

Applications of Machine Learning Techniques in Improving Industrial Energy Efficiency: A Systematic Literature Review

Rojas Mauricio Emmy de Fátima¹ , Reyes Calderon Santos Yoel¹ , Mansilla Alza, Óscar Rafael¹ 

¹Universidad Tecnológica del Perú, Perú, U20213107@utp.edu.pe, U18200777@utp.edu.pe, omansilla@utp.edu.pe

Abstract— This systematic literature review compiles and analyzes the main research developments, emerging approaches, and trend lines related to the use of Machine Learning techniques aimed at improving energy efficiency in industrial settings. Using the PRISMA and PICO methodologies, 42 selected studies are evaluated based on inclusion criteria such as recency, thematic relevance, and practical application. The results show that Machine Learning techniques—such as neural networks, decision trees, and hybrid models—have been primarily used for energy consumption prediction, anomaly detection, and industrial process optimization. However, a fragmentation of knowledge is evident, with a predominance of studies conducted in simulated environments and a lack of validation in real-world scenarios. Limitations in the interoperability and scalability of the implemented models

are also identified. In this regard, this review proposes a unified conceptual framework to guide future research and integrated industrial applications, promoting intelligent and sustainable energy management aligned with green manufacturing and green information technologies. The findings support the potential of Machine Learning as a key tool in the digital transformation of the industrial sector toward greater energy efficiency and emissions reduction.

Keywords — Machine Learning, Energy consumption, Data analysis, Industrial sustainability, Energy optimization

Aplicaciones de técnicas de Machine Learning en la mejora de la eficiencia energética industrial. Una Revisión Sistemática de la Literatura

Rojas Mauricio Emmy de Fátima¹ , Reyes Calderon Santos Yoel¹ , Mansilla Alza, Óscar Rafael¹ 
¹Universidad Tecnológica del Perú, Perú, U20213107@utp.edu.pe, U18200777@utp.edu.pe, omansilla@utp.edu.pe

Resumen– La presente revisión sistemática de la literatura recopila y analiza los principales desarrollos investigativos, enfoques emergentes y líneas de tendencia vinculadas con el uso de técnicas de Machine Learning orientadas a mejorar la eficiencia energética en entornos industriales. A través del uso de las metodologías PRISMA y PICO, se evaluarán 42 estudios seleccionados, mediante criterios de inclusión como actualidad, relevancia temática y aplicación práctica. Los resultados demostraron que las técnicas de Machine Learning como redes neuronales, árboles de decisión y modelos híbridos, han sido empleadas principalmente para la predicción del consumo energético, la detección de anomalías y la optimización de procesos industrial. Sin embargo, se evidencia una fragmentación del conocimiento, con predominancia de estudios en entornos simulados y falta de validación en escenarios reales. También se identificarán limitaciones en la interoperabilidad y escalabilidad de los modelos implementados. En ese sentido, esta revisión propone un marco conceptual unificado que permita orientar investigaciones futuras y aplicaciones industriales integradas, promoviendo una gestión energética inteligente, sostenible y alineada con los principios de manufactura verde y tecnologías de información verde. Los hallazgos respaldan el potencial del Machine Learning como herramienta clave para la transformación digital del sector industrial hacia una mayor eficiencia energética y reducción de emisiones.

Palabras clave– Machine Learning, Energy consumption, Data analysis, Industrial sustainability, Energy optimization.

I. INTRODUCCIÓN

El creciente consumo de energía en la industria manufacturera a nivel mundial ha generado una creciente preocupación por el impacto ambiental y económico que esto representa. La industria manufacturera ocupa un lugar destacado entre los sectores con mayor demanda de energía, lo que ha impulsado la necesidad de implementar estrategias de eficiencia energética que permitan reducir gastos operativos y reducir la liberación de gases contaminantes a la atmósfera.

Bajo este contexto, las soluciones basadas en tecnologías digitales y la manufactura verde han cobrado relevancia, al buscar soluciones sostenibles y tecnológicamente avanzadas que contribuyan a una huella ecológica reducida. Particularmente, las técnicas de Machine Learning (ML) han emergido como herramientas clave para enfrentar estos desafíos. A lo largo de los años, diversos estudios han empleado modelos de ingeniería, estadísticos y de aprendizaje automático para predecir y optimizar el consumo de energía basándose en datos históricos [1][2]. Sin embargo, estos estudios tienden a centrarse en aplicaciones específicas o en el desarrollo de metodologías particulares, sin lograr integrar de manera holística los diferentes enfoques disponibles [2].

El uso de ML en la industria no solo permite mejorar la predicción del consumo energético, sino también detectar anomalías, realizar mantenimiento predictivo y

optimizar el funcionamiento de sistemas energéticos complejos. A pesar de los avances, persisten retos significativos en la interoperabilidad de los modelos, la estandarización de metodologías y su aplicación a gran escala en entornos industriales reales.

A pesar de los avances tecnológicos y del creciente interés en la eficiencia energética dentro del sector industrial, existe un vacío significativo en la literatura científica en cuanto a técnicas para mejorar dicha eficiencia. Las investigaciones actuales presentan enfoques diversos y fragmentados, con métricas que varían según el tipo de industria, la tecnología aplicada o el objetivo de análisis. Esta falta de estandarización dificulta la comparación entre estudios, la validación de resultados y la aplicación práctica de modelos de mejora energética. En consecuencia, no se cuenta con un marco común que oriente a investigadores y profesionales hacia una evaluación consistente y útil de la eficiencia energética en entornos industriales [3].

Una revisión sistemática que integre los enfoques actuales sobre el uso de Machine Learning en la eficiencia energética industrial es fundamental para avanzar hacia sistemas de gestión más adaptativos, sostenibles y en tiempo real. Este análisis permitirá consolidar el conocimiento existente, identificar brechas relevantes y proponer direcciones futuras para una implementación más efectiva. Además, contribuirá a fortalecer prácticas de manufactura verde y tecnologías de información verde, en alineación con las metas internacionales de desarrollo sostenible y control de emisiones contaminantes.

La eficiencia energética industrial ha cobrado una importancia creciente debido al impacto ambiental y económico asociado al consumo excesivo de energía. Sin embargo, aún existe una dispersión en la información sobre su aplicación y efectividad en relación con los métodos tradicionales. Para abordar este problema, se busca responder la siguiente pregunta: ¿Qué técnicas de Machine Learning se han aplicado para mejorar la eficiencia energética en contextos industriales y qué nivel de eficacia han demostrado en comparación con otros métodos tradicionales de optimización energética?, para ello se planteó como objetivo analizar las aplicaciones de técnicas de Machine Learning en la mejora de la eficiencia energética industrial a mediante una revisión sistemática de la literatura.

II. METODOLOGÍA

A. ESTRATEGIA DE BÚSQUEDA SISTEMÁTICA

Para el desarrollo este estudio, se efectuó una Revisión Sistemática de la Literatura (RSL) con el objetivo de obtener una recopilación exhaustiva de los documentos científicos relevantes. Para ello, se utilizó la estrategia PICO, la cual permite formular preguntas de investigación claras y estructuradas, facilitando la identificación y selección de literatura especializada en el tema.

La pregunta de investigación principal (RQ) fue: ¿De qué manera las técnicas de Machine Learning se han aplicado para mejorar la eficiencia energética en contextos industriales y qué desafíos se han identificado en su implementación?

A partir de esta pregunta, se desglosaron las siguientes preguntas secundarias:

- RQ1: ¿Cómo se ha definido y medido la eficiencia energética en entornos industriales?
- RQ2: ¿Qué técnicas de Machine Learning se han implementado en el sector industrial para optimizar el consumo energético?
- RQ3: ¿Qué resultados se han reportado respecto a la aplicación de técnicas de Machine Learning para la optimización del consumo energético en entornos industriales?
- RQ4: ¿En qué contextos industriales se han implementado métodos tradicionales de optimización energética, y de qué manera se ha incorporado el Machine Learning en dichos entornos?

Los componentes de la estrategia PIOC utilizados se detallan en la siguiente tabla:

TABLA I.
COMPONENTES DEL PIOC

P (Problema / Población)	I (Intervención)	O (Resultados)	C (Contexto)
Industrial energy efficiency measurement.	Machine learning for energy prediction and optimization.	Improvement in energy efficiency.	Traditional energy optimization methods.
Energy consumption patterns.	ML algorithms for anomaly detection.	Performance outcomes.	Rule- based energy control.
Energy performance indicators.	Data-driven models in industrial settings.	Reduction in energy consumption and cost	Conventional systems in industry.

Para guiar la búsqueda sistemática de literatura, se utilizó la combinación de palabras clave basada en cada componente de la estrategia PICO, como se detalla a continuación en la TABLA II.

TABLA II.
PALABRAS CLAVE POR COMPONENTE PIOC

Componente	Concepto clave	Palabras clave utilizadas
P (Problema)	Eficiencia energética industrial	"industrial energy efficiency", "energy consumption", "energy performance"
I (Intervención)	Técnicas de Machine Learning	"machine learning", "ML-algorithms", "data-driven models"
O (Resultados)	Resultados en eficiencia energética	"energy savings", "efficiency improvement", "performance metrics"
C (Contexto)	Métodos tradicionales de optimización energética	"optimization", "energy optimization", "rule-based systems"

La ecuación de búsqueda fue la siguiente:

("industrial energy efficiency" OR "energy consumption" OR "energy performance") AND ("machine learning" OR "ML- algorithms" OR "data-driven models") AND ("optimization" OR "energy optimization" OR "rule-based systems") AND ("energy savings" OR "efficiency improvement" OR "performance metrics")

B. PROCESOS DE SELECCIÓN DE ESTUDIOS

La exploración de literatura se llevó a cabo utilizando las bases de datos Scopus, donde se identificaron 241 artículos.

Se aplicaron los siguientes criterios de inclusión (CI):

- CI1: Estudios centrados en el uso de Machine Learning en eficiencia energética.
- CI2: Investigaciones aplicadas al entorno industrial o con aplicación directa en entornos productivos.
- CI3: Artículos que presenten resultados medibles de mejora energética.

Criterios de exclusión (CE):

- CE1: Estudios fuera del ámbito industrial.
- CE2: Publicaciones anteriores al año 2019.
- CE3: Publicaciones en idiomas distintos al español o inglés.
- CE4: Documentos que no correspondan a "artículo".

Con el fin de lograr resultados alineados con el tema de estudio, esta investigación se fundamentó en la versión más reciente y en español de la declaración PRISMA (Preferred Reporting Items for Systematic reviews and Meta-Analysis), la cual sirve como una herramienta que simplifica la identificación, selección, evaluación y síntesis de la literatura pertinente al área investigada [7].

Para recopilar la información necesaria para la revisión sistemática, se realizaron consultas en bases de datos reconocidas por su fiabilidad y calidad, como Scopus. Se emplearon palabras clave relevantes como "machine learning", "energy optimization" y "traditional optimization

methods", combinadas mediante operadores booleanos (por ejemplo, AND, OR) con el fin de optimizar la búsqueda y generar diversas cadenas de consulta en los artículos científicos.

En relación con los criterios de inclusión, se estableció un rango temporal para los artículos científicos, abarcando desde 2020 hasta 2025. Se aceptaron trabajos tanto en español como en inglés que fueran de acceso abierto. Asimismo, se consideraron aquellos documentos cuyas palabras clave estuvieran estrechamente relacionadas con el tema de estudio, incluso si no coincidían de manera exacta.

Por otro lado, se excluyeron los estudios publicados fuera del rango temporal establecido, aquellos que no cumplían con estándares académicos mínimos o que no estaban disponibles en texto completo para su evaluación.

Como resultado de la aplicación rigurosa de estos criterios, se seleccionaron un total de 42 artículos científicos para su análisis dentro del marco de esta revisión sistemática.

En la Fig. 1, se presenta un resumen claro de la metodología PRISMA empleada. Es por ello, que se consiguió una alineación precisa entre los objetivos planteados y los estudios escogidos.




Fig. 1 Diagrama de flujo PRISMA en 4 niveles

III. RESULTADOS


En esta sección se exponen los principales hallazgos derivados del análisis bibliométrico y del contenido temático de los 42 artículos científicos seleccionados en la revisión sistemática. Estos resultados permiten identificar de manera estructurada las tendencias temporales de publicación, la procedencia geográfica de las investigaciones, así como las principales aplicaciones, beneficios y limitaciones reportadas en el uso de técnicas de Machine Learning orientadas a la mejora de la eficiencia energética en entornos industriales.

A. Resultados bibliométricos de la revisión sistemática

En la Fig. 2 se presenta la distribución porcentual de los artículos según su año de publicación. Se observa que 2025 y 2024 concentran la mayor parte de la producción, con el 17 y el 16 respectivamente. A continuación, el año 2023 aporta un 5, mientras que 2022 registra un 4 del conjunto de

estudios seleccionados. Este comportamiento sugiere un incremento en la actividad investigadora en los dos años más recientes, concentrando casi cuatro de cada cinco trabajos analizados.

Fig. 2 Distribución de la literatura seleccionada según el año de publicación.



En la Fig. 3 se muestra la procedencia geográfica de los estudios seleccionados. Más de la mitad (54 %) de las publicaciones provienen de Asia, destacando China con un 36 %, seguida de India con un 14 %, y pequeñas contribuciones de Turquía y Catar con un 2 % cada uno. Europa aporta un 24 % del total, repartido entre Reino Unido (10 %), Canadá, España y Estados Unidos (5 %), y Finlandia, Francia y Grecia (2 %). Por su parte, América Latina y África quedan marginalmente representadas con Brasil y Australia (2 %) y Sudáfrica (2 %). Estos datos ponen de manifiesto el protagonismo de Asia y Europa en el desarrollo de soluciones basadas en Machine Learning para optimizar la eficiencia energética en entornos industriales.




Fig. 3 Distribución de la literatura seleccionada según el país de origen

En la Tabla III se presentan los principales artículos incluidos en esta revisión sistemática, junto con su correspondiente clasificación cuartil según de Scopus. La mayoría de los estudios provienen de revistas Q1, lo cual refleja un alto nivel de rigurosidad académica. Además, se identificaron clasificados como Q2 y Q3, lo que complementa la diversidad de fuentes sin comprometer la calidad científica general del análisis.

TABLA III
REVISTAS DE ALTO IMPACTO IDENTIFICADAS EN LA REVISIÓN
SISTEMÁTICA SOBRE LA EFICIENCIA ENERGÉTICA INDUSTRIAL

Fuente	Cuartil
International Journal of Control, Automation and Systems	Q1
Applied Thermal Engineering	Q1
Journal of Food Engineering	Q1
Energy	Q1
Case Studies in Thermal Engineering	Q1
Thermal Science and Engineering Progress	Q1
Chemical Engineering and Processing - Process Intensification	Q1
Transportation Research Part E: Logistics and Transportation Review	Q1
Applied Energy	Q1
EAI Endorsed Transactions on Energy Web	Q1
Journal of Supercomputing	Q1
Electronics	Q1
Energy and Buildings	Q2
Processes	Q2
Building Simulation	Q2
Energies	Q2
Sustainability	Q2
Building and Environment	Q2
Simulation Modelling Practice and Theory	Q2
Reaction Chemistry and Engineering	Q2
Decision Science Letters	Q2
Journal of Manufacturing Systems	Q2
IEEE Transactions on Consumer Electronics	Q2
Thermal Science and Engineering Progress	Q3
Building and Environment	Q3
Journal of Asian Architecture and Building Engineering	Q3
Frontiers in Artificial Intelligence	Q3
Results in Engineering	Q3
Journal of Electrical Engineering and Technology	Q3

B. Resultados de contenido de la revisión sistemática

La Figura 4 muestra la distribución de los porcentajes de eficiencia energética reportados en los estudios seleccionados antes de la implementación de algoritmos de Machine Learning. Esta curva representa la línea base tradicional, donde los valores registrados varían entre un mínimo cercano al 30 % [9],[21], [22], [47], [48] y un máximo del 98 % [19], [20], [34], [46]. El gráfico evidencia una dispersión considerable entre los artículos, lo que indica diferencias en los métodos empleados y los contextos de aplicación.




Fig. 4 Eficiencia energética base con métodos tradicionales

RQ1: ¿Cómo se ha definido y medido la eficiencia energética en entornos industriales?

Diversos estudios identificados aplican múltiples indicadores para evaluar la eficiencia energética en entornos industriales, mostrando una amplia diversidad metodológica. El consumo total de energía [8], [15], [21], [23], [25], [27], [30], [33], [34], [38], [42], [46-49] aparece como métrica principal al cuantificar el impacto energético global de los procesos. Adicionalmente, algunos trabajos incorporan la reducción porcentual del consumo energético [9], [10], [24] [28] como medida complementaria. El indicador energy savings [13], [20], [32], [36], [39], [43-45] traduce las mejoras energéticas en beneficios económicos directos. Para procesos térmicos, se utilizan métricas como el coeficiente de rendimiento (COP) [13], [14] y el power usage effectiveness (PUE) [29], evaluando la eficiencia de conversión energética. Asimismo, el energy use intensity (EUI) [22], [37] permite una evaluación normalizada del consumo respecto a la producción. Otros indicadores específicos, como heating load, wire to water efficiency, specific energy Consumption y peak to average ratio [23], ofrecen un análisis más detallado de los distintos aspectos operativos. En el ámbito ambiental, las emisiones de CO₂ [30], [32] son consideradas en varios estudios como medida del impacto ambiental asociado al consumo energético. Finalmente, el overall energy equipment effectiveness (OEE) [18] surge como un indicador integral que contempla disponibilidad, rendimiento y calidad operativa de los equipos, ver Fig.5.




Fig. 5. Indicadores de eficiencia energética en entornos industriales

Respecto a los principales factores que afectan la eficiencia energética, ordenados por su frecuencia en la literatura analizada. Las condiciones y modos de operación [9], [10], [17-19], [21], [23], [25], [34], [35], [39], [40], [43], [47-49] resultan ser el factor predominante, subrayando la importancia de la gestión operativa sobre el desempeño energético. En segundo lugar, las condiciones ambientales [8], [12-15], [26], [29-31], [33], [36], [37], [44], [45] destacan por su influencia directa en los sistemas térmicos y de climatización. La carga térmica y demanda de producción

[20], [22], [24], [38], [46] también se identifican como factores determinantes, junto a las características y eficiencia del equipo [11], [16], [32], [41], donde aspectos tecnológicos y de mantenimiento impactan el consumo energético. Finalmente, factores como el diseño del sistema [27], [28] y el mantenimiento preventivo [42], aunque menos estudiados, representan áreas críticas para la mejora continua de la eficiencia, ver Fig. 6.




Fig. 6. Factores que determinan el rendimiento energético en entornos industriales

RQ2: ¿Qué técnicas de Machine Learning se han implementado en el sector industrial para optimizar el consumo energético?

En relación con las técnicas de machine learning aplicadas a la optimización energética, se ha clasificado su uso según la frecuencia reportada en la literatura. En el cuartil Q1 —correspondiente a las metodologías más empleadas— destacan las redes neuronales [9], [10], [14–16], [18], [19], [22], [25], [32], [33], [35–37], [40], [41], [45], seguidas por los árboles de decisión y métodos de ensamblado [8], [11], [13], [17], [20], [21], [24], [31], [34], [38], [39], [42–44], [48], valoradas por su capacidad de interpretar relaciones no lineales y adaptarse a datos heterogéneos. En el cuartil Q2, que representa un uso moderado, se ubican las técnicas SVM/SVR [26], [30], [47] y el deep learning general [23], [27–29]. Estas metodologías son reconocidas por su eficacia en problemas de clasificación y modelado de alta dimensionalidad. Finalmente, en el cuartil Q3, correspondiente a técnicas de menor frecuencia, se encuentran los modelos estadísticos/regresión [12], [46], y las metaheurísticas (PSO, GA, etc.) [49]. Aunque su uso es limitado, estas técnicas aún conservan valor en contextos específicos de modelado o búsqueda de soluciones óptimas, tal como se puede observar en la Fig. 7.




Fig. 7. Frecuencia en la aplicación de algoritmos de machine learning

En relación con el impacto de los diferentes tipos de algoritmos en la eficiencia energética, los árboles de decisión y métodos de ensamblado presentan el mayor incremento de rendimiento frente a los enfoques tradicionales, con una mejora del 13.76 % [8], [11], [13], [17], [20], [21]. Les siguen las técnicas de deep learning (13 %) [23], [27] y SVM/SVR (10.81 %) [26], [30], reconocidas por su capacidad para modelar relaciones no lineales complejas y adaptarse a entornos industriales con alta variabilidad. En un nivel ligeramente inferior, los modelos estadísticos alcanzan una mejora del 10.50 % [12], [46], mientras que las redes neuronales (NN) [9], [10], [14–16], [18], [19] reportan un aumento del 9.05 %. Aunque estas técnicas son ampliamente utilizadas, su efectividad puede depender de factores como la calidad de los datos, la arquitectura del modelo y el grado de entrenamiento aplicado. Finalmente, las metaheurísticas como PSO y GA muestran la menor ganancia relativa (2.3 %) [49], posicionándose entre los algoritmos de menor impacto cuando se emplean de forma aislada. Sin embargo, continúan siendo valiosas en problemas de optimización compleja o cuando se integran en enfoques híbridos, como se aprecia en la Fig. 8.




Fig. 8. Comparativa de eficiencia energética entre algoritmos de Machine Learning y enfoques tradicionales por tipo de técnica

Respecto al ciclo energético industrial, la fig. 9 revela que la mayor proporción de estudios aplica machine learning en la etapa de predicción (62%), evidenciando su utilidad para anticipar consumo y demanda. La optimización representa un 26%, orientada a mejorar configuraciones operativas, mientras que el control inteligente alcanza un 12%, mostrando un campo emergente para fortalecer la gestión en tiempo real de sistemas energéticos industriales. (ver fig 9)




Fig 9. Distribución del uso de ML en el ciclo energético industrial

RQ3: ¿Qué resultados se han reportado respecto a la aplicación de técnicas de Machine Learning para la optimización del consumo energético?

Con relación a los beneficios obtenidos tras la implementación de técnicas de machine learning en contextos industriales, expresados en función del número de artículos que los reportan. Se observa que el beneficio más reportado corresponde a la toma de decisiones más inteligente [8], [10-12], [14], [15], [18], [19], [21], [23], [24], [31-33], [37], [45], representando la categoría de mayor presencia en los estudios analizados. Le siguen la automatización de procesos operativos [16], [28], [33], [35], [39], [42-45], la adaptabilidad a condiciones cambiantes [17], [27], [28], [36], [41], [44], [47], [49], y la reducción del consumo energético [9], [16], [22], [26], [38], [39], [43]. Beneficios como la mejora de la resiliencia operativa, reducción de errores humanos y optimización de mantenimiento predictivo fueron mencionados con menor frecuencia, destacando su carácter complementario dentro del conjunto de investigaciones revisadas, tal como se observa en la Fig.10.



Fig. 10. Beneficios cualitativos tras la implementación de técnicas de Machine Learning

Desde la perspectiva de los obstáculos metodológicos en los estudios analizados sobre la aplicación de técnicas de machine learning en la eficiencia energética industrial. Una proporción significativa de los artículos revisados evidencia que la problemática más frecuente corresponde a los aspectos relacionados con la calidad, cantidad y variabilidad de los datos utilizados [8], [11-16], [18], [19], [22], [23], [26], [29], [31], [33], [36], [38], [42], [44], [45], lo que representa un desafío crítico en el desarrollo de modelos robustos y generalizables. Por otro lado, se identificaron limitaciones asociadas al alto coste computacional y la complejidad algorítmica [9], [10], [25], [27], [30], [41], [47], así como problemas de estabilidad en los algoritmos de optimización [28], [49]. Otros estudios resaltan dificultades relacionadas con el sobreajuste, la incertidumbre en las predicciones, la latencia operativa, las barreras de implementación y la limitada escalabilidad de los modelos. La variedad de desafíos evidencia la necesidad de seguir perfeccionando tanto la calidad de los datos como los enfoques metodológicos empleados, como se puede observar en la Fig.11.



Fig.11. Limitaciones presentadas en la aplicación del machine learning para la eficiencia energética industrial

RQ4: ¿En qué contextos industriales se han implementado métodos tradicionales de optimización energética, y de qué manera se ha incorporado el ML?

En lo referente a los enfoques tradicionales utilizados previamente en la industria energética. El control manual o

ajustes operativos realizados por personal técnico, mencionado en estudios como [8], [13], [24], [25], [39], [42], fue el enfoque más recurrente, con presencia en nueve investigaciones, lo que denota su uso extendido a pesar de su carácter no automatizado. Por otro lado, el uso de modelos estadísticos clásicos, como la regresión y el análisis de datos, fue reportado en los artículos [11], [15-18], [26], [31], [33-35], permitiendo estimaciones y predicciones sobre el comportamiento energético bajo condiciones conocidas. Asimismo, la simulación computacional, presente en [20],[21], [30], [37], [45], emergió como una herramienta relevante para evaluar escenarios energéticos mediante modelos virtuales. Los modelos físicos o de caja blanca, como los observados en [9],[12], fueron aplicados para representar con precisión los procesos físicos. En menor proporción, se reportaron enfoques como los modelos empíricos [10],[19], el control por reglas predefinidas [14],[23], y técnicas de programación matemática [28],[40], utilizadas para resolver problemas específicos de optimización. Finalmente, el uso de controladores clásicos como los PLC, mencionado en [36], evidencia la persistencia de sistemas convencionales en la gestión energética industrial, como se puede apreciar en la Fig.12.




Fig 12. Enfoques tradicionales aplicados en la industria energética

La Fig.13 analiza la integración de machine learning con metodologías tradicionales. Los modelos híbridos son los más representados (45%), combinando capacidades predictivas y modelos físicos o estadísticos. Le siguen la optimización dinámica (29%) y el control inteligente (26%), mostrando el avance hacia sistemas de gestión energética autónomos y adaptativos.




Fig 13. Aplicación de machine learning en la gestión energética tradicional

El análisis de los artículos seleccionados revela una mejora generalizada en la eficiencia energética al emplear algoritmos de machine learning frente a los enfoques tradicionales. En particular, en los artículos [11], [13], [25], [27], [33], [35] y [39], se observan niveles de eficiencia superiores al 90 % con modelos optimizados, lo que evidencia el alto potencial del aprendizaje automático para mejorar el rendimiento en aplicaciones energéticas. Sin embargo, también se identifican casos puntuales [8], [10], [26], [36] y [48] donde los métodos tradicionales superan a los modelos de ML. Estos resultados sugieren que la efectividad del aprendizaje automático no es universal, y puede depender de factores como la disponibilidad de datos, el tipo de sistema modelado o la configuración de los algoritmos. A pesar de estas variaciones, la tendencia general muestra que el uso de técnicas de ML contribuye de forma significativa a mejorar la eficiencia energética, consolidándose como una herramienta clave en procesos industriales modernos, como se puede ver en la Fig.14.




Fig. 14 Desempeño energético entre modelos tradicionales vs modelos optimizados con Machine Learning

IV. DISCUSIÓN

Los hallazgos obtenidos a partir del análisis de los estudios seleccionados permiten sostener que, la aplicación de algoritmos de Machine Learning (ML) contribuye significativamente a la mejora de la eficiencia energética en contextos industriales. Este constituye el principal hallazgo de esta Revisión Sistemática de la Literatura, y se sustenta empíricamente en los artículos [11], [27] y [39], los cuales reportan niveles de eficiencia energética superiores al 90 % mediante la implementación de modelos de ML optimizados. Dichos valores reflejan la capacidad de estas técnicas para modelar relaciones no lineales complejas, adaptarse a condiciones operativas variables y generar respuestas más eficientes en comparación con enfoques tradicionales [8] y [20]. No obstante, también se identificaron casos en los que la mejora obtenida fue marginal. En los estudios [22] y [47], los modelos de ML no lograron superar significativamente a los enfoques tradicionales, evidenciando reducciones de eficiencia energética poco representativas. Esta limitada mejora sugiere que la eficacia de aprendizaje automático no es un uniforme y puede verse condicionada por diversos factores contextuales tales como, la calidad, la disponibilidad de los datos, la complejidad del sistema modelado o una calibración insuficiente en los hiperparámetros del algoritmo [49].

Dentro de los enfoques analizados, se observó a las redes neuronales y métodos de ensamblado como principales técnicas empleadas para la predicción y optimización

energética en contextos industriales. Esta preferencia refleja su capacidad para modelar relaciones no lineales complejas, lo que las hace particularmente efectivas ante la heterogeneidad de datos industriales. Este resultado coincide con la revisión realizada en el sector químico [9], pero difiere de lo reportado por [13] y [42] donde se encontró un mayor uso de regresión y árboles de decisión. La divergencia puede explicarse por la evolución reciente en las herramientas de aprendizaje profundo y por el creciente acceso a mayor capacidad computacional. Respecto a la evaluación comparativa de eficiencia entre tipos de algoritmos, se evidenciaron que los árboles de decisión y los métodos de ensamblado representan las técnicas con mayor impacto en la mejora de la eficiencia energética, alcanzando un incremento promedio del 13.76 % respecto a los enfoques tradicionales [8], [13], [17]. Este hallazgo refuerza lo reportado por [20], donde se resalta la solidez de los métodos de ensamblado en entornos con datos incompletos o ruidosos, reforzando su aplicabilidad en escenarios de producción reales. Posteriormente, se posicionan las técnicas de deep learning (13 %) [28] y [29] y los algoritmos basados en máquinas de vectores de soporte (SVM/SVR) (10.81 %) [26], los cuales han demostrado ser especialmente efectivos en la modelación de relaciones no lineales complejas y en la gestión simultánea de múltiples variables. Esta capacidad ha sido ampliamente documentada en la literatura como una ventaja crítica en sectores donde las interacciones entre variables energéticas no responden a patrones lineales predecibles [47]. Por el contrario, los modelos estadísticos clásicos y las redes neuronales artificiales presentan mejoras más discretas (10.50 % y 9.05 %, respectivamente) [9], [10], [15], esta menor efectividad relativa podría estar relacionada con su dependencia de supuestos más restrictivos, y una sensibilidad elevada a la calidad de datos de entrenamiento, lo que limita su capacidad de generalización en entornos con alta variabilidad operativa. Finalmente, las técnicas metaheurísticas, como el Particle Swarm Optimization (PSO) y los algoritmos genéticos (GA) reportaron el menor impacto relativo (2.3 %) [49], aunque su rendimiento directo en términos de eficiencia energética, es limitado cuando se emplean de forma aislada, su valor persiste en escenarios de optimización compleja. Tal como lo plantea [17], estas técnicas resultan útiles en la calibración de parámetros y en la exploración de espacios de solución donde los modelos tradicionales presentan restricciones funcionales.

Otro hallazgo significativo es la amplia diversidad de métricas: consumo total, reducción porcentual, energy savings, COP, PUE, EUI y OEE, entre otras. Coincidimos con los hallazgos presentados en [13], [21] [29], donde el consumo total y el COP figuran como métricas centrales; sin embargo, [22] prioriza el uso de métricas normalizadas como el EUI, lo cual apunta hacia un enfoque más comparativo entre distintas escalas de planta. La aparición del OEE en nuestra RSL destaca un enfoque más integral que vincula la eficiencia energética con la productividad operativa, ampliando así el alcance del análisis más allá del consumo. En cuanto a los factores que determinan el rendimiento energético, se identificó como más recurrente el análisis de los modos de operación y condiciones ambientales, lo que coincide con lo reportado por [9], [10], [17] en su estudio sobre optimización térmica en procesos de coquización. No obstante, [13] y [22] atribuye

mayor peso a la carga térmica, lo que indica un enfoque más centrado en el diseño del sistema que en su uso operativo.

Casi la mitad de los estudios analiza modelos híbridos, lo que refleja una tendencia hacia soluciones más robustas y adaptables. Esto coincide con aplicaciones en granjas de datos descritas por [17], [19], [22] no obstante, se contradice con lo reportado por [39], donde se sugiere que los modelos puramente estadísticos aún pueden superar a los híbridos en precisión bajo condiciones de datos limitados; nuestros resultados muestran que la combinación de ML y modelos físicos mejora la adaptabilidad, aunque incrementa la complejidad computacional. Respecto a los principales desafíos identificados, destaca como la barrera más citada la calidad, cantidad y variabilidad de los datos utilizados. Este patrón coincide con lo reportado por [13] y [19] en el contexto de manufactura avanzada. Pese a que, algunos estudios como [25] y [47] se enfocaban mayormente en el sobreajuste, nuestra revisión revelaron una problemática más amplia, que incluye además el elevado coste computacional, la complejidad algorítmica y la inestabilidad en los procesos de optimización. Estos factores afectaron directamente la robustez y reproducibilidad de los modelos propuestos, limitando así su implementación a gran escala.

A la luz de estos hallazgos, se sugiere como línea de investigación futura el establecimiento de protocolos estandarizados para la recolección y validación de datos industriales, así como el desarrollo de algoritmos más ligeros y eficientes que mantengan un equilibrio entre precisión y viabilidad operativa. Asimismo, urge fortalecer las pruebas en entornos reales, dado que muchos trabajos analizados se desarrollan en contextos simulados, lo cual introduce incertidumbre sobre su aplicabilidad práctica.

En conjunto, nuestros resultados responden a las preguntas planteadas inicialmente sobre las técnicas más utilizadas, los indicadores predominantes y las condiciones que influyen en el desempeño energético, y muestran la creciente complejidad en la implementación de soluciones basadas en ML en la industria. Esta revisión no solo sistematiza el conocimiento actual, sino que también revela vacíos críticos que deben abordarse para avanzar hacia una eficiencia energética más inteligente, sostenible y aplicable en entornos industriales reales.

V. CONCLUSIONES

El objetivo de esta revisión sistemática fue analizar cómo se han aplicado las técnicas de Machine Learning (ML) para mejorar la eficiencia energética en contextos industriales y qué desafíos se han identificado en su implementación. A partir del análisis de 42 artículos, se identificó que la aplicación de algoritmos de Machine Learning contribuye significativamente a la mejora de la eficiencia energética en entornos industriales, con reportes de eficiencia superiores al 90 % en modelos optimizados. Las técnicas más empleadas fueron redes neuronales, árboles de decisión y métodos de ensamblado, destacando estos últimos por presentar el mayor incremento promedio (13.76 %) respecto a los enfoques tradicionales, seguidos por técnicas de deep learning (13 %) y máquinas de vectores de soporte (10.81 %). En contraste, los modelos estadísticos y las redes neuronales artificiales mostraron mejoras más discretas (entre 9 % y 10.5 %), mientras que las metaheurísticas obtuvieron el impacto más

bajo (2.3 %), aunque con utilidad comprobada en contextos de optimización híbrida. Nuestros hallazgos indican una clara preferencia por técnicas supervisadas, mientras que los métodos no supervisados permanecen poco explorados, a pesar de su promesa para aplicaciones de control adaptativo en tiempo real.

Respecto a los indicadores utilizados, se observó una notable fragmentación y ausencia de estandarización. Las métricas más recurrentes fueron el consumo total, el Energy Savings, el COP y el PUE, lo que dificultó la comparación entre estudios y la adopción de mejores prácticas en el sector. También se constató que los modos de operación y las condiciones ambientales son los factores más influyentes en el rendimiento energético, con aplicaciones concentradas mayoritariamente en la etapa de predicción, seguidas por optimización y, en menor medida, control inteligente. Si bien se evidencia una tendencia hacia la automatización y la toma de decisiones basada en datos, aún persisten barreras metodológicas importantes, como la variabilidad y calidad de los datos, el alto costo computacional y la dificultad para implementar estos modelos en entornos reales.

En relación con la aplicabilidad práctica las técnicas de ML, especialmente las redes neuronales y los métodos de ensamblado, muestran un alto potencial, su uso está sesgado hacia entornos controlados o simulados. Esta falta de validación en contextos reales limita la generalización de los resultados y su impacto directo en plantas industriales. Además, persisten barreras metodológicas importantes como la calidad, variabilidad de los datos, el alto costo computacional y la complejidad para implementar estos modelos en tiempo real.

Esta revisión sistemática consolidó y estructuró el conocimiento disperso sobre ML aplicado a la eficiencia energética industrial, respondiendo integralmente a las preguntas de investigación planteadas. Al reunir, organizar y comparar enfoques tradicionales y modernos, no solo se aportó al cuerpo de conocimiento actual, sino que también se propone una base conceptual para futuras investigaciones. Como principales recomendaciones se sugiere el desarrollo de marcos estandarizados para evaluar la eficiencia energética, validar los modelos en entornos reales mediante tecnologías como los gemelos digitales, e investigar técnicas emergentes como el aprendizaje por refuerzo y el control adaptativo. No obstante, una limitación de este estudio fue la exclusión de literatura en idiomas distintos al inglés y español, así como la dependencia de una única base de datos científica, lo cual podría restringir el alcance de los hallazgos.

REFERENCIAS

- [1] Cheng S, Yun W., McMurtrey M.D., Jerred N.D., Liou F., Ju L. (2021). A comprehensive review on additive manufacturing applications in the energy sector. *Applied Energy*, 282, Article 116041.
- [2] C. Rodriguez, L. Degioanni, L. Kameni, R. Vidal & G. Neglia, "Evaluating the Energy Consumption of Machine Learning: Systematic Literature Review and Experiments." 2024 arXiv preprint arXiv:2408.15128.
- [3] R.-H. Santiago, G. A. Coca, y O. D. Castrillón, "Programming in a manufacturing system of the 'job shop' type with a focus on sustainability," *Informacion Tecnologica*, vol. 27, no. 6, pp. 31–52, 2016.
- [4] Q. W. Khan, A. N. Khan, B. Misbah, R. Ahmad, and D. H. Kim, "Dynamic energy cost prediction for industrial and commercial buildings using advanced machine learning and multi-pricing models," *J. Build. Eng.*, vol. 103, Art. no. 112055, 2025.
- [5] J. Jeong, S. Park, J. Park, J. Song, and J. Kwak, "Machine-learning-assisted process optimization for high-performance organic thermoelectrics," *Adv. Energy Mater.*, vol. 15, no. 14, Art. no. 2403431, 2025.
- [6] B. Mortazavi, "Recent advances in machine learning-assisted multiscale design of energy materials," *Adv. Energy Mater.*, vol. 15, no. 9, Art. no. 2403876, 2025.
- [7] M. J. Page *et al.*, "The PRISMA 2020 statement: An updated guideline for reporting systematic reviews," *BMJ*, vol. 372, p. n71, Mar. 2021. doi: 10.1136/bmj.n71.
- [8] Y. Bai, D. Sun, L. Liu, Y. Shen, and H. Yao, "Energy-saving optimization of air-conditioning water system based on machine learning and improved bat algorithm," *Energy Build.*, Art. no. 115333, 2025.
- [9] P. Zhao *et al.*, "A machine learning and CFD modeling hybrid approach for predicting real-time heat transfer during cokemaking processes," *Fuel*, Art. no. 132273, 2024.
- [10] J. Du, Y. Wang, and Z. Ji, "Application of a hybrid improved particle swarm algorithm for prediction of cutting energy consumption in CNC machine tools," *Int. J. Precis. Eng. Manuf. - Green Technol.*, 2024.
- [11] Y. Hao and X. Ma, "A hybrid grey system model based on stacked long short-term memory layers and its application in energy consumption forecasting," *Processes*, vol. 12, no. 8, Art. no. 1749, 2024.
- [12] M. Shafiq *et al.*, "Thermal modeling and machine learning for optimizing heat transfer in smart city infrastructure balancing energy efficiency and climate impact," *Therm. Sci. Eng. Prog.*, Art. no. 102868, 2024.
- [13] X. Lefebvre, V. Ashok, D. Claveau-Mallet, E. Robert, and E. Bedard, "Data-driven cooling tower optimization: A comprehensive analysis of energy savings using microsand filtration," *Appl. Therm. Eng.*, vol. 228, 2025.
- [14] J. Lin *et al.*, "Multi-objective cooling control optimization for air-liquid cooled data centers using TCN-BiGRU-Attention-based thermal prediction models," *Build. Simul.*, 2024.
- [15] S. Li, A. Malvandi, H. Feng, and C. Shao, "Uncertainty-aware constrained optimization for air convective drying of thin apple slices using machine-learning-based response surface methodology," *J. Food Eng.*, vol. 360, Art. no. 112503, 2025.
- [16] A. Shahcheraghian and A. Ilinca, "Advanced machine learning techniques for energy consumption analysis and optimization at UBC campus: Correlations with meteorological variables," *Energies*, vol. 17, no. 18, 2024.
- [17] J. Xu *et al.*, "Data based digital twin for operational performance optimization in CFB boilers," *Energy*, vol. 293, 2024.
- [18] K. Yılmaz, İ. Ö. Aksu, M. Göçken, and T. Demirdelen, "Sustainable textile manufacturing with revolutionizing textile dyeing: Deep learning-based, for energy efficiency and environmental-impact reduction," *Sustainability*, vol. 16, no. 18, 2024.
- [19] T. Manimegalai *et al.*, "Enhancing heat exchanger design using autoencoder model for predicting efficiency and cost in chemical processing," *Case Stud. Therm. Eng.*, vol. 49, 2025.

- [20] F. Olifant, S. Hancock, J. du Plessis, J. van Laar, and C. Schutte, "Machine learning approach to identify important parameters influencing pumping load shift in a complex dewatering system of a deep-level mine," *Mining*, vol. 4, no. 2, 2024.
- [21] W. Zhang *et al.*, "Machine learning-boosted multi-objective optimization of integrated shading systems: Enhancing daylight availability, glare protection, and energy savings," *Build. Environ.*, vol. 259, 2025.
- [22] X. Zhou, H. Yang, and S. Xiong, "Optimization of thermal energy conversion efficiency and economic value evaluation in hybrid manufacturing based on machine learning," *Therm. Sci. Eng. Prog.*, vol. 38, 2025.
- [23] Z. Chen, J. Zhang, F. Xiao, K. Xu, and Y. Chen, "Physically consistent data-driven optimal sequencing strategy for variable speed pumps in large building chiller plants," *Build. Environ.*, vol. 260, 2025.
- [24] A. N. Sayed *et al.*, "Enhancing building sustainability: A digital twin approach to energy efficiency and occupancy monitoring," *Energy Build.*, 2025..
- [25] W. Cong *et al.*, "Process intensification and economic evaluation of adiponitrile production based on hybrid modeling," *Chem. Eng. Process.*, 2025.
- [26] I. A. Kachalla, C. Ghiaus, and M. Baseer, "Comparative analysis of machine learning models for prediction and forecasting of electric water boilers energy consumption," *Appl. Therm. Eng.*, 2025.
- [27] P. Klanatsky *et al.*, "Real long-term performance evaluation of an improved office building operation involving a data-driven model predictive control," *Energy Build.*, 2025.
- [28] D. Wang, J. Wu, X. Chang, and H. Yin, "Distributed multi-agent reinforcement learning approach for energy-saving optimization under disturbance conditions," *Transp. Res. Part E*, 2025.
- [29] H. Kahil, S. Sharma, P. Välisuo, and M. Elmusrati, "Reinforcement learning for data center energy efficiency optimization: A systematic literature review and research roadmap," *Appl. Energy*, 2025.
- [30] R. S. Ghoneim, M. Arabasy, and A. N. Abdulhadi, "AI-driven optimization of indoor environmental quality and energy consumption in smart buildings: A bio-inspired algorithmic approach," *J. Adv. Comput. Intell. Inform.*, 2025.
- [31] C. Copiaco and M. Nour, "Optimizing the operation of grid-interactive efficient buildings (GEBs) using machine learning," *Sustainability*, vol. 16, no. 20, 2024.
- [32] A. M. Tzortzis *et al.*, "AI4EF: Artificial intelligence for energy efficiency in the building sector," *SoftwareX*, 2025.
- [33] D. Shrivastava and P. Goswami, "Internet of things driven hybrid neuro-fuzzy deep learning building energy management system for cost and schedule optimization," *Front. Artif. Intell.*, 2025.
- [34] I. Nugrahanto, H. Gunawan, and H.-Y. Chen, "Innovative approaches to sustainable computer numeric control machining: A machine learning perspective on energy efficiency," *Sustainability*, vol. 16, no. 9, 2024.
- [35] A. Papacharalampopoulos *et al.*, "Learning more with less data in manufacturing: The case of turning tool wear assessment through active and transfer learning," *Processes*, vol. 12, no. 6, 2024.
- [36] X. Liang *et al.*, "Awareness-guided incremental control optimization for chilled water system with deep learning model under cold-start scenarios," *Build. Environ.*, 2024.
- [37] M. H. Mehraban, S. M. E. Sepasgozar, A. Ghomimoghdam, and B. Zafari, "AI-enhanced automation of building energy optimization using a hybrid stacked model and genetic algorithms," *Results Eng.*, 2025.
- [38] B. S. Panigrahi, R. K. Kanna, P. P. Das, S. K. Sahoo, and T. Dutta, "Machine learning based intelligent management system for energy storage using computing application," *EAI Endorsed Trans. Energy Web*, 2024.
- [39] R. Barriga, M. Romero, D. Nettleton, and H. Hassan, "Advanced data modeling for industrial drying machine energy optimization," *J. Supercomput.*, 2022.
- [40] S. Wang *et al.*, "Data center temperature prediction and management based on a two-stage self-healing model," *Simul. Model. Pract. Theory*, vol. 137, 2024.
- [41] O. J. Fisher, L. Xing, X. Tian, X. Y. Tai, and J. Xuan, "Responsive CO₂ capture: Predictive multi-objective optimisation for managing intermittent flue gas and renewable energy supply," *React. Chem. Eng.*, 2023.
- [42] R. Barriga, M. Romero, and H. Hassan, "Machine learning for energy-efficient fluid bed dryer pharmaceutical machines," *Electronics*, vol. 12, no. 20, 2023.
- [43] F. Cheng *et al.*, "A novel data-driven air balancing method with energy-saving constraint strategy to minimize the energy consumption of ventilation system," *Energy*, vol. 239, 2022.
- [44] R. Lavanya, C. Murukesh, and N. R. Shanker, "Development of machine learning based microclimatic HVAC system controller for nano painted rooms using human skin temperature," *Cogn. Syst. Res.*, 2023.
- [45] N. Elshaboury, "Investigating the occupant existence to reduce energy consumption by using a hybrid artificial neural network with metaheuristic algorithms," *Decis. Sci. Lett.*, 2022.
- [46] Z. Abusaq *et al.*, "Improving energy performance in flexographic printing process through lean and AI techniques: A case study," *Energies*, vol. 16, no. 4, 2023.
- [47] M. Saez, K. Barton, F. Maturana, and D. M. Tilbury, "Modeling framework to support decision making and control of manufacturing systems considering the relationship between productivity, reliability, quality, and energy consumption," *J. Manuf. Syst.*, vol. 62, 2022.
- [48] P. R. X. do Carmo *et al.*, "A data-driven model for the optimization of energy consumption of an industrial production boiler in a fiber plant," *Energy*, vol. 277, 2023.
- [49] C. Thuppari *et al.*, "Energy-aware compression and consumption algorithms for efficient TinyML model using Aquila optimization in industrial IoT," *IEEE Trans. Consum. Electron.*, vol. 70, no. 1, pp. 49–56, 2024.