized databases employed in this review are Scopus, IEEE, ACM, and Google Scholar. This analysis provided a perspective on the artificial intelligence techniques utilized in this field, facilitating the identification of current and emerging trends. This offers a clear understanding of upcoming opportunities to enhance accuracy in electric power prediction and decision-making.

A notable finding of this review was the predominant usage of Artificial Neural Networks (ANN) as the most prevalent technique in Machine Learning applied to electric power prediction. This preference is justified by the inherent ability of ANN to identify complex patterns and relationships in data, making them a valuable tool for electric power prediction. Additionally, the importance of essential factors in electric power prediction is highlighted, such as the significance of collecting relevant and representative data, encompassing historical and contextual information. Data preprocessing, which involves cleaning and transforming collected data to adequately prepare them for analysis and modeling, and data splitting, crucial for avoiding biases and accurately evaluating the predictive capability of the model, are also emphasized.

Keywords: artificial intelligence, Electric energy, Machine learning, Prediction, Systematic literature review.

Palabras clave: aprendizaje automático, Energía eléctrica, Inteligencia artificial, Predicción, Revisión sistemática de literatura.

¿Cómo citar?

Yandar, K.I., Reveló-Sánchez, O., Bolaños, M.E. Machine learning para la predicción de energía eléctrica: una revisión sistemática de literatura. Ingeniería y Competitividad, 2024, 26(2)e-304113875
<https://doi.org/10.25100/iyc.v26i2.13875>

Recibido: 17-04-24

Aceptado: 17-06-24

Correspondence:

kandel@udenar.edu.co

Este trabajo está bajo una licencia internacional Creative Commons Atribución-No Comercial-CompartirIgual4.0.



Conflicto de intereses: ninguno declarado

OPEN  ACCESS

Why was it conducted?:

En la actualidad, la transición energética se ha convertido en una pieza clave para mitigar el cambio climático y garantizar un suministro energético sostenible y seguro mediante el uso de fuentes de energía renovable, como la solar, eólica, hidroeléctrica y geotérmica. Sin embargo, la implementación de estas fuentes presenta grandes retos, especialmente en términos de variabilidad e intermitencia, que complican su integración en los sistemas energéticos existentes. Por ello, surge la necesidad de investigar sobre técnicas que permitan mitigar estos desafíos y facilitar el proceso de transición energética. En este contexto, la aplicación de técnicas de inteligencia artificial (IA) se ha vuelto esencial ya que la IA puede mejorar significativamente la precisión en la predicción de la generación de energía eléctrica y apoyar la toma de decisiones informadas en un sector que está en constante evolución.

What were the most relevant results?

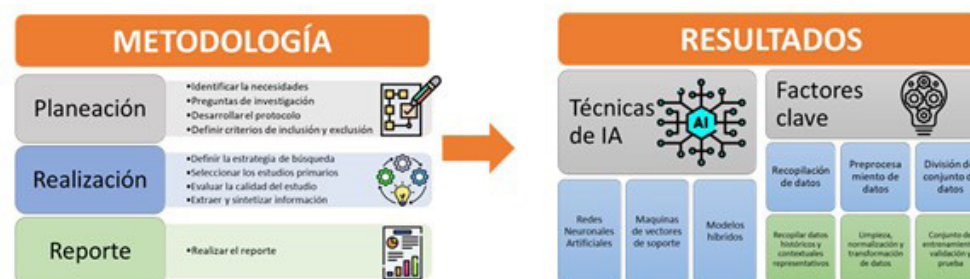
El estudio destaca que la técnica de inteligencia artificial (IA) más utilizada para la predicción de energía eléctrica son las Redes Neuronales Artificiales (RNA). Estas redes son altamente valoradas debido a su capacidad para identificar patrones complejos y relaciones sutiles en grandes volúmenes de datos, lo que les permite realizar predicciones precisas y adaptarse a diversas condiciones operativas.

Además, el estudio subraya la importancia crucial de varios factores para mejorar la precisión y eficacia de los modelos predictivos. En primer lugar, es esencial recopilar datos históricos y contextuales representativos, ya que una base de datos robusta y bien estructurada proporciona el fundamento necesario para el entrenamiento de los modelos de IA. Estos datos deben abarcar diversas variables relevantes, incluyendo patrones de consumo de energía, condiciones meteorológicas, y otros factores contextuales que puedan influir en la generación y demanda de energía.

El preprocesamiento de datos también se destaca como un factor fundamental. Este proceso incluye la limpieza de datos para eliminar inconsistencias y errores, la normalización para asegurar que todas las variables se encuentren en una escala comparable, y la transformación de datos para resaltar las características más relevantes. Un preprocesamiento adecuado asegura que los datos alimentados en las RNA sean de alta calidad, mejorando así la precisión del modelo. Finalmente, el estudio enfatiza la importancia de una correcta división del conjunto de datos en subconjuntos de entrenamiento, validación y prueba. Esta división permite evaluar y ajustar el modelo de manera efectiva, asegurando que no se sobreajuste a los datos de entrenamiento y que pueda generalizar bien a datos no vistos.

What do these results contribute?

La revisión sistemática de la literatura proporciona una perspectiva sobre las tendencias actuales y emergentes en el uso de la inteligencia artificial (IA) para la predicción de energía. Este enfoque no solo identifica oportunidades futuras para el desarrollo de técnicas más avanzadas y eficientes, sino que también establece una base sólida para investigaciones y aplicaciones prácticas posteriores. Al recopilar y analizar investigaciones previas, se facilita la creación de soluciones innovadoras para los desafíos energéticos contemporáneos. Los resultados de esta revisión ofrecen una comprensión clara de las técnicas de IA más efectivas para la predicción de energía eléctrica, lo que puede mejorar significativamente la precisión en las predicciones y optimizar la gestión de los recursos energéticos. Esta mejora en la precisión de las predicciones permite a los gestores de energía tomar decisiones más informadas, contribuyendo a una gestión más eficiente y sostenible de los sistemas energéticos.



Graphical Abstract

Introducción

La generación de energía es vital para cubrir las necesidades energéticas de la sociedad. Sin embargo, las fuentes tradicionales están disminuyendo, lo que podría provocar una crisis energética por su escasez. Por tanto, es imperativo buscar nuevas fuentes de energía. En este sentido, se ha observado un incremento constante en el empleo de fuentes de energía renovable, lo que plantea nuevos retos para asegurar la entrega fiable y de alta calidad de los servicios en la red de distribución eléctrica.

El uso de técnicas de IA para analizar y optimizar la generación y consumo de energía eléctrica se ha vuelto esencial para optimizar el aprovechamiento de los recursos provenientes de las energías renovables. Al analizar datos históricos y en tiempo real, y considerar variables externas, se obtiene una comprensión más profunda del mercado energético, lo que respalda la toma de decisiones fundamentadas.

En un sector donde las condiciones cambian constantemente, esta capacidad de anticipación que brindan las técnicas de IA se convierte en un recurso invaluable que no solo permite la adaptación, sino también el liderazgo en un entorno competitivo y complejo.

El *Machine Learning* representa una subdisciplina fundamental dentro del campo de la inteligencia artificial. Su funcionamiento se apoya en algoritmos que aprenden a partir de datos, tomando decisiones de manera similar a los procesos cognitivos humanos (1). Esta capacidad ha adquirido un papel esencial en la predicción de energía eléctrica, donde la aplicación de modelos respaldados por técnicas de IA, como las redes neuronales artificiales han demostrado ser una herramienta importante en este campo.

En este sentido, la contribución teórica de esta investigación radica en la recopilación y análisis de investigaciones previas en la disciplina de la IA aplicada a la predicción de energía eléctrica. Este artículo de RSL (Revisiones Sistemáticas de Literatura) permite identificar tendencias, ventajas y limitaciones de las técnicas de IA aplicadas a la predicción de energía eléctrica, jugando un papel crucial en la transición hacia un sistema energético más sostenible, al proporcionar un entendimiento de las técnicas de IA utilizadas con el propósito de optimizar la gestión de la energía.

Por otra parte, el aporte metodológico de esta revisión va dirigido a la descripción del método utilizado para seleccionar, analizar y sintetizar la literatura relevante en el campo. Al seguir un enfoque sistemático y transparente, la RSL asegura la validez de los resultados obtenidos. Este rigor metodológico permite a investigadores y profesionales en las disciplinas de ingeniería de sistemas, ingeniería eléctrica e ingeniería ambiental confiar en las conclusiones derivadas de la síntesis de evidencia científica y brindar un punto de partida para la generación de soluciones orientadas a abordar los desafíos ambientales contemporáneos con mayor eficacia y precisión.

El artículo se divide en 4 apartados que son los siguientes: en el primero, se realiza una breve introducción, en el segundo se detalla el método de investigación empleado; los resultados y la discusión se exponen en el tercero; y las conclusiones se presentan en el cuarto apartado. Finalmente, se incluyen las referencias.

Metodología

Se lleva a cabo esta RSL adaptando la estrategia metodológica de Zapata y Barón (2) la cual tiene su fundamento en el proceso de RSL propuesto por Kitchenham y Charters (3). En este sentido, la figura 1, describe las fases y actividades desarrolladas para esta revisión.



Figura 1. Proceso de RSL.

Planeación

Identificar las necesidades de la RSL

Realizar una RSL sobre las técnicas de inteligencia artificial empleadas en la predicción de energía eléctrica permite identificar, analizar y recopilar la literatura relevante asociada con este campo. Estos hallazgos proporcionarán una base sólida que puede ser compartida con la comunidad científica

Especificar las preguntas de investigación

Para Kitchenham y Charters (3) la actividad crucial radica en la elaboración de las preguntas de investigación, las cuales sirven como guía para el desarrollo de las actividades de búsqueda de los estudios primarios como también para la extracción y síntesis de la información.

En esta investigación se plantean dos interrogantes que se detallan a continuación:

RQ1. ¿Qué técnicas de IA se utilizan para la predicción de energía eléctrica?

RQ2. ¿Cuáles son los factores clave que se emplean para la predicción de energía eléctrica?

Desarrollar el protocolo

En la ejecución de esta RSL se aplican los siguientes procedimientos: (i) la identificación de fuentes de estudio pertinentes y adecuadas para la investigación; (ii) la elaboración de cadenas de búsqueda, con el propósito de identificar los estudios potenciales a incluir en el análisis; (iii) la definición de criterios de inclusión y exclusión con el fin de discernir los estudios pertinentes para la investigación.

Definir los criterios de inclusión y exclusión

El propósito de la definición de estos criterios consiste en elegir la literatura pertinente para la investigación estableciendo límites claros y específicos para la selección de estudios

relevantes que serán incluidos en el análisis. En este contexto, los criterios específicos para esta revisión se detallan en la tabla 1.

Tabla 1. Criterios de inclusión y exclusión

Criterios de inclusión
Ventana temporal (2013 – 2023).
Estudios que se refieran a técnicas de inteligencia artificial que se utilizan para la predicción de energía eléctrica.
Título del documento relacionado con las técnicas de inteligencia artificial utilizadas en el contexto de energía eléctrica.
Palabras clave relacionadas con la investigación
Criterios de exclusión
No se tienen en cuenta investigaciones en un idioma diferente a inglés o español
Artículos duplicados
No se tiene en cuenta las revisiones o mapeos de literatura

Para la definición de la ventana temporal en un periodo de 10 años se tuvo en cuenta que el campo de la inteligencia artificial (IA) y las técnicas de predicción han experimentado avances significativos en la última década. Por lo cual, extender el período de revisión a 10 años nos permite capturar el desarrollo y la evolución de diversas técnicas, ofreciendo una visión más completa de cómo han mejorado, cómo se han adaptado a nuevas necesidades y cómo han surgido nuevas propuestas y retos en el sector energético.

Realización de la RSL

Una vez que el protocolo ha sido definido, la ejecución de la RSL se divide en cuatro actividades, las cuales se detallan a continuación:

Estrategia de búsqueda

En el marco de esta investigación, se incluye la utilización de cadenas de búsqueda. Según Zapata y Barón (2) "Las cadenas de búsqueda son configuraciones que describen las preguntas de investigación. Estas cadenas son los criterios ingresados en los motores de búsqueda de las fuentes digitales"

La cadena de búsqueda para la RSL sobre técnicas de IA que se utilizan en el contexto de energía eléctrica es la siguiente: ("artificial intelligence techniques") AND ("energy trading" OR "energy transaction" OR "energy exchange" OR "energy management").

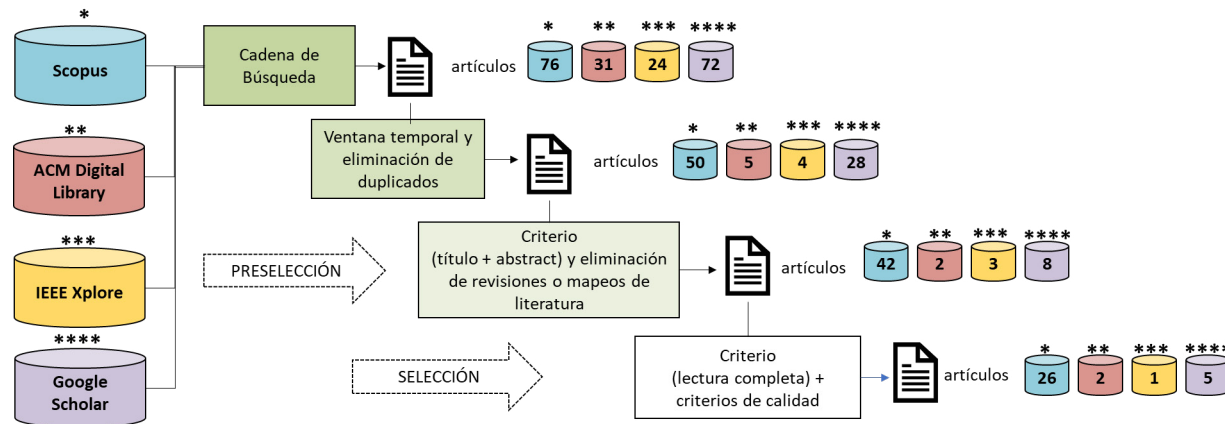
Seleccionar los estudios primarios

El objetivo de esta actividad es seleccionar los estudios realmente relevantes que aporten a dar respuesta a las preguntas de investigación definidas (3).

Identificar las fuentes de estudios

La búsqueda de literatura sobre técnicas de IA que se utilizan en el contexto de energía eléctrica se realiza utilizando bases de datos bibliográficas digitales como *Scopus*, *Acm Digital Library*, *Ieee Xplore Digital Library* y *Google Scholar*. Los resultados de esta búsqueda se presentan en la figura 2.

Figura 2. Resultados fuentes de estudio



Seleccionar los estudios

Se encontró un conjunto de 203 registros bibliográficos potencialmente pertinentes utilizando la cadena de búsqueda definida en las cuatro fuentes bibliográficas previamente seleccionadas. Posteriormente, se realizó un proceso de depuración que abarcó la ventana temporal entre los años 2013 y 2023, así como la eliminación de duplicados, lo que arrojó un total de 87 registros. Dentro de esta selección depurada, se procedió a examinar tanto los títulos como los resúmenes de los artículos con el fin de identificar aquellos que abordaban directamente técnicas de IA que se utilizan en el contexto de energía eléctrica. Como resultado de este análisis, se destacaron 55 registros que fueron sometidos a una revisión completa.

Evaluar la calidad del estudio

Para garantizar la calidad en la selección de los estudios se aplican cuatro criterios fundamentales establecidos por Collazos et al. (4). Estos criterios incluyen: la relevancia del contenido para abordar las preguntas planteadas en la revisión, la claridad en la definición de los objetivos de la investigación, la adecuada descripción del contexto en el que se lleva a cabo el estudio y una presentación clara de los resultados, que engloban tres aspectos esenciales de calidad: el establecimiento de un nivel mínimo de calidad, la credibilidad y la pertinencia de los estudios.

La calidad fue evaluada mediante el análisis de los 55 registros completos, seguido de la evaluación del grado de adhesión a los criterios preestablecidos. A partir de este proceso, se identificó un conjunto final de 34 documentos que sirvieron como principales fuentes de información para la RSL. Estos documentos se detallan en la tabla 4 junto con sus referencias bibliográficas, organizados de manera cronológica según el año de publicación.

Tabla 2. Documentos revisados

Año	No	Referencia
2013	2	(5), (6)
2014	0	
2015	1	(7)
2016	3	(8), (9), (10)
2017	3	(11), (12), (13)
2018	3	(14), (15), (16)
2019	3	(17), (18), (1)
2020	4	(19), (20), (21), (22)
2021	7	(23), (24), (25), (26), (27), (28), (29)
2022	3	(30), (31), (32)
2023	16	(33), (34), (35), (36), (37) (38) (39) (40) (41) (42) (43) (44) (45) (46) (47) (48)
2024	2	(49) (50)

Extracción y síntesis de resultados

La etapa conclusiva del proceso se enfocó en la extracción de datos con el fin de responder las preguntas de investigación previamente definidas, así como en la síntesis de los resultados. A partir de la selección de documentos, se llevaron a cabo extracciones de metadatos específicos, extraídos de los registros bibliográficos.

Estos metadatos incluyen detalles como: el título, año de publicación, fuente de publicación, autores y país de afiliación institucional en la fecha de publicación del artículo, centrándose en las técnicas de IA aplicadas en el ámbito de la energía eléctrica. Para facilitar la comprensión del estudio se realiza una clasificación de los términos técnicas y modelos, considerando que los artículos revisados los emplean de manera indistinta. En la tabla 3 se presenta un extracto.

Tabla 3. Extracción de datos

Autor	Técnica / Modelo	Factores relevantes	Aporte
(29)	<i>Artificial neural networks (ANN)</i> y <i>Support vector machine (SVM)</i>	<ol style="list-style-type: none"> 1. Recopilación de datos (energéticos y meteorológicos durante un periodo de 2 años) 2. Preprocesamiento de datos 3. División del conjunto de datos (entrenamiento, prueba y validación) 	Se utilizan dos técnicas de IA como <i>Artificial neural networks (ANN)</i> y <i>Support vector machine (SVM)</i> para predecir la demanda máxima de energía para estimar el uso de energía para un edificio de oficinas en un campus universitario basándose en datos meteorológicos y datos históricos de energía.
(30)	<i>Decision Trees</i>	<ol style="list-style-type: none"> 1. Recopilación de datos (tiempo, precio y temperatura durante el periodo de 1 año) 2. Preprocesamiento 3. División del conjunto de datos (entrenamiento y prueba) 	Se propone la implementación de tecnologías como el Internet de las cosas (IoT) y el aprendizaje automático para la gestión y conservación de energía en edificios haciendo uso de la técnica <i>Decision Trees</i> .
(22)	<i>Support vector machine (SVM)</i> y <i>Artificial neural networks (ANN)</i>	<ol style="list-style-type: none"> 1. Recopilación de datos (datos históricos consumo) 2. División del conjunto de datos (entrenamiento, prueba y validación) 	Propone la predicción del consumo de energía en edificios residenciales, haciendo uso de <i>Support Vector Machine (SVM)</i> y <i>Radial Basis Functions Neural Network (RBFNN)</i> .
(18)	<i>K-means</i> y <i>Artificial neural networks (ANN)</i>	<ol style="list-style-type: none"> 1. Recopilación de datos (uso de energía de edificios, datos meteorológicos) 2. Desarrollo de IA 3. Implementación del modelo 4. Análisis de escenarios 	Propone la predicción del consumo de energía en un campus haciendo uso de la técnica de <i>K-means</i> y <i>long-short term memory (LSTM)</i> .

Esta investigación completa está disponible en el siguiente enlace: [extraccióndedatos.pdf](#)

La figura 3 representa diversas técnicas/modelos de IA que se utilizan en el contexto de energía eléctrica.

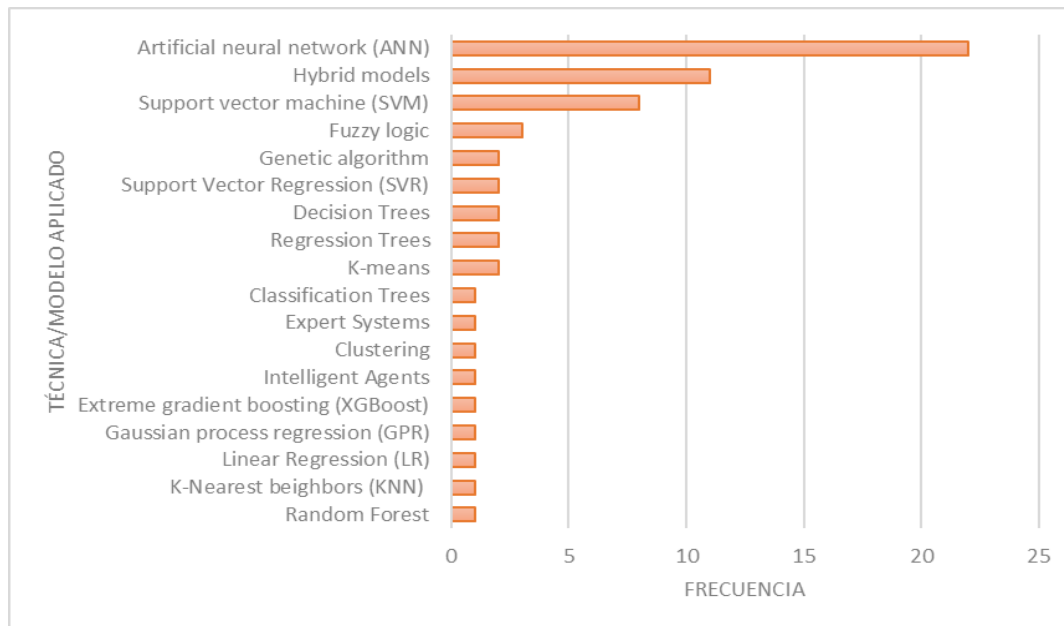


Figura 3. Técnicas/modelos aplicados

Reporte de la RSL

La etapa conclusiva de una revisión sistemática implica la redacción y divulgación de los hallazgos de la revisión a la comunidad relevante (3). Este reporte se presenta en la sección de resultados del presente artículo.

Resultados y discusión

Se realizó un análisis detallado de las distintas técnicas de IA empleadas en la predicción de energía eléctrica. Se observó que *Machine Learning* es la subdisciplina de inteligencia artificial más ampliamente adoptada, gracias a su capacidad para modelar relaciones complejas, manejar grandes conjuntos de datos y realizar pronósticos que abarcan diversos intervalos temporales.

Además, entre las técnicas más sobresalientes que se utilizan para el pronóstico de energía eléctrica se encuentran las RNA, los modelos híbridos y las máquinas de vectores de soporte. Estas técnicas han demostrado ser pilares esenciales en el análisis energético y la generación de pronósticos.

Es relevante señalar que la mayoría de los estudios analizados emplean las RNA en entornos como edificios o casas residenciales orientadas a la optimización del consumo energético. Estas redes facilitan la predicción de picos de demanda y permiten ajustar automáticamente la distribución de energía para maximizar la eficiencia y reducir los costos. Adicionalmente, los campus universitarios desempeñan un papel crucial en el desarrollo de estas técnicas predictivas, permitiendo la gestión eficiente del consumo energético en múltiples edificaciones y servicios, mediante la integración de datos provenientes de diversas fuentes, como condiciones meteorológicas y patrones de uso de las instalaciones. Esto no solo impulsa la sostenibilidad, sino que también provee una plataforma de investigación invaluable para estudiantes y profesionales. Por último, las microrredes emergen como un ámbito significativo para la aplicación de las RNA, ya que facilitan la integración de fuentes de energía renovable en la red eléctrica. Al predecir las variaciones en la generación de energía solar y eólica, y ajustar la demanda a estos cambios se contribuye a la creación de una infraestructura energética más resiliente y

preparada para responder a las necesidades de una población urbana en expansión. Esta preferencia se sustenta en su estructura inherente para identificar patrones y relaciones en los datos, lo que las hace especialmente idóneas para enfrentar una diversidad de desafíos. Su habilidad para modelar y prever estos comportamientos con mayor precisión en comparación con los métodos convencionales las posiciona como una herramienta de gran utilidad en este ámbito.

Además, se evidencia de manera consistente que la recopilación, el preprocesamiento y la división de datos (entrenamiento, prueba y validación) son aspectos importantes en la mayoría de los estudios al abordar la obtención de información relacionada con los factores relevantes para la realización de modelos de predicción de energía eléctrica. Estos factores se establecen como bases para garantizar la calidad y confiabilidad de dichos modelos.

Finalmente, las preguntas de investigación establecidas en la fase de planeación de esta revisión se responden a continuación.

RQ1. ¿Qué técnicas de IA se utilizan para la predicción de energía eléctrica?

Tras analizar los resultados obtenidos se manifiesta claramente que las técnicas de inteligencia artificial más empleadas se encuentran dentro del ámbito de Machine Learning. En particular, sobresale la aplicación de redes neuronales artificiales como un enfoque de alta relevancia en este contexto, y esto se debe a una serie de atributos inherentes que las hacen especialmente idóneas para abordar una amplia variedad de desafíos en la predicción de energía eléctrica.

Las redes neuronales artificiales, al ser ampliamente preferidas, se distinguen por su capacidad intrínseca para discernir patrones y relaciones en los datos. Este rasgo es particularmente valioso cuando se trata de prever tanto la generación como el consumo de energía. Además de esta destreza en la detección de patrones, estas redes también tienen la capacidad de modelar relaciones complejas y no lineales, lo que es esencial en el contexto de la energía eléctrica, donde las variables pueden estar interconectadas de maneras intrincadas.

En el contexto de la predicción de energía eléctrica, las redes neuronales artificiales sobresalen como la técnica más comúnmente empleada y efectiva, teniendo un papel crucial. Su habilidad para ofrecer pronósticos precisos y adaptados a la complejidad del sector energético las posiciona como un elemento central para la implementación exitosa de soluciones de inteligencia artificial en este ámbito.

Por otro lado, las máquinas de vectores de soporte (SVM por sus siglas en inglés) y los modelos híbridos sobresalen como alternativas adicionales para el desarrollo de modelos de predicción de energía eléctrica, según el contexto de aplicación. Las SVM son especialmente útiles para manejar problemas no lineales, ya que transforman los datos a espacios de mayor dimensión donde se vuelven linealmente separables mediante el uso de *kernels* adecuados. Esto permite a las SVM generalizar bien, haciéndolas menos propensas al sobreajuste en comparación con otros modelos más complejos. Su aplicación sobresale cuando se cuenta con un conjunto pequeño de datos para su entrenamiento. En el caso de la aplicación los modelos híbridos se evidencian que mejoran la precisión y el rendimiento general del sistema al combinar diferentes técnicas, adaptándose a una amplia variedad de problemas y tipos de datos, y proporcionando soluciones versátiles y adaptables, pero son más demandantes en términos de recursos computacionales y tiempo de procesamiento.

RQ2. ¿Cuáles son los factores clave que se emplean para la predicción de energía eléctrica?

La predicción de la energía eléctrica implica tener en cuenta una variedad de factores clave que son fundamentales para obtener pronósticos precisos y confiables. En la mayoría de los estudios examinados en esta RSL, resalta la importancia de factores

como la recopilación de datos siendo la base fundamental para llevar a cabo análisis y modelizaciones efectivas, lo que permite capturar patrones y tendencias con mayor precisión. Asimismo, el correcto preprocesamiento de los datos asegura la coherencia y uniformidad de los mismos, y la división del conjunto de datos en subconjuntos de entrenamiento, validación y prueba, emerge como una fase fundamental para valorar el desempeño del modelo predictivo. Estos aspectos se consideran como elementos esenciales en el proceso de predicción de energía eléctrica, sirviendo como pilares fundamentales para asegurar la efectividad y exactitud de los resultados obtenidos.

Conclusiones

En este estudio se utilizó una metodología de RSL con el propósito de recopilar, analizar y sintetizar los avances de investigación pertinentes al campo de estudio. Inicialmente, se identificaron 203 registros bibliográficos potencialmente pertinentes utilizando la cadena de búsqueda definida en la actividad 1.2.1. Una vez realizado el proceso de depuración y teniendo en cuenta los criterios de inclusión y exclusión previamente definidos se seleccionaron 55 registros que fueron sometidos a una revisión completa. De estos, 34 trabajos fueron incluidos como la base de evidencia empleada para responder a las dos preguntas clave establecidas. La RSL destaca que, en la predicción de energía eléctrica, las técnicas de IA más utilizados se encuentran dentro del ámbito de Machine Learning, específicamente el uso de RNA emergen como la técnica más prevalente y eficaz. Su capacidad para identificar patrones y relaciones en los datos las convierte en una elección especialmente valiosa en la predicción de energía eléctrica.

La adecuada ejecución de factores como la recopilación, el preprocesamiento y la división de los datos se revela como un elemento de gran relevancia en el proceso de desarrollo de un modelo predictivo. Estos pasos no solo mejoran el rendimiento del modelo, sino que también aseguran la precisión y calidad de las predicciones resultantes. Por tanto, su correcta ejecución es fundamental para obtener resultados fiables y significativos en el ámbito de la predicción.

La implementación de la estrategia metodológica garantiza que los resultados obtenidos constituyan un cimiento robusto que pueda ser compartido con la comunidad científica.

A través del desarrollo de esta revisión sistemática es posible brindar a la comunidad científica una visión general de la investigación sobre el uso técnicas/modelos de Inteligencia Artificial, específicamente en el campo de *Machine Learning* que se utilizan para la predicción de energía eléctrica. Además de mostrar el creciente número de publicaciones y una variedad de enfoques para tratar el tema. Esto, como se mencionó anteriormente, puede explotarse para abrir nuevas e importantes oportunidades para la investigación futura.

Considerando que las redes neuronales artificiales (RNA) representan la técnica/modelo de *Machine Learning* más utilizada para la predicción en el sector eléctrico y considerando que el espectro de aplicación de las RNA es muy amplio, sería provechoso realizar un estudio detallado sobre los tipos específicos de RNA empleados en este ámbito como línea de investigación futura.

Referencias

1. Zuitao Ma. Neural Networks Used for Time Series Prediction of Power Consumption. University of Oslo; 2019.
2. Barón A, Zapata C. Estrategia Metodológica para la Elaboración de Síntesis Conceptuales en Ingeniería de Software: una Aplicación al Caso del Constructo Teórico de Práctica. 4th Int Conf Softw Eng Res Innov CONISOFT. 2016;

3. Charters BK and S. Guidelines for performing systematic literature reviews in software engineering. Tech report, Ver 23 EBSE Tech Report EBSE. 2007;1:1–54.
4. Revelo-Sánchez O, Collazos-Ordóñez CA, Jiménez-Toledo JA. El trabajo colaborativo como estrategia didáctica para la enseñanza/aprendizaje de la programación: una revisión sistemática de literatura. *Tecnológicas*. 2018;21(41).
5. Gómez Sarduy JR, Monteagudo Yanes JP, Granado Rodríguez ME, Quiñones Ferreira JL, Torres YM. Determining cement ball mill dosage by artificial intelligence tools aimed at reducing energy consumption and environmental impact. *Ing e Investig [Internet]*. 2013 Sep 1;33(3):49–54. Available from: <https://revistas.unal.edu.co/index.php/ingev/article/view/41043>
6. Chaouachi A, Kamel RM, Andoulsi R, Nagasaka K. Multiobjective Intelligent Energy Management for a Microgrid. *IEEE Trans Ind Electron [Internet]*. 2013 Apr;60(4):1688–99. Available from: <http://ieeexplore.ieee.org/document/6157610/>
7. Al-Daraiseh A, El-Qawasmeh E, Shah N. Multi-agent system for energy consumption optimisation in higher education institutions. *J Comput Syst Sci [Internet]*. 2015 Sep;81(6):958–65. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0022000014001743>
8. Yuce B, Rezgui Y, Mourshed M. ANN–GA smart appliance scheduling for optimised energy management in the domestic sector. *Energy Build [Internet]*. 2016 Jan;111:311–25. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0378778815303820>
9. Saleh AI, Rabie AH, Abo-Al-Ez KM. A data mining based load forecasting strategy for smart electrical grids. *Adv Eng Informatics [Internet]*. 2016 Aug;30(3):422–48. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S1474034616301331>
10. Olatomiwa Lanre J. Optimal planning and design of hybrid renewable energy system for rural healthcare facilities / Olatomiwa Lanre Joseph. 2016;
11. Bose BK. Artificial Intelligence Techniques in Smart Grid and Renewable Energy Systems—Some Example Applications. *Proc IEEE [Internet]*. 2017 Nov;105(11):2262–73. Available from: <http://ieeexplore.ieee.org/document/8074546/>
12. Mutombo NMA. Development of neuro-fuzzy strategies for prediction and management of hybrid PV-PEMFC-battery systems. University of KwaZulu-Natal; 2017.
13. Vantuch T, Prilepok M. An ensemble of multi-objective optimized fuzzy regression models for short-term electric load forecasting. In: 2017 IEEE Symposium Series on Computational Intelligence (SSCI) [Internet]. IEEE; 2017. p. 1–7. Available from: <http://ieeexplore.ieee.org/document/8285348/>
14. Chou JS, Tran DS. Forecasting energy consumption time series using machine learning techniques based on usage patterns of residential householders. *Energy [Internet]*. 2018 Dec;165:709–26. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0360544218319145>
15. Hussein H. An Optimal Design Methodology of Adaptive Neuro-Fuzzy Inference System for Energy Load Forecasting - Hail city case study (Saudi Arabia). In: *Proceedings of the Fourth International Conference on Engineering & MIS 2018 [Internet]*. New York, NY, USA: ACM; 2018. p. 1–7. Available from: <https://dl.acm.org/doi/10.1145/3234698.3234765>
16. Borja Pozo L. Double Smart Energy Harvesting System for self-powered Industrial IoT. Universidad del País Vasco; 2018.

17. Alhebshi F, Alnabils H, Bensenouci A, Brahimi T. Using artificial intelligence techniques for solar irradiation forecasting: The case of Saudi Arabia. In: Proceedings of the International Conference on Industrial Engineering and Operations Management. 2019. p. 926–7.
18. Fathi S, Srinivasan R. Climate Change Impacts on Campus Buildings Energy Use. In: Proceedings of the 1st ACM International Workshop on Urban Building Energy Sensing, Controls, Big Data Analysis, and Visualization [Internet]. New York, NY, USA: ACM; 2019. p. 112–9. Available from: <https://dl.acm.org/doi/10.1145/3363459.3363540>
19. Grigoraş G, Neagu BC. An Advanced Decision Support Platform in Energy Management to Increase Energy Efficiency for Small and Medium Enterprises. Appl Sci [Internet]. 2020 May 19;10(10):3505. Available from: <https://www.mdpi.com/2076-3417/10/10/3505>
20. Waheed W, Xu Q. Optimal Short Term Power Load Forecasting Algorithm by Using Improved Artificial Intelligence Technique. In: 2020 2nd International Conference on Computer and Information Sciences (ICCIS) [Internet]. IEEE; 2020. p. 1–4. Available from: <https://ieeexplore.ieee.org/document/9257675/>
21. Timur O, Zor K, Çelik Ö, Teke A, İbrikçi T. Application of Statistical and Artificial Intelligence Techniques for Medium-Term Electrical Energy Forecasting: A Case Study for a Regional Hospital. J Sustain Dev Energy, Water Environ Syst [Internet]. 2020 Sep;8(3):520–36. Available from: <http://www.sdewes.org/jsdewes/pid7.0306>
22. Tran DH, Luong DL, Chou JS. Nature-inspired metaheuristic ensemble model for forecasting energy consumption in residential buildings. Energy [Internet]. 2020 Jan;191:116552. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0360544219322479>
23. Cáceres L, Merino JI, Díaz-Díaz N. A Computational Intelligence Approach to Predict Energy Demand Using Random Forest in a Cloudera Cluster. Appl Sci [Internet]. 2021 Sep 17;11(18):8635. Available from: <https://www.mdpi.com/2076-3417/11/18/8635>
24. Rocha HRO, Honorato IH, Fiorotti R, Celeste WC, Silvestre LJ, Silva JAL. An Artificial Intelligence based scheduling algorithm for demand-side energy management in Smart Homes. Appl Energy [Internet]. 2021 Jan;282:116145. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0306261920315555>
25. Rizwan M, Alharbi YR. Artificial Intelligence Based Approach for Short Term Load Forecasting for Selected Feeders at Madina, Saudi Arabia. Int J Electr Electron Eng Telecommun [Internet]. 2021;10(5):300–6. Available from: <http://www.ijeetc.com/index.php?m=content&c=index&a=show&catid=213&id=1534>
26. Mui KW, Wong LT, Satheesan MK, Balachandran A. A Hybrid Simulation Model to Predict the Cooling Energy Consumption for Residential Housing in Hong Kong. Energies [Internet]. 2021 Aug 9;14(16):4850. Available from: <https://www.mdpi.com/1996-1073/14/16/4850>
27. Khan A, Rizwan M. ANN and ANFIS Based Approach for Very Short Term Load Forecasting: A Step Towards Smart Energy Management System. In: 2021 8th International Conference on Signal Processing and Integrated Networks (SPIN) [Internet]. IEEE; 2021. p. 464–8. Available from: <https://ieeexplore.ieee.org/document/9566146/>



28. Hajjaji I, Alami H El, El-Fenni MR, Dahmouni H. Evaluation of Artificial Intelligence Algorithms for Predicting Power Consumption in University Campus Microgrid. In: 2021 International Wireless Communications and Mobile Computing (IWCMC) [Internet]. IEEE; 2021. p. 2121–6. Available from: <https://ieeexplore.ieee.org/document/9498891/>
29. Chen Y, Phelan P. Predicting peak energy demand for an office building using artificial intelligence (ai) approaches. In: American Society of Mechanical Engineers, Power Division (Publication) POWER. 2021.
30. Raju L, K P V, S SAA, V V, V B. Building Energy Management and Conservation using Internet of Things. In: 2022 International Conference on Sustainable Computing and Data Communication Systems (ICSCDS) [Internet]. IEEE; 2022. p. 970–4. Available from: <https://ieeexplore.ieee.org/document/9760907/>
31. Alsaidan I, Rizwan M, Alaraj M. Solar energy forecasting using intelligent techniques: A step towards sustainable power generating system. Malik H, Chaudhary G, Srivastava S, editors. J Intell Fuzzy Syst [Internet]. 2022 Jan 25;42(2):885–96. Available from: <https://www.medra.org/servlet/aliasResolver?alias=iospress&doi=10.3233/JIFS-189757>
32. Sasaki Y, Ueoka M, Uesugi Y, Yorino N, Zoka Y, Bedawy A, et al. A Robust Economic Load Dispatch in Community Microgrid Considering Incentive-based Demand Response. IFAC-PapersOnLine [Internet]. 2022;55(9):389–94. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S2405896322004530>
33. Grimaccia F, Niccolai A, Mussetta M, D'Alessandro G. ISO 50001 Data Driven Methods for Energy Efficiency Analysis of Thermal Power Plants. Appl Sci [Internet]. 2023 Jan 20;13(3):1368. Available from: <https://www.mdpi.com/2076-3417/13/3/1368>
34. Manchalwar AD, Patne NR, Vardhan BVS, Khedkar M. Peer-to-peer energy trading in a distribution network considering the impact of short-term load forecasting. Electr Eng [Internet]. 2023 Aug 19;105(4):2069–81. Available from: <https://link.springer.com/10.1007/s00202-023-01793-8>
35. Selvaraj R, Kuthadi VM, Baskar S. Smart building energy management and monitoring system based on artificial intelligence in smart city. Sustain Energy Technol Assessments. 2023;56.
36. Millo F, Rolando L, Tresca L, Pulvirenti L. Development of a neural network-based energy management system for a plug-in hybrid electric vehicle. Transp Eng [Internet]. 2023 Mar;11:100156. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S2666691X22000549>
37. Kim G, Lee G, An S, Lee J. Forecasting future electric power consumption in Busan New Port using a deep learning model. Asian J Shipp Logist [Internet]. 2023 Jun;39(2):78–93. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S2092521223000184>
38. El Bakali S, Ouadi H, Gheouany S. Solar Radiation Forecasting Using Artificial Intelligence Techniques for Energy Management System. In: Lecture Notes in Networks and Systems [Internet]. 2023. p. 408–21. Available from: https://link.springer.com/10.1007/978-3-031-35245-4_38
39. Li F, Wan Z, Koch T, Zan G, Li M, Zheng Z, et al. Improving the accuracy of multi-step prediction of building energy consumption based on EEMD-PSO-Informer and long-time series. Comput Electr Eng. 2023;110.
40. Martinez SB. Energy management systems for smart homes and local energy communities based on optimization and artificial intelligence techniques. Universidad Politécnica de Cataluña; 2023.





41. Mohamed K, Elnaz Y, Elaheh Y, Mehdi Zareian J. The Role of Mechanical Energy Storage Systems Based on Artificial Intelligence Techniques in Future Sustainable Energy Systems. *Int J Electr Eng Sustain* [Internet]. 2023;1:22. Available from: <https://ijees.org/index.php/ijees/index>
42. El Abbadi N, El Youbi MS. ENHANCING WIND ENERGY FORECASTING THROUGH THE APPLICATION OF ARTIFICIAL INTELLIGENCE TECHNIQUES: A COMPREHENSIVE STUDY. *Int J Tech Phys Probl Eng*. 2023;15(3).
43. Abdul Baseer M, Almunif A, Alsaduni I, Tazeen N. Electrical Power Generation Forecasting from Renewable Energy Systems Using Artificial Intelligence Techniques. *Energies*. 2023;16(18).
44. Sadeghian Broujeny R, Ben Ayed S, Matalah M. Energy Consumption Forecasting in a University Office by Artificial Intelligence Techniques: An Analysis of the Exogenous Data Effect on the Modeling. *Energies*. 2023;16(10).
45. Abdulwahid AH. Artificial Intelligence-based Control Techniques for HVDC Systems. Vol. 7, *Emerging Science Journal*. 2023.
46. Harrou F, Sun Y, Taghezouit B, Dairi A. Artificial Intelligence Techniques for Solar Irradiance and PV Modeling and Forecasting. Vol. 16, *Energies*. 2023.
47. Zhao M. Modernized Power System Optimal Operation & Safety Protection through Mathematical and Artificial Intelligence Techniques. University of Pittsburgh; 2023.
48. Fiorotti R, Rocha HRO, Coutinho CR, Rueda-Medina AC, Nardoto AF, Fardin JF. A novel strategy for simultaneous active/reactive power design and management using artificial intelligence techniques. *Energy Convers Manag*. 2023;294.
49. Versaci M, La Foresta F. Fuzzy Approach for Managing Renewable Energy Flows for DC-Microgrid with Composite PV-WT Generators and Energy Storage System. *Energies*. 2024;17(2).
50. Zahraoui Y, Korotko T, Mekhilef S, Rosin A. ANN-LSTM Based Tool for Photovoltaic Power Forecasting. In: 4th International Conference on Smart Grid and Renewable Energy, SGRE 2024 - Proceedings. 2024.