

**Aplicación de Machine Learning para la Eficiencia y Predicción Energética en Microrredes
Colombianas**

Liany Stella Villa Carpio

Universidad EAN

Especialización en Machine Learning

Seminario de investigación

1 de Junio 2025

Resumen

En este documento de investigación se analiza como los modelos de machine learning están siendo utilizados alrededor del mundo para la gestión energética de microrredes. Se realiza un estudio cualitativo de carácter exploratorio mediante la revisión de literatura científica. Las herramientas de análisis de datos utilizadas fueron el análisis bibliométrico en un primer nivel, y en un segundo nivel, un análisis de contenido de los documentos más relevantes con ayuda de la herramienta ATLAS.ti y un esquema de codificación. Las categorías analizadas se centran en los modelos de Machine learning utilizados, aplicaciones en el sector energético y el contexto de implementación, Con los resultados se realiza una propuesta de un modelo teórico que se adapta a las necesidades del sector energético Colombiano.

Palabras clave: Machine Learning, microrredes, predicción energética, sostenibilidad, IA, eficiencia energética.

Problema de investigación

Alrededor de Colombia aproximadamente 1.9 millones de personas carecen de acceso a energía, en un gran número de lugares la infraestructura eléctrica es limitada o inexistente (Granit, 2023). Las microrredes solares y eólicas han surgido en los últimos años como soluciones sostenibles para abastecer a estas comunidades reduciendo la dependencia de generadores diésel que son costosos y contaminantes. La implementación de estas tecnologías

enfrenta desafíos económicos y falta de apoyo del gobierno, lo que dificulta que se adopten en comunidades rurales e indígenas como los Wayuu en La Guajira.

las microrredes han sido altamente estudiadas en países como Estados Unidos y se ha demostrado su efectividad para mejorar la resiliencia energética, reducir costos y facilitar la transición a energías limpias (Muttagee, Furqan, & Boudet, 2023). En lugares de este país como Vermont y Carolina del Norte se ha mejorado la estabilidad del suministro y se ha disminuido la dependencia de las redes centrales. Si queremos replicar estos beneficios en Colombia se deben superar las barreras económicas y adoptar tecnologías como Machine Learning que permiten optimizar la gestión y sostenibilidad de las microrredes a largo plazo (Granit, 2023).

Además de los desafíos económicos y regulatorios, la implementación de microrredes en Colombia requiere una planificación integral que considere factores técnicos, ambientales y sociales. Rodríguez-Zabala et al. (2021) Se destaca que la sostenibilidad de estas soluciones depende de la integración de recursos energéticos distribuidos y una gestión eficiente que optimice el uso de las fuentes renovables disponibles. A diferencia de los sistemas tradicionales, las microrredes permiten mejorar la continuidad del suministro eléctrico, reducir la dependencia de combustibles fósiles y minimizar la huella de carbono. Sin embargo, su implementación en zonas rurales sigue siendo limitada debido a la falta de acceso a financiamiento y capacitación técnica, lo que dificulta su expansión en comunidades vulnerables.

La participación comunitaria es clave para el éxito de las microrredes en Colombia, ya que aquellas que respetan la cosmovisión y estructura social de las comunidades, como los Wayuu en La Guajira, tienen mayores probabilidades de ser aceptadas y sostenibles (Benavides-Castillo et

al., 2021). Sin embargo, su eficiencia puede mejorarse mediante Machine Learning, Si se optimiza la distribución de energía según la demanda real, anticipando fallos en el sistema y gestionando de manera inteligente el almacenamiento en baterías. Estas tecnologías permiten un suministro más estable y autónomo con el que se reducen interrupciones y costos operativos, lo que beneficiaría directamente a las comunidades rurales con acceso limitado a asistencia técnica.

En Colombia, las microrredes han sido una solución para abastecer de energía a comunidades rurales y zonas no interconectadas, donde la infraestructura eléctrica es limitada o inexistente. Sin embargo, su eficiencia y sostenibilidad dependen de una gestión óptima de los recursos energéticos. En este contexto, los modelos de Machine Learning (ML) representan una herramienta innovadora, Estudios previos han demostrado que técnicas como Light Gradient Boosting Machine (LGBM) pueden mejorar significativamente la fiabilidad de los pronósticos energéticos, reduciendo la dependencia de combustibles fósiles y aumentando la estabilidad del sistema (Suanpang & Jamjuntr, 2024). Dado el potencial de estas tecnologías, esta investigación busca responder la pregunta: ¿Cómo pueden los modelos de Machine Learning optimizar la gestión y eficiencia de las microrredes en Colombia para mejorar el suministro de energía en comunidades rurales y zonas no interconectadas?.

Objetivos

Objetivo general.

Analizar cómo los modelos de Machine Learning pueden optimizar la gestión y eficiencia de las microrredes en Colombia en las cuales se mejore la predicción de demanda, así como la distribución energética y el almacenamiento.

Objetivos específicos.

- Identificar los modelos de ML más utilizados para optimización de microrredes, analizando aplicaciones en el sector energético.
- Evaluar el estado actual de las microrredes en Colombia y su potencial para integrar técnicas de Machine Learning.
- Examinar el impacto de Machine Learning en la gestión energética de microrredes.
- Proponer un modelo teórico de aplicación de Machine Learning en microrredes colombianas, teniendo en cuenta los desafíos y oportunidades en su proceso de implementación.

Justificación

Este estudio analizará cómo los modelos de Machine Learning pueden ayudar a gestionar mejor las microrredes en Colombia, viendo cómo afectan la eficiencia energética y el almacenamiento de energía. Para las empresas de energía, estos descubrimientos ayudarán a entender cómo estos modelos pueden bajar costos y mejorar la estabilidad del suministro.

La investigación tiene como objetivo aumentar el entendimiento sobre el uso de Machine Learning en redes descentralizadas, para crear un marco teórico que se pueda aplicar en futuros desarrollos. Los resultados de este trabajo pueden ser útiles para la planificación energética en Colombia, ayudando así en las estrategias de sostenibilidad y digitalización del sector. Este estudio es importante porque se encuentran oportunidades y retos que pueden surgir al usar tecnologías avanzadas para mejorar la eficiencia energética. Esta investigación se realiza en el área de Machine Learning, bajo el grupo INDEVOS, y se enfoca en soluciones que usan la naturaleza y en cambios hacia la sostenibilidad. Se trata el problema de manera innovadora, teniendo en cuenta los desafíos energéticos del país.

Marco teórico

Esta sección presenta el marco teórico de esta investigación, con la cual se busca estudiar cómo se pueden usar técnicas de Machine Learning para predecir y mejorar el uso de energía en microrredes en Colombia. También se analizan antecedentes internacionales y nacionales que muestran avances, faltas y retos en la digitalización energética. Se muestran los conceptos y teorías que guían el análisis, incluyendo enfoques de sostenibilidad, modelos de microrredes y leyes relacionadas.

La transición energética mundial ha promovido el avance de tecnologías distribuidas como las microrredes, que son muy importantes en áreas con poca cobertura eléctrica, como lo son muchos lugares de Colombia. Estas estructuras, al combinar fuentes de energía renovables poco comunes con herramientas de inteligencia artificial como el machine learning, permiten responder de manera eficiente a los desafíos energéticos actuales. La implementación de

sistemas predictivos que usan aprendizaje automático ha mostrado mejoras importantes en la operación, control y sostenibilidad de estas redes. Sin embargo, todavía hay desafíos con su escalabilidad, integración en situaciones vulnerables y adaptación al entorno social y técnico. En este sentido, es importante revisar los avances recientes que apoyen la relevancia de esta investigación.

Varios estudios internacionales han mostrado que el uso de modelos de machine learning para predecir el consumo y la generación de energía mejora mucho la eficiencia operativa de las microrredes. Por ejemplo, Karunarathne et al. (2024) usaron redes neuronales convolucionales (CNN) para predecir la demanda de energía por hora en una microrred híbrida en Sri Lanka, se logró una alta precisión y se disminuyó el desbalance entre carga y generación. Singh et al. (2024) usaron Support Vector Machines (SVM) en una microrred multi fuente conectada a la red. En esta casuística se logró reducir los costos operativos en un 8.4% y aumentar el uso de energía renovable en un 12%. Adicionalmente, Bonetto y Rossi (2017) estudiaron modelos de regresión supervisada para hogares europeos y encontraron que métodos como Gradient Boosting y Random Forest son más efectivos para hacer pronósticos a corto plazo.

Las revisiones sistemáticas han ayudado a identificar las técnicas más comunes y las nuevas tendencias en el área. Alazemi et al. (2024) destacan que los modelos como Deep Neural Networks, Support Vector Machines y modelos de ensamble son los más comunes en la

predicción de energía de fuentes renovables. Wazirali et al. (2023) hicieron una clasificación detallada de modelos usados en microrredes, separándolos por el tiempo de predicción y la complejidad del modelo. También se enfatizó la importancia de incluir estas herramientas en sistemas de energía de la vida real. Alkabbani et al. (2021) estudiaron cómo mezclar técnicas de machine learning con algoritmos metaheurísticos como PSO (Particle Swarm Optimization) y GA (Genetic Algorithm) para mejorar la precisión y la rapidez de respuesta. De manera similar, Fallah et al. (2018) examinaron cómo son útiles los sistemas híbridos que combinan redes neuronales y lógica difusa en redes inteligentes, teniendo en cuenta las condiciones cambiantes del entorno.

Otros enfoques han expandido el uso del aprendizaje automático más allá de predecir, hacia el monitoreo, la protección y la seguridad operativa de las microrredes. Barkhi et al. (2024) desarrollaron un sistema que utiliza SVM para detectar y clasificar fallas eléctricas, logrando una precisión de más del 99.7%, incluso cuando hay incertidumbre en la resistencia de falla. De una forma más completa, Aravind et al. (2025) incluyeron herramientas de inteligencia artificial en un esquema de microrred que es resistente. Este esquema considera el manejo de la demanda, la respuesta a eventos extremos y la ciberseguridad en sistemas con mucha energía renovable.

En Colombia, se han creado experiencias importantes que mejoran el uso de tecnologías de energía descentralizada. En Puerto Carreño (Vichada), Colmenares-Quintero et al. (2023) utilizaron una estructura que combina sensores IoT, almacenamiento en la nube y visualización de datos para seguir y anticipar el comportamiento energético en tiempo real. Banguero et al.

(2019) informaron sobre el rendimiento técnico de la primera microrred fotovoltaica en Chocó. Validaron su funcionamiento durante un año y usaron herramientas dinámicas para modelar el flujo óptimo de energía. Estas experiencias muestran que las microrredes son técnicamente viables en áreas que no están conectadas y que pueden ser una solución sostenible que se puede replicar.

En el área académica, se han estudiado estrategias avanzadas de control para hacer que los sistemas aislados sean más estables. Pineda Muñoz y Gauthier Sellier (2020) compararon el rendimiento de tres tipos de controladores: proporcional integral, predictivo y servocontrol lineal cuadrático, en una microrred híbrida. Se concluyó que los modelos predictivos ofrecen más eficiencia, menos esfuerzo de control y una mejor respuesta ante problemas. Estas propuestas son muy importantes para crear algoritmos que se adapten en entornos en cambio.

Adicionalmente también se han creado modelos que analizan la viabilidad financiera y el efecto social de las microrredes en áreas desconectadas. Guerrero Hernández y Ramos de Arruda (2021) estudiaron el potencial técnico y económico de una microrred solar con almacenamiento híbrido en Cumaribo. Concluyeron que su uso disminuye más del 50% las emisiones de dióxido de carbono y el consumo de energía fósil, y es factible incluso sin subsidios. Cerón et al. (2025) realizaron una revisión crítica de las normas en Colombia, señalando que más de 117,000 personas podrían aprovechar las microrredes comunitarias según el Plan Indicativo de Expansión de Cobertura Energética y el Plan Energético Nacional, siempre que se adapten a las condiciones

geográficas y sociales del área. La sostenibilidad energética no solo implica avances tecnológicos, sino también la incorporación de principios de justicia social y participación comunitaria. Swarnakar y Singh (2022) proponen un enfoque de gobernanza local para la transición energética justa, donde las comunidades no son solo receptoras de tecnología, sino actores activos en el diseño, gestión y apropiación de los sistemas energéticos. Este modelo comunitario fortalece la equidad en el acceso a la energía y promueve una transformación estructural inclusiva.

Considerando el panorama internacional, Bombaerts et al. (2020) desarrollan el concepto de justicia energética transfronteriza, en donde se destaca que la transición energética debe atender desigualdades históricas, diferencias regionales y estructuras de poder. En la misma línea, Löhr et al. (2022) analizan los aprendizajes de procesos energéticos en África Occidental, subrayando que las transiciones sostenibles deben ser sensibles al contexto sociocultural y político, y evitar reproducir inequidades previas. Adicionalmente, Sánchez et al. (2023) aportan evidencia cuantitativa sobre la relación entre energías renovables, crecimiento económico y emisiones de CO₂ en países latinoamericanos, señalando que una mayor participación de renovables puede reducir significativamente el impacto ambiental sin comprometer el desarrollo económico. Estas perspectivas fundamentan el enfoque sostenible y justo que orienta la implementación de microrredes en territorios vulnerables como los colombianos.

Las microrredes han surgido como soluciones importantes en la transición energética, al unir fuentes renovables, almacenamiento y control inteligente en sistemas adaptados a las necesidades locales. Mahdavi et al. (2020) las dividen en arquitecturas de corriente alterna (AC), corriente

directa (DC) e híbridas, según su compatibilidad con las tecnologías y redes que ya existen. Pueden funcionar con control centralizado o distribuido, lo que afecta su autonomía y eficiencia. Jadav et al. (2017) señalan que el control distribuido ayuda a gestionar la energía de manera local, especialmente en áreas remotas.

Según Roosa (2020), conectar microrredes con fuentes de energía renovable hace que el suministro sea más confiable y disminuye la dependencia de redes centrales. Además, ayudan a tener más resistencia ante eventos climáticos extremos. Adegboyega et al. (2025) revisan experiencias de implementación en corriente directa, en donde destacan su eficiencia y también se mencionan algunos desafíos regulatorios.

El aprendizaje automático es una parte de la inteligencia artificial que se centra en crear algoritmos que pueden aprender de los datos y mejorar con la experiencia. Jung (2022) presenta este concepto desde sus bases en donde explica cómo los algoritmos detectan patrones, también crean modelos y hacen predicciones sin haber sido programados de manera específica para cada tarea. El autor describe tres categorías principales del aprendizaje automático: supervisado, no supervisado y por refuerzo, cada una con sus propias técnicas y usos. Se destaca la importancia del conjunto de datos así como de la separación entre entrenamiento y prueba, y se menciona el sobreajuste (overfitting) como uno de los problemas más comunes en el entrenamiento de modelos de machine learning.

Gopal (2019) explica de manera más práctica los pasos de un flujo de trabajo típico de machine learning. Se explica que se deben elegir las variables importantes y la evaluación del modelo se debe realizar usando métricas de rendimiento como lo son precisión, recall y F1-score.

Este enfoque se apoya en el trabajo de Tiwari et al. (2023), en el cual reúnen ejemplos de cómo se usan estas técnicas para mejorar sistemas de energía, y así facilitar la toma de decisiones y prever comportamientos complejos. Reddy et al. (2023) demuestra cómo estos modelos se utilizan en sistemas de energía híbridos y logran adaptarse de manera flexible a cambios en el ambiente.

En la legislación colombiana se ha demostrado que se valora las energías renovables no convencionales gracias a la Ley 1715 de 2014, que fomenta su uso con incentivos fiscales, acceso regulado a la red y opciones para la participación privada. Esta ley es el comienzo para desarrollar microrredes, pero todavía hay problemas en su implementación en áreas rurales, como la falta de infraestructura y apoyo de instituciones. Caro Acevedo y Jaramillo Duque (2021) sugieren cambios en las regulaciones para hacer más fácil la inclusión de tecnologías renovables distribuidas. También destacan la importancia de ajustar las reglas a las condiciones locales y de eliminar obstáculos legales que afectan la conexión y los derechos de acceso. Estas propuestas refuerzan la base legal del modelo presentado en esta investigación.

Metodología

Primer nivel

Enfoque, alcance y diseño de la investigación

Esta investigación se llevó a cabo con un enfoque cualitativo exploratorio, esto debido a que el objetivo final es llegar a una comprensión de cómo se están adoptando actualmente los modelos de machine learning en procesos relacionados con las microrredes al rededor del mundo,

adicionalmente, no se realizó manipulación de variables cuantitativas. Con este análisis base se realiza una comparativa con el estado de adopción en el contexto Colombiano. Este proceso se realizó por medio del estudio de la literatura científica existente.

Por otro lado, se planteó una diseño no experimental, transversal y documental, ya que no se realizó intervención en un contexto real, ni tampoco se realizó manipulación de variables. Para esta investigación se realizó una revisión sistemática de publicaciones académicas por medio de unos criterios temáticos, temporales y geográficos, adicionalmente, la documentación fue recolectada en un solo momento y no se realizó un seguimiento longitudinal.

Por último el alcance de la investigación fue de carácter descriptivo y aplicado, ya que en una primera instancia se busca describir las aplicaciones del machine learning en microrredes energéticas y aterrizar estos conceptos en un contexto colombiano, y en una segunda instancia, proponer un modelo teórico aplicable en Colombia, que se alineé con las necesidades energéticas actuales del país.

Definición de variables

Teniendo en cuenta que esta investigación tiene un enfoque cualitativo, no se definieron variables como se haría para un enfoque cuantitativo. Para estructurar el análisis realizado de la literatura científica, se definieron categorías conceptuales claves, que permiten identificar patrones, enfoques, aplicaciones, y vacíos en el uso de modelos de machine learning en las microrredes energéticas alrededor del mundo, en un primer nivel, y en un segundo nivel en el contexto colombiano.

Las categorías de análisis que se definieron están estrechamente relacionadas con cada uno de los objetivos específicos definidos para la investigación, y la revisión exploratorio inicial de la literatura. Estas se tendrán en cuenta tanto para el análisis bibliométrico, como la codificación con ATLAS.ti. en la siguiente tabla se presentan las definiciones conceptuales y operacionales de las categorías.

Categoría	Definición conceptual	Definición operacional	Dimensiones
Modelos de machine learning	Algoritmos y técnicas computacionales que realizan predicciones o clasificaciones a partir de datos.	Se identifica el modelo utilizado en cada uno de los artículos citados (Árboles de decisión, Support Vector Machines, etc.)	Tipo de modelo, arquitectura.
Aplicaciones en microrredes	Uso específico que se le da al modelo en la gestión y operación de sistemas eléctricos descentralizados.	Se identifican casos, simulaciones, implementaciones en gestión de energía, predicción de demanda, almacenamiento, etc.	Gestión, control, predicción, automatización.
Eficiencia energética y optimización	Cómo se aprovechan los recursos energéticos en las iniciativas basadas en datos y modelos de ML.	Análisis de métricas, indicadores o beneficios mencionados en los artículos como resultado de la implementación de modelos de ML.	Indicadores de eficiencia, costos, estabilidad, rendimiento.
Contexto Colombiano	Condiciones particulares del país para la implementación de tecnologías energéticas inteligentes.	Casos nacionales, autores Colombianos, marcos normativos	Regulación, retos y oportunidades.

Tabla 1. Fuente: elaboración propia

Población y Muestra

En el contexto de las investigaciones cualitativas y documentales, la población corresponde a publicaciones académicas, técnicas y científicas en las que se aborde el tema de estudio, en este caso, el uso de modelos de machine learning en el contexto de microrredes energéticas. En esta población se incluyen artículos indexados en bases de datos, en su mayoría de Scopus, acompañado de Google scholar, y documentos institucionales de entidades del sector energético y tesis académicas que se encuentran disponibles públicamente.

Debido a la naturaleza exploratoria del estudio, se optó por un muestreo no probabilístico de tipo intencional, basado en criterios temáticos, geográficos y temporales. A continuación se relacionan las consultas realizadas en las bases de datos. Estas consultas se realizaron en dos niveles, al primer nivel se le dio un enfoque global, y al segundo nivel, se le dio un enfoque local.

Nivel	Consulta	Sentencia	Base de datos	Muestra
Global	La consulta está orientada a identificar publicaciones en donde se exponga la aplicación de modelos de ML en microrredes energéticas, mediante términos clave en título, resumen o palabras clave.	TITLE-ABS-KEY (("Machine Learning" OR "Artificial Intelligence" OR "Data-driven models" OR "AI-driven optimization") AND ("Microgrids" OR "Energy Microgrids" OR "Smart Microgrids" OR "Renewable Microgrids" OR "Distributed Energy Resources" OR "DER") AND	SCOPUS	664

		("Energy Optimization" OR "Demand Prediction" OR "Load Forecasting" OR "Energy Management" OR "Energy Efficiency" OR "Grid Control" OR "Distributed Energy Management" OR "Microgrid Operation" OR "Smart Energy Systems" OR "Energy Storage Optimization" OR "Renewable Integration")) AND PUBYEAR > 2014		
Local	La consulta está orientada a identificar publicaciones en donde se exponga la aplicación de modelos de ML en microrredes energéticas, en donde al menos un autor está afiliado a una entidad Colombiana, mediante términos clave en título, resumen o palabras clave.	TITLE-ABS-KEY (("Machine Learning" OR "Artificial Intelligence" OR "Data-driven models" OR "AI-driven optimization") AND ("Microgrids" OR "Energy Microgrids" OR "Smart Microgrids" OR "Renewable Microgrids" OR "Distributed Energy Resources" OR "DER") AND ("Energy Optimization" OR "Demand Prediction" OR "Load Forecasting" OR "Energy Management" OR "Energy Efficiency" OR "Grid Control" OR "Distributed Energy Management" OR "Microgrid Operation" OR "Smart Energy Systems" OR "Energy Storage Optimization" OR "Renewable Integration")) AND PUBYEAR > 2014 AND AFFILCOUNTRY ("Colombia")	SCOPUS	9
Local	La consulta traerá todos los documentos que tengan las frases machine learning y microrredes limitado a sitios colombianos.	"machine learning" "microrredes" site:.co	Google Scholar	3

Local	La consulta busca documentos PDF técnicos como informes o planes de gobierno solo en portales oficiales del gobierno Colombiano.	“Machine learning” “Microrredes” site: gov.co filetype:pdf	Google	3
--------------	--	--	--------	---

Tabla 2. Fuente: elaboración propia

Segundo nivel

Selección de métodos o instrumentos para recolección de información

Para esta investigación de carácter cualitativo y documental, los métodos de recolección de información no se basan en mediciones directas, se realizan revisiones sistemáticas de literatura científica y técnica. Los instrumentos principales que se utilizaron fueron Bibliometrix en RStudio, para realizar el análisis bibliométrico. Con este instrumento se logró identificar tendencias globales con respecto al uso de machine learning en microrredes energéticas mediante el procesamiento de metadatos extraídos de la base de datos SCOPUS. Para el nivel global se procesaron 664 documentos, y para el nivel local, solo se procesaron 9 documentos ya que la información en bases de datos para Colombia en este tema es limitada.

Como segundo instrumento se utilizó el software ATLAS.ti como apoyo para el análisis cualitativo temático de una muestra intencionada de los 26 artículos más relevantes y de libre acceso de la consulta en SCOPUS para el nivel global, y para el nivel local se tomaron en cuenta 10 documentos, entre artículos, trabajos de grado, marcos normativos y documentos gubernamentales. Esta parte de la investigación se orientó a codificar e interpretar de forma

sistemática los documentos seleccionados con base en un plan de codificación previamente estructurado y alineado con los objetivos específicos de la investigación

Técnicas de análisis de datos

El análisis de datos se divide en dos fases, para la primera fase se realiza un análisis bibliométrico con ayuda de la librería bibliometrix en RStudio para identificar las tendencias globales en el uso de machine learning en microrredes energéticas. Los indicadores analizados son los siguientes:

- Palabras claves más utilizadas
- Distribución de publicaciones por año.

Para la segunda fase se realizó un análisis cualitativo a partir de las codificaciones de los documentos más relevantes con ATLAS.ti en el cual se siguió un enfoque de análisis temático, para organizar los hallazgos en categorías, y de esa forma poder identificar patrones, tendencias, vacíos en la literatura, desafíos y oportunidades. Con la herramienta las citas importantes fueron clasificadas según el plan de codificación para poder de esa forma facilitar el análisis del contenido y la interpretación de los resultados. Con la información recolectada ya se puede diseñar el modelo teórico.

A continuación se puede visualizar el plan de codificación:

Familia (Categoría)	Código (Etiqueta)
Modelos de ML	Redes neuronales

Modelos de ML	SVM
Modelos de ML	Aprendizaje por refuerzo
Aplicaciones en microrredes	Predicción de demanda
Aplicaciones en microrredes	Gestión energética
Aplicaciones en microrredes	Automatización de microrredes
Fuentes de energía	Energía solar
Fuentes de energía	Energía eólica
Fuentes de energía	Energía hidráulica
Impacto / eficiencia	Mejora en eficiencia
Impacto / eficiencia	Reducción de costos
Contexto	Colombia
Contexto	Casos internacionales

Tabla 3. Fuente: Elaboración propia

Análisis y discusión de los resultados

Análisis bibliométrico

Para la primera fase del análisis bibliométrico, se tuvo en cuenta 664 artículos de la base de datos Scopus, y los resultados fueron los siguientes:

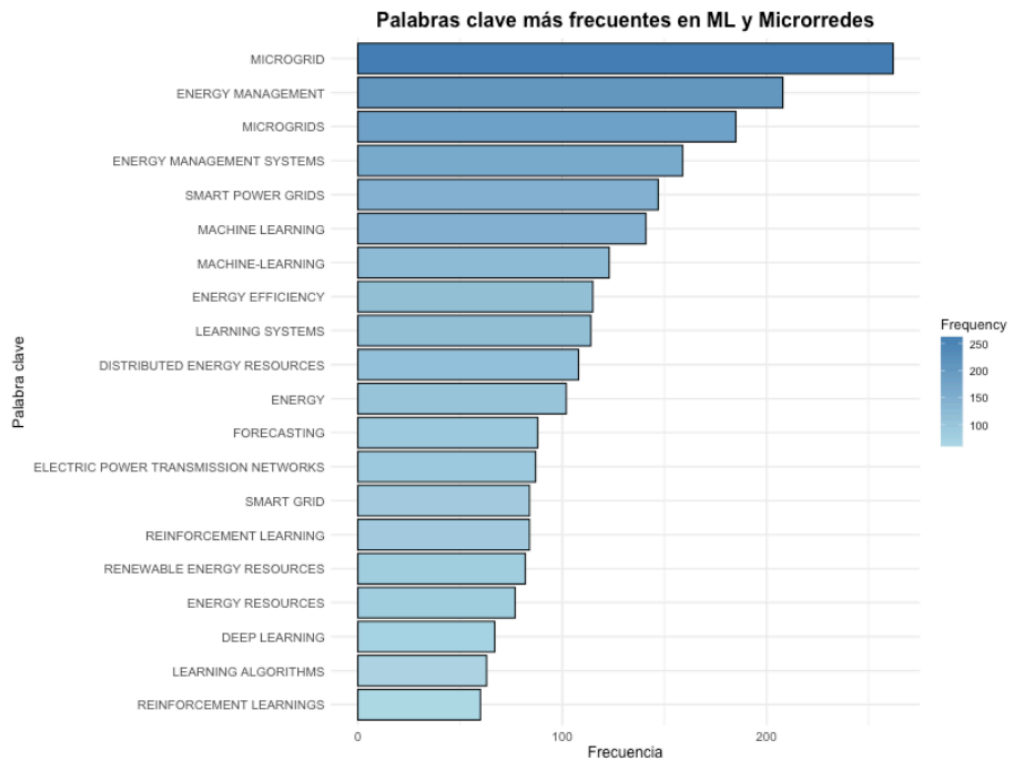


Imagen 1. Fuente: Elaboración propia // RStudio // Bibliometrix

El la imagen 1 se visualiza la distribución de las 20 palabras clave más utilizadas en los 664 artículos analizados. La palabra clave que más aparece en los artículos es “Microgrid” seguido de “Energy Management” y “machine learning”. Los términos relacionados con ML que se ven con más frecuencia, son “Reinforcement Learning” y “Deep Learning”.

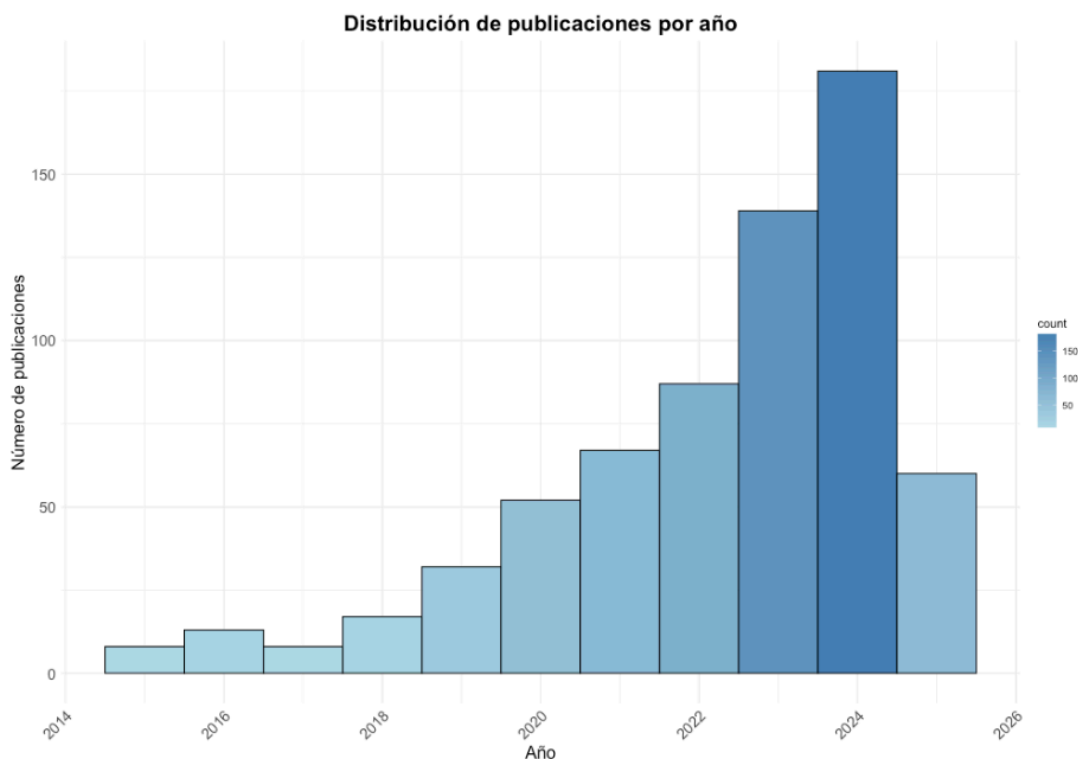


Imagen 2. Fuente: Elaboración propia // RStudio // Bibliometrix

En la imagen 2 se muestra un histograma con el número de publicaciones por año en un rango de tiempo de 10 años, desde el 2015 hasta el 2025. Se nota un crecimiento constante desde el 2015, sin embargo este es más elevado desde el 2020, debido a que los modelos de machine learning empiezan a ser más adoptados, y el nivel de maduración de los frameworks (Pytorch, Tensorflow) es más alto. En el 2024 se publicaron aproximadamente 180 artículos de esta temática.

Para el segundo nivel del análisis bibliométrico la búsqueda se limitó a Colombia. El número de artículos analizados fue de 9.

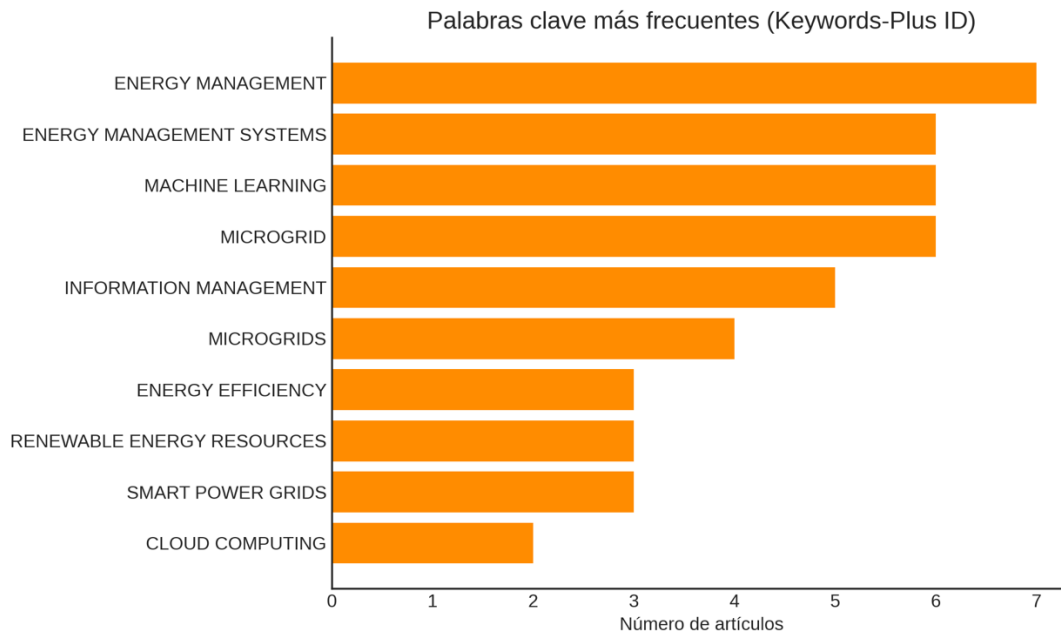


Imagen 3. Fuente: Elaboración propia // Bibliometrix

En la imagen anterior se evidencia la distribución de las palabras claves para los artículos de Colombia. Como en el análisis anterior, las palabras claves que lideran son “Energy management”, “Microgrid” y “Machine Learning”, pero se introducen nuevos términos como cloud computing.




Imagen 4. Fuente: Elaboración propia // Bibliometrix

A diferencia del primer nivel, no hay una relación entre el paso de los años y el número de artículos debido a la poca información disponible. El año en donde se publicaron más artículos fue el 2023, a diferencia del 2022 en donde no se publicó ningún artículo.

Análisis Cualitativo

El objetivo de realizar el análisis cualitativo fue poder identificar cuáles son los modelos de Machine Learning que se está utilizando al rededor del mundo para la gestión y predicción de microrredes. A continuación se presentan los resultados del proceso de codificación.

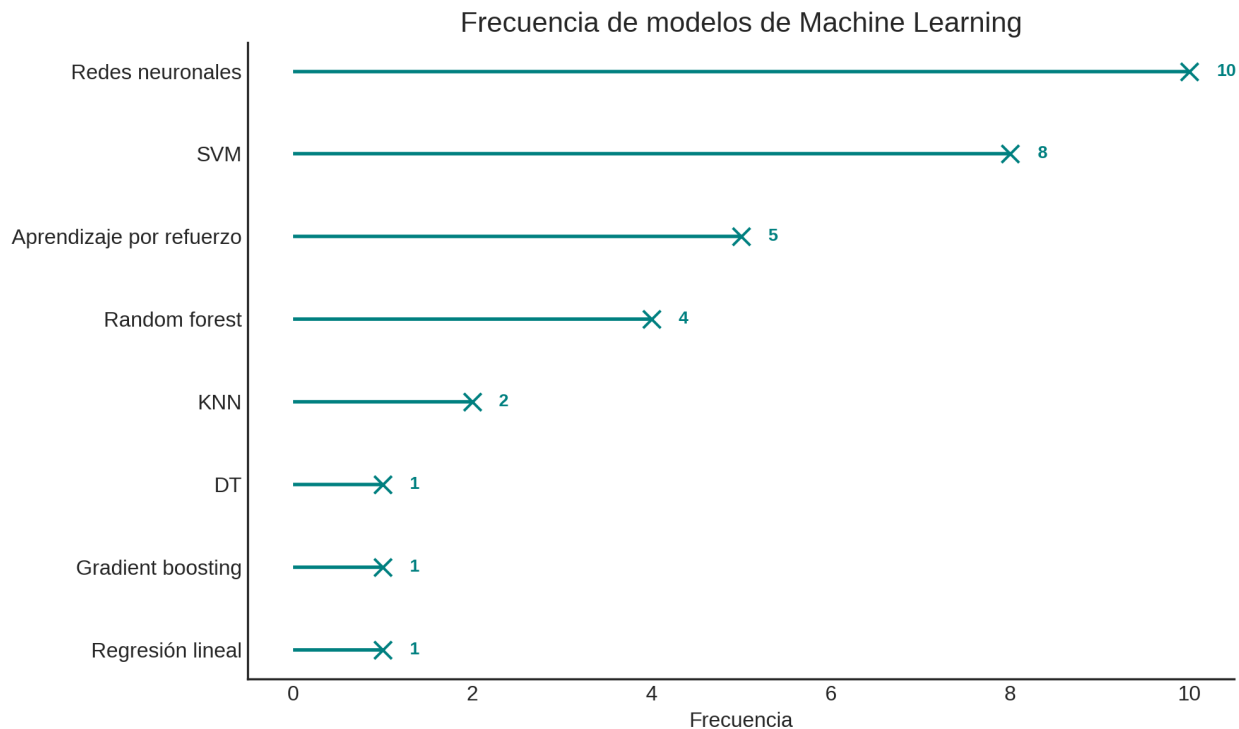


Imagen 5. Fuente: Elaboración propia // ATLAS.ti

En el gráfico anterior se identifican los modelos de ML más utilizados, las redes neuronales lideran con 10 menciones, seguido de Support Vector Machine y modelos de aprendizaje por refuerzo a continuación se desglosa cada uno de estos:

Las redes neuronales como LSTM (Long Short-Term Memory) y CNN – LSTM se utilizan más que todo para el pronóstico de carga eléctrica y generación solar en intervalos horarios o subhorarios (cada 15 o 30 minutos). Sus datos de entrada pueden ser: Series temporales de consumo histórico (kWh), serie de generación PV (Fotovoltaica) en kWh, variables climáticas como la irradiación solar y la temperatura, información calendario como el día de la semana, hora del día y si es festivo o no. Dos arquitecturas relevantes en el análisis se describen a continuación:

- Un modelo LSTM (Alhussein et al., 2020) toma como input T valores previos y predice la demanda para las próximas H horas.
- En un modelo híbrido de CNN-LSTM (Sarmas et al., 2022), primero hay capas convolucionales que extraen patrones locales y luego capas LSTM capturan dependencias temporales de largo plazo.

Durante el proceso de entrenamiento la tendencia es utilizar una división entrenamiento/validación/prueba de aproximadamente 70%, 15%, 15 %, función de pérdida MSE o MAE, optimizador Adam y “early stopping” para evitar sobreajuste. Si el pronóstico generado excede la demanda, se programa el cargue de las baterías, en el caso contrario se reserva la batería. (Kermani et al., 2021; Sarmas et al., 2022).

Support vector machine se emplea en pronósticos de generación fotovoltaica en momentos puntuales, o para la clasificación de perfiles de carga como por ejemplo, días soleados o días nublados. Las variables de entrada a considerar están relacionadas con variables meteorológicas , horas del día, día del año, etc. En las regresiones como muestran Lan et al. (2021), se entrena una función e-insensible que ignora errores menores a un umbral dado, lo cual hace al modelo robusto frente a ruido en las mediciones meteorológicas. A través de la validación cruzada, se logra un pronóstico más confiable cuando solo hay algunos meses de datos históricos, como sucede en muchas microrredes rurales. Una vez que el modelo está listo, se guarda (por ejemplo, usando pickle) y se incorpora al EMS. Cada hora, recibe la información del clima actual y hace una predicción específica de PV, que se

mezcla con los pronósticos de demanda para regular el uso de baterías o generadores (Lan et al., 2021).

En las microrredes, el aprendizaje por refuerzo profundo (DRL) se utiliza para entrenar un "agente". Este agente toma decisiones automáticas basadas en la predicción de la generación de energía solar, la estimación de la demanda y el nivel de carga de la batería en cada instante. Así se decide, cuanta energía extraer o inyectar de la batería y cuándo es mejor encender el generador diésel. Durante el entrenamiento, el agente usa un simulador de la microrred: prueba diferentes acciones como cargar la batería, descargarla o encender el generador, observa lo que sucede y recibe una recompensa que penaliza el uso innecesario de diésel, los cortes de energía y las descargas muy profundas de la batería. Con el tiempo, la red neuronal que está detrás del agente "aprende" cuáles son las mejores acciones para cada situación, así reduce el costo operativo y previene apagones. Una vez que se ha entrenado al agente, se exporta el modelo. En la operación real de la microrred, solo se necesita darle la predicción de generación, la demanda estimada y el estado de la batería. Él devolverá rápidamente la mejor instrucción para cargar o descargar, o para encender el generador, adaptándose de forma dinámica a los cambios en tiempo real (Lee & Choi, 2020)

En otros hallazgos, los estudios revisados demuestran que la energía solar y la energía eólica son las fuentes renovables más utilizadas en microrredes: todos los artículos incluyen sistemas fotovoltaicos, y más de la mitad incorporan turbinas eólicas .

Estado de las microrredes en Colombia

A pesar de que anteriormente mencionamos que es poca la información relacionada con las microrredes en Colombia en motores de búsqueda como Scopus, la realidad es que en los últimos 5 años Colombia ha tenido un crecimiento sostenido con respecto a las instalaciones de microrredes sobre todo en zonas rurales, que se alimentan de energía solar y cuentan con un respaldo diesel. En 2021 fue inaugurado un proyecto en Unguía en el departamento del Chocó que interconecta 780 kWp en PV, 333 kWh de baterías y 4 generadores diesel, que beneficia a más de 10000 familias. Con este proyecto se evita la quema de aproximadamente 328000 litros de combustible (Latam Green., 2021) .

Según la UPME(2022), para el 2025 se espera que al menos 150 microrredes empiecen a operar en zonas no interconectadas, cada una con sistemas de medición digital que envíen datos de consumo y generación cada 30 minutos. UPME (2022). En la “estrategia nacional de comunidades energéticas” el ministerio de minas y energías (2024) incluyó incentivos para las instalaciones de microgeneradores solares y baterías, esto con la condición de monitoreo remoto de parámetros eléctricos (MinMinas, 2024) , (Congreso de la República de Colombia, 2024).

Aunque la infraestructura de datos es básica se propone un modelo teórico que aproveche la infraestructura mínima de monitoreo (datos semihorarios de consumo y generación) y el respaldo diésel existente para incorporar técnicas de Machine Learning en el despacho automático. En la primera etapa, un modelo LSTM entrenado con los datos históricos cada 30 minutos de PV,

demanda y nivel de carga de la batería generaría pronósticos de carga y generación para las siguientes 24 horas, con un error aceptable (MAPE entre 25 % y 40 %). Esa predicción alimentaría una lógica de despacho basada en reglas híbridas: si la generación solar prevista es superior a la demanda, se prioriza la carga de la batería hasta un SoC máximo (p. ej., 90 %); si la generación solar prevista es insuficiente y el nivel de la batería supera el umbral mínimo (p. ej., 20 %), se descarga la batería para cubrir la demanda; finalmente, si persiste el déficit, se enciende el generador diésel. En una segunda fase de evolución del modelo, se reemplazaría la lógica de reglas rígidas por un agente de Deep Reinforcement Learning, que pueda coordinar en tiempo real la batería y el diésel en función de la predicción y los precios de combustible, optimizando dinámicamente el uso de recursos. De este modo, con el despliegue de medidores digitales, enlaces GSM y un mini-servidor local que ejecute el LSTM y el agente DRL, las microrredes rurales colombianas podrían reducir significativamente el consumo de diésel, maximizar el uso de la energía solar y garantizar la continuidad del suministro sin necesidad de reglas predefinidas.

Conclusiones

Con el análisis bibliométrico se logró evidenciar que a nivel global el interés por la aplicabilidad de modelos de machine learning en la gestión de microgrids ha aumentado de forma sostenida desde el 2015, acelerándose notablemente desde el 2020, esto debido al auge de frameworks como Pytorch y tensor Flow. Las palabras claves más dominante es “Energy management” y le siguen “Microgrids” y “Machine Learning”. Esto lo que refleja que la

investigación se centra en el uso de modelos de machine learning en la gestión de microrredes. Cuando se restringe la investigación para Colombia, los 664 artículos se reducen a 9, por lo que la información es muy poca para llevar a cabo un análisis más profundo. Sin embargo, se visualizó que el año en donde más artículos se publicaron para esta búsqueda fue 2023.

Durante el desarrollo de esta investigación se evidenció que los modelos de machine learning más utilizados para la eficiencia y la predicción energética son las redes neuronales (LSTM y CNN-LSTM), a esta le siguen los modelos de SVM que ayudan a completar tareas relacionadas con la clasificación o estimación del estado de la carga, y Los modelos de DRL (Deep reinforcement learning) para el despacho dinámico.

En el contexto Colombiano, las microrredes rurales con fotovoltaica t respaldo diesel han crecido notablemente en los últimos 5 años como el proyecto en Unguía Chocó. Según UPME y MinCiencias, para el 2025 se espera la construcción de al menos 150 microrredes en zonas no interconectadas que incluyan medidores digitales que reportan cada 30 minutos. Si tenemos en cuenta esta infraestructura, ya permite implementar prototipos de ML para la gestión de las microrredes. Finalmente se realiza una propuesta de un modelo teórico híbrido para generar pronósticos de demanda y generación de energía en microrredes en Colombia.

Referencias

Alazemi, T., Darwish, M., & Radi, M. (2024). Renewable energy sources integration via machine learning modelling: A systematic literature review. *Heliyon*, 10, e26088.

<https://doi.org/10.1016/j.heliyon.2024.e26088>

Alkabbani, H., Ahmadian, A., Zhu, Q., & Elkamel, A. (2021). Machine learning and metaheuristic methods for renewable power forecasting: A recent review. *Frontiers in Chemical Engineering*, 3, 665415. <https://doi.org/10.3389/fceng.2021.665415>

Aravind, K., Thethi, H. P., Rao, B. D., Tewari, P., Emad, R., & Balachandran, P. K. (2025). Advanced supply-demand optimization in renewable-powered microgrids. *E3S Web of Conferences*, 619, 02002. <https://doi.org/10.1051/e3sconf/202561902002>

Banguero, E., Aristizábal, A. J., Habib, A., & Ospina, D. (2019). Experimental investigation and optimal power flow modelling of the first renewable microgrid in Chocó, Colombia. *Energy Procedia*, 157, 953–965. <https://doi.org/10.1016/j.egypro.2018.11.262>

Barkhi, M., Pourhossein, J., & Hosseini, S. A. (2024). Integrating fault detection and classification in microgrids using supervised machine learning considering fault resistance uncertainty. *Scientific Reports*, 14, 28466. <https://doi.org/10.1038/s41598-024-77982-7>

Benavides-Castillo, J. M., Carmona-Parra, J. A., Rojas, N., Stansfield, K. E., Colmenares-Quintero, J. C., & Colmenares-Quintero, R. F. (2021). Framework to design water-energy solutions based on community perceptions: Case study from a Caribbean coast community in Colombia. *Cogent Engineering*, 8(1), 1905232. <https://doi.org/10.1080/23311916.2021.1905232>

Bonetto, R., & Rossi, M. (2017). Machine learning approaches to energy consumption forecasting in households. arXiv preprint. <https://arxiv.org/abs/1706.09648>

Cerón, J. A., Gómez-Luna, E., & Vasquez, J. C. (2025). Driving the energy transition in Colombia for off-grid regions: Microgrids and non-conventional renewable energy sources. *Energies*, 18(4), 1010. <https://doi.org/10.3390/en18041010>

Colmenares-Quintero, R. F., Maestre-Gongora, G., Valderrama-Riveros, O. C., Baquero-Almazo, M., & Stansfield, K. E. (2023). A data-driven architecture for smart renewable energy microgrids in non-interconnected zones: A Colombian case study. *Energies*, 16(23), 7900. <https://doi.org/10.3390/en16237900>

Fallah, S. N., Deo, R. C., Shojafar, M., Conti, M., & Shamshirband, S. (2018). Computational intelligence approaches for energy load forecasting in smart energy management grids: State of the art, future challenges, and research directions. Semantic Scholar. <https://www.semanticscholar.org/reader/c0297ab6b59e4e8b675d554faa73638ca3800974>

Granit, I. (2023). What makes Colombia's indigenous peoples adopt microgrids? Social acceptance and financial constraints in renewable energy diffusion. *Energy Research & Social Science*, 101, 103132. <https://doi.org/10.1016/j.erss.2023.103132>

Guerrero Hernández, A. S., & Ramos de Arruda, L. V. (2021). Economic viability and optimization of solar microgrids with hybrid storage in a non-interconnected zone in Colombia. *Environment, Development and Sustainability*, 23, 12842–12866. <https://doi.org/10.1007/s10668-020-01188-w>

Karunaratne, M. G. I. U., Sudasinghe, P. B., Weeratunge, H. Y., & Herath, D. (2024). Enhancement of load demand forecasting in microgrids using convolutional neural networks. *Engineer: Journal of the Institution of Engineers, Sri Lanka*, 57(4), 37–45. <https://doi.org/10.4038/engineer.v57i4.7664>

Muttaqee, M., Furqan, M., & Boudet, H. (2023). Community response to microgrid development: Case studies from the U.S. *Energy Policy*, 181, 113690. <https://doi.org/10.1016/j.enpol.2023.113690>

Pineda Muñoz, E. A., & Gauthier Sellier, A. (2020). Comparative study of three control strategies for the frequency regulation of an isolated microgrid. *Revista Ingeniería*, 25(2). <https://doi.org/10.14483/23448393.16144>

Rodríguez-Zabala, A., López-García, D., Carvajal-Quintero, S. X., & Arango-Manrique, A. (2021). A comprehensive review of sustainability in isolated Colombian microgrids. *Tecnura*, 25(70), 126–145. <https://doi.org/10.14483/22487638.18619>

Singh, A. R., Kumar, R. S., Bajaj, M., Khadse, C. B., & Zaitsev, I. (2024). Machine learning-based energy management and power forecasting in grid-connected microgrids with multiple distributed energy sources. *Scientific Reports*, 14, 19207. <https://doi.org/10.1038/s41598-024-70336-3>

Suanpang, P., & Jamjuntr, P. (2024). Machine learning models for solar power generation forecasting in microgrid application: Implications for smart cities. *Sustainability*, 16(1), 495. <https://doi.org/10.3390/su16010495>

Wazirali, R., Yaghoubi, E., Abujazar, M. S. S., Ahmad, R., & Vakili, A. H. (2023). State-of-the-art review on energy and load forecasting in microgrids using artificial neural networks, machine learning, and deep learning techniques. *Electric Power Systems Research*, 225, 109792. <https://doi.org/10.1016/j.epsr.2023.109792>

Mahdavi Tabatabaei, N., Kabalci, E., & Bizon, N. (Eds.). (2020). *Microgrid Architectures, Control and Protection Methods*. Springer. <https://doi.org/10.1007/978-3-030-23723-3>

Jadav, K. A., Karkar, H. M., & Trivedi, I. N. (2017). A Review of Microgrid Architectures and Control Strategy. *Journal of The Institution of Engineers (India) Series B*, 98(6), 591–598. <https://doi.org/10.1007/s40031-017-0287-3>

Roosa, S. A. (Ed.). (2020). *Fundamentals of Microgrids: Development and Implementation (Chapter 6: Linking Microgrids with Renewable Generation)*. Taylor & Francis.

Adegboyega, A. W., Sepasi, S., Howlader, H. O. R., Griswold, B., Matsuura, M., & Roose, L. R. (2025). DC Microgrid Deployments and Challenges: A Comprehensive Review of Academic and Corporate Implementations. *Energies*, 18(5), 1064. <https://doi.org/10.3390/en18051064>

Jung, A. (2022). *Machine Learning: The Basics*. Springer. <https://doi.org/10.1007/978-981-16-8193-6>

Gopal, M. (2019). *Applied Machine Learning*. McGraw-Hill Education.

Tiwari, M. K., Kumar, M. R., Rofin, T. M., & Mitra, R. (Eds.). (2023). *Applications of Emerging Technologies and AI/ML Algorithms*. Springer. <https://doi.org/10.1007/978-981-99-1019-9>

Reddy, B. K., Ayyagari, K. S., Medam, R. R., & Alhaider, M. (2023). Application of Machine Learning Techniques in Modern Hybrid Power Systems – A Case Study. In C. Sharmeela, P.

Sanjeevikumar, P. Sivaraman, & M. Joseph (Eds.), IoT, Machine Learning and Blockchain Technologies for Renewable Energy and Modern Hybrid Power Systems (pp. 173–204). River Publishers.

https://www.riverpublishers.com/chapter_details.php?book_id=1062&chapter_id=845

Swarnakar, P., & Singh, M. K. (2022). Local Governance in Just Energy Transition: Towards a Community-Centric Framework. *Sustainability*, 14(11), 6495.

<https://doi.org/10.3390/su14116495>

Bombaerts, G., Jenkins, K., Sanusi, Y. A., & Wang, G. (Eds.). (2020). *Energy Justice Across Borders*. Springer. <https://doi.org/10.1007/978-3-030-24021-9>

Löhr, K., Matavel, C. E., Tadesse, S., Yazdanpanah, M., Sieber, S., & Komendantova, N. (2022). Just Energy Transition: Learning from the Past for a More Just and Sustainable Hydrogen Transition in West Africa. *Land*, 11(12), 2193. <https://doi.org/10.3390/land11122193>

Sánchez, M. J., Benito, B., & Carrera, E. (2023). Economic Growth and Pollution Nexus in Mexico, Colombia, and Venezuela (G-3 Countries): The Role of Renewable Energy in Carbon Dioxide Emissions. *Heliyon*, 9(5), e17949. <https://doi.org/10.1016/j.heliyon.2023.e17949>

Congreso de Colombia. (2014). Ley 1715 de 2014 – Por medio de la cual se regula la integración de las energías renovables no convencionales al sistema energético nacional. Diario Oficial No. 49.129. <https://www.funcionpublica.gov.co/eva/gestornormativo/norma.php?i=57353>

Caro Acevedo, E. A., & Jaramillo Duque, A. (2021). Guidelines to Define a Regulatory Proposal in the Transition and Inclusion of Non-conventional Renewable Energies in Colombia and Its Role in the Development of Smart Cities. In Y. Iano et al. (Eds.), *BTSym 2020, SIST 233* (pp. 227–237). Springer. https://doi.org/10.1007/978-3-030-75680-2_27

Alhussein, M., Aurangzeb, K., & Haider, S. I. (2020). Hybrid CNN-LSTM Model for Short-Term Individual Household Load Forecasting. *IEEE Access*, *8*, 180544-180557. Scopus. <https://doi.org/10.1109/ACCESS.2020.3028281>

Sarmas, E., Strompolas, S., Marinakis, V., Santori, F., Bucarelli, M. A., & Doukas, H. (2022). An Incremental Learning Framework for Photovoltaic Production and Load Forecasting in Energy Microgrids. *Electronics (Switzerland)*, *11*(23). Scopus. <https://doi.org/10.3390/electronics11233962>

ermani, M., Adelmanesh, B., Shirdare, E., Sima, C. A., Carni, D. L., & Martirano, L. (2021). Intelligent energy management based on SCADA system in a real Microgrid for smart building

applications. *_Renewable Energy_, _171_*, 1115-1127. Scopus.

<https://doi.org/10.1016/j.renene.2021.03.008>

Lan, T., Jermittiparsert, K., Alrashood, S. T., Rezaei, M., Al-Ghussain, L., & Mohamed, M. A. (2021). An advanced machine learning based energy management of renewable microgrids considering hybrid electric vehicles' charging demand. *_Energies_, _14_(3)*. Scopus.

<https://doi.org/10.3390/en14030569>

Lee, S., & Choi, D.-H. (2020). Energy management of smart home with home appliances, energy storage system and electric vehicle: A hierarchical deep reinforcement learning approach. *_Sensors (Switzerland)_, _20_(7)*. Scopus.

<https://doi.org/10.3390/s20072157>

Unidad de Planeación Minero-Energética (UPME). (2022). Reporte final de despliegue de redes inteligentes. Recuperado el 1 de junio de 2025, de

https://www1.upme.gov.co/DemandayEficiencia/Documents/Reporte_Final_Despliegue_Nets_Inteligentes.pdf

Ministerio de Minas y Energía (MinMinas). (2024). Metodología general – Estrategia nacional de comunidades energéticas. Recuperado el 1 de junio de 2025, de

<https://www.minenergia.gov.co/documents/13312/Metodologia-General-Estrategia-Nacional-Comunidades-Energeticas-2024.pdf>

Latam-Green. (2021, 15 de diciembre). Colombia presenta su más grande microrred fotovoltaica. Recuperado el 1 de junio de 2025, de <https://latam-green.com/colombia-presenta-su-mas-grande-microrred-fotovoltaica/>

Unidad de Planeación Minero-Energética (UPME). (2022). Documento PROURE 2022–2030: Plan de desarrollo energético rural. Recuperado el 1 de junio de 2025, de https://www1.upme.gov.co/DemandayEficiencia/Documents/PROURE/Documento_PROURE_2022-2030_v4.pdf

Universidad Pontificia Bolivariana (UPB). (2023). Microrredes y transición energética. Recuperado el 1 de junio de 2025, de https://investigacion.upb.edu.co/files/67444604/Microrredes_y_Transicion_Energetica_Version_Digital.pdf

Colombia Inteligente. (s. f.). Microrredes sostenibles zonas no interconectadas (ZNI). Recuperado el 1 de junio de 2025, de <https://colombiainteligente.org/producto/microrredes-sostenibles-zni/>

Congreso de la República de Colombia. (2024). Resolución 40509 de 2024: Registro de comunidades energéticas. Recuperado el 1 de junio de 2025, de https://normograma.mintic.gov.co/mintic/compilacion/docs/resolucion_minminas_40509_2024.htm

Economía OCDE. (2023). Plan Energético Nacional (PEN) 2022–2052. Recuperado el 1 de junio de 2025, de

https://www1.upme.gov.co/DemandayEficiencia/Documents/PEN_2020_2050/Actualizacion_PEN_2022-2052_VF.pdf